

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université A. MIRA-BEJAIA



Faculté de Technologie
Département de Génie Electrique
Laboratoire de Maitrise des Energies Renouvelables

THÈSE

Présentée par
MELAHI Ahmed

Pour l'obtention du Diplôme de
DOCTORAT EN SCIENCES

Filière : Electrotechnique
Option : Commande Electrique

Thème

**Pilotage et caractérisation de systèmes de
positionnement à forte dynamique pour la
cartographie du potentiel de surface**

Soutenue le 14/03/2026 devant le Jury composé de :

Nom et Prénom	Grade		
Mr Boubekour MENDIL	Professeur	Univ. de Bejaia	Président
Mr Boukhalfa BENDAHMANE	Professeur	Univ. de Bejaia	Rapporteur
Mr Lucian DASCALESCU	Professeur Emérite	Univ. de Poitiers	Co-rapporteur
Mr Ahcene BOUZIDA	Professeur	Univ. de Bouira	Examineur
Mr Koussaila IFFOUZAR	MCA	ENSTA d'Alger	Examineur
Mr Allaoua RAHMANI	MCA	Univ. de Bejaia	Examineur

Année Universitaire : 2025-2026

Remerciements

Je tiens à remercier mon directeur de thèse, le Professeur Boukhalifa BENDAHMANE pour sa disponibilité, conseils, encouragements et surtout le soutien moral durant la préparation de ma thèse.

Ma profonde reconnaissance s'adresse à mon co-directeur de thèse, le Professeur émérite Lucian DASCALESCU, pour son accueil chaleureux durant mon stage au sein du Laboratoire d'Electrostatique Appliquée de l'IUT d'Angoulême (France). Je le remercie pour les éclaircissements qu'il a apportés pour m'orienter dans la réalisation de mon travail de thèse, pour ses encouragements et surtout sa gentillesse.

Je remercie également le Président et les membres de jury de me faire l'honneur d'accepter de juger mon travail de thèse.

Je tiens aussi à remercier profondément le Docteur Belaid TABTI, pour sa proposition de la réalisation de ce travail et ses encouragements.

Je tiens aussi à remercier Marian-Bogdan Neagoe et Eka Yopa Prawatya pour l'aide et les discussions fructueuses au sein du Laboratoire d'Electrostatique Appliquée de l'IUT d'Angoulême (France).

Ma reconnaissance à tous ceux qui ont contribué de près ou de loin à la réussite de ce travail.

Mes remerciements vont à mes parents, que Dieu les reçoit dans son vaste paradis.

En fin, je remercie ma petite famille pour le bon environnement de travail à domicile.

Dédicace

Je dédie ce travail :

à la mémoire de mes parents,

à ma femme et mes enfants,

à mes frères et sœurs,

à toute ma famille,

à tous mes amis.

Table des matières

Introduction générale	1
------------------------------------	---

Chapitre I : Etat de l'art

I.1 Introduction.....	4
I.2 Electrostatique.....	5
I.3 Mesure du potentiel de surface et déclin du potentiel.....	7
I.4 Sondes électrostatiques.....	8
I.5 Systèmes de positionnement rapide.....	9
I.5.1 Machines électriques.....	9
I.5.1.1 Moteur asynchrone.....	10
I.5.1.2 Moteur synchrone à aimants permanents.....	11
I.5.1.3 Moteur pas à pas.....	11
I.5.2 Robots manipulateurs.....	11
I.5.2.1 Robot cartésien.....	12
I.5.2.2 Robot SCARA.....	13
I.5.2.3 Robot Delta.....	14
I.6 Techniques avancées de l'automatique pour le positionnement.....	15
I.6.1 Commande optimale.....	15
I.6.2 Commande adaptative.....	16
I.6.3 Commande prédictive.....	16
I.6.4 Commande robuste.....	17
I.7 Intelligence artificielle pour le positionnement.....	18
I.7.1 Réseaux de neurones artificiels.....	19
I.7.2 Logique floue.....	21

I.7.3 Réseaux neuro-flous.....	23
I.7.4 Optimisation par essaims de particules (Particle Swarm Optimization : PSO)...	24
I.7.5 Algorithme des colonies des abeilles artificielles (Artificial Bee Colonies : ABC).....	24
I.7.6 Optimisation par la recherche stochastique (Stochastic Search Algorithms : SSA).....	26
I.8 Problématique.....	26
I.9 Conclusion.....	28

Chapitre II : Commande intelligente des machines électriques

II.1 Introduction.....	30
II.2 Commande adaptative et optimale, basée sur l'algorithme du gradient, appliquée à la MAS.....	30
II.2.1 Commande adaptative et optimale basée sur l'algorithme du gradient.....	30
II.2.2 Application à la commande de la MAS.....	31
II.3 Commande adaptative optimale basée sur la logique floue appliquée à la MAS.....	38
II.3.1 Première étape.....	39
II.3.2 Deuxième étape.....	41
II.4 Commande adaptative optimale basée sur la logique floue appliquée à la MSAP.....	46
II.5 Commande adaptative optimale basée sur la logique floue appliquée au MPP.....	49
II.6 Commande prédictive basée sur les RNA et l'algorithme ABC appliquée à la MAS.....	52
II.7 Conclusion.....	56

Chapitre III : Techniques de commande intelligentes appliquées aux robots

III.1 Introduction.....	57
III.2 Commande adaptative floue optimale appliquée à un robot SCARA motorisé par deux MSAP.....	57

III.3 Commande adaptative floue optimale appliquée au robot SCARA motorisé par deux MPP.....	60
III.4 Commandes prédictive et PID guidées par les données, appliquée au robot SCARA...	62
III.5 Commande prédictive quantifiée basée sur les réseaux de neurones artificiels et les essaims de particules (PSO) appliquée au robot SCARA.....	64
III.6 Commande floue d'un robot Delta (NN pour MGD et MGI).....	67
III.7 Commande neuro-floue adaptative d'un robot Delta (NN pour MGD et MGI).....	72
III.8 Commande robuste neuro-floue adaptative appliquée à un système de positionnement 2d rapide.....	75
III.9 Conclusion.....	78

Chapitre IV : Cartographie du potentiel de surface : mesure et reconstitution

IV.1 Introduction.....	80
IV.2 Plateforme de cartographie.....	80
IV.3 Trajectoire suivie pour la mesure.....	81
IV.4 « Surface fitting » à l'aide d'un réseau de neurones RBF (Radial Basis Functions Neural network).....	83
IV.5 Modélisation et caractéristiques de la sonde.....	84
IV.6 Reconstitution du potentiel réel.....	95
IV.7 Etude comparative de différentes approches pour la reconstitution du potentiel réel de surface.....	107
IV.8 Conclusion.....	117

Conclusion générale.....	118
---------------------------------	------------

Références bibliographiques

Annexes

Liste des figures

Figure I.1 : Principe de charge par (a) tribo-électricité (b) décharge couronne [1].....	5
Figure I.2 : Courbes de déclin du potentiel de surface pour différentes valeurs de la tension de charge positive [1].....	7
Figure I.3 : Mesure du potentiel de surface [1].....	8
Figure I.4 : Robots cartésiens [72].....	12
Figure I.5 : Robots SCARA [94].....	13
Figure I.6 : Modèle géométrique.....	13
Figure I.7 : Robots Delta [98].....	14
Figure I.8 : Exemple de FFNN [144].....	19
Figure I.9 : Exemples de réseaux RBF [152].....	20
Figure I.10 : Trajectoires pour le balayage (va et vient, Lissajous) [182].....	27
Figure I.11 : Exemple de distributions du potentiel de surface [182].....	28
Figure I.12 : Mesures sur les trajectoires avec lenteur de déplacement de la sonde [182]....	28
Figure I.13 : Mesures sur les trajectoires avec rapidité de déplacement de la sonde [182]...	28
Figure II.1 : Schéma de la commande adaptative.....	30
Figure II.2 : Schémas fonctionnels de la régulation des courants I_{sd} et I_{sq} et de la vitesse Ω	33
Figure II.3 : Schéma de la commande adaptative optimale appliquée à la MAS.....	36
Figure II.4 : Application de la commande adaptative optimale basée sur la méthode du gradient à la MAS.....	37
Figure II.5 : Application de la commande à la MAS : évolution des paramètres k_i , $i = 1, 3, 5, 6$ et 9	38
Figure II.6 : Fonctions d'appartenance.....	40
Figure II.7 : Schéma de la commande adaptative optimale appliquée à la MAS.....	42
Figure II.8 : Application de la commande adaptative optimale basée sur la logique floue à la MAS.....	43

Figure II.9 : Application de la commande à la MAS : évolution des paramètres k_i , $i = 1, 3, 7, 8$ et 9	44
Figure II.10 : Application de la commande adaptative optimale basée sur la logique floue à l'association onduleur-MAS.....	45
Figure II.11 : Application de la commande à l'association onduleur-MAS : évolution des paramètres k_i , $i = 1, 3, 7, 8$ et 9	46
Figure II.12 : Application de la commande adaptative optimale basée sur la logique floue à la MSAP.....	48
Figure II.13 : Application de la commande à la MSAP : évolution des paramètres k_i , $i = 3, 7, 8$ et 9	49
Figure II.14 : Application de la commande adaptative optimale basée sur la logique floue au moteur pas à pas.....	51
Figure II.15 : Application au moteur pas à pas : évolution des paramètres k_i , $i = 7, 8$ et 9 ..	52
Figure II.16 : Commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC.....	54
Figure II.17 : Algorithme ABC pour l'optimisation.....	55
Figure II.18 : Application de la commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC à la MAS.....	56
Figure III.1 : Poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MSAP (1 ^{ère} et 2 ^{ème} articulations).....	58
Figure III.2 : Erreurs de poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MSAP (1 ^{ère} et 2 ^{ème} articulations).....	59
Figure III.3 : Poursuite de trajectoire du robot SCARA motorisé par 2 MSAP en coordonnées opérationnelles.....	59
Figure III.4 : Poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MSAP (1 ^{ère} et 2 ^{ème} articulations).....	59
Figure III.5 : Erreurs de poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MSAP (1 ^{ère} et 2 ^{ème} articulations).....	60

Figure III.6 : Poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MPP (1 ^{ère} et 2 ^{ème} articulations).....	60
Figure III.7 : Erreurs de poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MPP (1 ^{ère} et 2 ^{ème} articulations).....	61
Figure III.8 : Poursuite de trajectoire du robot SCARA motorisé par 2 MPP en coordonnées opérationnelles (1 ^{ère} et 2 ^{ème} articulations).....	61
Figure III.9 : Poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MPP (1 ^{ère} et 2 ^{ème} articulations).....	61
Figure III.10 : Erreurs de poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MPP (1 ^{ère} et 2 ^{ème} articulations).....	62
Figure III.11 : Poursuite de trajectoire du robot SCARA (1 ^{ère} et 2 ^{ème} articulations).....	64
Figure III.12 : Structure de la commande prédictive quantifiée basée sur les réseaux de neurones et les essaims de particules (PSO).....	65
Figure III.13 : Poursuite et erreurs de poursuite de trajectoire du robot SCARA dans les coordonnées articulaires (T en secondes et W et Y sont la consigne et la réponse respectivement données en rad).....	66
Figure III.14 : Signaux de commande appliquées au robot SCARA (T en secondes et U (ie U1 et U2) en Volts).....	66
Figure III.15 : Poursuite de trajectoire du robot SCARA dans les coordonnées opérationnelles (X et Y en mètre).....	67
Figure III.16 : Structure du robot Delta.....	67
Figure III.17 : Données pour l'apprentissage des réseaux de neurones artificiels du MGD et du MGI du robot Delta.....	68
Figure III.18 : Poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles.....	69
Figure III.19 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles.....	70
Figure III.20 : Poursuite de trajectoire du robot Delta dans les coordonnées articulaires...	71

Figure III.21 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées articulaires.....	71
Figure III.22 : Poursuite de trajectoire du robot Delta dans l'espace opérationnel.....	72
Figure III.23 : Poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles avec la commande neuro-floue adaptative.....	73
Figure III.24 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles avec la commande neuro-floue adaptative.....	74
Figure III.25 : Poursuite de trajectoire du robot Delta dans les coordonnées articulaires avec la commande neuro-floue adaptative.....	74
Figure III.26 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées articulaires avec la commande neuro-floue adaptative.....	75
Figure III.27 : Poursuite de trajectoire du robot Delta dans l'espace opérationnel avec la commande neuro-floue adaptative.....	75
Figure III.28 : Modèle simplifié d'un système de positionnement rapide basé sur des moteurs à courant continu MCC avec des perturbations mécaniques et électriques.....	76
Figure III.29 : Commande robuste neuro-floue adaptative appliquée au système de positionnement ayant une dynamique rapide basé sur des MCC.....	77
Figure IV.1 : Plateforme pour la cartographie du potentiel de surface.....	80
Figure IV.2 : Trajectoire utilisée pour le balayage.....	81
Figure IV.3 : La position (X, Y) de la sonde en fonction du temps.....	82
Figure IV.4 : Potentiel de surface mesuré sur la trajectoire en fonction du temps.....	82
Figure IV.5 : Potentiel de surface mesuré sur la trajectoire.....	83
Figure IV.6 : Potentiel de surface mesuré, données utilisées dans l'apprentissage et potentiel prédit après apprentissage.....	83
Figure IV.7 : Surface fitting avec un réseau de neurones RBF.....	84
Figure IV.8 : Deux expériences (a) un disque de 35mm de rayon (b) un rectangle de 20mm de largeur.....	85
Figure IV.9 : Exemple de profil de la fonction d'étalement du point (PSF : Point Spread Function).....	86

Figure IV.10 : Première approche : détermination des sommes S_i (points marqués en rouge) pour $n_p = m_p = 11$	87
Figure IV.11: Potentiel mesuré sur la trajectoire (a) expérience 1(b) Expérience 2.....	88
Figure IV.12 : Approximation par les réseaux de neurones RBF du potentiel mesurée (a) première expérience (b) deuxième expérience.....	89
Figure IV.13 : Les PSF obtenues (a) 1 ^{ère} approche (b) 2 ^{ème} approche (c) 3 ^{ème} approche (d) la meilleur PSF sous la forme gaussienne.....	90
Figure IV.14 : Comparaison des PSF obtenues (a) profils des PSF (b) Coût en fonction des itérations pour la 2 ^{ème} et la 3 ^{ème} approche.....	91
Figure IV.15 : Les PFS inverses obtenues (a) 1 ^{ère} approche (2) 2 ^{ème} approche (c) 3 ^{ème} approche (c) la meilleure PSF sous la forme gaussienne x cosinus.....	93
Figure IV.16 : Comparaison des PFS inverse obtenues (a) profils des PFS inverse (b) coûts en fonction des itérations pour la 1 ^{ère} , la 2 ^{ème} et la 3 ^{ème} approche.....	93
Figure IV.17 : Validation théorique : (a) Gaussienne (b) Gaussienne x cosinus.....	94
Figure IV.18 : Validation expérimentale pour les PSF (les erreurs : $V_m - V_{m_cal}$) (a) 1 ^{ère} expérience (b) 2 ^{ème} expérience.....	94
Figure IV.19 : Validation expérimentale pour les PSF inverses (les erreurs : $V_r - V_{r_cal}$) (a) 1 ^{ère} expérience (b) 2 ^{ème} expérience.....	95
Figure IV.20 : La PSF de la sonde utilisée.....	96
Figure IV.21 : Deux expériences avec un seul passage et considération de la symétrie (a) un disque de 35 mm de rayon (b) un rectangle de 20 mm de largeur.....	96
Figure IV.22 : Le potentiel mesuré sur les trajectoire (a) 1 ^{ère} expérience (b) 2 ^{ème} expérience.....	99
Figure IV.23 : L'approximation par les réseaux de neurones RBF des potentiels de surface mesurés V_m (a) 1 ^{ère} expérience (b) 2 ^{ème} expérience.....	99
Figure IV.24 : Validation théorique (1 ^{er} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.....	100

Figure IV.25 : Validation théorique (2 ^{ème} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.....	101
Figure IV.26 : Validation théorique (3 ^{ème} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.....	102
Figure IV.27 : Validation expérimentale (1 ^{ère} expérience) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.....	103
Figure IV.28 : Validation expérimentale (1 ^{ère} expérience) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.....	104
Figure IV.29 : La PSF inverse.....	105
Figure IV.30 : Prise de sections du potentiel réel calculé en utilisant la PSF inverse (a) 1 ^{ère} expérience (b) 2 ^{ème} expérience.....	105
Figure IV.31 : Détermination de la distribution réelle du potentiel sur la surface d'un isolant chargé par tribo-électricité (a) potentiel mesuré représenté par le réseau de neurones RBF (b) potentiel calculé par l'algorithme de recherche stochastique (c) lissage du potentiel réel calculé en utilisant un réseau de neurone MLP (d) prise de sections (e) évolution du critère en fonction des itérations.....	106
Figure IV.32 : Données pratiques (expérimentales).....	107
Figure IV.33 : Données théoriques.....	107
Figure IV.34 : Fonction caractéristique de la sonde (2d-Point Spread Function PSF)...	108
Figure IV.35 : Fonction caractéristique de la sonde (1d-Point Spread Function PSF)....	108
Figure IV.36 : Reconstruction du potentiel réel par la méthode directe à partir des données théoriques.....	111
Figure IV.37 : Reconstruction du potentiel réel par la méthode basée sur PSO à partir des données théoriques.....	112
Figure IV.38 : Reconstruction du potentiel réel par la méthode basée sur la recherche stochastique à partir des données théoriques.....	112

Figure IV.39 : Comparaison entre les erreurs de reconstruction par les méthodes directe, PSO et stochastique en utilisant les données théoriques.....	113
Figure IV.40 : Comparaison entre les critères à minimiser dans la reconstruction par les méthodes directe, PSO et stochastique en utilisant les données théoriques.....	113
Figure IV.41 : Reconstruction du potentiel réel par la méthode directe à partir des données expérimentales.....	114
Figure IV.42 : Reconstruction du potentiel réel par la méthode basée sur PSO à partir des données expérimentales.....	114
Figure IV.43 : Reconstruction du potentiel réel par la méthode basée sur la recherche stochastique à partir des données expérimentales.....	115
Figure IV.44 : Comparaison entre les reconstructions par les méthodes directe, PSO et stochastique en utilisant les données expérimentales.....	115
Figure IV.45 : Comparaison entre les critères à minimiser dans la reconstruction par les méthodes directe, PSO et stochastique en utilisant les données expérimentales.....	116

Liste des tableaux

Tableau II.1 : Table des règles du système flou	40
Tableau II.2 : Table des règles du régulateur de η_{56}	41
Tableau IV.1 : Comparaison des performances (norme ∞ / moyenne de la norme 1).....	89
Tableau IV.2 : Effet de l'initialisation du profil de la PSF.....	89
Tableau IV.3 : Comparaison des performances.....	91
Tableau IV.4 : Effet de l'initialisation du profil de la PSF inverse.....	92

Liste des symboles

Abréviations

- ABC : Artificial Bee Colony
- ANN : Artificial Neural Network
- ConvNets : Convolutional Neural Networks
- COG : Center Of Gravity
- COA : Center Of Area
- Delta : Delta Robot
- FFNN : Feed Forward Neural Networks
- FPGA : Field Programmable Gate Array
- GA : Genetic Algorithm
- GPC : Generalized Predictive Control
- H₂ : Commande optimale et robuste basée sur la norme quadratique
- H_∞ : Commande optimale et robuste basée sur la norme H_∞ (sup.)
- HOM : High Of Maxima
- LF : Logique Floue
- LFT : Linear Fractional Transform
- LOM : Low Of Maxima
- LQ : Commande Linéaire quadratique
- LQG : Commande linéaire quadratique gaussienne
- LSTM : Long Short-Term Memory
- LTR : Loop Transfer Recovery
- MAS : Machine Asynchrone
- MCC : Moteur à courant continu
- MCD : Modèle Cinématique Direct
- MCI : Modèle Cinématique Inverse
- MDD : Modèle Dynamique Direct
- MDI : Modèle Dynamique Inverse
- MGD : Modèle Géométrique Direct
- MGI : Modèle Géométrique Inverse
- MOM : Mean Of Maxima
- MPC : Model Predictive Control
- MPP : Moteur Pas à Pas
- MSAP : Machine Synchrone à Aimants Permanents

NFLC : Neuro-fuzzy Logic Controller
 NG : Négatif Grand (sous-ensemble flou)
 NM : Négatif Moyen (sous-ensemble flou)
 PID : Proportional, Integral and Derivative controller
 PFC : Predictive Functional Control
 PG : Positif Grand (sous-ensemble flou)
 PM : Positif Moyen (sous-ensemble flou)
 PSO : Particle Swarm Optimization
 PSF : Point Spread Function : Fonction d'étalement du point
 PCB : Printed Circuit Board
 R : Régulateur
 RBF : Radial Basis Function
 RBFNN : Radial Basis functions Neural Networks
 RecNN : Recurrent Neural Networks
 RecNets : Recurrent Neural Networks
 RNA : Réseaux de Neurones Artificiels
 RNF : Réseaux Neuro-Flous
 S : Système
 SCARA : Selective Compliance Assembly Robot Arm
 SoC : System on Chip
 SSA : Stochastic Search Algorithm
 Z : Zéro (sous-ensemble flou)

Symboles

α : Paramètre des fonctions F pour calculer les D_i à partir des d_i
 a : Ensemble des paramètres a_i des régulateurs flou ou neuro-flou du robot Delta
 a_i : Paramètres des conclusions des régulateurs flou ou neuro-flou du robot Delta
 a_1 : Paramètre du régulateur neuro-flou du MCC
 a_2 : Paramètre du régulateur neuro-flou du MCC
 a_{ij} : Nombre de répétitions de F_j dans la somme S_i
 B : Coefficient du frottement visqueux [N.m.s/rad]
 b : Biais d'un neurone

- b : Ensemble des paramètres b_i des régulateurs flou ou neuro-flou du robot Delta
- b_i : Paramètres des conclusions des régulateurs flou ou neuro-flou du robot Delta
- b_1 : Paramètre du régulateur neuro-flou du MCC
- b_2 : Paramètre du régulateur neuro-flou du MCC
- C_{em} : Couple électromagnétique [N.m]
- C_e^* : Couple de référence [N.m]
- C_r : Couple résistant [N.m]
- c : Ensemble des paramètres c_i des régulateurs flou ou neuro-flou du robot Delta
- c : Pas fixe du PSO
- c, c^i_1 et c^i_2 : Constantes (des pas fixes)
- c_1, c_2, c_3 et c_4 : Paramètres des fonctions d'appartenance du superviseur flou
- c_i : Paramètres des conclusions des régulateurs flou ou neuro-flou du robot Delta
- δe : Perturbation sur l'entrée du MCC
- δs : Perturbation sur la sortie du MCC
- δ_d : Erreur rétro propagée au neurone d
- $\delta Vr_{i,p,k}$: Incrément du potentiel de surface réel pris au point (i) (cas linéique) pour la particule p à l'itération k
- D : Forces dissipatives généralisées [N], [N.m], ...
- D_i : Obtenues à partir de d_i pour calculer les w_i
- d : Dimension de l'espace des solutions (espace de recherche)
- d_i : Distance entre M_i et M_t pour $i=1, \dots, N$
- d_l : Distance minimale entre M_t et les M_i
- de : Dérivée de l'erreur de poursuite entrée n°2 des régulateurs flou ou neuro-flou du robot Delta
- $dk_i, i=1, \dots, 10$: Ajustements des paramètres k_1, \dots, k_{10}
- ε : Erreur rétro propagée
- ε : Erreur de poursuite du modèle de référence (Régulateur neuro-flou du MCC)
- E : Ensemble de neurones (nœuds) ayant p comme paramètre
- $E1, E2$: Sous-ensembles flous (valeurs linguistiques)
- E_i : Nouvelles valeurs des paramètres dans la ligne i de la base de données
- $E_{i,old}$: Anciennes valeurs des paramètres dans la ligne i de la base de données

- $E_{i,new}$: Nouvelles valeurs des paramètres proposées par la mise à jour pour la ligne i de la base de données
- e_{Ω}, e_{Cem} : Erreurs en vitesse [rad/s] et en couple [N.m]
- e : Erreur de poursuite entrée n°1 des régulateurs flou ou neuro-flou du robot Delta
- F : Sous-ensemble flou (valeur linguistique)
- F : Fonctions décroissantes pour calculer les D_i à partir des d_i
- F : Coefficient du frottement visqueux [N.m.s/rad]
- F : Forces généralisées [N], [N.m], ...
- F_i : Profile de la PSF pris au point i (centré au point 11)
- $F_{i-p,j-q}$: Fonction d'étalement du point centrée à (p, q) et prise au point (i,j)
- F_{i-p} : Fonction d'étalement du point centrée à (p) et prise au point (i) (cas linéique)
- F_{inv_i} : Valeur du profile de la fonction d'étalement du point inverse (PSF inverse) prise au point i
- $f(x_1,x_2)$: Conclusion d'une règle floue (système flou de Sugeno)
- f : Fonction d'activation d'un neurone
- f : Fonction d'étalement du point (PSF)
- f : Coefficient du frottement visqueux [N.m.s/rad]
- f_d : Fonction d'activation du neurone d
- f_i : Fitness associé à la source i
- f_i : Fonctions des conclusions des régulateurs flou ou neuro-flou du robot Delta
- $f(x_i)$: Fonction objectif dans l'algorithme ABC
- f_1, \dots, f_5 : Conclusions du superviseur flou
- f_x, f_y : Coefficients du frottement visqueux des moteurs à courant continu selon les axes X et Y
- $f_{ij;pq}$: Fonction PSF centrée au point n° (p,q) et prise (calculée) au point (i,j)
- f_{ij} : Valeurs de la fonction PSF (centrée à $(0,0)$) calculée au point (i,j)
- $f_{inv_{ij}}$: Valeur de la PSF inverse prise au point (i,j)
- $G_1(s), G_2(s)$ et $G_3(s)$: Fonctions de transfert des sous-systèmes électriques et mécanique des Machines MAS, MSAP et MPP
- η : Nombre aléatoire dans $[0,1]$
- η : Pas d'apprentissage
- η_1, \dots, η_{10} : Pas du gradient pour chaque paramètre k_1, \dots, k_{10}
- η_{56} : Sortie du superviseur flou
- η_m : Pas du gradient pour le paramètre m (Régulateur neuro-flou du MCC)

- η_σ : Pas du gradient pour le paramètre σ (Régulateur neuro-flou du MCC)
- η_{a1}, η_{a2} : Pas du gradient pour a_1 et a_2 (Régulateur neuro-flou du MCC)
- η_{b1}, η_{b2} : Pas du gradient pour b_1 et b_2 (Régulateur neuro-flou du MCC)
- H_{max} : Déplacement maximal dans la recherche stochastique
- h_{max} : Pas fixe dans la recherche stochastique
- i_{ds} : Courant statorique sur l'axe direct [A]
- i_{qs} : Courant statorique sur l'axe en quadrature [A]
- I_p : Entrée du neurone p du réseau de neurones artificiel
- I_{sd} : Courant statorique sur l'axe direct [A]
- I_{sq} : Courant statorique sur l'axe en quadrature [A]
- I_{sd}^* : Courant de référence sur l'axe direct [A]
- I_{sq}^* : Courant de référence sur l'axe en quadrature [A]
- J : Critère global pour la détermination du potentiel de surface calculé
- J : Moment d'inertie [Kg.m²]
- J : Coût (à minimiser durant l'apprentissage) (Loss Function)
- J_x, J_y : Moments d'inertie des moteurs à courant continu selon les axes X et Y
- J_{pq} : Critère à minimiser local au point (p, q)
- $J_{pq, n}$: Critère à minimiser local au point (p, q) calculé à l'itération n
- J, J_Ω, J_{Cem} et J_u : Critère à minimiser, de vitesse, du couple et de commande
- J_n : Critère global calculé à l'itération n
- $J_{best\ old}$: Ancienne valeur du critère global
- K : Régulateur robuste H_∞ (fonction de transfert)
- K : Coefficient de constriction
- K_m : Constante de couple [N.m/A]
- K_{p1}, K_{i1} : Paramètres du régulateur R_1
- K_{p2}, K_{i2} : Paramètres du régulateur R_2
- K_{p3}, K_{i3} et K_{d3} : Paramètres du régulateur R_3
- k : itération
- k_1, k_2, \dots, k_{10} : Paramètres du régulateur adaptatif optimal (gradient, flou) proposé
- $\lambda_\Omega, \lambda_{Cem}, \lambda_u$: Pondérations dans le critère J
- λ : Paramètre des fonctions F pour calculer les D_i à partir des d_i
- L : Lagrangien [joules]
- L_d : Valeur minimale de la position (solution) dans la dimension d
- L_d : Inductance sur l'axe direct [H]

- L_q : Inductance sur l'axe en quadrature [H]
- L_r : Inductance rotorique [H]
- L_s : Inductance statorique [H]
- l_1 : Longueur de la 1^{ère} liaison du robot SCARA [m]
- l_2 : Longueur de la 2^{ème} liaison du robot SCARA [m]
- $\mu_i(x_1, x_2)$: Fonction d'appartenance
 - μ_1 : Fonction d'appartenance du régulateur neuro-flou du MCC
 - μ_2 : Fonction d'appartenance du régulateur neuro-flou du MCC
 - M : Inductance mutuelle [H]
 - M : Mesures prises pour le régulateur guidé par les données
- (M_i, X_i, Φ_i) : Ligne n° i de la base de données (Mesures, Entrées, Paramètres)
 - M_t : Mesures actuelles à l'instant t
 - M_i : Mesures dans la ligne i de la base de données
 - m : Paramètre du régulateur neuro-flou du MCC
 - m : Ensemble des paramètres m_i des régulateurs flou ou neuro-flou du robot Delta
 - m_i : Paramètres des fonctions d'appartenance des régulateurs flou ou neuro-flou du robot Delta
- m_p, m_s : Nombre de points pour la sonde et pour l'échantillon respectivement selon Y
 - N : Nombre d'échantillon dans la base de données
 - N : Nombre de règles floues des régulateurs flou ou neuro-flou du robot Delta
 - N_r : Nombre de dents du rotor
 - net : Argument de la fonction d'activation d'un neurone
 - net_d : Argument de la fonction d'activation du neurone d
- n_p, n_s : Nombre de points pour la sonde et pour l'échantillon respectivement selon X
 - Ω : Vitesse de rotation [rad/sec]
 - Ω^* : Vitesse de rotation de référence [rad/s]
 - ω_s : Vitesse angulaire synchrone (de synchronisme) [rad/sec]
 - O : Sortie d'un neurone
 - O^* : Neurone (nœud) ayant p comme paramètre
 - O_k : Sortie du neurone k du réseau de neurones artificiel
 - O_s : Sortie du neurone s
 - Φ : Paramètres du régulateur guidé par les données

- Φ : Paramètres à prendre pour le régulateur guidé par les données
- Φ_l : Paramètres du régulateur guidé par les données correspondant à la distance minimale d_l
- Φ_i : Paramètres du régulateur guidé par les données selon la ligne i de la base de données
- Φ_{rd} : Flux rotorique sur l'axe direct [Wb]
- Φ_{rq} : Flux rotorique sur l'axe en quadrature [Wb]
- Φ_r : Flux rotorique [Wb]
- φ_m : Flux magnétique [Wb]
- $\Phi_i=(kp_i, ki_i, kd_i)$: Paramètres du régulateur PID guidé par les données (la ligne i)
- $\Phi_i=(H_i, P_i)$: Paramètres du régulateur GPC guidé par les données (la ligne i)
- φ : Nombre aléatoire dans $[0, 1]$
- φ : Fonction à base radiale (générique)
- Φ_{ij} : Fonctions à base radiale associées aux neurones du réseau RBF
- p : Nombre de paires de pôles
- p : Poids (système neuroflou)
- p_{new} : Nouvelle valeur du poids (système neuroflou)
- P_{old} : Ancienne valeur du poids (système neuroflou)
- P_i : Probabilité pour choisir la source i
- q : Coordonnées généralisées [m], [rad], ...
- ρ_i : Fonction d'appartenance normalisées des régulateurs flou ou neuro-flou du robot Delta
- R : Règle floue
- R : Résistance [Ω]
- $R(X, \Phi)$: Régulateur guidé par les données
- R_r : Résistance rotorique [Ω]
- R_s : Résistance statorique [Ω]
- $R_1(s), R_2(s)$ et $R_3(s)$: Régulateurs des sous-systèmes électriques et mécanique des Machines MAS, MSAP et MPP
- r : Entrée de référence pour le régulateur robuste H_∞
- r, r^j_1 et r^j_2 : Choisis dans $[0, 1]$ aléatoirement (des pas variables)
- r_{p1} : Nombre aléatoire dans $[0, 1]$
- r_{p2} : Nombre aléatoire dans $[0, 1]$
- r_1, r_2 : Nombres aléatoires dans $[0, 1]$
- σ : Paramètre des fonctions d'appartenance du superviseur flou
- σ : Paramètre des fonctions F pour calculer les D_i à partir des d_i

- σ : Paramètre du régulateur neuro-flou du MCC
- S : Sortie du MCC
- S_i : Somme partielle selon l'axe X de la PSF discrétisée centrale
- Sm : Sortie du modèle de référence
- Sr : Sortie de référence (entrée pour le régulateur neuro-flou)
- s : Ensemble des paramètres s_i des régulateurs flou ou neuro-flou du robot Delta
- s_i : Paramètres des fonctions d'appartenance des régulateurs flou ou neuro-flou du robot Delta
- θ : Paramètre à ajuster par la méthode du gradient
- θ_1 : Angle de la 1^{ère} liaison du robot SCARA [rad]
- θ_2 : Angle de la 2^{ème} liaison du robot SCARA [rad]
- $(\theta_1, \theta_2, \theta_3)$: Coordonnées articulaires
- τ : Couple calculé par le régulateur R_3 [N.m]
- T : Energie cinétique [joules]
- t : Numéro de l'itération en cours dans l'algorithme ABC
- U_d : Valeur maximale de la position (solution) dans la dimension d
- U_k : Ensemble des valeur admissibles de la commande (quantifiée)
- u : Vecteur de commande
- u : Sortie des régulateurs flou ou neuro-flou du robot Delta
- u_{ds} : Commande sur l'axe direct [V]
- u_{qs} : Commande sur l'axe en quadrature [V]
- $u_{p,k}$: Position (solution, commande) de la particule p à l'itération k
- u_{gb} : Meilleure position (solution, commande) globale
- $u_{p,lb}$: Meilleure position (solution, commande) locale de la particule p
- $u_{k,i}$: Valeurs admissibles pour la commande (quantifiée)
- V : Energie potentielle [joules]
- Vm : Potentiel de surface mesuré
- Vm_p : Potentiel de surface mesuré (cas linéique) pris au point (p)
- Vm_c : Potentiel de surface mesuré central
- $Vm_c(x_i)$: Potentiel de surface mesuré centrale au point x_i
- Vm_{pq} : Potentiel de surface mesuré discret au point n° (p, q)
- Vm_calc_{pq} : Potentiel de surface mesuré calculé au point (p, q)
- $Vm_calc_{pq, n}$: Potentiel de surface mesuré calculé au point (p, q) à l'itération n
- VR_n : Ensemble de Vr_calc_n possibles à l'itération n

- $VR_{pq, n}$: Ensemble de valeurs possibles du potentiel de surface réel au point (p, q) à l'itération n
- Vr_calc : Potentiel de surface réel calculé
 - Vr_{ij} : Potentiel de surface réel pris au point (i, j)
- $Vr_calc_{pq, n, new}$: Nouvelle meilleur valeur du potentiel de surface réel calculé au point (p, q) à l'itération n
- $Vr_calc_C_{pq, n}$: Valeur centrale du potentiel de surface réel calculé au point (p, q) à l'itération n dans la recherche stochastique guidée
- $Vr_calc_L_{pq, n}$: Valeur à gauche du potentiel de surface réel calculé au point (p, q) à l'itération n dans la recherche stochastique guidée
- $Vr_calc_R_{pq, n}$: Valeur à droite du potentiel de surface réel calculé au point (p, q) à l'itération n dans la recherche stochastique guidée
- $Vr_calc_{pq, n, old}$: Ancienne meilleur valeur du potentiel de surface réel calculé au point (p, q) à l'itération n
 - $Vr_calc_{pq, n}$: Potentiel de surface réel calculé au point (p, q) à l'itération n
 - Vr_calc_n : Potentiel de surface réel calculé à l'itération n
 - Vr_calc : Potentiel de surface réel calculé
- $Vr_calc_{best\ new}$: Nouveau meilleur potentiel de surface calculé
 - VrC : Potentiel de surface réel central (cas linéique) dans la recherche stochastique
 - VrL : Potentiel de surface réel à gauche (cas linéique) dans la recherche stochastique
 - VrR : Potentiel de surface réel à droite (cas linéique) dans la recherche stochastique
 - Vr_{ij} : Potentiel de surface réel pris au point (i, j)
 - Vr_i : Potentiel de surface réel pris au point (i) (cas linéique)
 - $Vr_{i, k}$: Potentiel de surface réel pris au point (i) à l'itération k (cas linéique)
 - $VrC_{i, k}$: Potentiel de surface réel central pris au point (i) à l'itération k (cas linéique) dans la recherche stochastique
 - $VrL_{i, k}$: Potentiel de surface réel à gauche pris au point (i) à l'itération k (cas linéique) dans la recherche stochastique
 - $VrR_{i, k}$: Potentiel de surface réel à droite pris au point (i) à l'itération k (cas linéique) dans la recherche stochastique
 - $Vr_{i, p, k}$: Potentiel de surface réel pris au point (i) (cas linéique) pour la particule p à l'itération k
 - $Vr_{best, i, k}$: Meilleur valeur du potentiel de surface réel pris au point (i) (cas linéique) à l'itération k
 - $v_{p, k}$: Vitesse de la particule p à l'itération k
 - v_k^i : Vitesse de déplacement de la particule i à l'itération k

- $v_{i,d}$: Vitesse de déplacement de l'abeille i dans la dimension d
- w : Vitesse de rotation mécanique [rad/s]
- w_i : Pondération associée à la ligne i dans la base de données
- w_i : Poids d'un neurone
- w_{ds} : Poids entre le neurone source (s) et le neurone destination (d)
- w_{new} : Nouvelle valeur du poids w
- w_{old} : Ancienne valeur du poids w
- w_r : Vitesse de rotation électrique [rad/s]
- w_{ds}^l : Poids de la couche l liant les neurones s (source, couche $l-1$) et d (destination, couche l)
- w_{ij} : Poids du réseaux de neurones artificiel RBF
- X : Abscisse en coordonnées opérationnelles [m]
- X : Entrées du régulateur guidé par les données
- (X, Y, Z) : Coordonnées opérationnelles
- $X_{i,d}$: Position (solution) de l'abeille n° i dans la dimension d
- x : Vecteur d'état
- x_1 : Première entrée du système flou
- x_2 : Deuxième entrée du système flou
- x_i : Entrées d'un neurone
- x_k^i : Position (solution) de la particule i à l'itération k
- x_{gbest} : Meilleur solution globale
- x_{lbest}^i : Meilleur solution locale de la particule i
- $xmin, xmax$: Valeurs minimale et maximale de la coordonnée X de l'échantillon
- Y : Ordonnée en coordonnées opérationnelles [m]
- y : Vecteur des sorties
- y_i : Conclusion des régulateurs flou ou neuro-flou du robot Delta
- $ymin, ymax$: Valeurs minimale et maximale de la coordonnée Y de l'échantillon
- z : Sortie du système flou

Introduction générale

Les isolants occupent une place de choix dans les nouvelles technologies. Des techniques de formation et de caractérisation de ces matériaux sont perfectionnés. Ils sont des éléments principaux dans certaines applications telles que les diélectriques, les filtres à électrets, les transducteurs et en télécommunication [1-12].

La compréhension des phénomènes liés à la génération de la charge d'espace et son évolution ainsi que le comportement des isolants chargés permettra, non seulement, la prévention des risques électrostatiques, mais aussi l'amélioration de leurs performances [13-18, 27, 33-36].

L'étude du comportement des isolants chargés nécessite l'utilisation de certains dispositifs expérimentaux parmi lesquels nous pouvons trouver ceux destinés à la cartographie du potentiel de surface, ceux destinés au dépôt de charges et ceux destinés à la neutralisation [19-26].

La cartographie sert à donner une image de la distribution de la charge sur la surface d'un matériau à des instants donnés et de suivre son évolution au cours du temps. La cartographie se fait selon deux axes et se base sur le balayage de la surface en suivant des trajectoires bien choisies vu les contraintes spatiales et temporelles. Le dispositif de cartographie doit suivre ces trajectoires et un bon système de commande est plus que nécessaire.

Les techniques de commande se basent sur le développement théorique d'algorithmes performants voire intelligents qui assurent la bonne poursuite des trajectoires.

L'objectif de ce travail est le pilotage et la caractérisation des systèmes de positionnement à forte dynamique pour la cartographie du potentiel de surface des matériaux isolants. Une bonne cartographie du potentiel de surface donne une image de la distribution des charges électriques sur la surface des isolants ou des échantillons chargés par décharges couronne ou par tribo-électricité.

Pour pouvoir bien présenter le travail effectué, nous avons organisé le manuscrit en quatre chapitres.

Le premier chapitre présente l'état de l'art dans l'étude du potentiel de surface des matériaux isolants ou conducteurs. Le dépôt de charges électriques par décharge couronne ou par tribo-électricité est abordé ainsi que la neutralisation en passant par le phénomène de déclin du

potentiel de surface. La procédure de mesure dynamique avec balayage par le positionnement dynamique de la sonde à induction électrostatique auto-compensée sera analysée. Une étude des systèmes de positionnement à forte dynamique (machines et robots) en vue de les utiliser dans la cartographie sera effectuée. En plus, différentes techniques de commande avancées et de l'intelligence artificiels seront présentées.

Le deuxième chapitre concerne la proposition de techniques de commande intelligente à appliquer aux différents types de moteurs électriques. Ces moteurs servent à positionner la sonde ou l'échantillon pour une bonne prise de mesure du potentiel de surface. Les techniques proposées se basent sur l'intelligence artificielle. La logique floue sera utilisée dans la commande adaptative optimale d'une machine asynchrone MAS en remplaçant la méthode du gradient pour trouver en ligne les valeurs des paramètres utilisés. Ensuite, cette technique de commande sera réutilisée dans la commande d'une machine synchrone à aimants permanents MSAP et d'un moteur pas à pas MPP qui seront les moteurs du robot SCARA étudié dans le troisième chapitre. Dans la suite, une commande prédictive basée sur les réseaux de neurones artificiels RNA et l'algorithme « Artificial Bee Colonies » (ABC) sera utilisée pour la commande de la machine asynchrone MAS. Les réseaux de neurones font la prédiction et l'algorithme ABC cherche la commande à appliquer par l'optimisation d'un critère à minimiser.

Dans le troisième chapitre, nous allons présenter différentes techniques de commande intelligentes appliquées aux robots utilisés dans la cartographie du potentiel de surface. D'abord, nous exploitons les résultats obtenus dans le chapitre précédent concernant la commande adaptative optimale basée sur la logique floue appliquée à la MSAP et au MPP pour réaliser la commande d'un robot SCARA motorisé par MSAP ou MPP. Ensuite, des techniques de commande prédictive guidée par les données ou basées sur les réseaux de neurones artificiels RNA et les essaims de particules PSO appliquées au robot SCARA seront présentées. La commande floue appliquée à un robot Delta dont le MGD et le MGI sont donnés par des réseaux de neurones artificiels RNA sera étudiée et améliorée par l'ajustement en ligne des paramètres du régulateur. Cette dernière technique est une commande neuro-floue adaptative appliquée au robot Delta. Le chapitre se termine par la proposition d'une technique de commande basée sur la méthode de synthèse H_∞ suivie d'un réglage neuro-flou adaptatif à modèle de référence appliquée à un système de positionnement motorisé par des moteurs à courant continu avec des perturbations externes et des incertitudes sur ses paramètres.

Le dernier chapitre présente la démarche à suivre pour une bonne reconstitution du potentiel réel sur la surface d'un matériau électriquement chargé (isolant ou conducteur). La procédure utilisée pour la mesure sera présentée et suivie d'expériences de mesures réalisées. Ensuite, plusieurs approches proposées pour la caractérisation de la sonde seront utilisées. Nous présenterons aussi les différentes approches proposées pour la reconstitution du potentiel réel de surface. Des études comparatives concernant les approches utilisées pour la caractérisation de la sonde ou les approches proposées pour la reconstitution seront conduites et ce afin de tirer les meilleurs conclusions et résultats.

La plateforme expérimentale dédiée à la cartographie est pilotée par ordinateur et elle est constituée à base de moteurs électriques (moteurs synchrones à aimants permanents ou moteurs pas à pas), de robots (SCARA ou Delta) ou de positionneurs X-Y (XY-stages). La structure Maître-Esclave est utilisée et le système de commande (multiprocesseurs) connecté à l'ordinateur assure le pilotage de la plateforme et l'acquisition de données.

Les derniers développements dans les domaines des calculateurs et de l'automatique permettent d'implémenter les différentes stratégies de commande appropriées aux systèmes de positionnement à forte dynamique.

L'interfaçage avec l'ordinateur permet de bons pilotage et collecte de données. L'automatisation de la procédure d'intervention procure une grande fiabilité dans la cartographie du potentiel de surface et par la suite une bonne caractérisation des isolants.

Chapitre I

Etat de l'art

I.1. Introduction

Ce chapitre présente l'état de l'art dans l'étude du potentiel de surface des matériaux isolants ou conducteurs, la procédure suivie pour la mesure du potentiel de surface, les différents types de systèmes de positionnement : moteurs, robots, étages XY (XY-stages), les techniques de commande automatiques utilisées en plus des techniques de l'intelligence artificielle.

Un dépôt de charges électriques par décharge couronne ou par tribo-électricité peut être effectué. Le phénomène de déclin du potentiel de surface indique que les charges déposées sont mobiles et qu'elles peuvent changer de position en se déplaçant soit sur la surface ou en entrant à l'intérieur du matériau. Ceci conduit à une distribution de charges variable avec le temps. C'est nécessaire de connaître cette distribution afin de caractériser le matériau. La distribution de charges électriques sur la surface du matériau n'est pas connue directement et puisqu'elle est étroitement liée au potentiel de surface, une procédure de mesure du potentiel de surface peut donner une image de cette distribution. Cette image est déformée vu les caractéristiques de la sonde utilisée pour la mesure. Une procédure de mesure du potentiel de surface avec balayage par le positionnement dynamique de la sonde à induction électrostatique auto-compensée est établie mais cette mesure n'est pas vraiment exacte surtout si la distribution réelle présente un grand gradient.

Les systèmes de positionnement présentent une grande diversité ; en passant par les tables de positionnement à 2 degrés de liberté, on distingue les machines électriques utilisées pour entrainer des convoyeurs par exemples et les robots manipulateurs utilisés dans le positionnement ou la poursuite de trajectoires. La diversité se range dans la précision et la taille de ces systèmes ainsi que de leur rapidité (forte dynamique). Un positionnement rapide en suivant des trajectoires bien précises peut conduire à réaliser des cartographies du potentiel de surface avant qu'il change trop.

Pour assurer la bonne poursuite de trajectoires, des techniques avancées de l'automatique sont utilisées : commande adaptative, optimale, robuste, prédictive, etc. Ces techniques sont combinées avec l'intelligence artificielle : réseaux de neurones artificiels, logique floue, réseaux neuro-flous, algorithme des colonies d'abeilles artificielles (ABC : Artificial Bee

Colony) afin d'améliorer les performances de la poursuite ainsi que dans l'obtention de bons résultats de mesure du potentiel de surface grâce aux méthodes de recherches stochastiques, de l'optimisation par essaims de particules (PSO : Particle Swarm Optimization) et mêmes les techniques de base comme l'algorithme du gradient et la méthode du point fixe.

Dans ce chapitre, nous passons en revue les notions de base liées à l'électrostatique et au dépôt de charges électriques par décharge couronne ou par tribo-électricité sur les surfaces des matériaux isolants, la distribution des charges et son lien avec le potentiel de surface ainsi que la procédure de mesure suivie et la sonde utilisée pour effectuer cette tâche. Ensuite, les systèmes de positionnement seront abordés (moteurs électriques, tables de positionnement x-y appelées étages XY : XY-stages, en plus des robots manipulateurs). Quelques techniques de commande avancées seront présentées suivies de quelques techniques de l'intelligence artificielle utilisées dans la commande, l'identification, l'estimation et l'optimisation. Enfin, la problématique concernant la cartographie du potentiel de surface sera posée.

I.2 Electrostatique

Les phénomènes liés à l'électrostatiques sont connus depuis longtemps. On peut trouver :

- Triboélectricité : le frottement entre deux isolants génère et déplace des charges électriques sur les surface de ces derniers.
- Décharge couronne conduit à la déposition des charges électriques sur les matériaux isolants.




Figure I.1 : Principe de charge par (a) tribo-électricité (b) décharge couronne [1].

Les effets de l'électrostatique sont très utilisés dans les différents domaines de l'industrie. De l'industrie automobile à l'industrie du textile et en passant par les filtres à électrets et la séparation de matériaux (granulaires) ainsi que l'extraction d'énergie et les applications ne cessent pas d'augmenter en nombre et en qualité.

Beaucoup de recherches sont destinées à caractériser les effets de l'électrostatique concernant des matériaux bien spécifiques comme les polymères [1-12].

Les polymères sont de plus en plus utilisés dans les applications industrielles. Ils sont utilisés souvent comme des composants en rotation ou en translation (glissement) dans différents dispositifs et machines mécaniques [13] car ils présentent des propriétés mécaniques excellentes en plus de la stabilité thermique.

L'apparition et la dissipation (déplacement) des charges électriques sur les surfaces des polymères forment les majeures caractéristiques de ces derniers. Ces charges électriques apparaissent par décharge couronne ou par triboélectricité (frottement de deux surfaces de polymères). Quand deux surfaces de polymères, initialement en contact, se séparent, un transfert de charges se réalise suivant différents facteurs qui déterminent le taux et le sens de ce transfert [14-19].

Des études concernant le dépôt de charges électriques par décharge couronne sur les surfaces de matériaux isolants (polymères) ont été conduites [20-23]. Dans ces études, l'accent est mis sur la détermination de la distribution des charges électriques sur le matériau et ce dans différents cas d'utilisation.

Les chercheurs ont étudié la relation entre les caractéristiques dynamiques du mouvement de frottement et le potentiel de surface des polymères en plus de dépôt de charges par décharge couronne ou par triboélectricité avec des approches comparatives [24].

Beaucoup de problèmes sont liés à l'électrostatique à cause de la génération ou la déposition de charges sur la surface des matériaux. Ces charges apparaissent et disparaissent sur les surfaces des polymères durant l'utilisation.

Les phénomènes de l'électrostatique présentent des risques comme les étincelles qui apparaissent quand deux objets chargés se rapprochent et le haut potentiel électrique qui apparaît sur les surfaces dû à l'accumulation des charges électriques (frottement par exemple avion-air).

Pour réduire les effets de ces problèmes, des études pour bien comprendre les phénomènes liés à la génération (dépôt) de charges électriques et leur déplacement sur les surfaces des matériaux sont plus que nécessaires.

I.3 Mesure du potentiel de surface et déclin du potentiel

La distribution des charges électriques sur l'échantillon est étroitement liée au potentiel de surface des matériaux. Ce dernier n'est que le résultat de la répartition des charges sur la surface des matériaux [25-31]. Cette répartition est dynamique et varie lentement ou rapidement selon les conditions (facteurs) présentes (type de matériau, concentration des charges, environnement).

Avec le temps, les charges électriques déposées sur la surface du matériau diélectrique se déplacent lentement ce qui conduit au changement du potentiel de surface. Le potentiel diminue lentement ou rapidement selon la situation. Des études ont montré qu'au début il y a une grande chute du potentiel à cause du déplacement des charges concentrées déjà dans des zones bien déterminées. Cette chute devient lente après un certain temps avant de se stabiliser (équilibre) [32-47].




Figure I.2 : Courbes de déclin du potentiel de surface pour différentes valeurs de la tension de charge positive [1].

Différentes plateformes expérimentales et approches de mesure du potentiel de surface ont été proposées. Des tests de différentes procédures de mesure du potentiel de surface ont été effectués afin de tirer des remarques et conclusions concernant la prise des mesures. La mesure est réalisée par des sonde électrostatiques sans contact avec le matériau.




Figure I.3 : Mesure du potentiel de surface [1].

I.4 Sondes électrostatiques

La mesure du potentiel de surface, la distribution ou la densité des charges électriques sur la surface est effectuée par des sondes électrostatiques sans contact avec l'échantillon. La mesure doit être bien interprétée pour pouvoir tirer les informations nécessaires pour déterminer la densité des charges et le potentiel de surface [49-55].

La sonde utilisée fait partie des sondes de type Kelvin, qui utilisent soit l'effet inductif ou l'effet capacitif avec des relations bien établies [56-58].

En fait, les sondes de Kelvin ne donnent pas la valeur du potentiel de surface au point considéré mais une moyenne pondérée des potentiels à tous les points dans le voisinage du point considéré. C'est une opération de convolution spatiale qui génère un potentiel mesuré différent du potentiel réel à partir d'une fonction caractéristique de la sonde appelée fonction d'étalement du point (Point Spread Function PSF) et du potentiel dans le voisinage du point considéré.

Le potentiel de surface mesuré $V_{m_{pq}}$ au point (p,q) est donné par la formule suivante

$$V_{m_{pq}} = \sum_{i=1}^{i=N} \sum_{j=1}^{j=M} f_{ij;pq} \cdot V_{r_{ij}} \quad (I.1)$$

Où

$V_{r_{ij}}$: potentiel de surface réel,

$f_{ij;pq}$: fonction d'étalement du point. Cette fonction est aussi appelée « noyau » de la convolution à deux dimensions.

La reconstitution du potentiel réel est nécessaire pour pouvoir déterminer la distribution des charges électriques sur la surface du matériau. Des méthodes proposées utilisent la déconvolution à deux dimensions, mais celle-ci n'est pas vraiment efficace vu la bande passante limitée [59-62].

I.5 Systèmes de positionnement rapide

De plus, la mesure peut se faire, point par point, ou en continu par un déplacement de la sonde suivant des trajectoires bien précises. Pour cela, des systèmes de positionnement ont été utilisés mais le résultat dépend de la qualité du système qui peut être rapide ou lent. Des systèmes de positionnement à base de machines électriques ont été déjà proposés [63-65]. Des étages XY (XY stages) sont déjà utilisés pour le positionnement précis [66-88]. D'abord des études de modélisation des systèmes à deux ou trois axes de mouvement (étages XYZ ou étages XY: XYZ stages or XY stages) ont été effectuées [66-71]. Ensuite, des techniques de commande classique [72-78], robuste [79-80] ou intelligente basée sur les réseaux de neurones artificiels et la logique floue [81-84] des XY-stages ont été proposées. Des implémentations sur des SoC ou FPGA ont été réalisées [85-88].

Des robots à deux degrés de liberté peuvent réaliser la tâche de positionnement si une bonne technique de commande est utilisée [89-111]. On peut utiliser des robots cartésiens (considérés comme des XY-stages), des robots SCARA [93] ou des robots parallèles comme le robot Delta connu pour sa rapidité dans les tâches de « Pick and place » dans l'industrie [94-106]. Les techniques avancées de commande utilisées s'étalent sur une grande variété de propositions allant de la commande adaptative, optimale, robuste, prédictive jusqu' aux techniques basées sur l'intelligence artificielle [107-111].

I.5.1 Machines électriques

Dans ce qui suit, nous présentons seulement les modèles des machines électriques utilisées sans entrer dans le détail. Ce modèle est donné dans le repère de Park et il est obtenu après quelques hypothèses simplificatrices. La littérature concernant ces machines est abondante.

I.5.1.1 Moteur asynchrone

Le modèle d'état de la MAS, dans le repère de Park, est donné comme suit :

$$\begin{cases} \frac{dx}{dt} = f(x) + h u + s_r C_r \\ y = [\Omega] \end{cases} \quad (I.2)$$

Où le vecteur d'état est :

$$x = [I_{sd}, I_{sq}, \Phi_{rd}, \Phi_{rq}, \Omega]^T \quad (I.3)$$

En plus, nous avons :

$$u = [V_{sd} \ V_{sq}]^T \quad (I.4)$$

$$\frac{dx}{dt} = [\dot{I}_{sd}, \dot{I}_{sq}, \dot{\Phi}_{rd}, \dot{\Phi}_{rq}, \dot{\Omega}]^T \quad (I.5)$$

$$\Phi_r = \sqrt{\Phi_{rd}^2 + \Phi_{rq}^2} \quad (I.6)$$

$$f(x) = \begin{bmatrix} -\gamma I_{sd} + \omega_s I_{sq} + \frac{K}{T_r} \Phi_{rd} + p \Omega K \Phi_{rq} \\ -\omega_s I_{sd} - \gamma I_{sq} - p \Omega K \Phi_{rd} + \frac{K}{T_r} \Phi_{rq} \\ \frac{M}{T_r} I_{sd} - \frac{1}{T_r} \Phi_{rd} + (\omega_s - p \Omega) \Phi_{rq} \\ \frac{M}{T_r} I_{sq} - (\omega_s - p \Omega) \Phi_{rd} - \frac{1}{T_r} \Phi_{rq} \\ p \frac{M}{j L_r} (\Phi_{rd} I_{sq} - \Phi_{rq} I_{sd}) - \frac{f \Omega}{j} \end{bmatrix} \quad (I.7)$$

$$h = \begin{bmatrix} \frac{1}{\sigma L_s} & 0 \\ 0 & \frac{1}{\sigma L_s} \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (I.8)$$

$$s_r = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ \frac{-1}{j} \end{bmatrix} \quad (I.9)$$

$$T_r = \frac{L_r}{R_r} \quad (I.10)$$

$$\sigma = 1 - \frac{M^2}{L_s L_r} \quad (I.11)$$

$$K = \frac{M}{\sigma L_s L_r} \quad (\text{I.12})$$

$$\gamma = \frac{R_s}{\sigma L_s} + \frac{M^2}{\sigma L_s L_r^2} \quad (\text{I.13})$$

p : nombre de paires de pole de la MAS.

I.5.1.2 Moteur synchrone à aimants permanents

Le modèle de la MSAP, dans le repère de Park, est donné comme suit

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds} - Ri_{ds} + pL_q w_r i_{qs}}{L_d} \\ \frac{di_{qs}}{dt} = \frac{u_{qs} - Ri_{qs} - p\varphi_m w_r - pL_d w_r i_{ds}}{L_q} \\ \frac{dw}{dt} = \frac{C_{em} - F.w - C_r}{J} \end{cases} \quad (\text{I.14})$$

avec le couple électromagnétique calculé comme suit :

$$C_{em} = \frac{3}{2}p(-L_q i_{ds} i_{qs} + L_d i_{ds} i_{qs} + \varphi_m i_{qs}) \quad (\text{I.15})$$

I.5.1.3 Moteur pas à pas

Le modèle du MPP, dans le repère de Park, est donné comme suit

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds} - Ri_{ds} + N_r w i_{qs}}{L} \\ \frac{di_{qs}}{dt} = \frac{u_{qs} - Ri_{qs} - N_r w i_{ds} - K_m w}{L} \\ \frac{dw}{dt} = \frac{C_{em} - B.w - C_r}{J} \end{cases} \quad (\text{I.16})$$

avec le couple électromagnétique calculé comme suit :

$$C_{em} = K_m i_{qs} \quad (\text{I.17})$$

I.5.2 Robots manipulateurs

De mêmes, nous présentons ici seulement les modèles (géométriques, cinématiques et dynamiques) des robots utilisés.

L'espace articulaire est lié aux coordonnées des actionneurs (leurs mouvements : déplacements dans les cas de translation ou angles dans le cas de rotation). L'espace opérationnel est liée à la base du robot, c'est le repère XYZ de l'espace 3d.

La relation entre les coordonnées articulaires et les coordonnées opérationnelles est appelée modèle géométrique. On distingue le modèle géométrique direct (MGD) et le modèle géométrique inverse (MGI). Le MGD concerne le passage des coordonnées articulaires vers les coordonnées opérationnelles et le MGI c'est l'opération inverse. Ces modèles sont en général non linéaires et même complexes.

La dérivation par rapport au temps du modèle géométrique conduit au modèle cinématique. Donc, on aura le modèle cinématique direct (MCD) à partir du MGD et le MCI à partir du MGI.

Le modèle cinématique est linéaire et lie les différentielles des coordonnées articulaires aux différentielles des coordonnées opérationnelles. Ces coordonnées différentielles sont liées à travers la matrice jacobienne obtenue par la dérivation des coordonnées opérationnelles par rapport aux coordonnées articulaires.

Coté modèle dynamique du robot, on distingue le modèle dynamique direct (MDD) et le modèle dynamique inverse (MDI). Dans le MDD, les accélérations généralisées sont données en fonction des coordonnées articulaires (positions généralisées), leurs dérivées premières (vitesses généralisées) et les forces généralisées (forces, couples, ...). Pour le MGI, c'est l'inverse, les forces généralisées sont données en fonction des positions généralisées, des vitesses généralisées et des accélérations généralisées.

I.5.2.1 Robot cartésien

Pour les robots cartésiens, l'espace articulaire est identique à l'espace opérationnel. La matrice jacobienne du modèle cinématique est égale à la matrice unité (avec les dimensions adéquates). Le modèle dynamique est simplifié et les axes (articulations) sont séparés et indépendants.



Figure I.4 : Robots cartésiens [72].

I.5.2.2 Robot SCARA

Un robot SCARA (Selective Compliance Assembly Robot Arm) est un robot dont le porteur est à deux degrés de liberté (2ddl). Ce porteur positionne l'effecteur dans le plans XY et l'effecteur peut orienter l'outil selon la tâche en cours (translation verticale ou autre).



Figure I.5 : Robots SCARA [94].

Les coordonnées articulaires sont les angles faites par le premier bras avec l'axe X et le deuxième bras avec le premier. Le modèle géométrique directe MGD est simple et est donné comme suit :

$$\begin{cases} X = l_1 \cos(\theta_1) + l_2 \cos(\theta_1 + \theta_2) \\ Y = l_1 \sin(\theta_1) + l_2 \sin(\theta_1 + \theta_2) \end{cases} \quad (\text{I.18})$$




Figure I.6 : Modèle géométrique.

Les modèles MGI, MCD et MCI peuvent être tirés directement de la relation (I.18).

Concernant le modèle dynamique, il faut passer par les lois de la mécanique analytique. En utilisant le lagrangien $L = T - V$ où T est l'énergie cinétique de tous les éléments mouvants du robot et V est l'énergie potentielle associée aux différentes parties du robot (à cause de la gravité), nous pouvons écrire la formule générale liant les coordonnées généralisées et les forces généralisées comme suit :

$$\frac{d}{dt} \left(\frac{\partial L}{\partial \dot{q}} \right) + \frac{\partial L}{\partial q} = F - D \quad (\text{I.19})$$

Avec

$q = \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix}$: les coordonnées généralisées,

F : les forces généralisées,

D : les forces dissipatives généralisées.

I.5.2.3 Robot Delta

Le robot Delta est un robot parallèle avec trois chaînes cinématiques allant de la base immobile à la nacelle mobile dans l'espace opérationnel XYZ. La nacelle en mouvement garde toujours la même orientation ; elle est toujours horizontale et ne fait pas de rotation autour de l'axe Z. Le positionnement se fait dans l'espace opérationnel XYZ par le biais des trois moteurs (actionneurs) fixés sur la base immobile et disposés dans une configuration spatiale bien spéciale (l'angle actionneur-centre de la base immobile-actionneur est de 120°).



Figure I.7 : Robots Delta [98].

Les trois axes de rotation des trois moteurs forment un triangle équilatère et la rotation des moteurs positionne la nacelle.

Le modèle géométrique directe MGD est assez délicat pour obtenir et de même pour les modèles MGI, MCD et MCI. Beaucoup de méthodes ont été proposées pour obtenir ces modèles analytiquement.

Concernant le modèle dynamique, le MDD et le MDI sont obtenus en utilisant la mécanique analytique. Beaucoup de méthodes ont été proposées aussi pour les avoir. Ces modèles sont complexes, mais avec des considérations pratiques, comme la légèreté des liaisons, de la nacelle et de la charge mécanique portée par la nacelle, on peut considérer que la dynamique du robot est seulement donnée par les dynamiques des trois moteurs.

En fait, vu la légèreté des parties mouvantes du robot Delta, il est très rapide et très utilisé dans l'industrie dans les tâches de « Pick and place ».

I.6 Techniques avancées de l'automatique pour le positionnement

Des algorithmes de commande adaptative, optimale, robuste, prédictive, sans modèle (model-free) de hautes performances ont été appliqués à la commande des machines-outils, des robots manipulateurs et des positionneurs XY [112-137].

Vu le comportement des machines et de leurs modèles non linéaires, qui sont parfois mal connus à cause des perturbations et des incertitudes, des études ont pris le cas des doubles intégrateurs comme modèles propres de ses systèmes, assujettis aux différents types de perturbations [130-133]. Ces études ont pu synthétiser des régulateurs robustes fiables qui peuvent être utilisés dans les systèmes de positionnement.

Les techniques de commande avancée (adaptative, robuste, optimale, prédictive, ...) sont largement utilisées dans les systèmes de commande des machines, des robots et en général dans les systèmes de positionnement rapide et de poursuite de trajectoires [174-181].

I.6.1 Commande optimale

La commande optimale est une technique avancée de l'automatique, elle se base sur la minimisation d'un critère. Selon le critère utilisé, on distingue : commande à temps minimal, commande à consommation minimale et commande à énergie minimale. Si le temps apparait explicitement dans le critère, donc en minimisant le critère c'est la durée de la commande qui sera minimisée. Si la valeur absolue du signal de commande apparait explicitement dans le critère donc c'est une commande optimale à consommation minimale. Si le carré du signal de

commande apparait dans le critère alors c'est une commande optimale à énergie minimale. La commande optimale est utilisée pour les systèmes continus et pour les systèmes discrets (échantillonnés). Le critère est un critère intégral (intégral en continu, sommation en discret) avec l'instant final (horizon) fixe ou variable même les états objectifs (targets) peuvent être fixes ou variables (mouvants).

Comme commande optimale, on peut citer :

- La commande LQ : Linear Quadratic.
- La commande H2.
- La commande H^∞ .
- La commande LQG/LTR.

I.6.2 Commande adaptative

C'est une commande numérique basée sur l'adaptation des paramètres du régulateur en temps réel suivant un critère de performance à minimiser dépendant de l'erreur de poursuite et peut être le signal de commande en plus.

Il existe deux approches de base : la commande adaptative directe et la commande adaptative indirecte. Dans la première approche, les paramètres du régulateur sont directement ajustés par des formules d'adaptation paramétrique sans passer par l'identification des paramètres du modèle du système sous commande, au contraire de l'approche indirecte où les paramètres du régulateur sont ajustés en fonction des paramètres du modèle du système sous commande après identification de ceux-ci par des algorithmes ou formules obtenus à partir du problème de minimisation du critère de performances.

De plus, la commande adaptative à modèle de référence permet de trouver les paramètres du régulateur et ce dans le but d'assurer un comportement en boucle fermée le plus proche possible d'un modèle choisi préalablement appelé « modèle de référence ». Dans ce cas, les formules d'adaptation paramétriques sont obtenues en minimisant le critère de performance qui dépend de l'erreur de poursuite du modèle de référence.

I.6.3 Commande prédictive

La commande prédictive est une technique de commande avancée. C'est une commande numérique basée sur la minimisation d'un critère dépendant de l'erreur et des signaux de

commande et/ou des incréments de la commande dans un futur proche dit horizon de prédiction. Si on s'intéresse seulement à quelques pas dans le future pour la commande, on distingue aussi l'horizon de commande.

Donc à un instant donné, un modèle de prédiction est utilisé pour prédire les sorties futures du système. Ces sorties seront comparées aux consignes en calculant les erreurs de poursuite prédites utilisées dans le critère. La loi de commande est obtenue en calculant une séquence d'incrément de la commande (selon l'horizon de commande) à chaque pas d'échantillonnage et seulement le premier incrément sera utilisé et rajouté à la valeur précédente de la commande pour former la valeur de commande à appliquer au système sous commande. Un modèle de convolution du système est utilisé aussi dans la commande prédictive car les incréments futurs de la commande sont pondérés par la réponse indicielle discrète du système dans le critère à minimiser.

Il existe plusieurs approches de commande prédictive, on trouve :

- GPC: Generalized Predictive Control.
- MPC: Model Predictive Control.
- PFC: Predictive Functional Control

I.6.4 Commande robuste

Dans la commande robuste, on prend en considération les perturbations et les incertitudes sur les paramètres dans la phase de synthèse (design), alors que dans la commande classique on teste la robustesse après la phase de synthèse de la loi de commande.

Donc, selon les perturbations et les incertitudes sur les paramètres du système sous commande, la méthode de synthèse de la commande robuste peut nous donner une réponse sur l'existence (la faisabilité) ou non du régulateur qui répond aux contraintes imposées par les perturbations et les incertitudes sur les paramètres. Et même, si la réponse est oui, la méthode de synthèse nous permet de réaliser le régulateur (la loi de commande).

La commande robuste présente une grande variété d'approches, on trouve : H_∞ , H_2 , μ -Analyse, μ -Synthèse, ...

D'autres techniques de commande présentent aussi de la robustesse sans la prise en considération des perturbations ou des incertitudes sur les paramètres. Parmi ces techniques, on

trouve la commande par modes de glissement (commande à structure variable), aussi on trouve la logique floue, etc.

I.7 Intelligence artificielle pour le positionnement

L'utilisation des robots et l'intelligence artificielle ont trouvé leurs utilités dans le domaine du positionnement rapide avec l'application des réseaux de neurones artificiels, la logique floue et les réseaux neuro-flous pour commander les tables de positionnement XY motorisées par des machines synchrones à aimants permanents ou des moteurs pas à pas afin d'avoir des systèmes rapides est précis [138-181].

Le « soft computing » est la base de la commande intelligente des systèmes. Il est basé sur les réseaux de neurones artificiels, la logique floue, les réseaux neuro-flous ainsi que le raisonnement probabiliste [138-139].

Les réseaux de neurones artificiels direct (feed-forward) ou à fonction de base radiale (RBF : Radial basis functions) sont utilisés combinés ou non avec les techniques d'optimisation par essaims de particules (PSO : Particle Swarm Optimization) ou par les algorithmes génétiques (GA : Genetic Algorithms) en plus des techniques de commande adaptative, optimale, robuste ou prédictive [140-154].

L'optimisation par essaims de particules (PSO) est aussi utilisée pour l'obtention des régulateurs PID ou autres en déterminant les paramètres qui minimisent un critère bien choisi englobant poursuite de consignes et optimisation de la commande (commande optimale) [155-156].

La logique floue est très adaptée pour les systèmes mal connus ou présentant des incertitudes sur leurs paramètres. Elle est utilisée soit seule [157-159] ou combinée avec les techniques de commande adaptative, optimale, robuste ou prédictive [160-173].

De plus, les réseaux neuro-flous gagnent des propriétés des réseaux de neurones (coté apprentissage) et des propriétés des systèmes flous (coté raisonnement approché). Pour cela, les réseaux neuro-flous sont très utilisés seuls ou combinés avec les autres techniques de l'automatique ou d'intelligence artificielle.

I.7.1 Réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des approximateurs universels. Ils sont très utilisés dans la modélisation, l'identification, l'estimation et la commande. Ils imitent la structure du cerveau par le traitement parallèle de l'information et l'apprentissage par l'ajustement des paramètres dits poids notés w (weights).

On distingue plusieurs types de réseaux de neurones artificiels : les réseaux feed-forward (FFNN : Feed-Forward Neural Networks), les réseaux à fonctions de base radiale (RBFNN : Radial Basis Functions Neural Networks), les réseaux récurrents (RecNN ou RecNets), les réseaux de convolution (ConvNets), les auto-encodeurs, les LSTM, les transformers, etc.

Dans le domaine de la commande et la modélisation des systèmes, on s'intéresse au réseaux FFNN, RBFNN et RecNN.




Figure I.8 : Exemple de FFNN [144].

Un neurone artificiel est donné par

$$\begin{cases} net = b + \sum_{i=1}^n w_i x_i \\ O = f(net) \end{cases} \quad (I.20)$$

Où b est le biais, les w sont les poids, net cumule les entrées pondérées par les poids w , O est la sortie du neurone et f sa fonction d'activation.

L'apprentissage se fait par l'algorithme de rétro propagation de l'erreur (error backpropagation) basée sur la méthode du gradient en minimisant un certain critère J dit « Coût ». Les paramètres du réseau sont ajustés selon la loi suivante :

$$w_{new} = w_{old} - \eta \frac{\partial J}{\partial w_{old}} \quad (I.21)$$

Où η est le pas du gradient appelé aussi pas d'apprentissage (learning rate).

De plus, pour un poids liant les neurones s (source) et d (destination), nous avons la formule :

$$\frac{\partial J}{\partial w_{d,s}} = \delta_d O_s \quad (\text{I.22})$$

Où O_s est la sortie du neurone (s) et δ_d est obtenu par la rétro propagation de l'erreur. En fait, δ_d est défini par la formule :

$$\delta_d = \frac{\partial J}{\partial net_d} \quad (\text{I.23})$$

Où net_d est la somme pondérée (par les poids w liés au neurone d) des entrées du neurones d .

$$net_d = \sum_s w_{d,s} O_s \quad (\text{I.24})$$

Si la sortie du neurone s est lié aux neurones d_i , $i = 1, \dots, n$, alors, on peut calculer les δ comme suit :

$$\delta_s = \left(\sum_{i=1}^n \delta_{d_i} w_{d_i,s} \right) \cdot O'_s \quad (\text{I.25})$$

Où O'_s est la dérivée de la sortie du neurone s (par rapport à net_s).

Pour les réseaux RBF, l'apprentissage se fait par l'utilisation de la méthode des moindres carrés pour trouver les poids w .




Figure I.9 : Exemples de réseaux RBF [152].

Les paramètres des fonctions de base radiale sont choisis soit directement et fixés une fois pour toutes par le concepteur selon sa tâche ou bien ajustés par apprentissage par la méthode de rétro propagation de l'erreur.

I.7.2 Logique floue

La logique floue a été introduite par L. A. Zadeh en 1965 comme réponse aux problèmes rencontrés par les systèmes experts dans le cas où les connaissances ne sont pas précises, ou en général, vagues. Avec la logique floue, le raisonnement approché devient une réalité et ce en imitant le raisonnement humain. Ainsi, un système physique (machine), dont le modèle est difficile à avoir vu la complexité et l'imprécision dans les paramètres, la présence du bruit de mesures, peut être piloté par une carte à microprocesseur (microcontrôleur ou en général un calculateur électronique) dont le programme implémenté est basé sur la logique floue en utilisant les connaissances de l'opérateur humain qui a appris déjà la conduite de ce système (cette machine).

Un système flou est aussi un approximateur universel. Il est construit de :

- Base de connaissances ou base de règles floues,
- Bloc fuzzification pour le passage du non flou vers le flou,
- Bloc moteur d'inférence qui imite le raisonnement humain en utilisant la base des règles floues et le résultat de la fuzzification
- Bloc de defuzzification où on génère la sortie nette (non floue)

La base des règles floues est formée d'un ensemble de règles données, par exemple, sous la forme :

$$R : \mathbf{Si} [(x_1 \text{ est } E_1) \mathbf{ET} (x_2 \text{ est } E_2)] \mathbf{Alors} (z \text{ est } F) \quad (d)$$

x_1 et x_2 sont les variables d'entrée et z la variable de la sortie.

$(x_1 \text{ est } E_1)$ est une proposition logique dont le degré de vérité est dans l'intervalle $[0, 1]$.

$(x_1 \text{ est } E_1)$, $(x_2 \text{ est } E_2)$ sont appelées prémisses (conditions, antécédents).

$(z \text{ est } F)$ est appelée conclusion.

ET : pour la conjonction des prémisses (conditions, antécédents).

Si...Alors... : pour l'implication floue.

d : le degré de vérité (ici de confiance) donné par le constructeur de ce système flou à cette règle.

E_1 , E_2 et F : des sous-ensembles flous présentant les valeurs linguistiques prises par les variables linguistiques associées aux entrées x_1 et x_2 et aux sorties (ici, une seule : z).

Un sous-ensemble flou est défini par sa fonction d'appartenance liant l'univers de discours (la plage de valeurs que peut prendre la variable x_1 , x_2 ou z par exemple) à l'intervalle $[0, 1]$. Ainsi, la proposition logique (x_1 est E_1) a un degré de vérité égale au degré d'appartenance de x_1 au sous-ensemble flou E_1 . L'étape de fuzzification réalise le passage du non flou vers le flou en calculant les degrés de vérité des prémisses.

Le raisonnement flou passe par la conjonction des prémisses, l'implication floue et l'agrégation floue. La conjonction et l'implication floue sont réalisées par l'opération dite norme triangulaire (comme cas particuliers : min, produit). L'agrégation regroupe les résultats donnés par chaque règle floue en utilisant une opération dite conorme triangulaire (comme cas particulier : max, somme probabiliste). La norme triangulaire et la conorme triangulaire sont des opérations binaires définies avec des axiomes bien précis.

A la fin de l'agrégation, le résultat est toujours flou parce qu'il est présenté sous forme d'une distribution de valeur d'appartenance sur tous les éléments de l'univers de discours de la sortie.

Afin de trouver une valeur nette pour la sortie z , on doit passer par l'étape de défuzzification. Plusieurs méthodes de défuzzification peuvent être utilisées :

- COG : Center Of Gravity, ou (COA : Center Of Area),
- LOM: Low Of Maxima,
- MOM: Mean Of Maxima,
- HOM: High Of Maxima.

On distingue les systèmes flous de type Mamdani, et ceux de type Sugeno. Mamdani utilise le raisonnement (inférence) max-min et les propositions floues symboliques à base de sous-ensemble flous dans les prémisses et les conclusions. Sugeno utilise le raisonnement sum-prod et les propositions floues symboliques dans les prémisses seulement et des expressions numériques pour les conclusions comme le montre l'exemple suivant :

$$R : \mathbf{Si} [(x_1 \text{ est } E_1) \mathbf{ET} (x_2 \text{ est } E_2)] \mathbf{Alors} (z = f(x_1, x_2)) \quad (d)$$

Dans ce cas, la sortie du système flou est donnée comme suit :

$$z = \frac{\sum_{i=1}^N \mu_i(x_1, x_2) f_i(x_1, x_2)}{\sum_{i=1}^N \mu_i(x_1, x_2)} \quad (I.26)$$

Où N est le nombre de règles floues dans la base des règles.

Les fonctions $\mu_i(x_1, x_2)$ sont le résultat de la conjonction des prémisses.

I.7.3 Réseaux neuro-flous

Plusieurs méthodes ont été proposées pour la combinaison entre les réseaux de neurones artificiels et les systèmes flous pour gagner les avantages des deux : l'apprentissage et le raisonnement approché.

On distingue les méthodes où chaque étape (bloc) d'un système flou est présentée par un réseau de neurones artificiels. Ainsi les fonction d'appartenance sont donnée par des FFNN, l'inférence aussi et même la defuzzification. Et de ce fait, l'apprentissage se fait par la méthode de rétro propagation de l'erreur comme présentée pour FFNN.

Une autre méthode de combinaison entre les systèmes flous et les réseaux de neurones artificiels est tout simplement basée sur la présentation de la formule qui donne la sortie z du système flou de Sugeno sous forme d'un réseau adaptatif généralisé dans lequel les nœuds (neurones) ayant des paramètres ajustables sont présentés par des carrés et les nœuds sans paramètres ajustables sont présentés par de cercles. Les liaisons ne portent pas de poids comme les réseaux de neurones, ils donnent seulement le sens de passage de l'information.

L'apprentissage se fait par l'algorithme de rétro propagation de l'erreur en minimisant le critère (Coût) noté J .

Soit p un paramètre qui apparait dans les nœuds de l'ensemble E . Alors, l'ajustement des paramètres se fait par la formule :

$$p_{new} = p_{old} - \eta \frac{\partial J}{\partial p_{old}} \quad (I.27)$$

Où $\frac{\partial J}{\partial p}$ sera calculé comme suit :

$$\frac{\partial J}{\partial p} = \sum_{o^* \in E} \frac{\partial J}{\partial o^*} \frac{\partial o^*}{\partial p} \quad (I.28)$$

On pose

$$\varepsilon^* = \frac{\partial J}{\partial o^*} \quad (I.29)$$

Donc

$$\frac{\partial J}{\partial p} = \sum_{o^* \in E} \varepsilon^* \frac{\partial o^*}{\partial p} \quad (I.30)$$

Le calcul des ε se fait par la rétro propagation de l'erreur.

Un système neuro-flou est aussi un approximateur universel.

I.7.4 Optimisation par essaims de particules (Particle Swarm Optimization : PSO)

La méthode d'optimisation par essaims de particules PSO est une méthode d'optimisation inspirée de la nature. Elle se base sur le comportement des groupes (poissons, oiseaux, ...) dans la recherche de solutions (nourritures par exemple). Dans le groupe, chaque individu a son comportement personnel (local) en plus d'un autre comportement lié au groupe. C'est une méthode de recherche informée où chaque individu connaît ce que les autres individus du groupe ont déjà trouvé. Les individus évoluent dans l'espace des solutions en cherchant la meilleure solution répondant aux exigences du problème posé.

En général, le problème est posé sous forme d'une minimisation (ou maximisation) d'un critère noté J .

L'évolution des individus est donnée par les équations (I.31).

Pour l'individu i , on a :

$$\begin{cases} v_{k+1}^i = K(v_k^i + c_1 r_1^i (x_{gbest} - x_k^i) + c_2 r_2^i (x_{lbest}^i - x_k^i)) \\ x_{k+1}^i = x_k^i + v_{k+1}^i \end{cases} \quad (I.31)$$

Où les v sont les vitesses de déplacement et les x sont les positions dans l'espace des solutions.

Les c sont des constantes (fixes) et les r sont choisis, à chaque itération, aléatoirement dans l'intervalle $[0, 1]$ et K le coefficient de constriction.

x_{gbest} est la solution correspondant à la meilleure valeur du critère J déjà trouvée.

x_{lbest}^i est la solution trouvée par l'individu correspondant à la meilleure valeur du critère J déjà trouvée par l'individu lui-même.

I.7.5 Algorithme des colonies des abeilles artificielles (Artificial Bee Colonies : ABC)

L'algorithme ABC est essentiellement appliqué aux problèmes d'optimisation continus. Il exploite le comportement des abeilles dans leurs colonies pour la recherche de la nourriture (nectar).

Une solution possible du problème est donnée par la position d'une source de nourriture. La quantité du nectar donne une image de la qualité de la solution. Cette qualité est appelée fitness de la solution.

L'algorithme commence par un choix aléatoire des solutions initiales puis il essaye d'améliorer ses solutions de proche en proche en explorant l'entourage des solutions actuelles afin de trouver mieux.

Les solutions sont les positions des sources de nourritures associées à une seule abeille ouvrière. Les abeilles observatrices choisissent une des sources ayant de meilleures qualité (fitness) en utilisant la méthode de sélection de la roulette. Les ouvrières et les observatrices cherchent en continu de nouvelles sources de nourriture dans leurs voisinages courants et ce en perturbant aléatoirement une composante, choisie aléatoirement, de leurs solutions courantes.

Après l'initialisation, l'algorithme passe par trois phases :

- Ouvrière
- Observatrice
- Eclaireuse

Dans la phase de l'abeille ouvrière, les ouvrières cherchent de nouvelles sources de nourritures ayant plus de nectar que le voisinage des sources déjà mémorisées. Elles trouvent de nouvelles sources et évaluent leurs qualités (fitness). Elles choisissent celle ayant le meilleur fitness. Après, elles partagent l'information avec les autres abeilles de la colonie.

L'abeille ouvrière commence à exploiter la source trouvée et si celle-ci est épuisée ou la qualité du nectar n'est pas bonne l'ouvrière arrête la collecte du nectar. Mais s'il reste une quantité assez suffisante de nectar, l'ouvrière peut continuer la collecte sans partager l'information avec les autres abeilles de la colonie.

Pour les abeilles observatrices (phase des observatrices), elles s'activent dès que toutes les abeilles ouvrières partagent leurs informations sur leurs sources de nourriture avec les abeilles observatrices. Les observatrices choisissent une source de nourriture parmi les autres selon une probabilité P_i déterminée par la méthode de sélection de la roulette. Cette probabilité est donnée par la formule suivante :

$$P_i = \frac{f_i}{\sum_{j=1}^M f_j} \quad (I.32)$$

Où f_i est le fitness associé à la source de nourriture i et M le nombre d'abeilles ouvrières (nombre de sources de nourriture).

Le fitness est calculé à partir de la fonction objectif f :

$$f_i = \begin{cases} \frac{1}{1+f(x_i)}, & \text{si } f(x_i) \geq 0 \\ 1 + |f(x_i)|, & \text{si } f(x_i) < 0 \end{cases} \quad (\text{I.33})$$

Après qu'une source de nourriture est choisie pour une observatrice, une source voisine est déterminée et un choix entre deux source est appliqué (selon leurs fitness). Cette phase se termine quand les nouvelles positions de toutes les sources de nourriture sont déterminées.

Dans la phase « Eclaireuse », les ouvrières deviennent des abeilles éclaireuses quand elles n'arrivent pas à améliorer leurs solutions. Ces solutions seront abandonnées et les abeilles éclaireuses prennent une nouvelle position choisie aléatoirement et redeviennent abeilles ouvrières.

Si la nouvelle source est meilleure ou égale à celle précédente (meilleure précédente) donc la nouvelle source sera gardée (nouvelle bonne solution).

Ces trois phases seront répétées et si le critère d'arrêt est satisfait, l'algorithme se termine et la solution meilleure est la dernière gardée.

I.7.6 Optimisation par la recherche stochastique (Stochastic Search Algorithms : SSA)

C'est un ensemble de méthodes basées sur les probabilités et les processus stochastiques. Ces méthodes assurent une optimisation globale par la recherche de nouvelles meilleures solutions en explorant les voisinages des meilleures solutions déjà trouvées. On distingue :

- Stochastic Hill Climbing
- Random Search
- Adaptive Random Search
- Iterated Local Search
- Guided Local Search

I.8 Problématique

Le positionnement (le balayage) est simplifié par l'utilisation de bonnes trajectoires bien définies comme :

- Le va et vient,
- Lissajous,
- Aléatoire avec une distribution normale

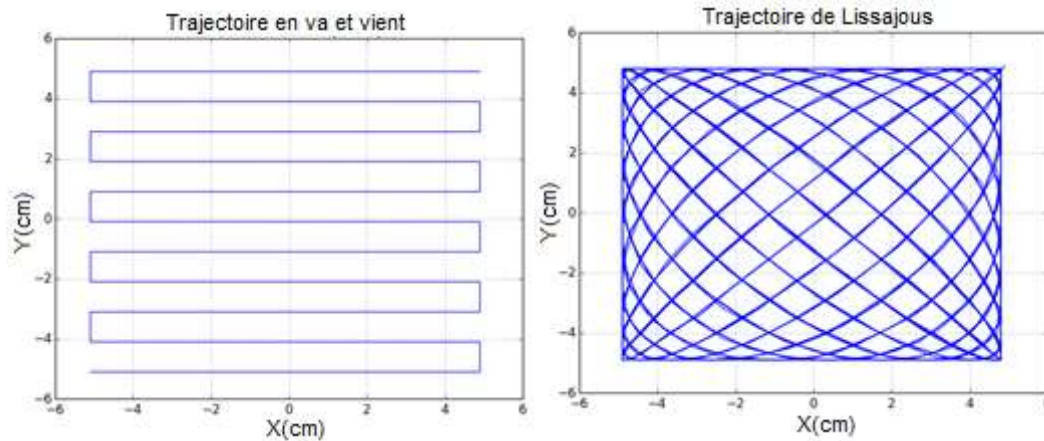


Figure I.10: Trajectoires pour le balayage (va et vient, Lissajous) [182].

Mais, les mesures données par la sonde ne sont qu'une image déformée des valeurs réelles du potentiel de surface. De plus, le potentiel de surface n'est pas fixe ; il chute suivant le mouvement ou déplacement des charges électriques sur la surface ou absorbées à l'intérieur du matériau, phénomène connu par « déclin du potentiel ». Il faut aussi vérifier et réduire l'effet du mouvement de la sonde sur la mesure.

Donc, l'objectif est d'étudier les systèmes de positionnement rapides afin de prendre des mesures du potentiel de surface avant qu'il change (trop) et d'utiliser cette mesure pour trouver la distribution réelle du potentiel de surface qui peut donner une meilleure image de la distribution des charges électriques déposées sur la surface du matériau par décharge couronne ou par tribo-électricité ou après neutralisation en réalisant des cartographies en images 2d et même des animations de la distribution en fonction du temps c'est-à-dire l'évolution de la distribution en fonction du temps.

Et même si possible, d'automatiser tout le processus de dépôt de charges, de mesure, de reconstitution du potentiel réel et de neutralisation.

Les figures suivantes présentent le problème lié au déclin de potentiel si le système de positionnement n'est pas rapide (Figure I.12) et dans le cas où le positionnement est rapide (Figure I.13). Les distributions réelles proposées sont à symétrie axiale pour la première et radiale pour la deuxième (Figure I.11) et les trajectoires suivies sont des Lissajous. En fait, les figures I.12 et I.13 présentent le potentiel de surface mesuré par la sonde lors de son passage sur les trajectoires. Comme le montre la figure I.12, la reconstitution du potentiel de surface n'est pas possible à partir de ces mesures, alors que la figure I.13 montre que la reconstitution est possible dans le cas où le balayage est rapide.




Figure I.11: Exemple de distributions du potentiel de surface [182].

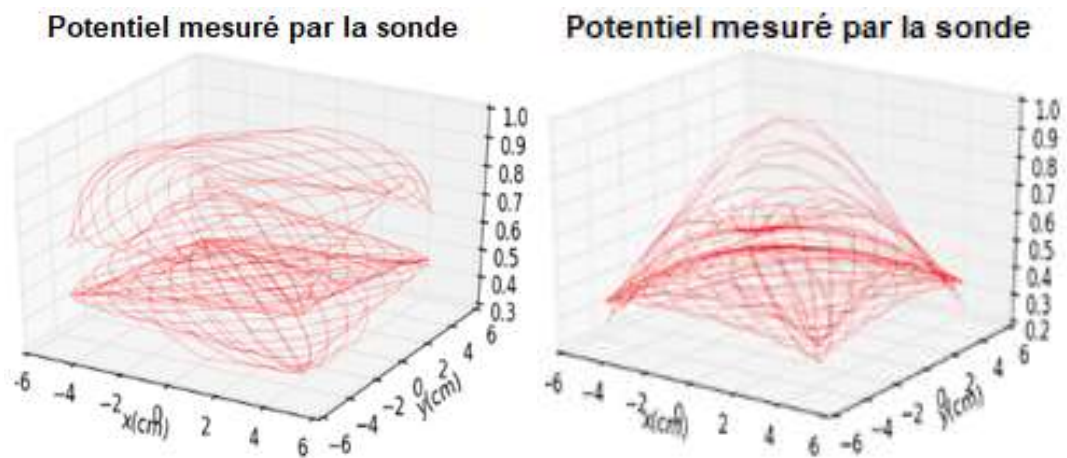


Figure I.12: Mesures sur les trajectoires avec lenteur de déplacement de la sonde [182].

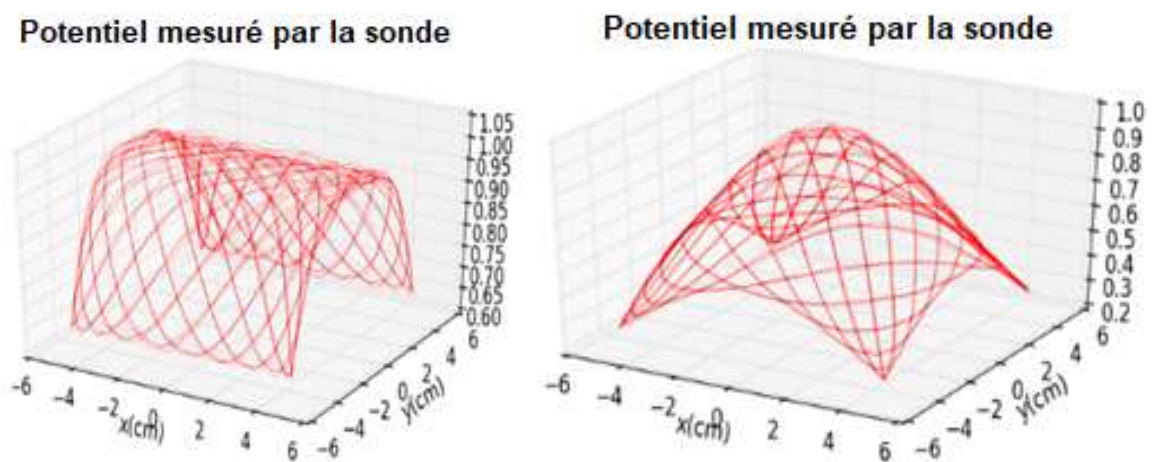


Figure I.13: Mesures sur les trajectoires avec rapidité de déplacement de la sonde [182].

I.9 Conclusion

Dans ce chapitre, nous avons vu le dépôt de charges électriques par décharge couronne ou par tribo-électricité sur les surfaces des matériaux isolants, la distribution des charges et son lien avec le potentiel de surface. Cette liaison nous permet de trouver la distribution des charges électriques sur la surface du matériau ce qui permet de l'étudier et de connaître ses caractéristiques. Nous avons présenté la relation qui lie la distribution réelle et la distribution mesurée et l'effet de la sonde qui donne juste une image un peu déformée du potentiel réel.

De plus, les systèmes de positionnement ont été présentés en donnant les modèles des différentes machines électriques ainsi que les modèles des robots manipulateurs utilisés dans ce travail.

Les techniques avancées de l'automatique ont été revues suivies de différentes approches de l'intelligence artificielle qui font partie du travail réalisé.

Le chapitre s'est terminé par la problématique qui est l'étude des systèmes de positionnement rapide (haute dynamique) et ce dans l'objectif d'avoir des cartographies du potentiel de surface en réduisant les effets liés au mouvement de la sonde utilisée, à la caractéristique (PSF) de la sonde ainsi que le déclin du potentiel.

Les chapitres qui suivent vont utiliser toutes les techniques et systèmes présentés dans ce chapitre.

Chapitre II

Commande intelligente de machines électriques

II.1 Introduction

Dans le but de faire le positionnement de l'échantillon ou de la sonde, nous allons proposer et appliquer des techniques de commande sur des machines électriques.

Ces techniques se basent sur l'intelligence artificielle côté logique floue, réseaux de neurones artificiels et l'algorithme « Artificial Bee Colonies » (ABC). En fait, elles sont des combinaisons de la commande adaptative optimale associée à la logique floue qui fuzzifie la méthode du gradient et l'autre est une commande prédictive combinée avec les réseaux de neurones pour la prédiction et l'algorithme ABC pour l'optimisation (minimisation).

La première combinaison sera appliquée aux machines électriques : MAS, MSAP et MPP alors que la deuxième concerne la MAS.

II.2 Commande adaptative et optimale, basée sur l'algorithme du gradient, appliquée à la MAS

II.2.1 Commande adaptative et optimale basée sur l'algorithme du gradient

La figure suivante présente le schéma de principe d'une commande adaptative directe où une étape d'identification du système peut être nécessaire ou non.

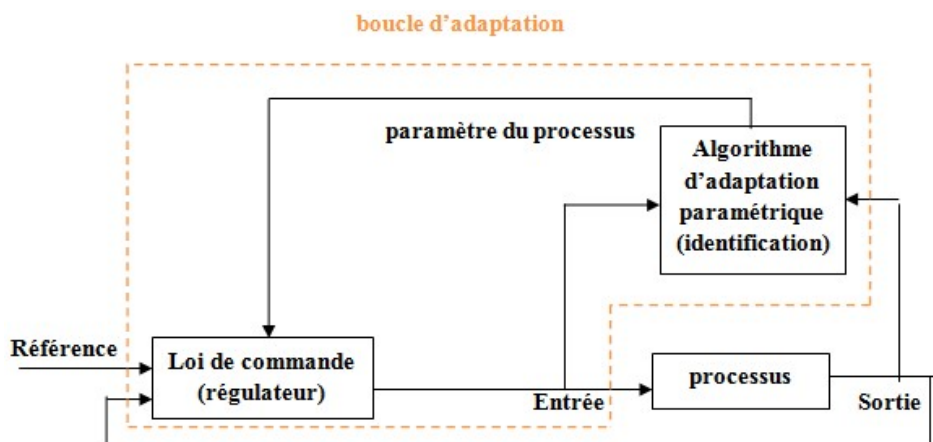


Figure II.1 : Schéma de la commande adaptative

Dans la commande adaptative indirecte, l'étape d'identification du système conduit à déterminer les paramètres du système. Ces paramètres sont utilisés dans les formules des lois de commande.

Dans la commande adaptative directe, l'étape d'identification d'un modèle pour le système n'est pas nécessaire et les lois de commande comportent des paramètres qui sont ajustés directement par les algorithmes d'adaptation paramétriques.

Les paramètres sont déterminés en minimisant un certain critère bien choisi pour la tâche de régulation et/ou optimisation de la commande. L'algorithme du gradient se prête très bien pour cette tâche surtout qu'il est relativement simple et ne demande pas trop de calcul.

Le principe de l'algorithme du gradient est de chercher les valeurs estimées des paramètres θ qui minimisent le critère de performance J d'une manière récursive en suivant la direction opposée de la plus grande pente $\partial J/\partial\theta$. L'algorithme du gradient est donné comme suit :

$$\dot{\theta} = -\eta \frac{\partial J}{\partial \theta} \quad (\text{II.1})$$

Avec

θ : vecteur des paramètres à estimer

J : le critère de performance.

η : le pas du gradient.

II.2.2 Application à la commande de la MAS

Avec le découplage, le modèle d'état de la MAS peut être présenté sous la forme suivante :

$$\dot{I}_{sd} = -\gamma I_{sd} + \frac{1}{\sigma L_s} u_{sd1} \quad (\text{II.2})$$

$$\dot{I}_{sq} = -\gamma I_{sq} + \frac{1}{\sigma L_s} u_{sq} \quad (\text{II.3})$$

$$\dot{\Omega} = \frac{1}{J} (C_e - C_r - f\Omega) \quad (\text{II.4})$$

Avec

$$u_{sd1} = \sigma L_s \omega_s I_{sq} + \frac{\sigma L_s K}{T_r} \Phi_{rd} + \sigma L_s p K \Phi_{rq} \Omega + u_{sd} \quad (\text{II.5})$$

$$u_{sq1} = -\sigma L_s \omega_s I_{sd} + \frac{\sigma L_s K}{T_r} \Phi_{rq} - \sigma L_s p \Omega K \Phi_{rd} + u_{sq} \quad (\text{II.6})$$

$$C_e = p \frac{M}{L_r} (\Phi_{rd} I_{sq} - \Phi_{rq} I_{sd}) \quad (\text{II.7})$$

Les entrées sont les tensions u_{sd1} , u_{sq1} et le couple électromagnétique est C_{em} et les sorties sont les courants I_{sd} , I_{sq} et la vitesse est Ω .

On voit bien que pour la régulation des courants I_{sd} et I_{sq} , il suffit de faire appel à un régulateur classique comme un PI, et pour la régulation de la vitesse Ω , un régulateur PID est suffisant.

Mais, le découplage n'est pas vraiment parfait. De ce fait, il faut faire appel à des techniques de la commande avancée comme la commande adaptative, optimale et si nécessaire un régulateur intelligent de type flou ou autre.

Les trois sous-systèmes sont donnés, respectivement, par les fonctions de transfert suivantes :

$$G_1(s) = \frac{1}{\sigma L_s(s+\gamma)} \quad (\text{II.8})$$

$$G_2(s) = \frac{1}{\sigma L_s(s+\gamma)} \quad (\text{II.9})$$

$$G_3(s) = \frac{1}{Js+f} \quad (\text{II.10})$$

Les régulateurs PI des courants I_{sd} et I_{sq} sont donnés, respectivement, comme suit :

$$R_1(s) = K_{p1} + \frac{K_{i1}}{s} \quad (\text{II.11})$$

$$R_2(s) = K_{p2} + \frac{K_{i2}}{s} \quad (\text{II.12})$$

Avec les paramètres :

$$K_{p1} = 1 \text{ et } K_{i1} = 50 \quad (\text{II.13})$$

$$K_{p2} = 1 \text{ et } K_{i2} = 50 \quad (\text{II.14})$$

Alors que le régulateur PID de la vitesse Ω est :

$$R_3(s) = K_{p3} + \frac{K_{i3}}{s} + K_{d3}s \quad (\text{II.15})$$

Avec :

$$K_{p3} = 0.3, K_{i3} = 0.05 \text{ et } K_{d3} = 0.01 \quad (\text{II.16})$$

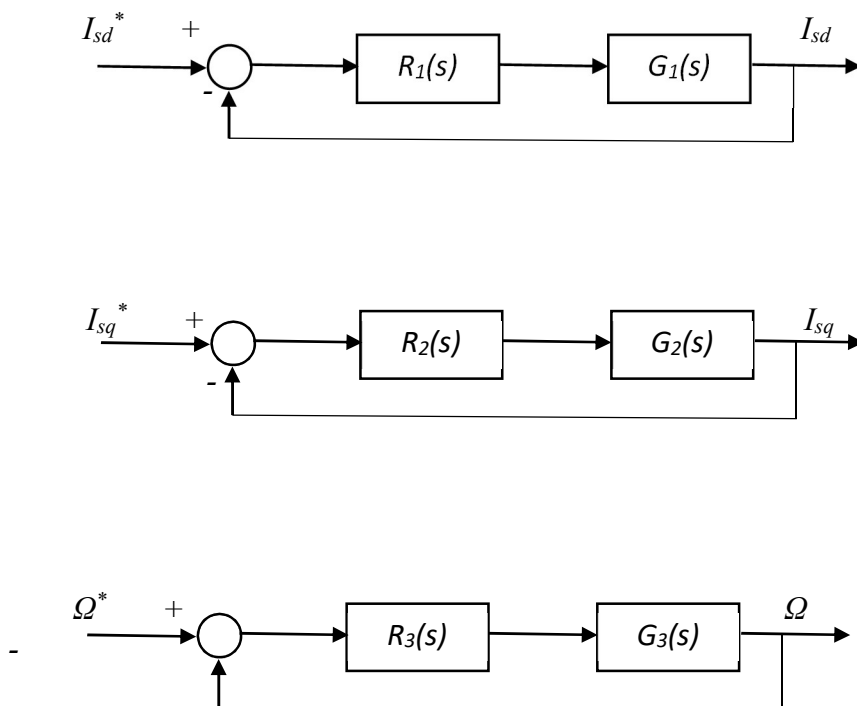


Figure II.2 : Schémas fonctionnels de la régulation des courants I_{sd} et I_{sq} et de la vitesse Ω .

Les signaux utilisés sont :

I_{sd}, I_{sd}^* : courants statoriques directes (sortie et référence respectivement).

I_{sq}, I_{sq}^* : courants statoriques en quadrature (sortie et référence respectivement).

Ω, Ω^* : vitesses (sortie et référence respectivement).

Ces régulateurs seuls n'arrivent pas à assurer la régulation de la MAS vu le découplage imparfait. Pour cela, il faut bien vérifier comment utiliser le découplage d'une manière avancée pour assurer la régulation de la MAS.

Le découplage est assuré par les équations suivantes :

$$\begin{cases} u_{sd} = u_{sd1} - \sigma L_s \omega_s I_{sq} - \frac{K}{T_r} \Phi_{rd} - p \Omega K \Phi_{rq} \\ u_{sq} = u_{sq} + \sigma L_s \omega_s I_{sd} - \frac{K}{T_r} \Phi_{rq} + p \Omega K \Phi_{rd} \end{cases} \quad (\text{II.17})$$

Les signaux u_{sd1} et u_{sq} sont les sorties des régulateurs PI : R_1 et R_2 .

Ces deux formules sont remplacées par :

$$\begin{cases} u_{sd} = u_{sd1} - \sigma L_s \omega_s I_{sq} + k_2 + k_1 \Omega \\ u_{sq} = u_{sq1} + \sigma L_s \omega_s I_{sd} + k_4 + k_3 \Omega \end{cases} \quad (\text{II.18})$$

Où k_1 , k_2 , k_3 et k_4 sont des paramètres à ajuster par l'algorithme d'adaptation paramétrique.

Dans le modèle d'état de la MAS, on pose $\dot{\Phi}_{rd} = 0$, $\dot{\Phi}_{rq} = 0$, $I_{sd} = I_{sd}^*$ et $I_{sq} = I_{sq}^*$.

Après des manipulations algébriques, on trouve :

$$I_{sd}^* = \frac{T_r}{M} p \Phi_{rq} \Omega + \frac{1}{M} \Phi_{rd} - \omega_s \frac{T_r}{M} \Phi_{rq} \quad (\text{II.19})$$

$$I_{sq}^* = \frac{T_r}{M} p \Phi_{rd} \Omega + \frac{1}{M} \Phi_{rq} - \omega_s \frac{T_r}{M} \Phi_{rd} \quad (\text{II.20})$$

Ces équations seront remplacées par :

$$\begin{cases} I_{sd}^* = k_5 \Omega + k_6 \\ I_{sq}^* = k_7 \Omega + k_8 \end{cases} \quad (\text{II.21})$$

avec k_5, k_6, k_7, k_8 des paramètres déterminés par des algorithmes d'adaptation.

De plus, le couple électromagnétique doit suivre un certain couple désiré C_{em}^* donné par l'expression suivante :

$$C_e^* = \tau + k_9 + k_{10}(\Omega^* - \Omega) \quad (\text{II.22})$$

Avec τ la sortie du régulateur PID et k_9, k_{10} des paramètres déterminés par des algorithmes d'adaptation.

Le critère de performance utilisé est le critère quadratique suivant :

$$J = \frac{1}{2} (\lambda_\Omega e_\Omega^2 + \lambda_{C_{em}} e_{C_{em}}^2 + \lambda_u u^2) \quad (\text{II.23})$$

Ce critère utilise les données instantanées. En fait, le critère sera écrit sous la forme suivante :

$$J = J_\Omega + J_{C_{em}} + J_u \quad (\text{II.24})$$

avec

$$J_\Omega = \frac{1}{2} \lambda_\Omega e_\Omega^2 = \frac{1}{2} \lambda_\Omega (\Omega^* - \Omega)^2 \quad (\text{II.25})$$

$$J_{C_{em}} = \frac{1}{2} \lambda_{C_{em}} e_{C_{em}}^2 = \frac{1}{2} \lambda_{C_{em}} (C_{em}^* - C_{em})^2 \quad (\text{II.26})$$

$$J_u = \frac{1}{2} \lambda_u u^2 = \frac{1}{2} \lambda_u (u_{sd}^2 + u_{sq}^2) \quad (\text{II.27})$$

L'utilisation de la méthode du gradient conduit à

$$\dot{k}_1 = -\eta_1 \frac{\partial J}{\partial k_1} = -\eta_1 \frac{\partial J_u}{\partial k_1} \quad (\text{II.28})$$

$$\dot{k}_2 = -\eta_2 \frac{\partial J}{\partial k_2} = -\eta_2 \frac{\partial J_u}{\partial k_2} \quad (\text{II.29})$$

$$\dot{k}_3 = -\eta_3 \frac{\partial J}{\partial k_3} = -\eta_3 \frac{\partial J_u}{\partial k_3} \quad (\text{II.30})$$

$$\dot{k}_4 = -\eta_4 \frac{\partial J}{\partial k_4} = -\eta_4 \frac{\partial J_u}{\partial k_4} \quad (\text{II.31})$$

$$\dot{k}_5 = -\eta_5 \frac{\partial J}{\partial k_5} = -\eta_5 \frac{\partial J_{cem}}{\partial k_5} \quad (\text{II.32})$$

$$\dot{k}_6 = -\eta_6 \frac{\partial J}{\partial k_6} = -\eta_6 \frac{\partial J_{cem}}{\partial k_6} \quad (\text{II.33})$$

$$\dot{k}_7 = -\eta_7 \frac{\partial J}{\partial k_7} = -\eta_5 \frac{\partial J_{cem}}{\partial k_7} \quad (\text{II.34})$$

$$\dot{k}_8 = -\eta_8 \frac{\partial J}{\partial k_8} = -\eta_8 \frac{\partial J_{cem}}{\partial k_8} \quad (\text{II.35})$$

$$\dot{k}_9 = -\eta_9 \frac{\partial J}{\partial k_9} = -\eta_9 \frac{\partial J_\Omega}{\partial k_9} \quad (\text{II.36})$$

$$\dot{k}_{10} = -\eta_{10} \frac{\partial J}{\partial k_{10}} = -\eta_{10} \frac{\partial J_\Omega}{\partial k_{10}} \quad (\text{II.37})$$

En imposant : $k_2 = 0$, $k_4 = 0$, $k_7 = 0$, $k_8 = 0$ et $k_{10} = 0$, il nous reste à ajuster seulement k_1 , k_3 , k_5 , k_6 et k_9 . L'algorithme du gradient conduit à :

$$\dot{k}_1 = -\eta_1 u_{sd} (\Omega^* - \Omega) \quad (\text{II.38})$$

$$\dot{k}_3 = -\eta_3 u_{sq} (\Omega^* - \Omega) \quad (\text{II.39})$$

$$\dot{k}_5 = -\eta_5 (C_{em}^* - C_{em}) \Omega \quad (\text{II.40})$$

$$\dot{k}_6 = -\eta_6 (C_{em}^* - C_{em}) \quad (\text{II.41})$$

$$\dot{k}_9 = -\text{sign}(A) \sqrt{|A|} \quad (\text{II.42})$$

$$A = -\eta_9 (\Omega - \Omega^*) \Omega \quad (\text{II.43})$$

De plus, le choix de $k_7 = 0$ et $k_8 = 0$ est pris pour avoir $I_{sq}^* = 0$ (orientation de flux). Nous avons aussi testé le cas où $k_5 = k_6 = 0$, au lieu de $k_7 = 0$ et $k_8 = 0$ (ce qui conduit à $I_{sd}^* = 0$), et nous avons eu des résultats similaires.

La structure globale de la commande est représentée par la figure suivante :




Figure II.3 : Schéma de la commande adaptative optimale appliquée à la MAS.

La simulation donne les résultats présentés dans les figures II.4 et II.5 qui suivent :

La bonne poursuite de la consigne avec un léger dépassement inférieur à 1% est assurée par l'adaptation des paramètres k_1 , k_3 , k_5 , k_6 et k_9 dont l'évolution temporelle est donnée dans la figure II.5.

Le courant i_{qs} suit la consigne imposée, $i_{qs}^* = 0 A$, par le fait que k_7 et k_8 sont nuls. Mais, il y a des oscillations très rapides à cause de la méthode du gradient utilisée qui est très sensible aux petites variations vu la présence des dérivées dans le calcul du gradient.

Le courant i_{ds} suit bien la consigne générée en utilisant la formule (II.21) où les paramètres k_5 et k_6 jouent un rôle très important.

Le couple électromagnétique généré suit le couple de consigne de la formule (II.22) qui est la somme de la sortie du régulateur PID et d'autres termes liés aux paramètres k_9 et k_{10} .

En fait le régulateur PID n'assure que la régulation du système linéaire dont la sortie est la vitesse sans tenir compte des effets des autres parties sur ce sous-système. Le paramètre k_9 a pour rôle d'ajouter une valeur ajustable au gain proportionnel du PID et le paramètre k_{10} est un

offset rajouté pour bien compenser les effets de l’inertie et la charge mécanique et ce pour arriver à un bon comportement transitoire et une bonne régulation. Donc, ensemble, ils forment un régulateur PID adaptatif avec offset ajustable en ligne.

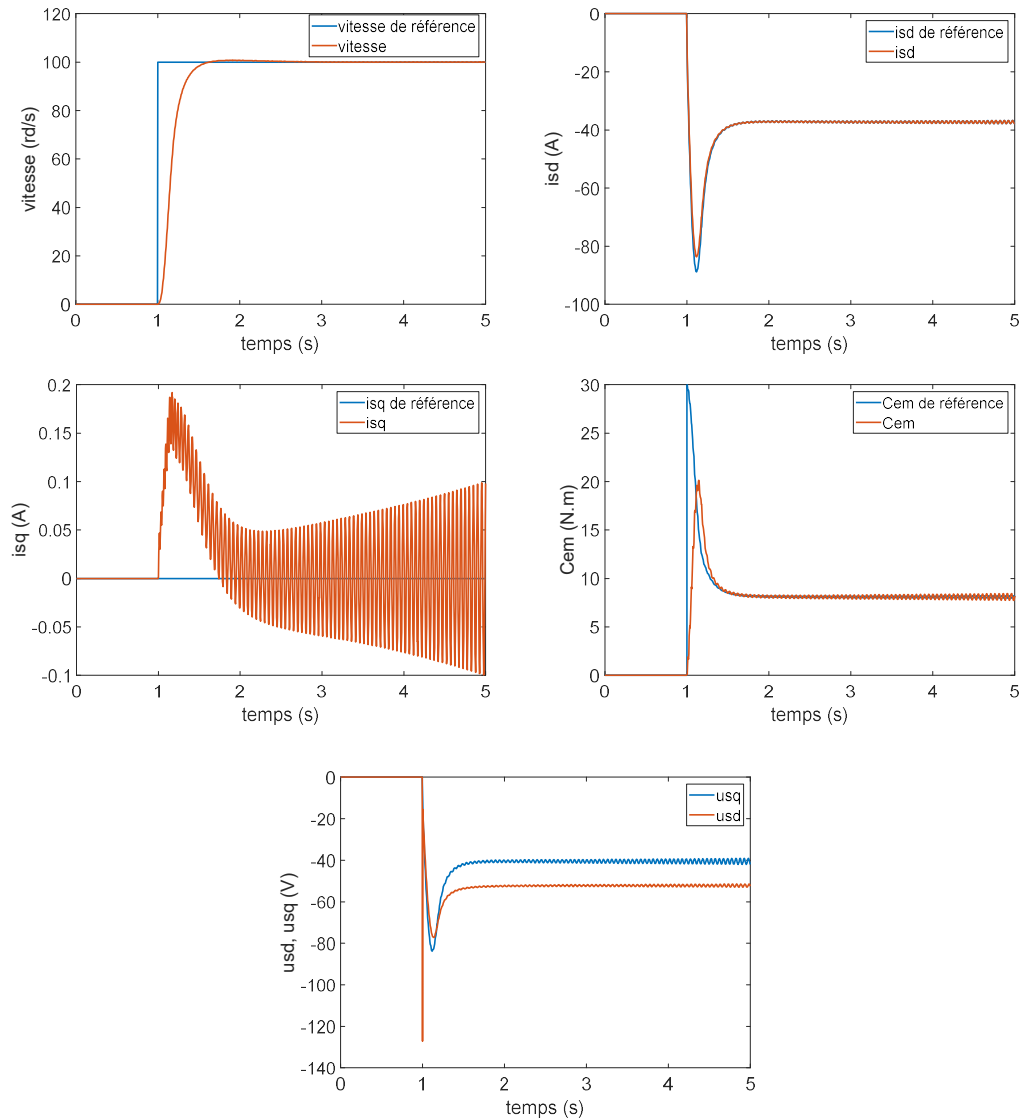


Figure II.4 : Application de la commande adaptative optimale basée sur la méthode du gradient à la MAS.

De plus, les tensions uds et uqs présentent quelques oscillations et ce toujours à cause de la méthode du gradient utilisée.

Dans la suite du travail, la méthode du gradient sera présentée par un système flou dont l’objectif est d’améliorer les performances et d’éliminer ces oscillations.

Dans la figure II.5, sont visualisées les évolutions des paramètres k_1 , k_3 , k_5 , k_6 et k_9 . Ces paramètres se comportent d’une manière adéquate sans oscillations ou changement rapide et ce

par le fait qu'ils sont obtenus après une intégration qui rajoute une petite lenteur dans le comportement de ces paramètres.

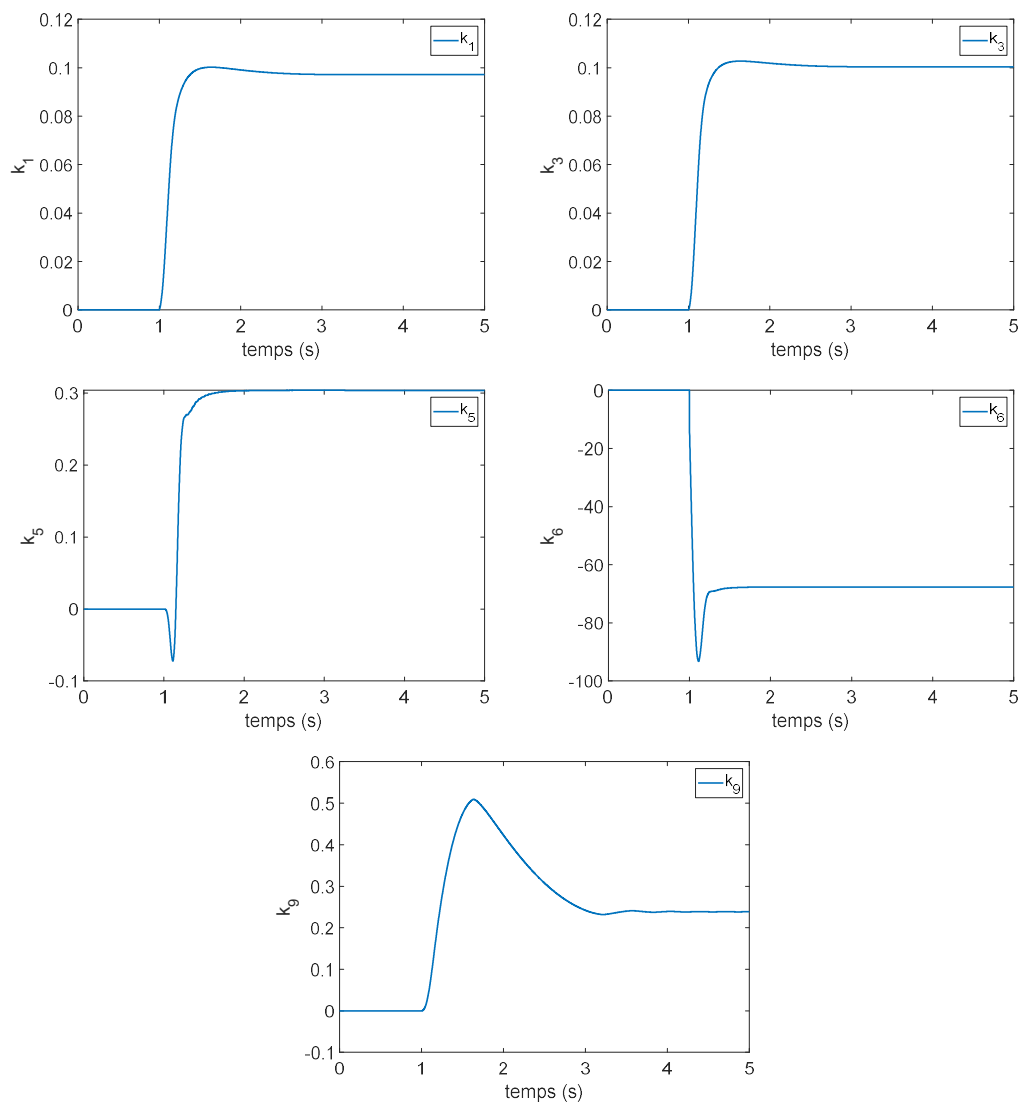


Figure II.5 : Application de la commande à la MAS : évolution des paramètres k_i , $i = 1, 3, 5, 6$ et 9 .

II.3 Commande adaptative optimale basée sur la logique floue appliquée à la MAS

Le passage vers la logique floue est pour remédier aux problèmes liés à la méthode du gradient. La méthode du gradient se base sur le calcul des dérivées ce qui amplifie les effets du bruit et ainsi conduit au risque d'instabilité ou de l'apparition des oscillations rapides néfastes au déroulement de la régulation. En fait, l'algorithme du gradient est très sensible à la présence du bruit.

Le passage vers le flou est réalisé étape par étape. Dans la première étape, nous avons remplacé l'algorithme du gradient par un système flou de type de Sugeno. Dans la deuxième étape, un superviseur flou est utilisé pour remédier au problème du fonctionnement différent de la MAS aux petites et aux grandes vitesses.

II.3.1 Première étape

Dans ce qui suit, nous avons pris : $k_2 = 0$, $k_4 = 0$, $k_5 = 0$, $k_6 = 0$ et $k_{10} = 0.07$. Il reste à déterminer les paramètres k_1 , k_3 , k_7 , k_8 et k_9 .

Ces paramètres sont ajustés par des systèmes flous de type de Sugeno (un système flou pour chaque paramètre). En fait, les systèmes flous sont identiques car ils représentent l'algorithme du gradient sous forme d'un système flou.

Chaque système flou a deux entrées qui dépendent des paramètres k_i $i = 1, 3, 7, 8$ et 9 .

Ces systèmes flous sont d'ordre zéro avec vingt-cinq règles qui prennent la forme suivante :

$$\text{Si entrée}_1 \text{ est } F_{1,i} \text{ ET entrée}_2 \text{ est } F_{2,i} \text{ ALORS } dk = a_i$$

Les sorties de ces systèmes flous sont données par la relation suivante :

$$dk = \frac{\sum_{i=1}^{25} \mu_i a_i}{\sum_{i=1}^{25} \mu_i} \quad (\text{II.44})$$

avec

$$\mu_i = \prod_{j=1}^2 \mu_{F_{j,i}} , \quad i = 1, \dots, 25 \quad (\text{II.45})$$

Les sous-ensembles flous des variables d'entrées sont définis comme suit : **NG : Négatif Grand**, **NM: Négatif Moyen**, **Z : Zéro**, **PM : Positif Moyen** et **PG : Positif Grand**.

Les fonctions d'appartenances pour les entrées sont données par la Figure (IV.5) :




Figure II.6 : Fonctions d'appartenance.

La table des règles floues pour calculer les incréments des paramètres dk_i , $i = 1, 3, 7, 8$ et 9 est présentée au tableau suivant :

Tableau II.1 : Table des règles du système flou

dk_i		Entrée 1				
		NG	NM	Z	PM	PG
Entrée 2	NG	f_1	f_2	f_3	f_4	f_5
	NM	f_2	f_2	f_3	f_4	f_4
	Z	f_3	f_3	f_3	f_3	f_3
	PM	f_4	f_4	f_3	f_2	f_2
	PG	f_5	f_4	f_3	f_2	f_1

Les conclusions des règles sont des constantes bien déterminées pour réaliser une multiplication approximative des deux entrées du système flou. Pour des raisons de symétrie, nous pouvons prendre pour conclusions : $f_1 = 1$, $f_2 = 0.25$, $f_3 = 0$, $f_4 = -0.25$ et $f_5 = -1$.

Cette étape est utilisée dans l'optimisation de la commande via les paramètres k_1 et k_3 . En exploitant les formules données précédemment dans la méthode du gradient, le paramètre k_1 est ajusté par un système flou dont les entrées sont u_{sd} et l'erreur de la vitesse. Ce paramètre sert à

optimiser la commande u_{sd} . De même, le paramètre k_3 est ajusté par un système flou dont les entrées sont u_{sq} et l'erreur de la vitesse et sert à optimiser la commande u_{sq} .

Le côté de la commande adaptative est en plus assuré par les paramètres k_7 , k_8 et k_9 . Le paramètre k_7 est ajusté par un système flou dont les entrées sont l'erreur en couple et le produit de la vitesse avec un certain paramètre η_{56} . De même pour le paramètre k_8 , les deux entrées du système flou sont l'erreur en couple et le paramètre η_{56} . Le paramètre η_{56} est obtenu par le superviseur flou présenté dans la suite de cette section. Le paramètre k_9 est ajusté par un système flou dont les entrées sont la vitesse de la sortie et l'erreur de la vitesse.

II.3.2 Deuxième étape

L'ajustement des paramètres k_5 et k_6 dépend fortement du niveau de la vitesse de référence. Un superviseur flou de type de Sugeno génère la valeur du paramètre η_{56} . Ce superviseur utilise comme entrée la vitesse du référence Ω^* .

Les fonctions d'appartenance sont choisies gaussiennes et sont données par l'expression suivante :

$$\mu_i(\Omega^*) = e^{-\left(\frac{\log_{10}(|\Omega^*+0.001|)-\log_{10}(c)}{\sigma}\right)^2}, \quad i = 1, 2, 3 \text{ et } 4 \quad (\text{II.46})$$

Avec $c_1 = 1, c_2 = 50, c_3 = 100, c_4 = 150$ sont les centres et $\sigma = 0.1$ un paramètre d'étalement des fonctions d'appartenance.

La table des règles est donnée par le tableau ci-dessous :

Tableau II.2 : Table des règles du régulateur de η_{56} .

Ω^*	Petite	Moyenne	Grande	Très Grande
η_{56}	$\frac{0.01+\Omega^*}{0.01+\Omega^{*2}}$	$5 * \frac{0.01+\Omega^*}{0.01+\Omega^{*2}}$	$10 * \frac{0.01+\Omega^*}{0.01+\Omega^{*2}}$	$15 * \frac{0.01+\Omega^*}{0.01+\Omega^{*2}}$

La figure ci-après présente le schéma complet de cette approche de commande appliquée à la MAS.

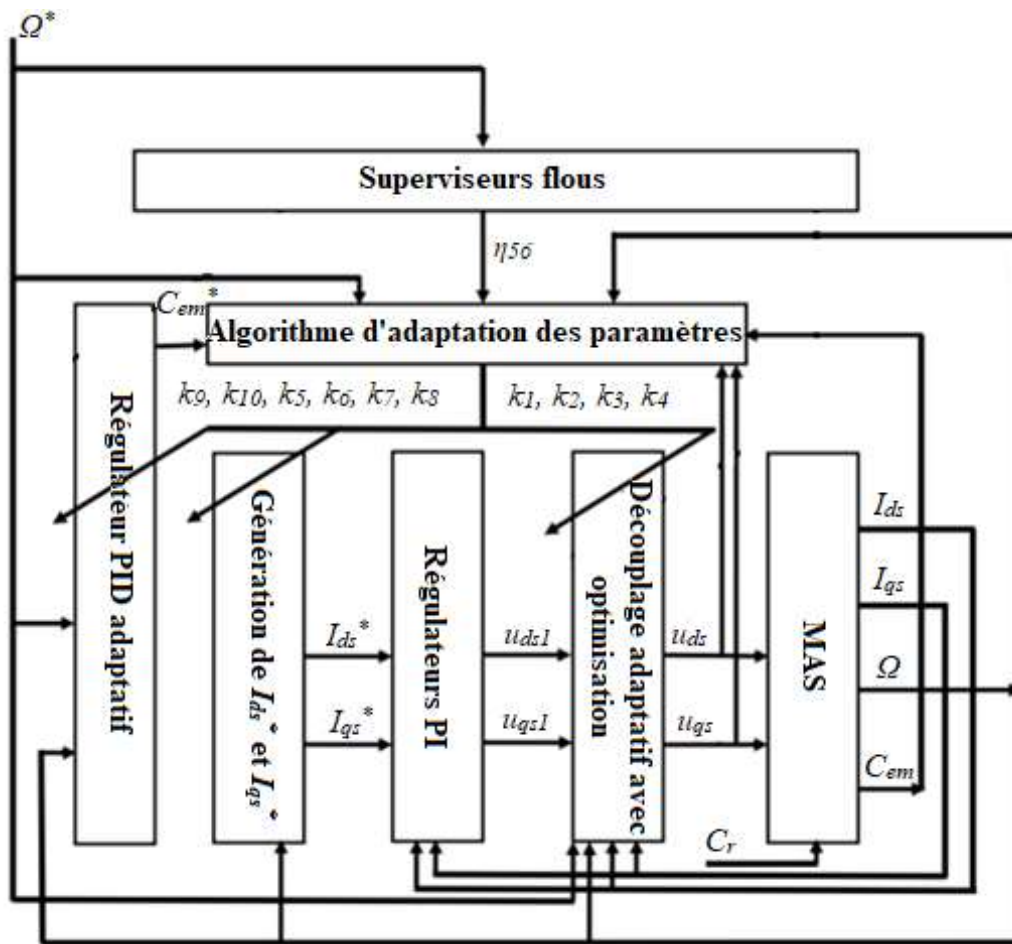


Figure II.7 : Schéma de la commande adaptative optimale appliquée à la MAS.

Les résultats de simulation de l'application de cette technique de commande sont donnés dans les figures II.8 et II.9.

La machine étant à l'arrêt, un échelon de consigne de vitesse est appliqué à l'instant $t=1s$. Nous pouvons voir le comportement dynamique de la machine où la vitesse s'approche de la vitesse de référence avec un léger dépassement (inférieur à 1%). Le temps de montée est de l'ordre de 0.2 seconde. De même pour le courant isd qui revient à 0 A (la consigne) après une descente légère suivie d'une montée rapide jusqu'à environ 1.4 A. ce courant présente quelques oscillations de faibles amplitudes atténuées rapidement.

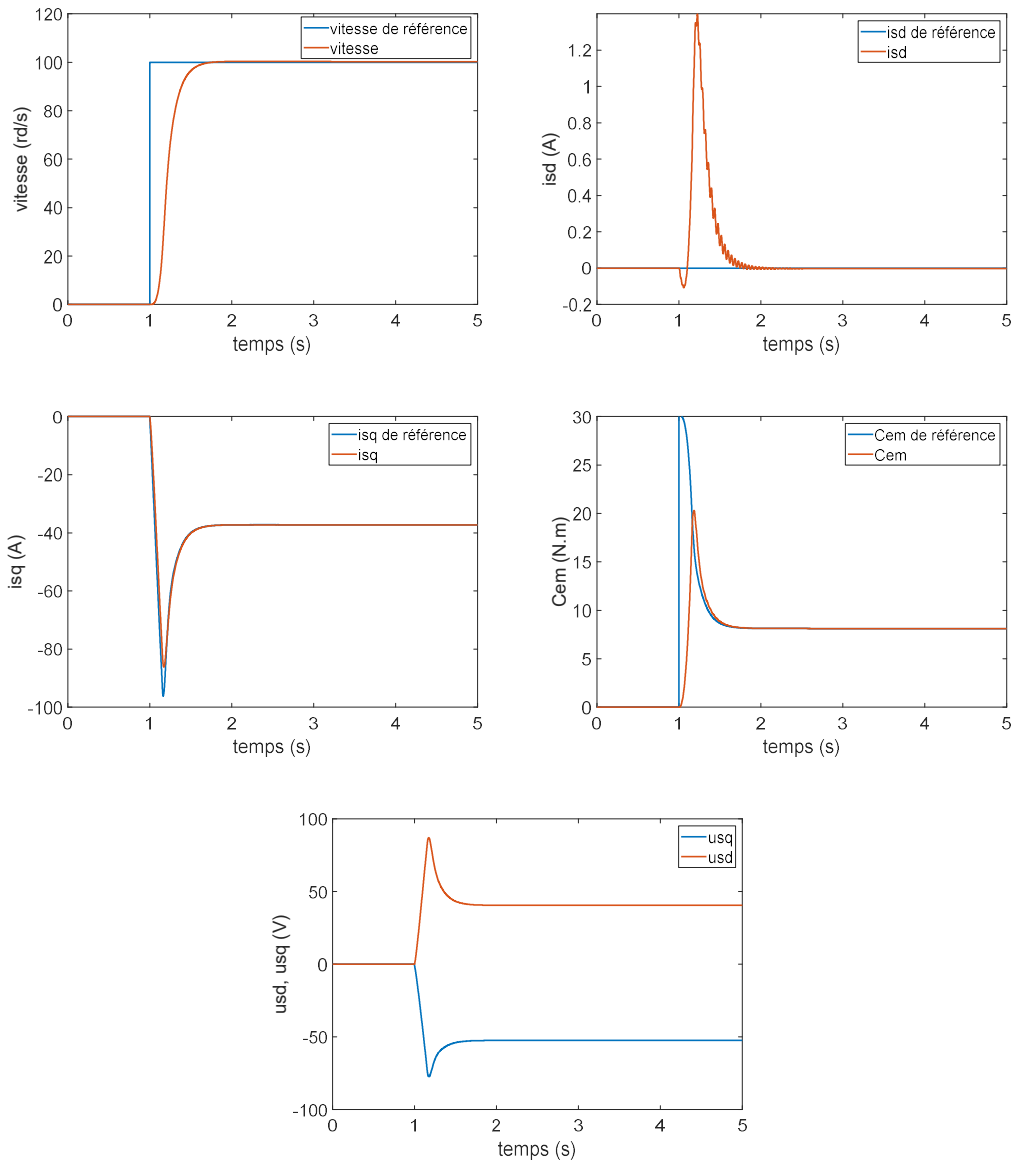


Figure II.8 : Application de la commande adaptative optimale basée sur la logique floue à la MAS.

Dans la figure II.9, l'évolution des paramètres en fonction du temps est présentée. Ces paramètres changent en continue et se stabilisent autour de leurs valeurs finales sans oscillations.

C'est ce changement qui assure la régulation, car les régulateurs PI et PID n'arrivent pas seuls à stabiliser la machine à cause des interconnexions (couplages) entre les trois sous-systèmes.

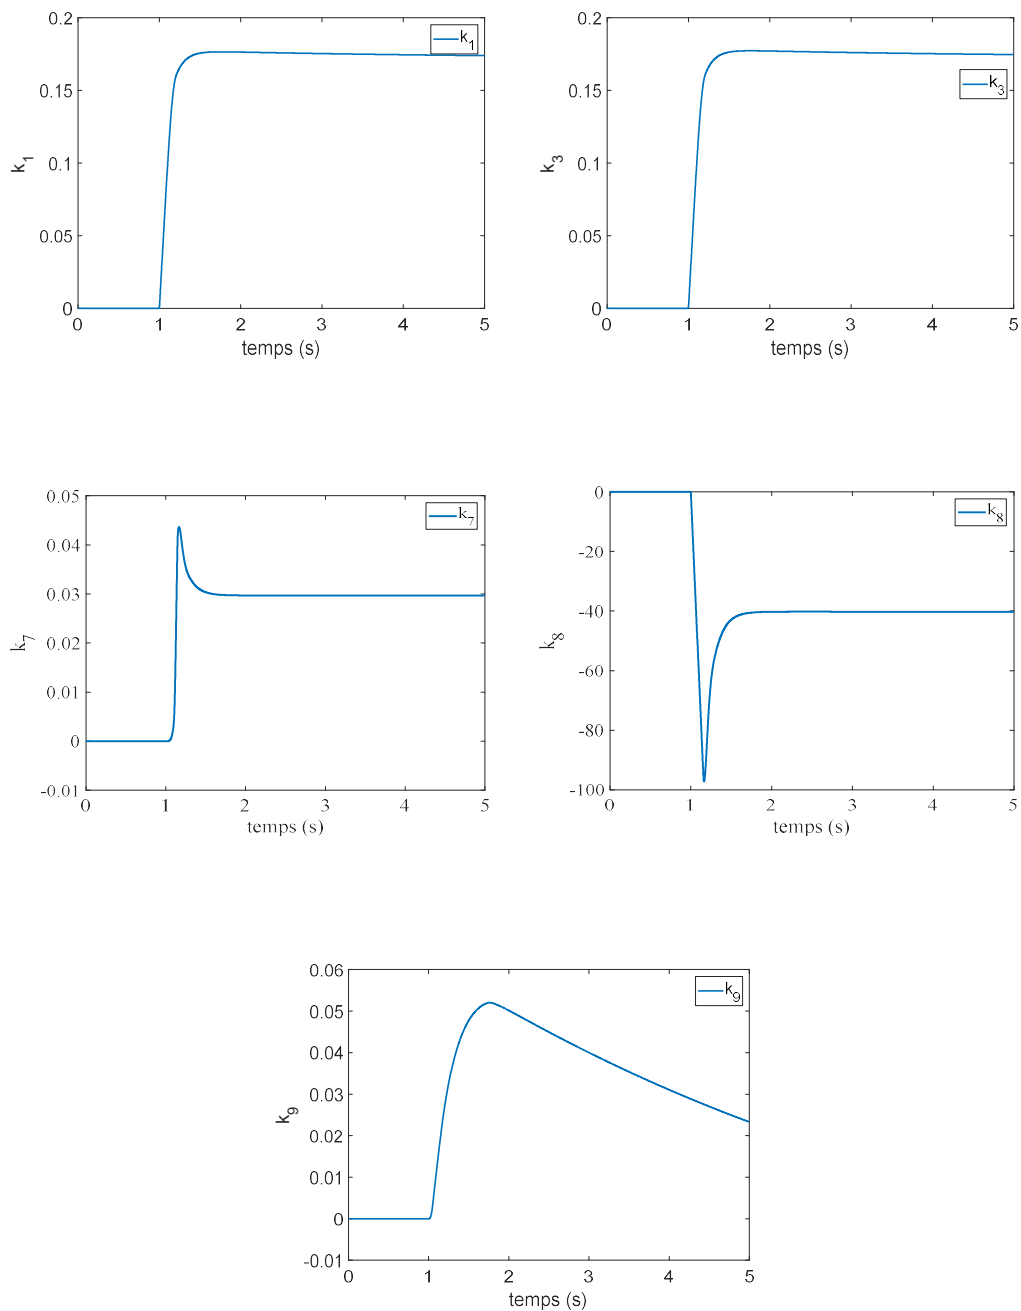


Figure II.9 : Application de la commande à la MAS : évolution des paramètres k_i , $i = 1, 3, 7, 8$ et 9 .

La simulation de la commande de l'association onduleur-MAS est présentée par les figures II.10 et II.11 ci-après. C'est à peu près le même comportement que sans onduleur du côté vitesse de sortie mais pour les courants i_{ds} , i_{qs} , le couple électromagnétique C_{em} et les tensions u_{ds} et u_{qs} , nous voyons l'apparition des oscillations rapides qui sont souvent associées à la présence des onduleurs.

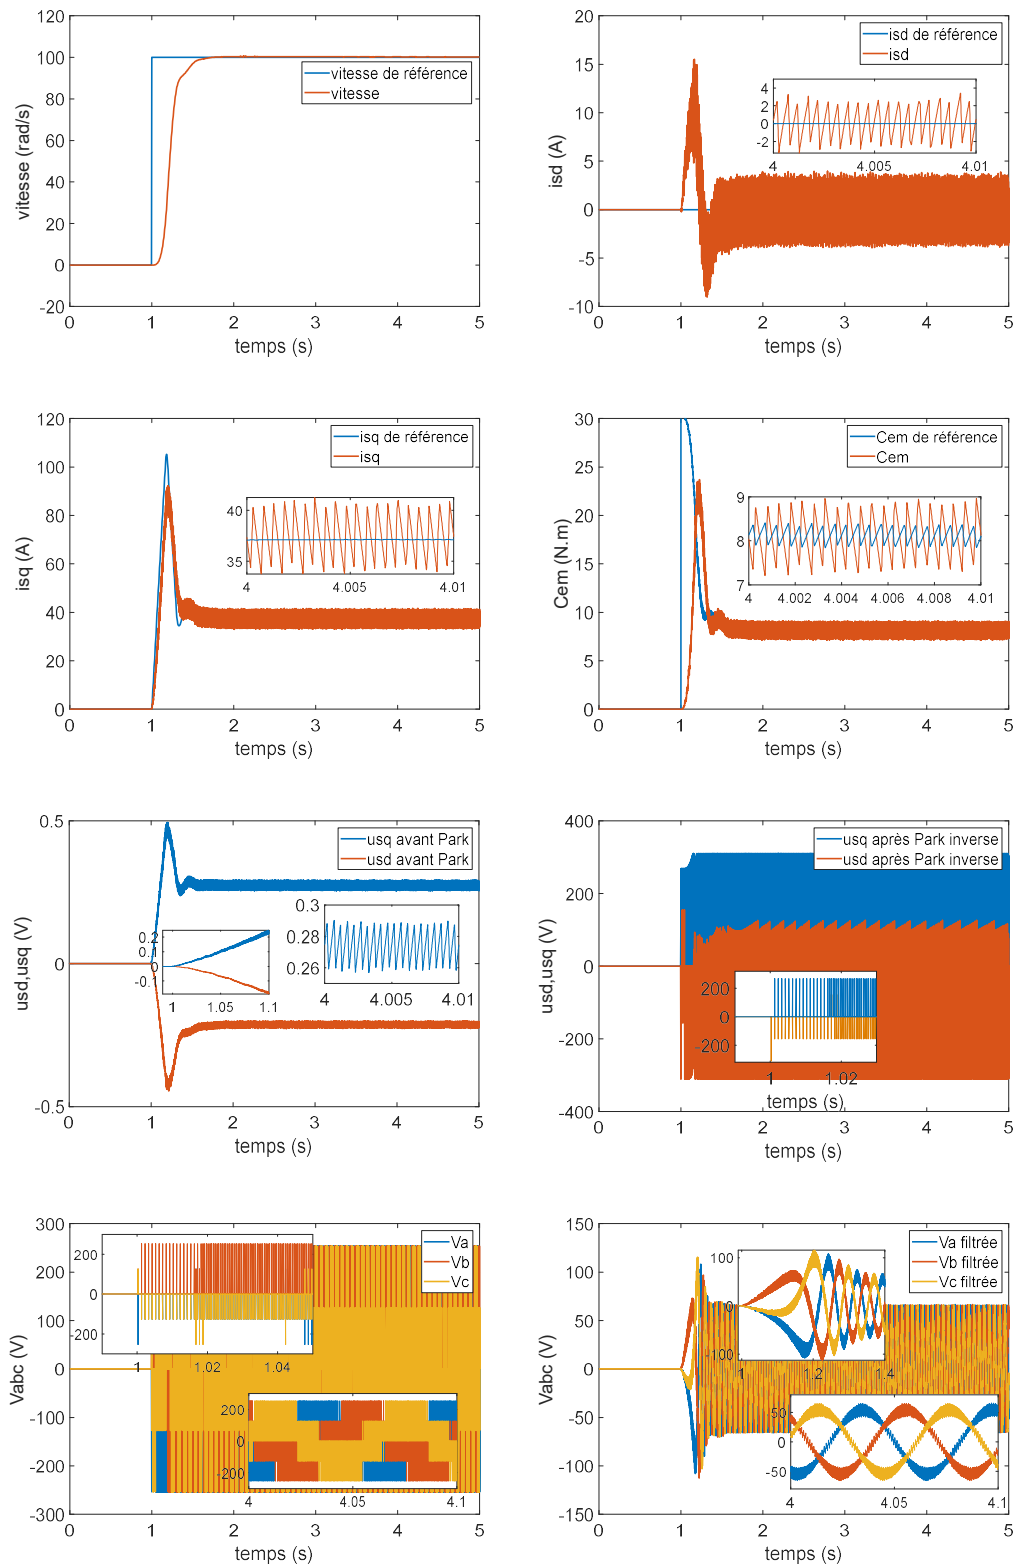


Figure II.10 : Application de la commande adaptative optimale basée sur la logique floue à l'association onduleur-MAS.

Pour l'évolution des paramètres k_i , $i = 1, 3, 7, 8$ et 9 , la convergence est bien claire. Les paramètres k_7 et k_8 sont utilisés au lieu de k_5 et k_6 ce qui induit que le courant de référence pour i_{ds} est nul ($i_{ds}^* = 0 A$).

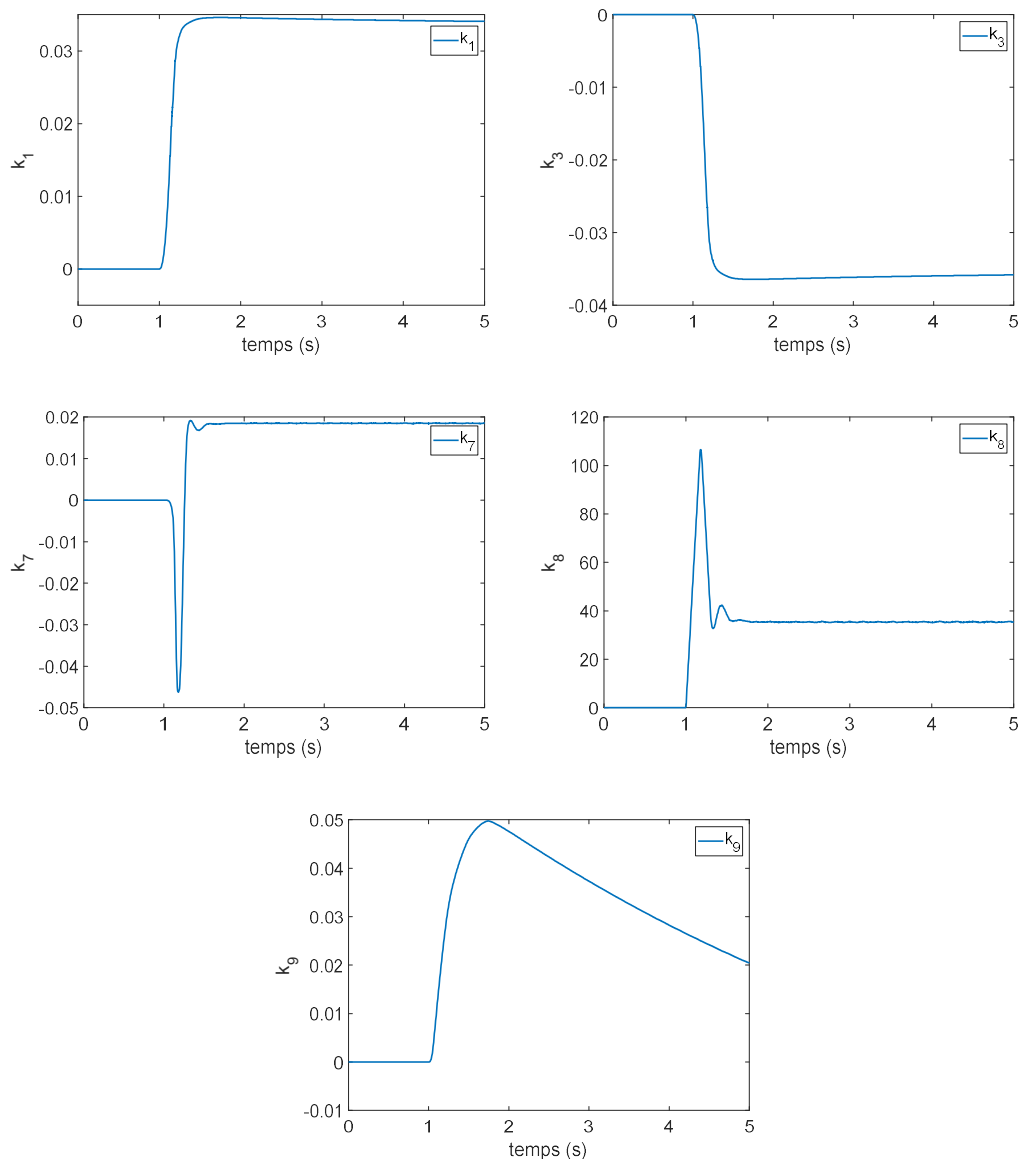


Figure II.11 : Application de la commande à l'association onduleur-MAS : évolution des paramètres k_i , $i = 1, 3, 7, 8$ et 9 .

II.4 Commande adaptative optimale basée sur la logique floue appliquée à la MSAP

La même approche a été utilisée pour la commande d'une MSAP. La même démarche de dimensionnement a été suivie. En fait, sans aucun changement dans le régulateur, sauf pour les formules concernant le découplage, la régulation de la MSAP a été obtenue avec de bonnes performances.

Le modèle du MSAP est donné comme suit :

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds} - Ri_{ds} + pL_q w_r i_{qs}}{L_d} \\ \frac{di_{qs}}{dt} = \frac{u_{qs} - Ri_{qs} - p\varphi_m w_r - pL_d w_r i_{ds}}{L_q} \\ \frac{dw}{dt} = \frac{C_{em} - F.w - C_r}{J} \end{cases} \quad (\text{II.47})$$

avec le couple électromagnétique calculé comme suit :

$$C_{em} = \frac{3}{2}p(-L_q i_{ds} i_{qs} + L_d i_{ds} i_{qs} + \varphi_m i_{qs}) \quad (\text{II.48})$$

On pose

$$u_{ds} = u_{ds1} - pL_q w_r i_{qs} \quad (\text{II.49})$$

$$u_{qs} = u_{qs1} + p\varphi_m w_r + pL_d w_r i_{ds} \quad (\text{II.50})$$

Le système se décompose en trois sous-systèmes découplés :

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds1} - Ri_{ds}}{L} \\ \frac{di_{qs}}{dt} = \frac{u_{qs} - Ri_{qs}}{L} \\ \frac{dw}{dt} = \frac{C_{em} - F.w - C_r}{J} \end{cases} \quad (\text{II.51})$$

Vu que les paramètres de la machine changent lors du fonctionnement, les formules (II.49) et (II.50) seront remplacées par les formules suivantes :

$$\begin{cases} u_{sd} = u_{ds1} - pL_q w_r i_{qs} + k_2 + k_1 w_r \\ u_{sq} = u_{qs} + pL_d w_r i_{ds} + k_4 + k_3 w_r \end{cases} \quad (\text{II.52})$$

De même, on propose de prendre les courants de référence i_{ds}^* et i_{qs}^* selon les formules suivantes

$$\begin{cases} i_{ds}^* = k_5 w + k_6 \\ i_{qs}^* = k_7 w + k_8 \end{cases} \quad (\text{II.53})$$

C'est une relation basée sur les paramètres k_5 , k_6 , k_7 et k_8 ajustables en ligne.

Les trois sous-systèmes sont régulés par des PI pour les courants et par un PID pour la vitesse. Ces régulateurs sont fixes et n'assurent que la régulation des sous-systèmes découplés sans rendre compte de la présence des interconnexions. Ces régulateurs seuls n'arrivent pas à commander la machine sans l'adaptation des paramètres utilisés.

Les paramètres seront ajustés par l'utilisation de la méthode du gradient fuzzifiée présentée dans la section précédente et appliquée à la MAS.

Les résultats de simulation de la commande appliquée au moteur synchrone à aimants permanents MSAP sont présentés dans les figures II.12 et II.13. Le comportement obtenu est très satisfaisant vu que la machine suit la consigne en vitesse et en courants. De plus, les paramètres sont bien ajustés et stabilisés sans oscillations.

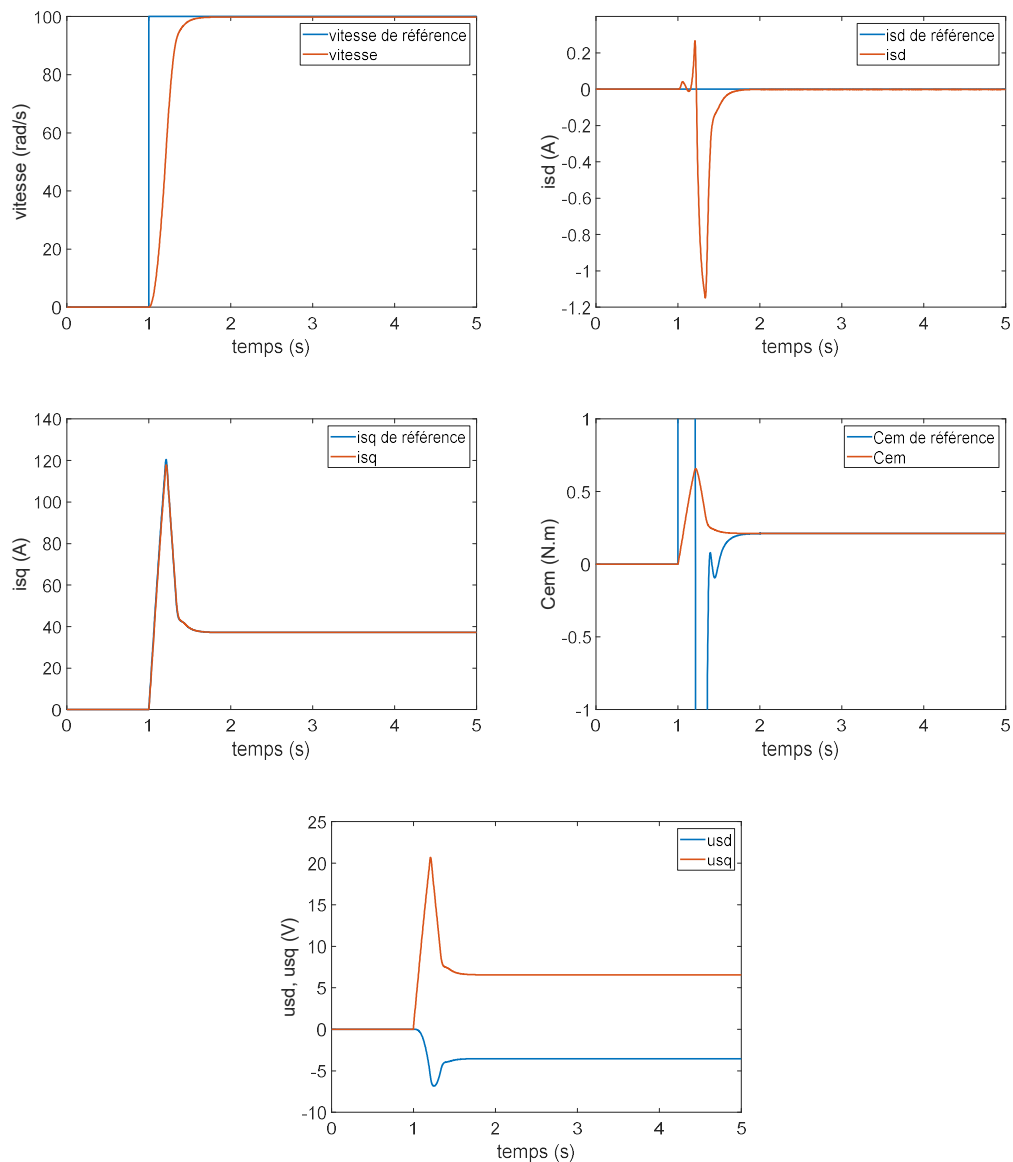


Figure II.12 : Application de la commande adaptative optimale basée sur la logique floue à la MSAP.

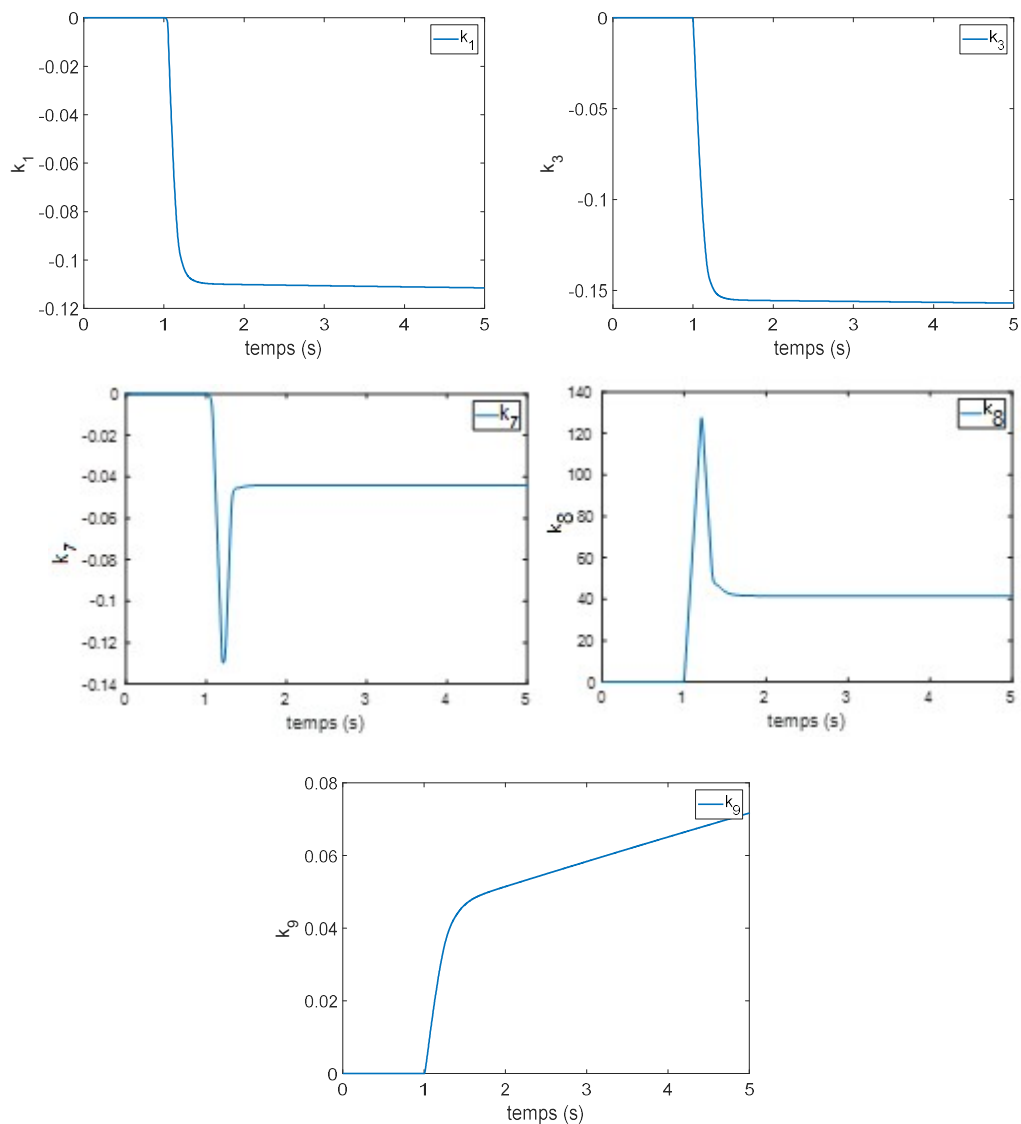


Figure II.13 : Application de la commande à la MSAP : évolution des paramètres k_i , $i = 3, 7, 8$ et 9 .

II.5 Commande adaptative optimale basée sur la logique floue appliquée au MPP

De même, pour l'application dans la commande d'un moteur pas à pas (MPP), la même démarche de dimensionnement a été suivie et sans aucun changement dans le régulateur, sauf pour les formules concernant le découplage, la commande du moteur pas à pas (MPP) a été obtenue avec de bonnes performances.

Le modèle du MPP est donné comme suit :

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds} - Ri_{ds} + N_r w i_{qs}}{L} \\ \frac{di_{qs}}{dt} = \frac{u_{qs} - Ri_{qs} - N_r w i_{ds} - K_m w}{L} \\ \frac{dw}{dt} = \frac{C_{em} - B \cdot w - C_r}{J} \end{cases} \quad (II.54)$$

avec le couple électromagnétique calculé comme suit :

$$C_{em} = K_m i_{qs} \quad (II.55)$$

On pose

$$u_{ds} = u_{ds1} - N_r w i_{qs} \quad (II.56)$$

$$u_{qs} = u_{qs1} + N_r w i_{ds} + K_m w \quad (II.57)$$

Le système se décompose en trois sous-systèmes découplés :

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{u_{ds1} - Ri_{ds}}{L} \\ \frac{di_{qs}}{dt} = \frac{u_{qs1} - Ri_{qs}}{L} \\ \frac{dw}{dt} = \frac{C_{em} - B \cdot w - C_r}{J} \end{cases} \quad (II.58)$$

En fait, ce découplage n'est bien assuré que si on connaît les paramètres de la machine. Vu que les paramètres de la machine changent lors du fonctionnement les formules (II.56) et (II.57) seront remplacées par les formules suivantes :

$$\begin{cases} u_{sd} = u_{sd1} - N_r w i_{qs} + k_2 + k_1 w \\ u_{sq} = u_{sq1} + N_r w i_{ds} + k_4 + k_3 w \end{cases} \quad (II.59)$$

De même, on propose de prendre les courants de référence i_{ds}^* et i_{qs}^* selon les formules suivantes :

$$\begin{cases} i_{ds}^* = k_5 w + k_6 \\ i_{qs}^* = k_7 w + k_8 \end{cases} \quad (II.60)$$

C'est une relation basée sur les paramètres k_5 , k_6 , k_7 et k_8 ajustables en ligne.

Les trois sous-systèmes sont régulés par des PI pour les courants et par un PID pour la vitesse. Comme avant, ces régulateurs fixes n'assurent que la régulation des sous-systèmes découplés sans rendre compte de la présence des interconnexions. Ces régulateurs seuls n'arrivent pas à commander la machine sans l'adaptation des paramètres utilisés.

Les résultats de simulation de la commande appliquée au moteur pas à pas MPP sont présentés dans les figures II.14 et II.15. Le comportement obtenu est très satisfaisant vu que la machine

suit la consigne en vitesse et en courants. De plus, les paramètres sont bien ajustés et stabilisés sans oscillations.

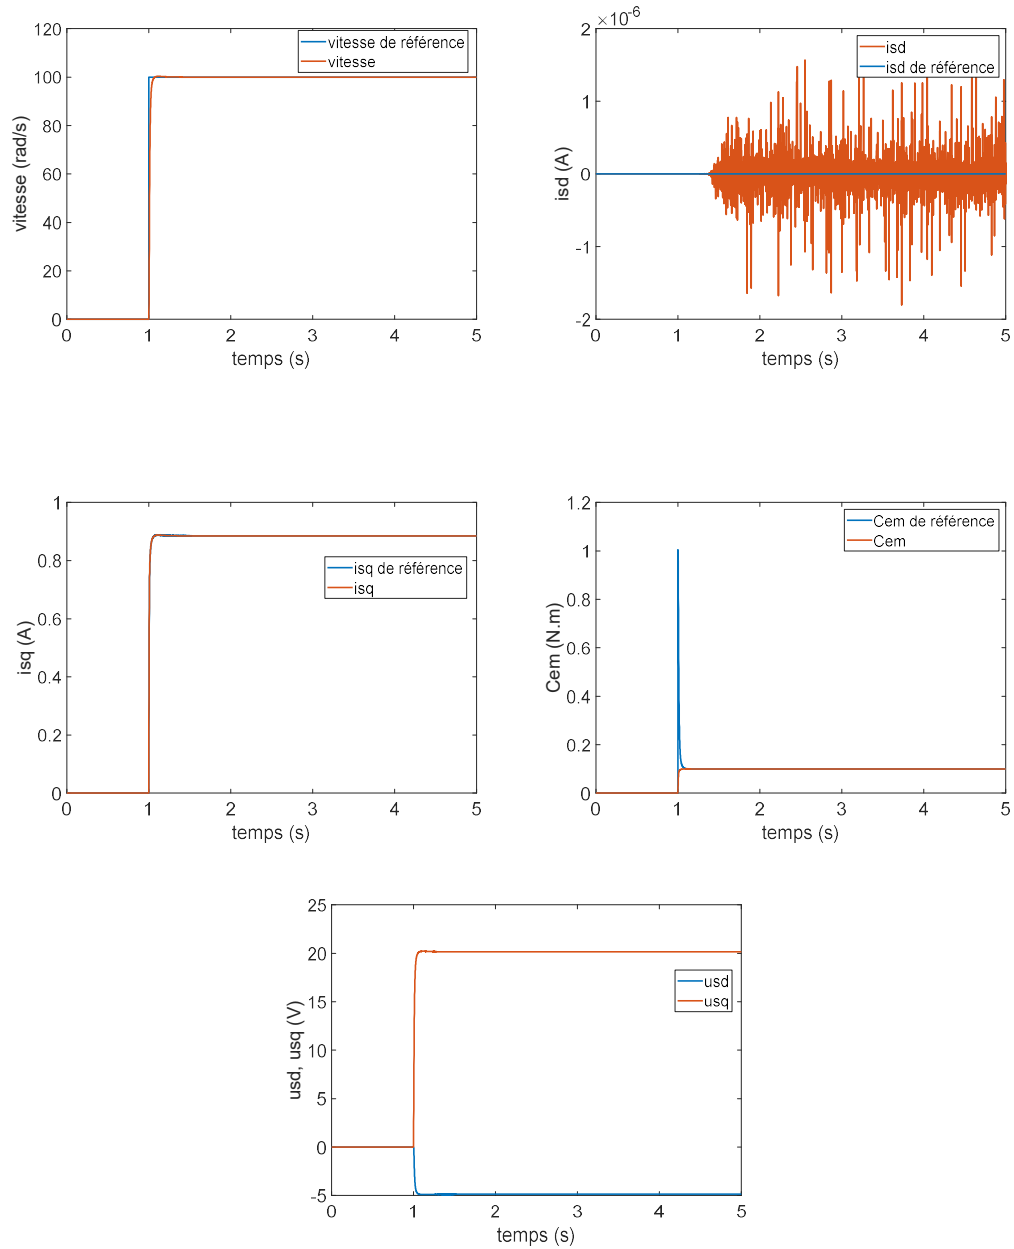


Figure II.14 : Application de la commande adaptative optimale basée sur la logique floue au moteur pas à pas.

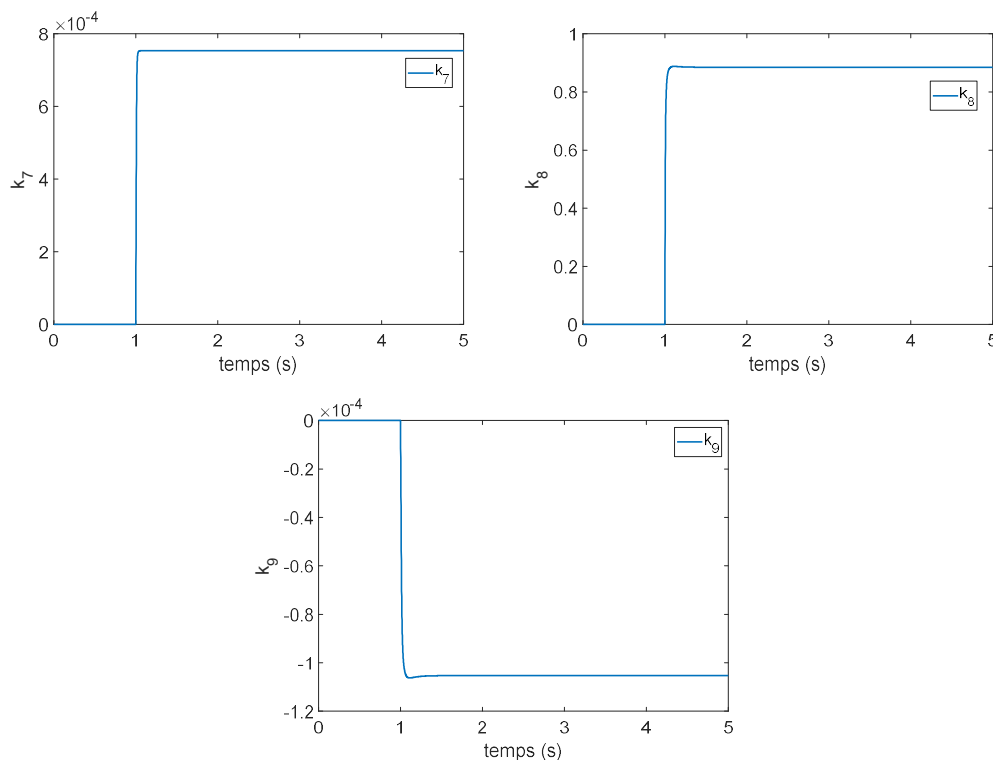


Figure II.15 : Application au moteur pas à pas : évolution des paramètres k_i , $i = 7, 8$ et 9 .

II.6 Commande prédictive basée sur les RNA et l'algorithme ABC appliquée à la MAS

Dans la technique de la commande prédictive, on a besoin d'un modèle de prédiction qui sert, à chaque pas d'échantillonnage, à prédire les sorties futures du système dans un horizon dit horizon de prédiction. Cette prédiction est utilisée dans l'optimisation de la commande ou l'incrément de la commande à appliquer au système sous contrôle. Le critère utilisé dans l'optimisation est lié à l'erreur des sorties : vitesse et courants en plus des signaux de commande.

Les méthodes utilisées pour l'optimisation dans le calcul de la commande ou l'incrément de la commande peuvent varier des moindres carrés récurrents ou non aux méthodes intelligentes.

Dans ce qui suit, on présente une commande prédictive dont le modèle de prédiction est un réseau de neurones artificiels de dimension adéquate (faible nombre de neurones et de couches) et l'optimisation sera basée sur l'algorithme « Artificial Bee Colonies ».

Le choix d'utiliser un réseau de neurones artificiels est pris pour leur capacité dans l'approximation des fonctions. En fait, les réseaux de neurones artificiels sont des approximateurs universels.

Le réseau de neurones utilisé est adéquatement dimensionné pour pouvoir l'entraîner à chaque pas d'échantillonnage et cet apprentissage doit se faire dans une période d'échantillonnage.

Les données utilisées doivent être consistantes et réduites en taille. Pour cela, on utilise les données précédentes récentes concernant le comportement du système. Avec la capacité du réseau de neurones artificiels à faire la généralisation, l'extrapolation et la réduction de l'effet du bruit, le réseau est utilisé pour prédire le comportement du système dans un futur proche.

Le réseau de neurones utilisé a pour modèle :

$$O_k = \sum_{l=1}^L w_{kl}^2 f_l \left(\sum_{p=1}^P w_{lp}^1 I_p \right) \quad (61)$$

où

I, O : les entrées/sorties du réseau de neurones

w : les poids selon les neurones et les couches

L'étape d'optimisation (minimisation) est assurée par l'algorithme ABC qui est une méthode inspirée de la nature concernant le comportement des abeilles dans leurs colonies pour la recherche de la nourriture. Dans ce comportement, on distingue : les ouvrières, les éclaireuses et les observatrices. Les ouvrières ont une source de nourriture commune avec les autres selon une certaine probabilité. Les éclaireuses cherchent de nouvelles sources de nourriture. Les observatrices échangent les informations avec les ouvrières concernant les sources de nourriture (déjà trouvées et localisées par les éclaireuses).

Ce comportement est copié ici pour la minimisation du critère afin de donner la commande ou l'incrément de la commande adéquats (optimaux ou proches).

La position de l'abeille, dont le numéro est i , à l'itération t est donnée par :

$$X_{i,d}(t) = L_d + r \cdot (U_d - L_d) \quad (62)$$

où

$X_{i,d}$: la position de l'abeille numéro i

$[L_d, U_d]$: intervalle de recherche

r : nombre aléatoire entre 0 et 1

d : la dimension (de l'espace de recherche, nombre de paramètres ou de valeurs à trouver).

Les ouvrières mettent à jour leurs positions selon la formule ci-après :

$$v_{i,d}(t + 1) = x_{i,d}(t) + \varphi \cdot (x_{i,d}(t) - x_{j,d}(t))$$

Le paramètre φ est aléatoire uniformément distribué dans l'intervalle [0,1]. La vitesse $v_{i,d}$ est à rajouter à la position $x_{i,d}$ pour avancer dans la recherche. Les indices i et j appartiennent à $\{1, \dots, M\}$ avec M la taille de la colonie.

Les observatrices vont choisir les sources de nourriture selon leurs qualités présentées sous forme d'une probabilité calculée comme suit :

$$P_i = \frac{f_i}{\sum_{j=1}^N f_j} \tag{II.63}$$

$$f_i = \begin{cases} \frac{1}{1+f(i)}, & \text{pour } f(i) \geq 0 \\ 1 + |f(i)|, & \text{pour } f(i) < 0 \end{cases} \tag{II.64}$$

f_i est le fitness pour la source n° i , $f(i)$ est une évaluation de la qualité et de la quantité de la source n° i et p_i la probabilité associée.

La figure suivante présente un schéma de l'application de cette méthode à la MAS. On voit bien trois parties. Dans la première, c'est l'apprentissage du réseau de neurones. En fait, chaque abeille a un réseau de neurone avec ses poids. Donc, chaque abeille doit trouver une commande ou incrément de commande selon son réseau de neurones. L'algorithme ABC complète la recherche en choisissant la meilleure valeur, pour l'instant, à appliquer la MAS.

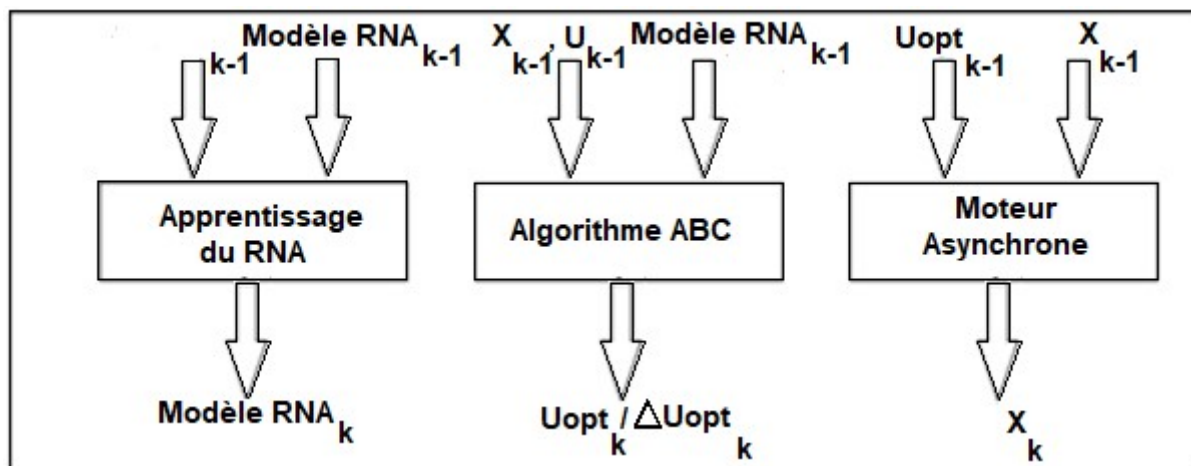


Figure II.16 : Commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC.

La figure II.17 illustre ce fait, on voit bien que chaque abeille adapte son réseau de neurones et applique une commande (la meilleure) au modèle sous forme de réseau de neurones et évalue

le coût (la valeur du critère). A la fin, l'optimisation est terminée par le choix de la meilleure valeur parmi celles proposées par les abeilles. C'est cette dernière qui sera appliquée à la machine.

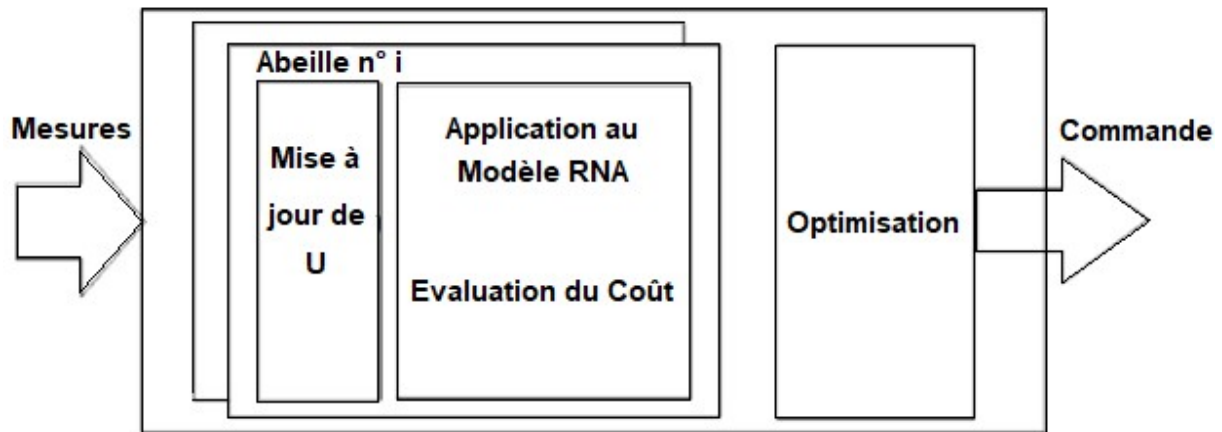


Figure II.17 : Algorithme ABC pour l'optimisation.

L'objectif de cette commande est d'assurer la poursuite des consignes dans le repère d-q. le critère minimise les erreurs entre les courants statoriques et leurs signaux de références respectifs ainsi que l'erreur en vitesse. L'optimisation conduit aux signaux de commande adéquats.

La figure II.18 présente les résultats de simulation de l'application de cette technique de commande. On voit bien beaucoup d'oscillations sur les signaux de commande et ceci est dû au fait qu'on a choisi un nombre faible d'abeilles et de neurones dans les réseaux de neurones artificiels.

De plus, on voit bien la poursuite de la consigne de vitesse. Au début, les réseaux de neurones n'avaient aucune connaissance sur le système sous contrôle, mais avec l'apprentissage, les réseaux s'acquièrent les connaissances nécessaires pour assurer la bonne modélisation de la MAS.

Cette technique de commande est prometteuse mais elle est gourmande en ressources de calcul. Il vaut mieux utiliser le calcul parallèle ou les FPGA pour l'implémenter.




Figure II.18 : Application de la commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC à la MAS.

II.7 Conclusion

Dans ce chapitre, nous avons appliqué différentes techniques de commande aux machines électriques. Nous avons commencé par la commande adaptative optimale basée sur la méthode du gradient appliquée à la MAS. Cette technique a montré son efficacité dans la poursuite de consignes avec de bonnes performances. Mais cette technique présentait des oscillations vu la sensibilité de la méthode du gradient aux bruits et aux changements rapides de différents signaux.

Cette lacune a été éliminée par l'utilisation de la logique floue au lieu de l'algorithme du gradient. En fait, la logique floue a permis de fuzzifier la méthode du gradient et ainsi enlever la sensibilité aux bruits et au changement rapide des signaux. La validité de cette dernière approche a été vérifiée par simulation en l'appliquant à la MAS et à l'association onduleur-MAS.

A cause des bonnes performances de la dernière technique, elle a été appliquée à la MSAP et au MPP sans grand changement sauf pour les parties concernant les interconnexions entre les différents sous-systèmes.

Ensuite, une technique de commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC a été appliquée à la MAS. Les performances sont prometteuses mais l'implémentation doit être faite en utilisant le calcul parallèle ou des FPGA.

Chapitre III

Techniques de commande intelligentes appliquées aux robots

III.1 Introduction

Dans ce chapitre, nous allons présenter différentes techniques de commande intelligentes appliquées aux robots utilisés dans la cartographie du potentiel de surface. Nous commençons par l'exploitation des résultats obtenus dans le chapitre précédent concernant la commande adaptative optimale basée sur la logique floue appliquée à la MSAP et au MPP. Ensuite, des techniques de commande prédictive guidée par les données ou basées sur les réseaux de neurones artificiels et le PSO seront présentées et appliquées au robot SCARA. La suite concerne la commande floue appliquée à un robot Delta dont le MGD et le MGI sont donnés par des réseaux de neurones artificiels. Cette dernière technique de commande sera améliorée par le passage vers le neuro-flou, ainsi un régulateur neuro-flou adaptatif sera utilisé pour la commande du robot Delta. Le chapitre se termine par la proposition d'une technique de commande basée sur la méthode de synthèse H_∞ suivie d'un réglage neuro-flou adaptatif à modèle de référence appliquée à un système de positionnement motorisé par des moteurs à courant continu avec des perturbations externes et des incertitudes sur ses paramètres et présentés sous forme de doubles intégrateurs.

III.2 Commande adaptative floue optimale appliquée à un robot SCARA motorisé par deux MSAP

Dans ce qui suit, nous allons utiliser un robot SCARA dont la motorisation est réalisée par deux moteurs synchrones à aimants permanents associés à leurs régulations adaptatives optimales basées sur la logique floue déjà présentées dans le chapitre précédent.

En fait, rien ne sera changé dans la commande des moteurs. Seulement les moteurs seront chargés mécaniquement par le robot. L'association machine-robot se fait via les réducteurs de vitesse et pour avoir le modèle complet du robot motorisé par les deux moteurs nous avons

ramené toutes les grandeurs utilisées dans le modèle du robot vers le côté machine synchrone à aimants permanents.

La régulation des machines chargées par le robot est faite toujours dans le côté vitesse de rotation. Pour le robot, nous avons besoin des coordonnées opérationnelles. L'utilisation du modèle géométrique inverse MGI du robot permet d'avoir les coordonnées articulaires dont les dérivées par rapport au temps donnent les vitesses de rotation que les deux MSAP doivent assurer.

L'utilisation du modèle cinématique direct MCD permet d'avoir les vitesses de déplacement dans les coordonnées opérationnelles et l'intégration peut donner la position de l'effecteur dans l'espace opérationnel. Ce passage conduit à des erreurs en plus dans les coordonnées opérationnelles qu'on peut réduire en utilisant tout simplement des régulateurs P, PI ou même PID. En général, un régulateur P suffit.

La simulation donne les résultats présentés sur les figures suivantes.

On voit bien la bonne poursuite et les erreurs maximales selon X et Y sont 6mm et 3cm respectivement ce qui est grand pour le côté poursuite mais ici nous avons forcé le robot à faire la trajectoire en 10 secondes. Si au lieu de 10 secondes, nous prenons par exemple 60 secondes ces erreurs seront bien réduites.

Pour le côté balayage pour faire la cartographie du potentiel de surface, ces erreurs n'affectent pas les résultats car ce qui nous intéresse dans ce cas est la position (X, Y) en cours et le potentiel V à cette position.




Figure III.1 : Poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MSAP (1^{ère} et 2^{ème} articulations).




Figure III.2 : Erreurs de poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MSAP (1^{ère} et 2^{ème} articulations).

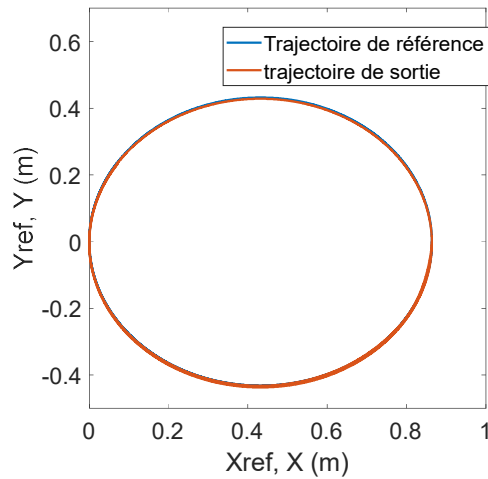


Figure III.3 : Poursuite de trajectoire du robot SCARA motorisé par 2 MSAP en coordonnées opérationnelles.

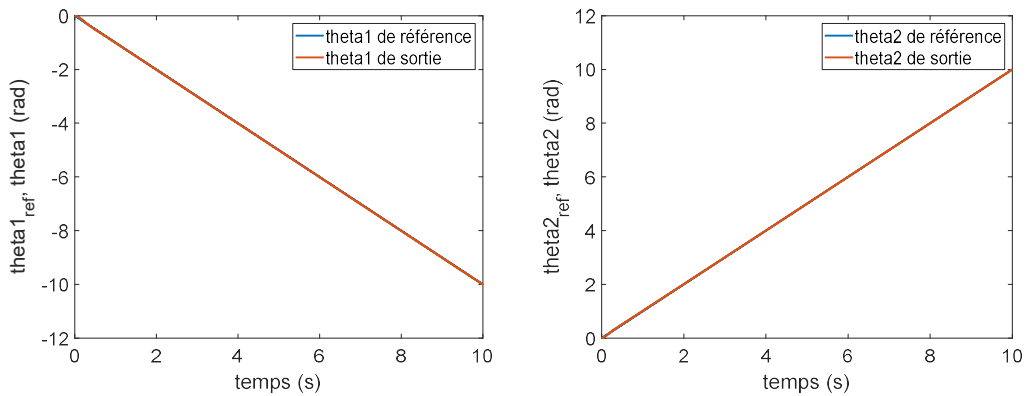


Figure III.4 : Poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MSAP (1^{ère} et 2^{ème} articulations).

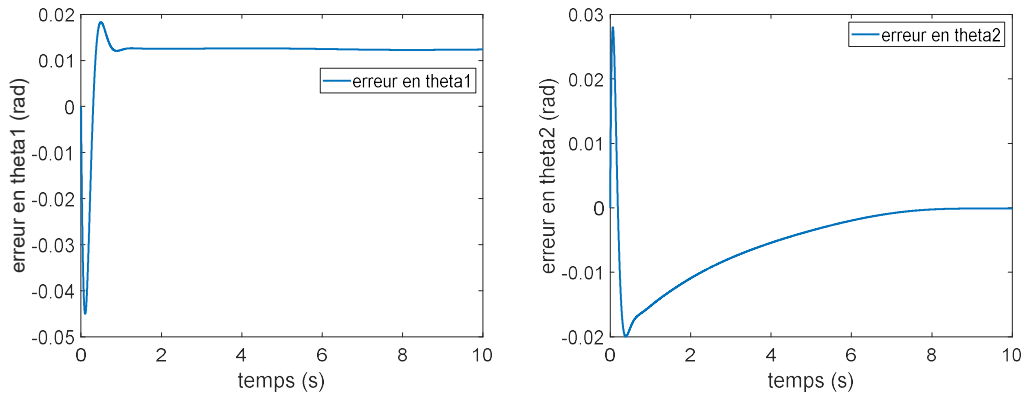


Figure III.5 : Erreurs de poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MSAP (1^{ère} et 2^{ème} articulations).

III.3 Commande adaptative floue optimale appliquée au robot SCARA motorisé par deux MPP

De même, l'utilisation d'un robot SCARA motorisé par deux moteurs pas à pas pour le balayage du potentiel de surface d'un échantillon isolant chargé électriquement peut être réalisée voire conseillée.

En suivant la même démarche que dans la section précédente, nous avons pu appliquer la commande adaptative optimale basée sur la logique floue aux moteurs pas à pas MPP chargés mécaniquement par le robot SCARA.

Les mêmes remarques que pour le cas précédent, mais ici vu l'utilisation des MPP, les performances sont nettement supérieurs




Figure III.6 : Poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MPP (1^{ère} et 2^{ème} articulations).




Figure III.7 : Erreurs de poursuite de trajectoire en coordonnées opérationnelles du robot SCARA motorisé par 2 MPP (1^{ère} et 2^{ème} articulations).




Figure III.8 : Poursuite de trajectoire du robot SCARA motorisé par 2 MPP en coordonnées opérationnelles (1^{ère} et 2^{ème} articulations).




Figure III.9 : Poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MPP (1^{ère} et 2^{ème} articulations).




Figure III.10 : Erreurs de poursuite de trajectoire en coordonnées articulaires du robot SCARA motorisé par 2 MPP (1^{ère} et 2^{ème} articulations).

III.4 Commandes prédictive et PID guidées par les données, appliquée au robot SCARA

L'objectif est d'avoir un régulateur universel où une fois le régulateur connecté au système il construit une base de données directement dans les premières périodes d'échantillonnage. Cette base de données sera mise à jour après et ce avec chaque utilisation. En plus, la base de données peut être initialisée en utilisant les connaissances préalables sur le système et son comportement autour de quelques points de fonctionnement.

Pour un système S , le régulateur R a une certaine structure avec des paramètres variables qui peuvent être modifiés afin d'avoir les bonnes performances voulues en boucle fermée. Le régulateur R est donné sous la forme $R(X, \Phi)$ où X représente les entrées du régulateur comme l'erreur de poursuite et sa dérivée, les états du système et/ou les sorties du système par exemple alors que Φ représente un vecteur contenant tous les paramètres du régulateur. Ces paramètres seront obtenus à partir de la base de données construite et mise à jour à chaque pas d'échantillonnage.

La base de données est donnée sous forme d'un tableau contenant les valeurs possibles de l'entrée X et d'un certain nombre de mesures supplémentaires sur le système ainsi que les valeurs correspondantes des paramètres Φ .

Ce tableau est présenté par (M_i, X_i, Φ_i) avec $i = 1, \dots, N$ et N le nombre d'échantillons dans le tableau.

Connaissant les mesures actuelles M_t , dans la boucle fermée, un algorithme de recherche basé sur l'utilisation de distances entre M_t et les M_i , peut déterminer les valeurs des paramètres à

utiliser dans le régulateur à cet instant. Cette détermination peut être faite avec plusieurs manières :

- Directement en prenant les valeurs des paramètres du tableau correspondant à la plus petite distance calculée : $\Phi = \Phi_i$ avec $d_i = \min(d_i), i = 1, \dots, N$.
- Par un calcul basé sur la somme pondérée où les poids sont approximativement inversement proportionnels aux distances d_i avec $i = 1, \dots, N$. (en utilisant par exemple Softmax, ou gaussienne, etc.). Dans ce cas on aura $\Phi = \sum w_i \cdot \Phi_i$ où $w_i = D_i / \sum D_j$ et les distances $D_j = F(d_j)$ et $F(d) = 1/(\lambda+d)$, $F(d) = \exp(-\alpha \cdot d)$ ou $F(d) = \exp(-(d/\sigma)^2)$ avec λ , α et σ des paramètres positifs.
- Aléatoirement parmi les valeurs trouvées dans le tableau et qui sont dans le voisinage de M_t .

Au démarrage, le tableau de données (base de données) n'est pas suffisamment bon pour la régulation et peut être il est très loin de la situation actuelle du système. Mais avec l'apprentissage, la mise à jour de la base de données, les résultats s'améliorent. L'apprentissage peut utiliser un modèle de référence et trouver de nouvelles valeurs des paramètres à partir des anciennes valeurs. Dans l'apprentissage, on peut utiliser l'algorithme du gradient, le PSO, les AG, la recherche stochastique ou n'importe quelle méthode d'optimisation.

La base de données est mise à jour par le remplacement direct où la nouvelle valeur trouvée remplace soit une autre valeur, dans le tableau, choisie aléatoirement, ou une valeur dans le tableau proche de celle présente selon M_t .

Une autre méthode est de passer de l'ancienne valeur vers la nouvelle valeur par passage doux et lisse et ce suivant la formule $E_i = E_{i,old} + r \cdot (E_{i,new} - E_{i,old})$ où r est aléatoire dans $[0,1]$ et E_i la nouvelle valeur calculée à partir de l'ancienne (dans le tableau) et de la nouvelle proposée.

Pour un régulateur PID, les paramètres sont $\Phi_i = (Kp_i, Ki_i, Kd_i)$ et pour la commande prédictive $\Phi_i = (H_i, P_i)$ vue la formule $\Delta u_{opt} = \frac{h^T(W-P)}{h^T h + \lambda}$.

Les résultats de l'application au robot SCARA sont présentés dans les figures ci-après.

La trajectoire est un passage doux du point (0,0) au point (1,1) dans les coordonnées articulaires (des angles en radians).

L'erreur maximale est de 0.02 rad pour les deux articulations et elle est atteinte au début du mouvement. L'erreur se décroît rapidement.




Figure III.11 : Poursuite de trajectoire du robot SCARA (1^{ère} et 2^{ème} articulations).

III.5 Commande prédictive quantifiée basée sur les réseaux de neurones artificiels et les essais de particules (PSO) appliquée au robot SCARA

Dans la commande prédictive proposée ici, on utilise plusieurs réseaux de neurones artificiels pour modéliser le robot SCARA dont le modèle est non linéaire. Cette modélisation est mise à jour à chaque période d'échantillonnage. Les réseaux de neurones sont choisis simples et de taille adéquate (nombre de couches et nombre de neurones). Le modèle des réseaux de neurones est donné par

$$O_k = \sum_{l=1}^L w_{kl}^2 f_l \left(\sum_{p=1}^P w_{lp}^1 I_p \right) \tag{III.1}$$

La recherche des valeurs des variables manipulées est réalisée par l'algorithme PSO qui sélectionne la meilleure valeur pour l'appliquer au robot. Pour aller vite dans la recherche de cette valeur, on a quantifié l'espace de recherche. Ainsi, le choix sera fait parmi un ensemble réduit de valeurs proposées aux particules. En plus, le nombre des itérations est aussi réduit afin de terminer la recherche dans une durée inférieure à celle de la période d'échantillonnage. Et n'oublions pas que même le nombre des particules est réduit aussi. Dans ce travail, nous avons pris 3 itérations et 30 particules.

Chaque particule calcule la commande à appliquer en utilisant les formules suivantes :

$$\begin{cases} v_{p,k} = K \cdot (v_{p,k-1} + r_{p1}(u_{gb} - u_{p,k-1}) + r_{p2}(u_{p,lb} - u_{p,k-1})) \\ u_{p,k} = u_{p,k-1} + v_{p,k} \end{cases} \tag{III.2}$$

Les valeurs des variables manipulées sont quantifiées pour avoir une recherche rapide et efficace. Nous avons pris 11 valeurs pour chaque variable manipulée.

$$U_k = \left\{ u_{k,i} \text{ tels que } u_{k,i} = u_{k,\min} + i \cdot \frac{(u_{k,\max} - u_{k,\min})}{n_k} \text{ pour } i = 0, \dots, n_k \right\} \quad (\text{III.3})$$

pour $k = 1$ et 2 .

La structure de la commande proposée est donnée par la figure suivante. On voit bien la partie de données utilisées pour l'apprentissage des réseaux de neurones ainsi que les valeurs quantifiées des variables manipulées. L'autre partie concerne les algorithmes d'apprentissage et de choix par la recherche en utilisant l'algorithme PSO.

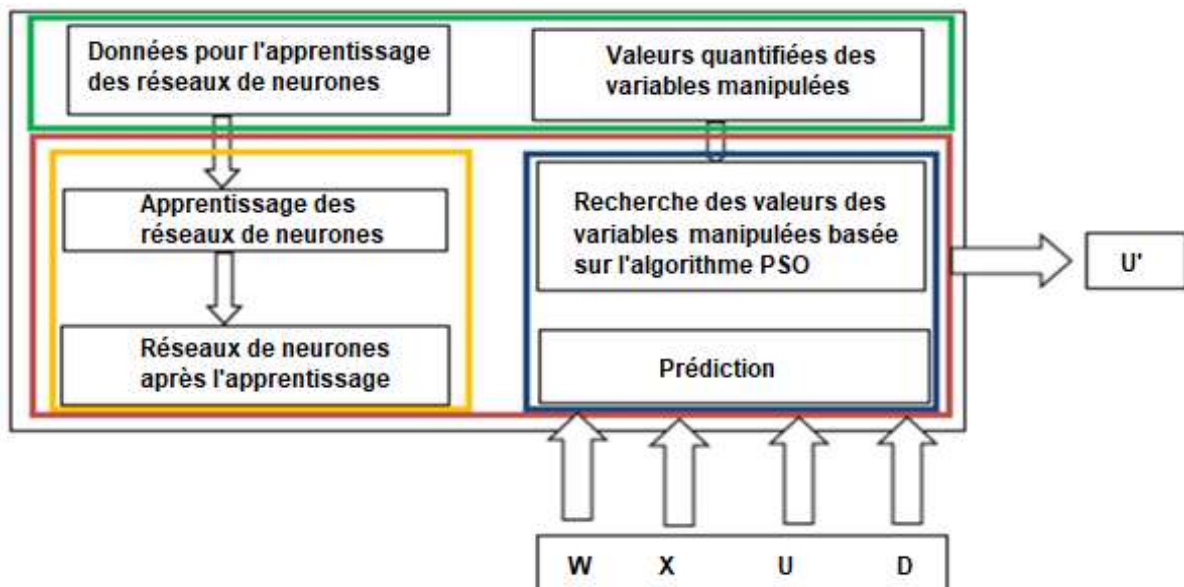


Figure III.12 : Structure de la commande prédictive quantifiée basée sur les réseaux de neurones et les essaims de particules (PSO).

Plusieurs variantes ont été appliquées. Ces variantes sont obtenues par la séparation des réseaux de neurones en sous-réseaux (chacun pour une seule sortie) et ce afin de simplifier l'apprentissage et de le rendre rapide.

Toutes les variantes ont 7 entrées et 10 neurones dans la couche cachée. Mais la première variante a 4 sorties, la deuxième a 2 sorties seulement et la troisième a une seule sortie.

Les données utilisées pour l'apprentissage des différents réseaux sont obtenues par l'excitation aléatoire du robot avec des entrées variant du minimum au maximum tolérés et sont stockées

dans la mémoire du régulateur et l'apprentissage utilise seulement les données qui sont proche de la situation actuelle du système marquée par les variables manipulées du moment.

Le modèle d'état du robot SCARA est utilisé dans la génération de ces données d'apprentissage et dans la simulation du robot lors de l'application de la commande en phase de simulation.

Les figures suivantes montrent les résultats de simulation dans la tâche de poursuite de la trajectoire donnée dans la figure III.15.

On voit bien le bon comportement et la bonne poursuite de la trajectoire désirée. De plus, la commande est quantifiée est présente des hauts et des bas à chaque pas d'échantillonnage. Un travail en plus est de réduire ce rapide changement des variables manipulées.




Figure III.13 : Poursuite et erreurs de poursuite de trajectoire du robot SCARA dans les coordonnées articulaires.




Figure III.14 : Signaux de commande appliquées au robot SCARA (T en secondes et U (ie U1 et U2) en Volts).




Figure III.15 : Poursuite de trajectoire du robot SCARA dans les coordonnées opérationnelles (X et Y en mètre).

III.6 Commande floue d'un robot Delta (NN pour MGD et MGI)

Le robot Delta est très utilisé dans les tâches de positionnement (pick and place) dans l'industrie. C'est un robot parallèle dont le modèle est assez compliqué. Vu la complexité des modèles géométriques direct et inverse du robot, nous avons opté pour l'utilisation de réseaux de neurones artificiels afin d'apprendre ces deux modèles. Ainsi, dans la suite, nous utilisons des réseaux de neurones artificiels pour modéliser les modèles géométriques direct et inverse.

La structure du robot est présentée dans la figure suivante :




Figure III.16 : Structure du robot Delta.

Les données d'apprentissage sont générées par le positionnement aléatoire du robot dans l'espace opérationnel et la prise des mesures en coordonnées articulaires ($\theta_1, \theta_2, \theta_3$) en plus de (X, Y, Z) la position en coordonnées cartésiennes (coordonnées opérationnelles). Comme ça, nous construisons une base de données qui lie les coordonnées articulaires avec les coordonnées opérationnelles. La figure ci-après montre les points de mesures pris pour l'apprentissage du MGD et du MGI.




Figure III.17 : Données pour l'apprentissage des réseaux de neurones artificiels du MGD et du MGI du robot Delta.

Le régulateur flou proposé est de type Sugeno dont la sortie est une somme pondérée des conséquences des règles floues. Les poids sont liés aux fonctions d'appartenance utilisées.

Celles-ci sont prises gaussiennes et les conséquences des règles sont linéaires ou affines par rapport aux entrées.

La sortie du régulateur est donnée par :

$$u = \sum_{i=1}^N \rho_i y_i \quad (\text{II.4})$$

Où $y_i = f_i(e, de) = a_i e + b_i de + c_i$, sont les conclusions des règles floues et $\rho_i(e, de)$, $i = 1, \dots, N$ sont les fonctions d'appartenance normalisées et N le nombre de règles floues.

Les fonctions d'appartenance comportent les paramètres m et s et les conclusions comporte les paramètres a , b et c .

Le robot Delta comporte 3 articulations dont chacune est contrôlée par un régulateur flou. Quatre règles floues pour chaque régulateur suffisent. Ceci correspond à la prise de deux fonctions d'appartenance pour l'entrée e et deux autres pour l'entrée de du régulateur.

Pour un bon choix des paramètres m , s , a , b et c , un bon comportement du robot est obtenu comme montré dans les figures ci-après.

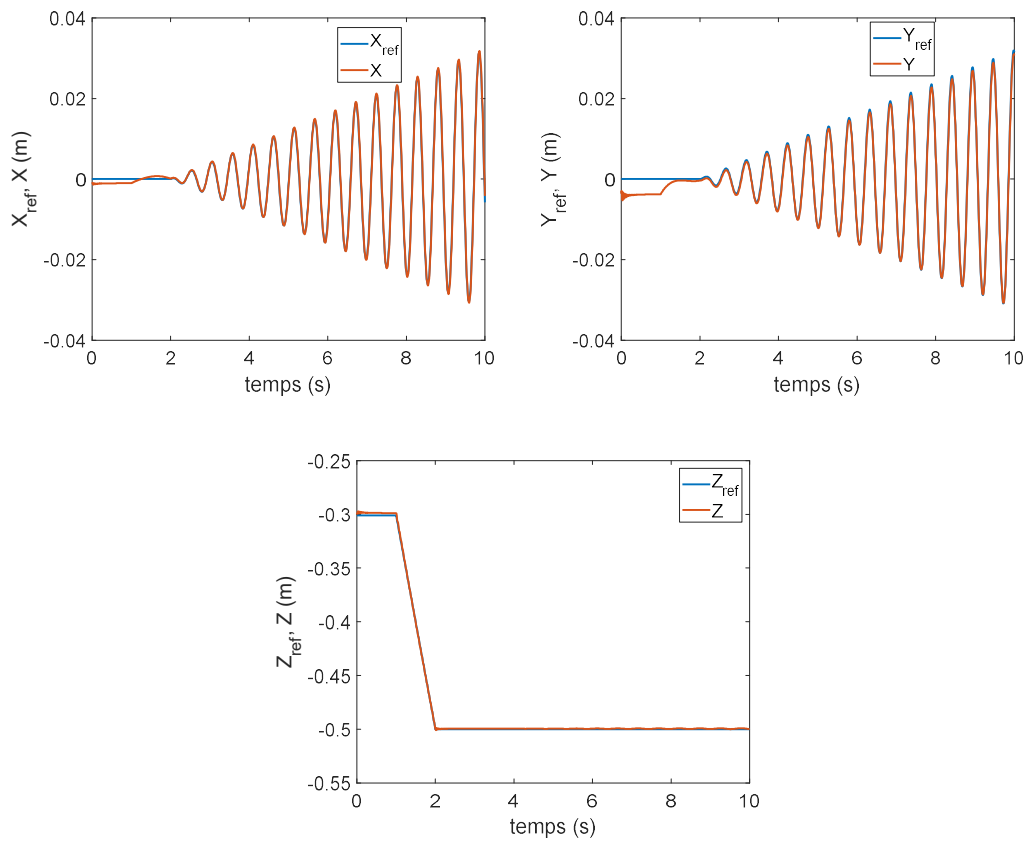


Figure III.18 : Poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles.

La bonne poursuite est nettement claire pour les coordonnées opérationnelles avec de petites erreurs dues à l'utilisation des réseaux de neurones pour le MGD et le MGI.

Dans les figures suivantes, on voit bien que l'erreur est faible. L'erreur maximale selon X est de 1.5 mm ce qui est grand pour un positionnement précis mais ceci n'est pas important dans notre cas car nous avons forcé le robot à suivre la trajectoire (spirale) rapidement et ce afin d'avoir le balayage avant que le déclin du potentiel de surface ne devienne remarquable. En fait, en ralentissant un peu le robot pour suivre cette trajectoire, les erreurs de poursuite seront très faibles et ça a été vérifié en prenant la durée de faire cette trajectoire égale à 60 secondes au lieu de 10 secondes comme ici.

Les erreurs sur la poursuite n'affectent pas les mesures du potentiel V et des position (X, Y) car l'objectif est le balayage et non pas la poursuite elle-même.

De même, les erreurs maximales selon Y et Z sont 6 mm et 4 mm respectivement.

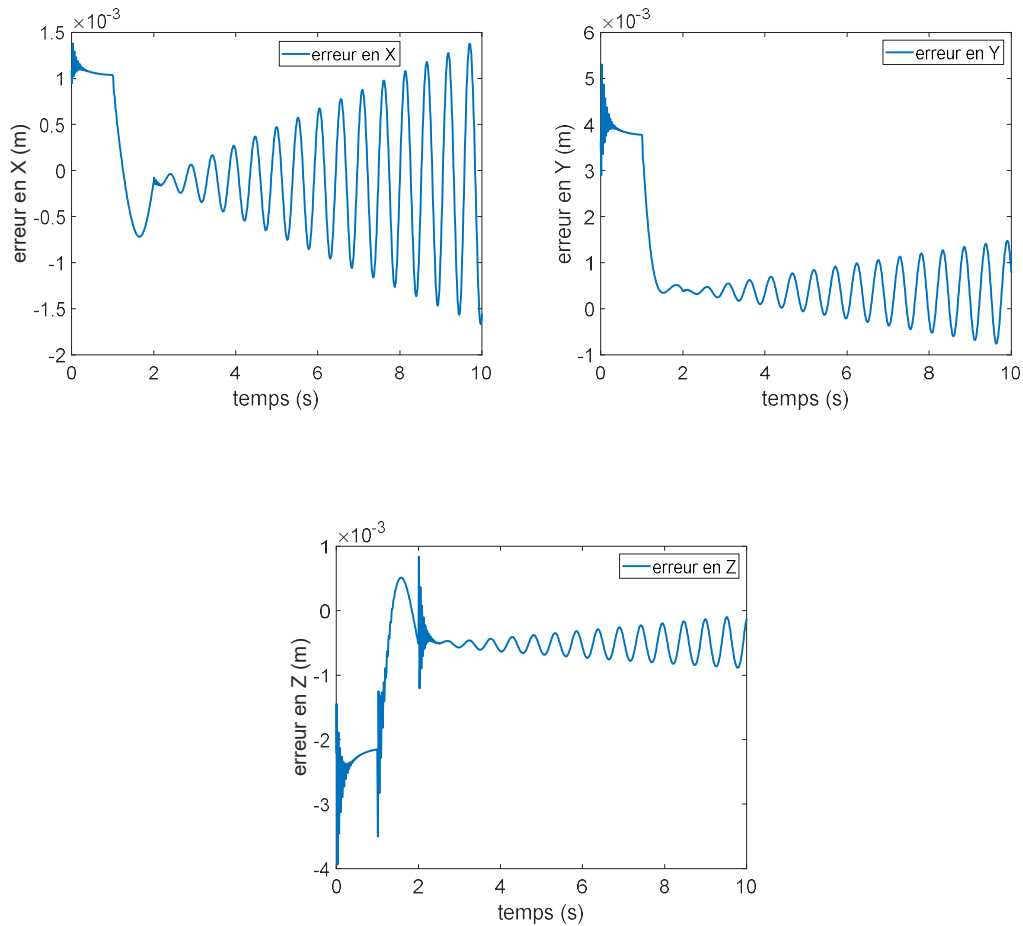


Figure III.19 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles.

Pour les coordonnées articulaires, la poursuite est très satisfaisante avec des erreurs maximales inférieures à 0.006 rad pour la première et la deuxième articulations et 0.015 rad pour la troisième articulation.

Les figures ci-après montrent les bons résultats ce qui implique que l'utilisation des réseaux de neurones pour modéliser le MGD et le MGI est la source des erreurs qui apparaissent dans les coordonnées opérationnelles.

Ces réseaux de neurones bien qu'ils éliminent les problèmes liés au MGD et MGI donnés analytiquement (singularités), ils doivent être bien ajustés pour réduire les erreurs dans les coordonnées opérationnelles.

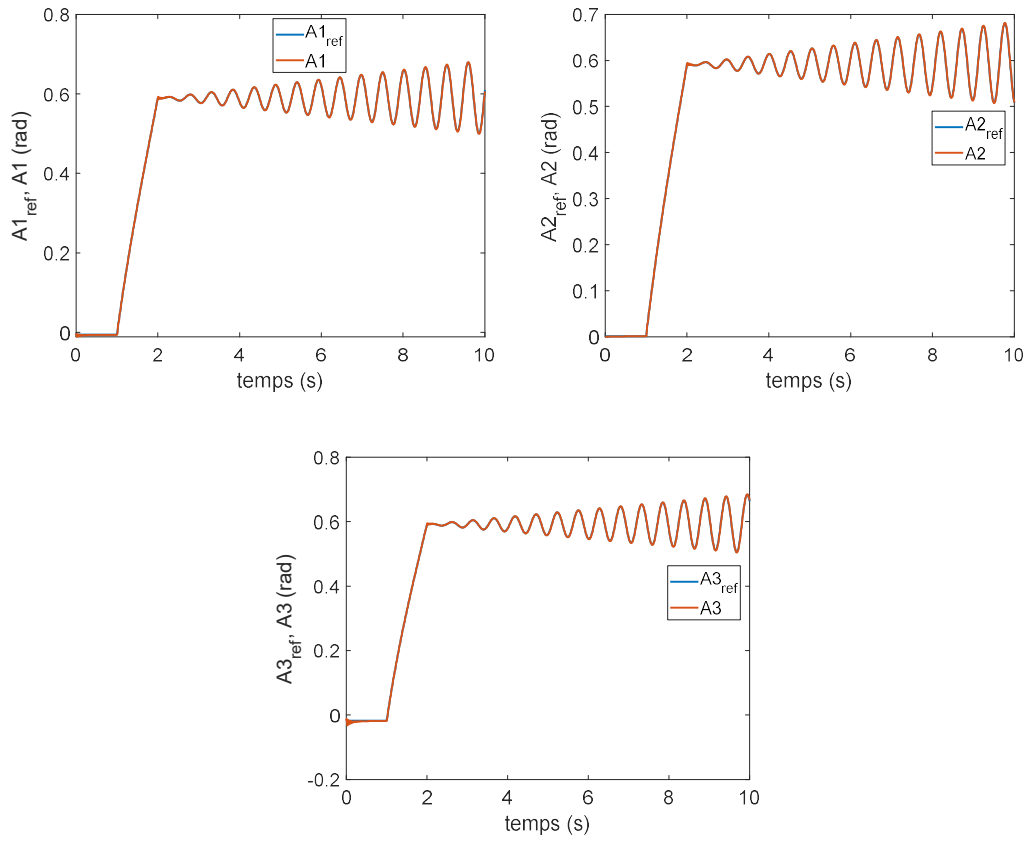


Figure III.20 : Poursuite de trajectoire du robot Delta dans les coordonnées articulaires.

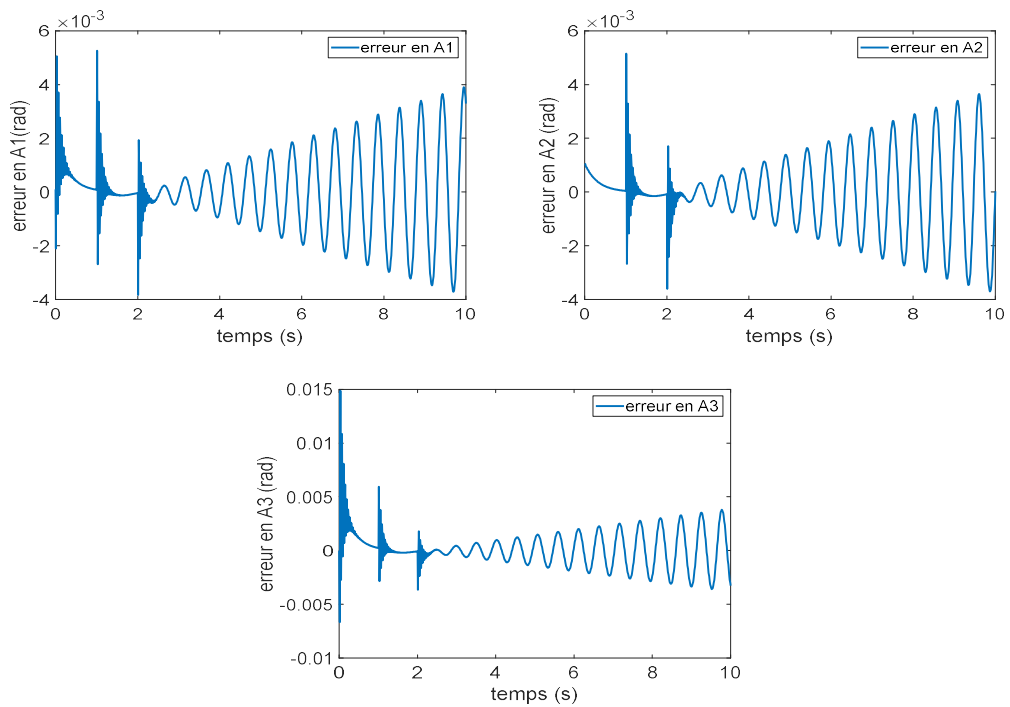


Figure III.21 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées articulaires.

La figure suivante présente la poursuite de la trajectoire (spirale) utilisée pour le balayage de l'échantillon. Toute erreur est bien causée par l'utilisation des réseaux de neurones artificiels.




Figure III.22 : Poursuite de trajectoire du robot Delta dans l'espace opérationnel.

III.7 Commande neuro-floue adaptative d'un robot Delta (NN pour MGD et MGI)

Dans ce qui suit, on essaye de réduire encore les erreurs de poursuite de trajectoire (spirale) et ce en utilisant l'apprentissage du régulateur neuro-flou. En fait, le régulateur neuro-flou a la même structure que le régulateur flou de la section précédente. Cette structure permet de le présenter sous forme d'un réseau adaptatif généralisé où les paramètres sont placés sur les nœuds (neurones) et non pas sur les liaisons.

L'apprentissage se fait par l'algorithme de rétropropagation et les paramètres sont ajustés en ligne à chaque fois le robot est utilisé. Le critère J à minimiser est lié à l'erreur de poursuite et peut contenir le signal de commande afin de le pénaliser.

L'apprentissage se base sur l'algorithme du gradient dont la formule est donnée comme suit pour un certain paramètre p (parmi les paramètres suivant : m, s, a, b ou c).

$$p_{new} = p_{old} - \eta \left[\frac{\partial J}{\partial p} \right]_{old} \quad (III.5)$$

Où η est le pas de gradient appelé aussi pas d'apprentissage et p_{old} et p_{new} l'ancienne valeur et la nouvelle valeur du paramètre p .

Le gradient $\partial J / \partial p$ est calculé comme suit

$$\frac{\partial J}{\partial p} = \sum o^* \frac{\partial J}{\partial o^*} \frac{\partial o^*}{\partial p} \quad (III.6)$$

Où la sommation s'étale sur tous les neurones dont la sortie est O^* ayant p comme paramètre.

L'application de la commande neuro-floue adaptative sur le robot Delta a donné les résultats présentés dans les figures suivantes.

Les remarques concernant la poursuite sont identiques à celles du cas du régulateur flou. Mais il y a une légère amélioration vue que le régulateur flou était bien dimensionné. En plus ça renforce le fait que les erreurs dans la poursuite dans les coordonnées opérationnelles sont dues à l'utilisation des réseaux de neurones.

Nous remarquons une légère différence dans les courbes des erreurs comparées à celles obtenues avec le régulateur flou.

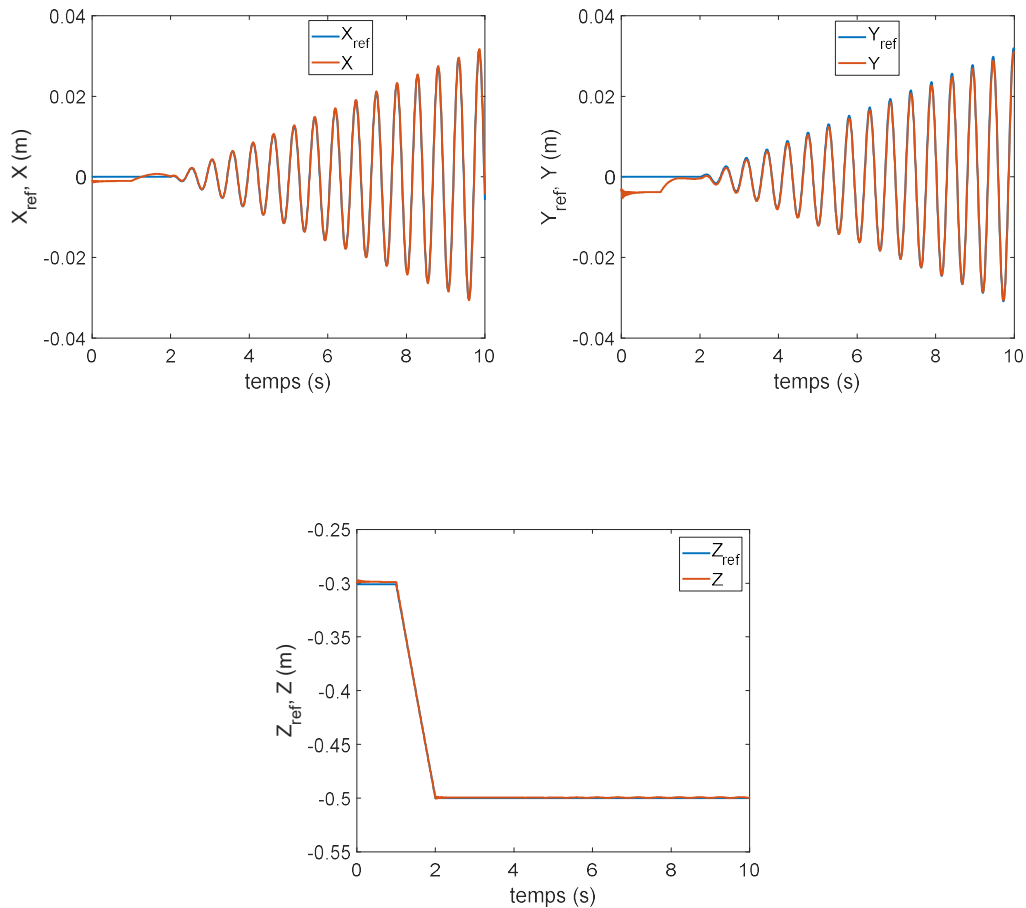


Figure III.23 : Poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles avec la commande neuro-floue adaptative.

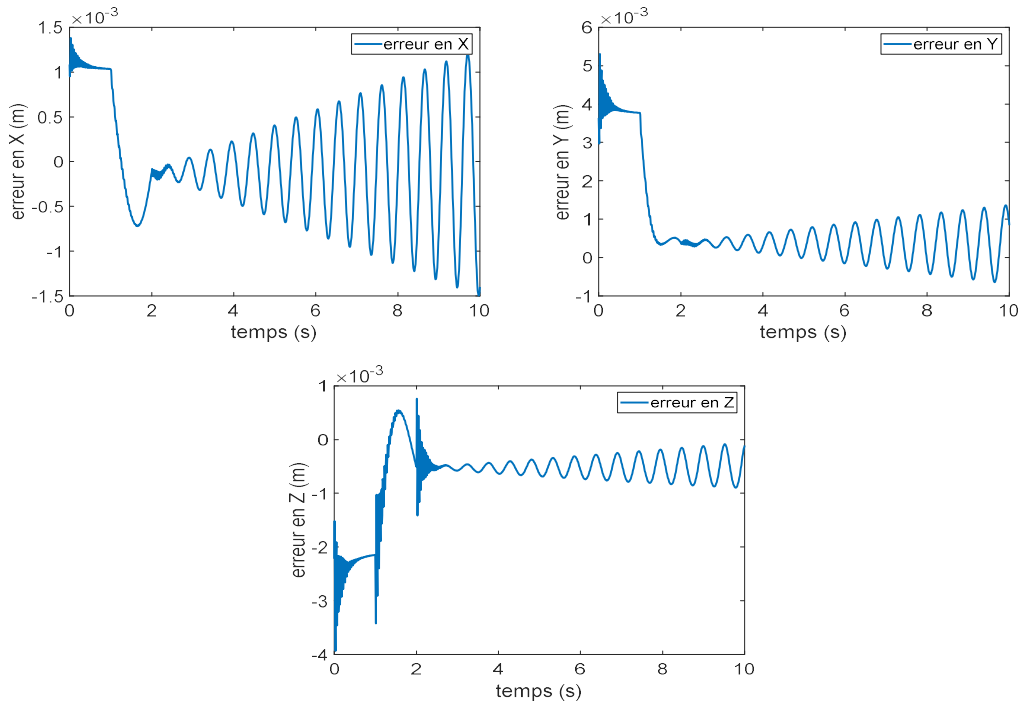


Figure III.24 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées opérationnelles avec la commande neuro-floue adaptative.

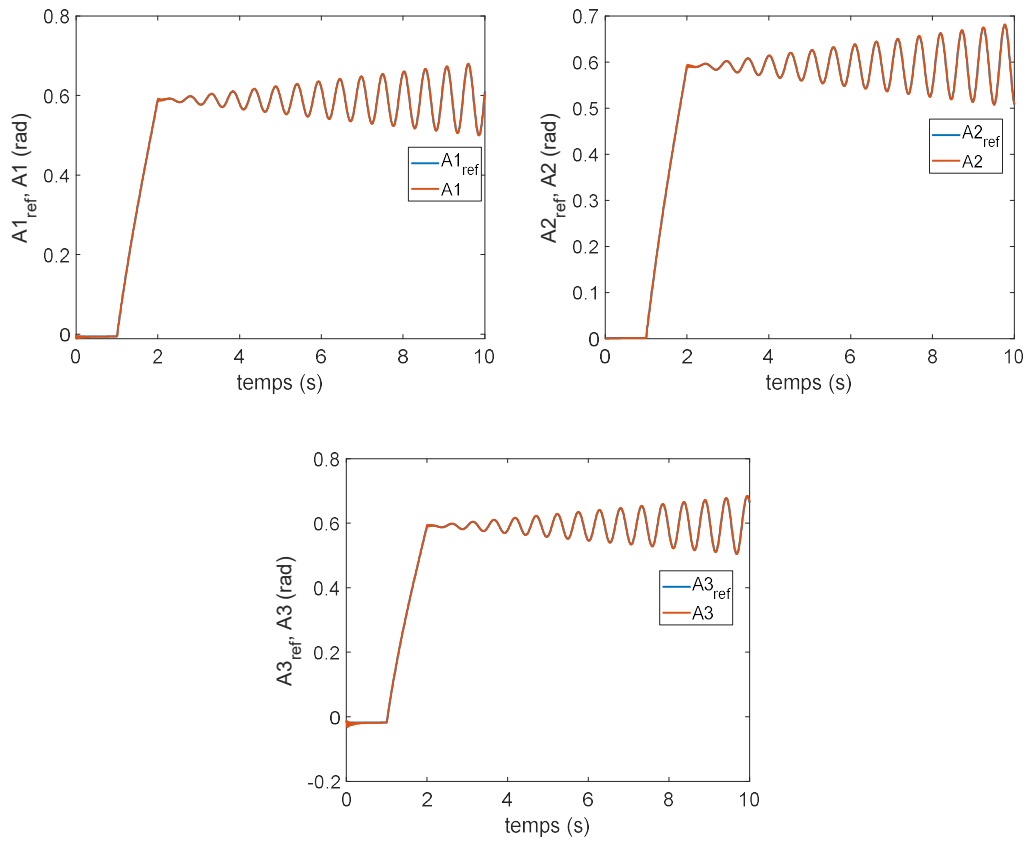


Figure III.25 : Poursuite de trajectoire du robot Delta dans les coordonnées articulaires avec la commande neuro-floue adaptative.

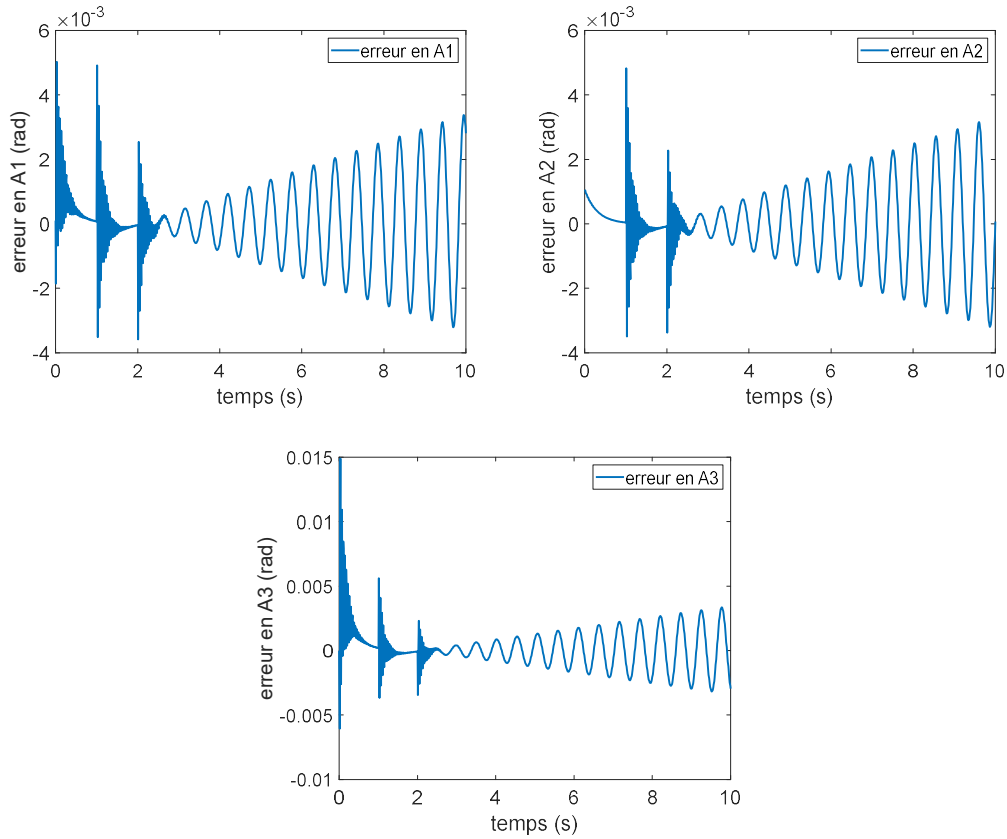


Figure III.26 : Erreurs en poursuite de trajectoire du robot Delta dans les coordonnées articulaires avec la commande neuro-floue adaptative.




Figure III.27 : Poursuite de trajectoire du robot Delta dans l'espace opérationnel avec la commande neuro-floue adaptative.

III.8 Commande robuste neuro-floue adaptative appliquée à un système de positionnement 2d rapide

Le système de positionnement présenté dans la figure suivante est constitué de deux sous-systèmes sous formes de doubles intégrateurs avec des perturbations. Les perturbations

modélisent les effets d'un couple résistant externe ainsi que les incertitudes dans les paramètres des moteurs à courant continu (les moments d'inertie J_x , J_y , les coefficients de frottement visqueux f_x et f_y ainsi que les gains k_x et k_y , ...) selon les axes X et Y .

La conception d'une commande robuste basée sur H_∞ utilise une forme de représentation dite LFT (Linear Fractional Transform).

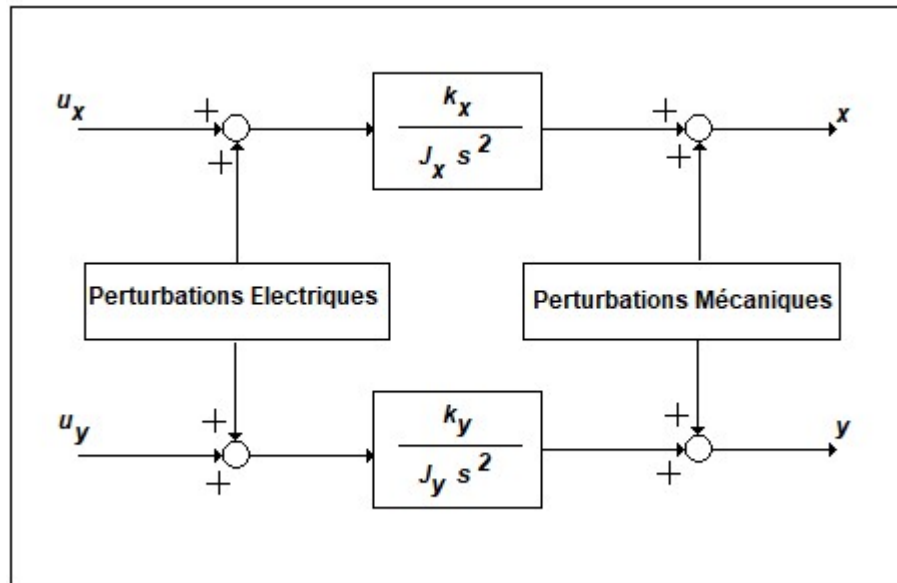


Figure III.28 : Modèle simplifié d'un système de positionnement rapide basé sur des moteurs à courant continu MCC avec des perturbations mécaniques et électriques.

Le système en boucle fermée est présenté dans la figure suivante et montre les différentes parties du régulateur. Le régulateur K est un régulateur robuste obtenu par la méthode H_∞ pour rejeter les effets des perturbations δe et δs . Le régulateur neuro-flou adaptatif est entraîné par l'algorithme de rétropropagation. Le régulateur neuro-flou à la forme d'un système flou de type Sugeno avec un bloc d'apprentissage qui assure l'ajustement de ses paramètres. L'objectif de l'ajustement des paramètres est de réduire l'erreur entre les sorties du système S et du modèle de référence S_m .

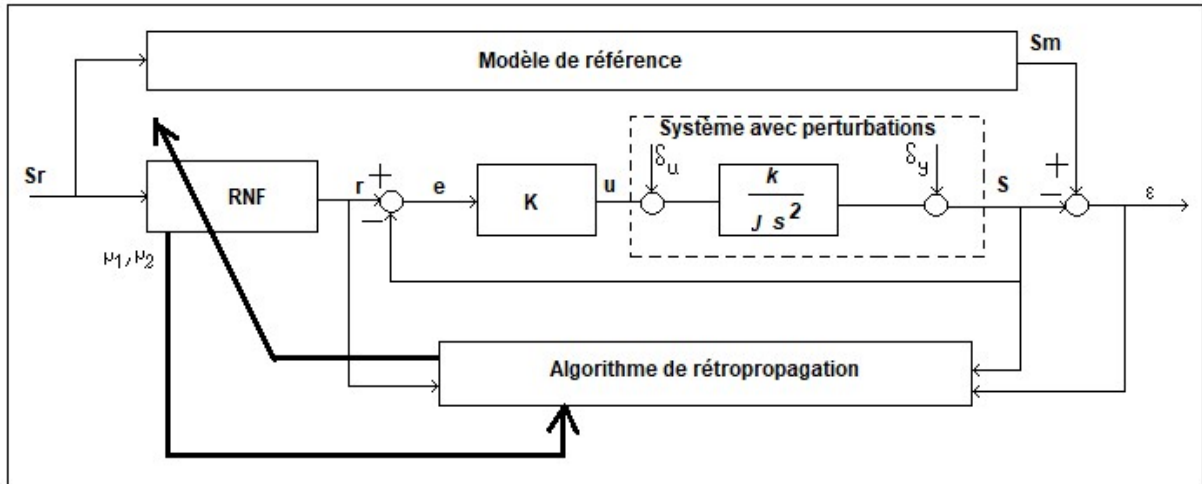


Figure III.29 : Commande robuste neuro-floue adaptative appliquée au système de positionnement ayant une dynamique rapide basé sur des MCC.

Le régulateur de type Sugeno calcule la référence modifiée r à appliquer au système régulé par le régulateur robuste K . La référence modifiée est donnée par l'équation suivante :

$$r = NFLC(Sr) \tag{III.7}$$

C'est à dire :

$$r = \frac{(\mu_1(Sr) \cdot f_1(Sr) + \mu_2(Sr) \cdot f_2(Sr))}{(\mu_1(Sr) + \mu_2(Sr))} \tag{III.8}$$

Où les fonctions d'appartenances sont :

$$\mu_1(Sr) = e^{-((Sr+m)/\sigma)^2} \tag{III.9}$$

$$\mu_2(Sr) = e^{-((Sr-m)/\sigma)^2} \tag{III.10}$$

Et les conséquences des règles floues sont donnés par :

$$f_1(Sr) = a_1 \cdot Sr + b_1 \tag{III.11}$$

$$f_2(Sr) = a_2 \cdot Sr + b_2 \tag{III.12}$$

L'algorithme de rétropropagation donne les formules d'apprentissage pour ajuster les paramètres m , σ , a_1 , a_2 , b_1 et b_2 :

$$\dot{m} = -\eta_m \cdot \left\{ \left[\frac{2}{\sigma^2} \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \cdot \frac{r_1 \cdot \mu_1 - r_2 \cdot \mu_2}{(\mu_1 + \mu_2)^2} \right] \cdot [(Sr - m) \cdot \mu_2 + (Sr + m) \cdot \mu_1] \right\} \tag{III.13}$$

$$\dot{\sigma} = -\eta_\sigma \cdot \left\{ \left[\frac{2}{\sigma^3} \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \cdot \frac{r_1 \cdot \mu_1 - r_2 \cdot \mu_2}{(\mu_1 + \mu_2)^2} \right] \cdot [(Sr - m)^2 \cdot \mu_2 - (Sr + m)^2 \cdot \mu_1] \right\} \tag{III.14}$$

$$\dot{a}_1 = \eta_{a_1} \cdot Sr \cdot \rho_1 \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \quad (\text{III.15})$$

$$\dot{b}_1 = \eta_{b_1} \cdot \rho_1 \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \quad (\text{III.16})$$

$$\dot{a}_2 = \eta_{a_2} \cdot Sr \cdot \rho_2 \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \quad (\text{III.17})$$

$$\dot{b}_2 = \eta_{b_2} \cdot \rho_2 \cdot \varepsilon \cdot \frac{\Delta S}{\Delta r} \quad (\text{III.18})$$

avec

$$\begin{cases} \varepsilon = Sm - S \\ \rho_1 = \frac{\mu_1}{\mu_1 + \mu_2} \\ \rho_2 = \frac{\mu_2}{\mu_1 + \mu_2} \end{cases} \quad (\text{III.19})$$

En fait, le régulateur robuste obtenu par la méthode H_∞ réduit les effets des perturbations mais le système en boucle fermée résultant n'assure pas nécessairement la rapidité voulue pour un balayage rapide. Ce qui conduit à l'utilisation d'un régulateur flou de type Sugeno avec deux règles floues seulement pour avoir la conduite nécessaire en imposant la poursuite d'un modèle de référence qui est choisi en fonction de la durée du déclin du potentiel de surface. En plus le recours à la commande adaptative, par l'apprentissage par rétropropagation, peut remédier aux problème de dimensionnement du régulateur flou.

Il y a deux régulateurs robustes neuro-flous adaptatifs pour les deux articulations du robot utilisé (SCARA ou autre).

III.9 Conclusion

Dans ce chapitre, nous avons présenté l'utilisation des robots pour le balayage de surface. Plusieurs techniques de commandes ont été utilisées. Nous avons commencé par le robot SCARA motorisé par deux MSAP régulés par la commande adaptative optimale basée sur la logique floue déjà traitée dans le chapitre précédent. Ensuite, le robot SCARA est motorisé par deux moteurs pas à pas MPP et avec la même technique de commande. Dans les deux cas, les performances sont acceptables pour les tâches de cartographie du potentiel de surface. Le cas du MPP est très apprécié vu les performances obtenues. Une commande PID (et une autre prédictive) guidée par les données a été appliquée à un robot SCARA. De bonnes performances ont été obtenues dans la poursuite de trajectoire. De même, une autre commande prédictive

avec des modèles de prédiction à base de réseaux de neurones artificiels et l'algorithme PSO pour l'optimisation a été utilisée, mais cette fois-ci la valeur de la commande a été quantifiée. Les résultats sont prometteurs mais cette technique nécessite un bon calculateur pour pouvoir l'implémenter. Vu la rapidité du robot Delta, nous l'avons utilisé avec une commande floue et une autre neuro-floue adaptative. Le robot Delta a un modèle complexe et présente des singularités dans ses modèles géométriques direct et inverse. L'utilisation de réseaux de neurones pour apprendre les MGD et le MGI a montré l'efficacité de la technique de commande avec des précautions à prendre de bien faire l'apprentissage des réseaux de neurones car sinon, des erreurs vont apparaître dans la poursuite dans les coordonnées opérationnelles. Ce chapitre se termine par la proposition d'une technique de commande robuste neuro-flou où un régulateur robuste obtenu par la synthèse H_∞ sert à stabiliser le système et ensuite un régulateur neuro-flou adaptatif assure la poursuite d'un modèle de référence.

Chapitre IV

Cartographie du potentiel de surface : mesure et reconstitution

IV.1 Introduction

Dans ce chapitre, nous allons présenter la démarche à suivre pour une bonne reconstitution du potentiel réel sur la surface d'un matériau électriquement chargé (isolant ou conducteur). D'abord, la procédure et le matériel utilisés pour la mesure seront présentés suivis d'expériences de mesures réalisées. Ensuite et en vue de faire la reconstitution, la caractérisation de la sonde utilisée sera faite par plusieurs méthodes proposées. La reconstitution du potentiel réel de surface sera réalisée par plusieurs approches. Des études comparatives concernant les approches utilisées pour la caractérisation de la sonde ou les approches proposées pour la reconstitution seront conduites et ce afin de tirer les meilleurs conclusions et résultats.

IV.2 Plateforme de cartographie

La plateforme utilisée pour la mesure du potentiel de surface sur les échantillons (matériaux isolants) est donnée par la figure ci-après :




Figure IV.1 : Plateforme pour la cartographie du potentiel de surface.

Cette plateforme se compose d'un système de positionnement 3d. L'élément mouvant porte la sonde et se déplace selon les axes X , Y et Z . L'échantillon est fixé en bas sur un support métallique (3) lié au neutre. La sonde (Trek, modèle 3450) (1) est placée à 3 mm sur l'échantillon. C'est une sonde auto-compensée à induction électrostatique qui effectue les mesures sans contact avec le matériau. Un circuit électronique de conditionnement est associé à cette sonde connecté à un voltmètre électrostatique (Trek, modèle P0865) (4). Les mesures sont transmises au PC via une carte d'acquisition de données (NI USB 6210) (5). Le PC est équipé du logiciel Labview (6) pour le traitement des données acquises.

IV.3 Trajectoire suivie pour la mesure

La trajectoire proposée et présentée par la figure IV.2 est générée par un programme Gcode écrit pour commander le mouvement de l'effecteur de la plateforme. La trajectoire démarre au centre en suivant les flèches rouges et vertes présentées sur la figure IV.2. Ainsi, un balayage de la surface de l'échantillon est obtenu.




Figure IV.2 : Trajectoire utilisée pour le balayage.

La figure ci-après donne l'évolution de la position de la sonde en fonction du temps $(X(t), Y(t))$.




Figure IV.3 : La position (X, Y) de la sonde en fonction du temps.

En se déplaçant sur la trajectoire, la sonde prend des mesures à chaque 100 ms. Ces mesures sont acquises au PC et stockées dans un fichier de données (un fichier .xlsx par exemple). Une fois les données stockées, elles seront prêtes à l'utilisation.

La figure IV.4 présente les mesures du potentiel de surface déjà acquises en fonction du temps de leur acquisition. C'est une fonction notée $V_m(t)$.




Figure IV.4 : Potentiel de surface mesuré sur la trajectoire en fonction du temps.

Les mesures $X(t)$, $Y(t)$ et $V_m(t)$ conduisent à la présentation en 3d du potentiel mesuré sur la trajectoire donnée $(X(t), Y(t))$. C'est une courbe paramétrique tridimensionnelle. Cette courbe est présentée par la figure IV.5.




Figure IV.5 : Potentiel de surface mesuré sur la trajectoire.

IV.4 « Surface fitting » à l'aide d'un réseau de neurones RBF (Radial Basis Functions Neural network)

Pour préparer les calculs qui vont suivre, nous allons générer une surface qui donne la distribution du potentiel de surface à n'importe quel point (x, y) . Ce qui nécessite la connaissance d'une fonction à deux variables $V_m(x, y)$. Cette fonction n'est pas connue mais elle sera approximée par un réseau de neurones RBF. L'apprentissage du réseau RBF se fait en utilisant les mesures déjà acquises et sauvegardées. La figure IV.6 présente en rouge les mesures prises pour l'apprentissage. Sur cette figure aussi, la validation de l'approximation est montrée par la courbe verte qui est très proche de la courbe originale (la courbe bleue).




Figure IV.6 : Potentiel de surface mesuré, données utilisées dans l'apprentissage et potentiel prédit après apprentissage.

En utilisant le réseau RBF déjà entraîné, nous pouvons tracer la surface de distribution du potentiel mesuré comme présentée à la figure IV.7.




Figure IV.7 : Surface fitting avec un réseau de neurones RBF

IV.5 Modélisation et caractéristiques de la sonde

Avant de pouvoir trouver la distribution réelle du potentiel de surface, on doit identifier la sonde. En fait, la sonde est un système (filtre spatio-temporel). Il donne la moyenne pondérée du potentiel de surface au voisinage d'un point et non pas le potentiel en ce point. La sonde est très rapide dans la prise de mesures ce qui signifie que la dynamique de la mesure est très rapide et le transitoire peut être négligé. Donc, pour le côté temporel, la mesure sera considérée constante et égale à la valeur présentée par la sonde. Même, le mouvement de la sonde n'affecte pas la mesure (en fait, l'effet est très faible voire négligeable car la réponse de la sonde selon la documentation Trek est inférieure à $200\mu s$).

Donc, afin de caractériser la sonde, nous réalisons deux expériences. Dans la première, un disque en cuivre de 35 mm de rayon connecté à $-500V$ sera utilisé. Dans la deuxième expérience, nous utiliserons un rectangle en cuivre de 20 mm de largeur et connecté à $-500V$.

Le mouvement de la sonde, sur l'échantillon à 3 mm de haut, est présentée par la figure IV.8.

C'est un mouvement en va et vient pour assurer le balayage. La période d'échantillonnage utilisée pour l'acquisition est fixée à 100 ms .




Figure IV.8 : Deux expériences (a) un disque de 35mm de rayon (b) un rectangle de 20mm de largeur.

L'opération de prise des mesures est basée sur la convolution. La mesure n'est que le résultat de la convolution (temporelle et spatiale) de la distribution du potentiel de surface réel avec une certaine fonction. Cette fonction est le noyau de la convolution (spatiale) et elle est appelée « fonction d'étalement du point » ou PSF (Point Spread Function). Ainsi, la mesure du potentiel à un point donné n'égale pas le potentiel réel à ce point. La formule de convolution discrétisée est donnée comme suit :

$$Vm_{pq} = \sum_{i=1}^{i=N} \sum_{j=1}^{j=M} f_{ij;pq} \cdot Vr_{ij} \quad (IV.1)$$

pour $p = 1, \dots, N$, $q = 1, \dots, M$, $N = n_p + n_s - 1$ et $M = m_p + m_s - 1$.

La matrice représentant les mesures sur l'échantillon est de dimension $n_s \times m_s$ et la matrice représentant la PSF est de dimension $n_p \times m_p$.

Un réseau RBF est utilisé pour l'approximation de la distribution du potentiel de surface. Ce réseau RBF permet de générer des valeurs pour le potentiel mesuré autres que les valeurs déjà acquises. Le réseau RBF est donné par la formule

$$RBF(x, y) = \sum_{i=1}^N \sum_{j=1}^M w_{ij} \phi_{ij}(x, y) \quad (IV.2)$$

Où les $\phi_{ij}(\dots)$ présentent des fonctions symétriques radialement et les w_{ij} sont les poids déterminés par l'apprentissage.

La PSF est à symétrie radiale vu la forme de la sonde. La sonde positionnée au point (x_c, y_c) a sa PSF donnée par

$$f(x - x_c, y - y_c) = \varphi(r) \Big|_{r=\sqrt{(x-x_c)^2+(y-y_c)^2}} \quad (IV.3)$$

La fonction $\varphi(r)$ est un profil de la PSF présenté par la figure suivante avec son centre situé à l'abscisse $i = 11$.




Figure IV.9 : Exemple de profil de la fonction d'étalement du point (PSF : Point Spread Function).

La PSF est à deux variables spatiales (x, y) et elle est obtenue à partir du profil par différentes méthodes.

Pour calculer la PSF discrète notée f_{ij} , on suit les équations suivantes :

$$f_{ij} = \begin{cases} F_{C_{ij}}, & \text{pour } C_{ij} \geq 1 \\ 0, & \text{ailleurs} \end{cases} \quad (IV.4)$$

où

$$C_{ij} = \frac{n_p + 1}{2} - \text{round} \left(\frac{1}{2} \sqrt{\left(i - \frac{n_p + 1}{2}\right)^2 + \left(j - \frac{m_p + 1}{2}\right)^2} \right)$$

pour $(i, j) \in \{1, \dots, n_p\} \times \{1, \dots, m_p\}$.

Une autre méthode est donnée comme suit :

$$f_{ij} = \begin{cases} (1 - \alpha_{ij}) \cdot F_{a_{ij}} + \alpha_{ij} \cdot F_{1+a_{ij}}, & \text{pour } a_{ij} > 0 \\ 0, & \text{ailleurs} \end{cases} \quad (IV.5)$$

où

$$\beta_{ij} = \frac{n_p+1}{2} - \sqrt{\left(i - \frac{n_p+1}{2}\right)^2 + \left(j - \frac{m_p+1}{2}\right)^2},$$

$$a_{ij} = \text{round}(\beta_{ij}) \text{ and } \alpha_{ij} = \beta_{ij} - a_{ij}.$$

Donc, pour déterminer la PSF, il suffit de déterminer son profil.

Plusieurs approches existent pour la détermination de la PSF. Dans la première approche, les mesures $Vm_c(x) = Vm(x, \frac{y_{min}+y_{max}}{2})$ pour $x \in [x_{min}, x_{max}]$ sont utilisées.

Les valeurs $S_i = Vm_c(x_i)$ sont calculées pour des valeurs équidistantes de $x_i \in [x_{min}, x_{max}]$ et $i = 1, \dots, \frac{n_p+1}{2}$. La PSF discrète est une matrice aux éléments suivants f_{ij} , pour $(i, j) \in \{1, \dots, n_p\} \times \{1, \dots, m_p\}$.

Sachant que $S_i - S_{i-1} = \sum_{j=1}^{m_p} f_{ij}$ pour $i = 1, \dots, \frac{n_p+1}{2}$ et que $S_0 = 0$ et qu'en plus, dans la somme $\sum_{j=1}^{m_p} f_{ij}$ quelques éléments F_j sont répétés a_{ij} fois, alors le profil F_i sera calculé en utilisant l'équation suivante :

$$S_i - S_{i-1} = \sum_{j=1}^{\frac{(n_p+1)}{2}} a_{ij} F_j \tag{IV.6}$$




Figure IV.10 : Première approche : détermination des sommes S_i (points marqués en rouge) pour $n_p = m_p = 11$.

Dans la deuxième approche, l'algorithme de recherche stochastique est utilisé pour trouver le profil de la PSF. L'algorithme propose les F_i pour $i = 1, \dots, \frac{n_p+1}{2}$ d'une manière aléatoire et

génère la PSF discrète f_{ij} pour $i = 1, \dots, n_p$ et $j = 1, \dots, m_p$ en utilisant la première méthode de la symétrie radiale.

Dans la troisième approche, le fait que le profil est monotone est utilisé pour accélérer les calculs et le profil F_i est donné par la formule suivante :

$$F_i = \min(F_{i,SSA}, (1 - L) \cdot F_{i-1} + L \cdot F_{i+1}) \quad (IV.7)$$

pour $i = 2, \dots, \frac{n_p-1}{2}$ and $0 \leq L \leq 1$.

Nous allons utiliser trois approches pour la détermination de la PSF inverse de la sonde. Dans la première approche, une recherche stochastique est appliquée pour trouver tous les F_{inv_i} en même temps. La deuxième approche se base sur l'application répétitive de la recherche stochastique pour une seule F_{inv_i} choisie aléatoirement à chaque pas. La troisième approche est basée sur une recherche stochastique guidée en choisissant aléatoirement un élément F_{inv_i} et en faisant un seul pas dans deux directions en même temps et en gardant la meilleure valeur.

Toutes ces techniques sont appliquées en utilisant les données expérimentales présentées par la figure IV.11.




Figure IV.11: Potentiel mesuré sur la trajectoire (a) expérience 1(b) expérience 2.

L'approximation par un réseau RBF est donnée par la figure IV.12.




Figure IV.12 : Approximation par les réseaux de neurones RBF du potentiel mesurée
 (a) première expérience (b) deuxième expérience.

Plusieurs résultats sont obtenus pour chaque approche comme présentés par le tableau IV.1.

Tableau IV.1 : Comparaison des performances (norme ∞ / moyenne de la norme 1).

Le critère utilisé est basé sur :		
	Norme ∞	Moyenne de la norme 1
1 ^{ère} appr.	0.0510	0.0038
2 ^{ème} appr.	0.0376/0.0027	0.0391/0.0017
3 ^{ème} appr.	0.0379/0.0021	0.040/0.0017

Dans le tableau IV.2, on peut voir que le profil initial gaussien et ascendant est le meilleur choix pour avoir un minimum d'itérations ainsi une accélération dans la détermination de la PSF.

Tableau IV.2 : Effet de l'initialisation du profil de la PSF.

Profil initial	Nombre d'itérations	
	2 ^{ème} appr.	3 ^{ème} appr.
Constant (0.5)	74 - 137	92 - 99
Linéaire, ascendant	21	18
Gaussien, ascendant	02 - 09	01 - 06
Linéaire, descendant	178 - 243	263 - 548

Le meilleur profil de la PSF sous la forme gaussienne est donné comme suit :

$$F_i = e^{-\left(\frac{i-1}{4}\right)^2} \quad (\text{IV.8})$$

La figure IV.13 donne les différents résultats de la détermination de la PSF suivant les différentes approches utilisées.

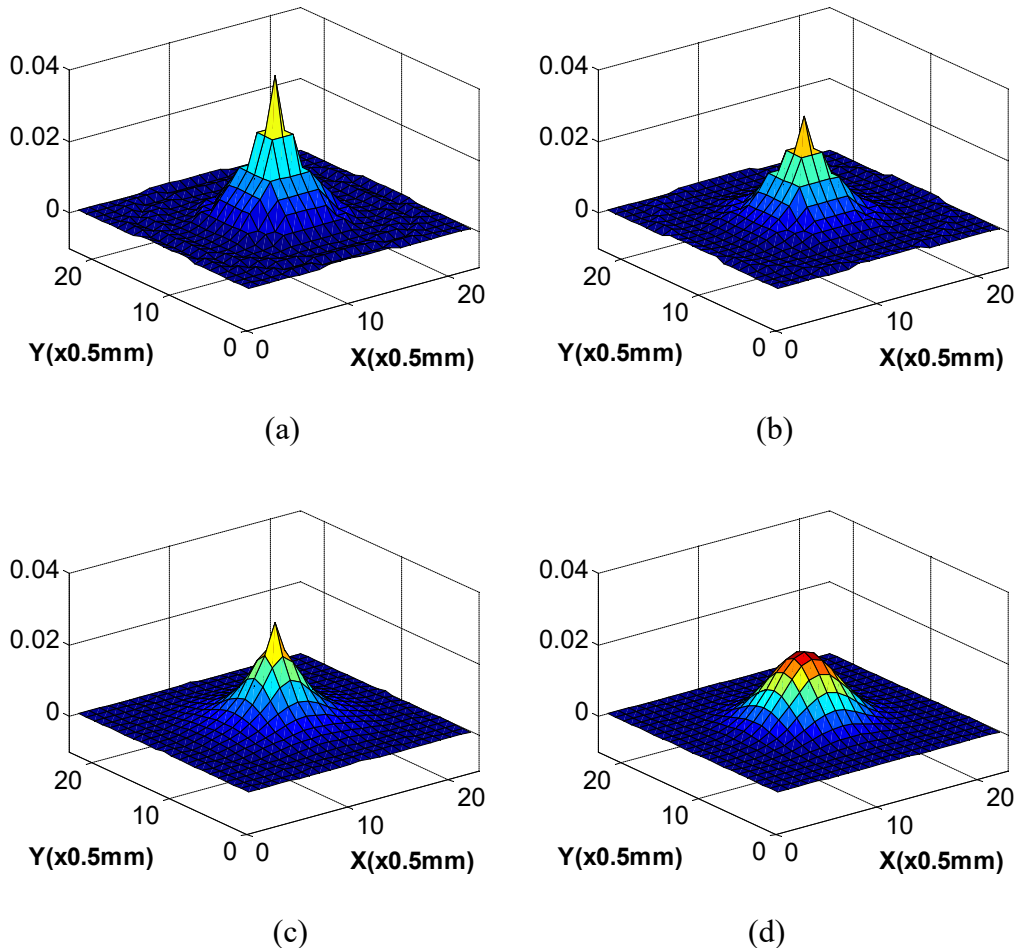


Figure IV.13 : Les PSF obtenues (a) 1^{ère} approche (b) 2^{ème} approche (c) 3^{ème} approche (d) la meilleure PSF sous la forme gaussienne.

Ces formes de la PSF sont proches mais ne sont pas identiques et il faut bien choisir la meilleure parmi elles. Le choix de la meilleure PSF suit les résultats de calcul des normes utilisées comme présentées dans le tableaux IV.1.

La figure IV.14 présente une comparaison graphique entre les différentes approches. On voit bien que c'est la troisième approche qui donne la meilleure PSF vu que le coût est le plus faible par rapport à ceux des autres approches.

La première approche est artificielle, pratique et il y a risque de manque de la précision. Elle donne des résultats proches à ceux de la deuxième approche au centre de la PSF alors qu'elle est très proche du résultat de la troisième approche quand on s'éloigne du centre de la PSF.

La PSF donnée sous la forme gaussienne est la mauvaise parmi ces approches surtout au centre de la PSF. Ce qui indique que la PSF n'est pas vraiment une gaussienne.

Donc en résumé, les approches proposées donnent des résultats proches et il faut bien choisir la PSF à utiliser dans l'étape de reconstitution de la distribution du potentiel réel.




Figure IV.14 : Comparaison des PSF obtenues (a) profils des PSF (b) coût en fonction des itérations pour la 2^{ème} et la 3^{ème} approche.

Pour les PSF inverses, Le tableaux IV.3 donne une comparaison entre les différentes approches utilisées.

Tableau IV.3 : Comparaison des performances.

	Norme ∞	Moyenne de la norme 1
1 ^{ère} approche	0.2607	0.0089
2 ^{ème} approche	0.2651	0.0084
3 ^{ème} approche	0.2452	0.008356

D'après le tableau IV.3, la troisième approche est la meilleure vu les valeurs de la moyenne de la norme 1. La norme ∞ ne permet pas de déterminer la meilleure approche.

Le tableau IV.4 montre l'effet du choix du profil initial pour la PSF inverse. On voit bien que le profil initial gaussien ascendant est le meilleur pour la deuxième et la troisième approche. Alors que le profil initial gaussien x cosinus est meilleur pour la première approche.

Tableau IV.4 : Effet de l'initialisation du profil de la PSF inverse.

Profil initial	Nombre d'itérations		
	1 ^{ère} appr.	2 ^{ème} appr.	3 ^{ème} appr.
Constant (0.5)	93	180	31
Linéaire, ascendant	49	47	16
Gaussien, ascendant	18	9	6
Gaussien x cosinus	14	12	8
Linéaire, descendant	84	227	55

Le meilleur profil sous la forme gaussienne x cosinus est donné comme suit :

$$F_{inv_i} = e^{-\left(\frac{i-12}{4}\right)^2} \cdot \cos\left(\frac{2\pi}{15} \cdot (i - 12)\right) \quad (\text{IV.9})$$

Les figures IV.15 et IV.16 montrent les résultats.

La figure IV.15 montre les différentes formes des PSF inverses obtenues, Ces PSF inverses se ressemblent et présentent des parties négatives (à la différence des PSF qui sont toujours positives). De plus, la PSF inverse prise comme donnée dans l'équation (IV.9) a une forme proche des autres mais elle n'est pas bonne pour l'obtention du potentiel de surface réel calculé.

La figure IV.16 (b) montre que la meilleure approche est la troisième vu la descente rapide du coût.

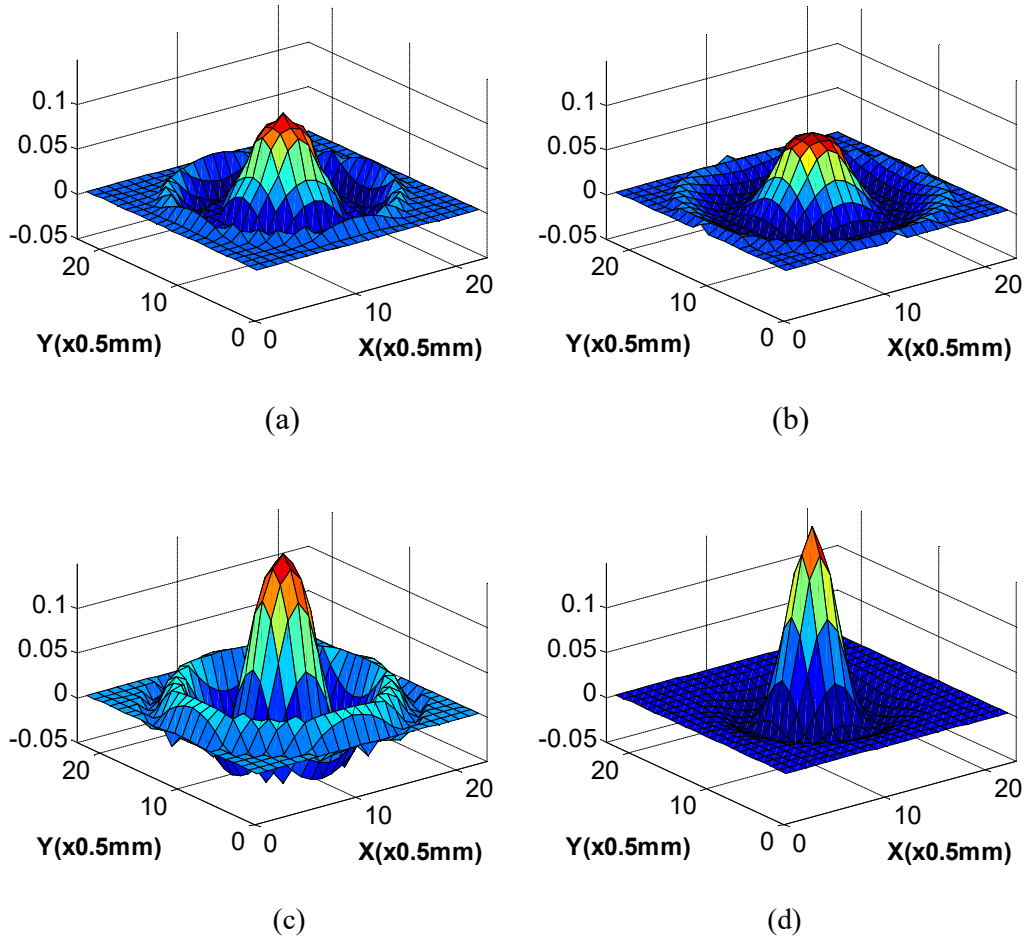


Figure IV.15 : Les PSF inverses obtenues (a) 1^{ère} approche (b) 2^{ème} approche (c) 3^{ème} approche (d) la meilleure PSF sous la forme gaussienne x cosinus.




Figure IV.16 : Comparaison des PFS inverse obtenues (a) profils des PFS inverse (b) coûts en fonction des itérations pour la 1^{ère}, la 2^{ème} et la 3^{ème} approche.

La validation théorique est basée sur des distributions réels théoriques du potentiel de surface de l'échantillon. Ces données théoriques sont générées en utilisant la PSF et son inverse. La figure IV.17 présente les distributions tests sous forme gaussienne et gaussienne X cosinus.

Le potentiel réel calculé est très proche du potentiel réel.

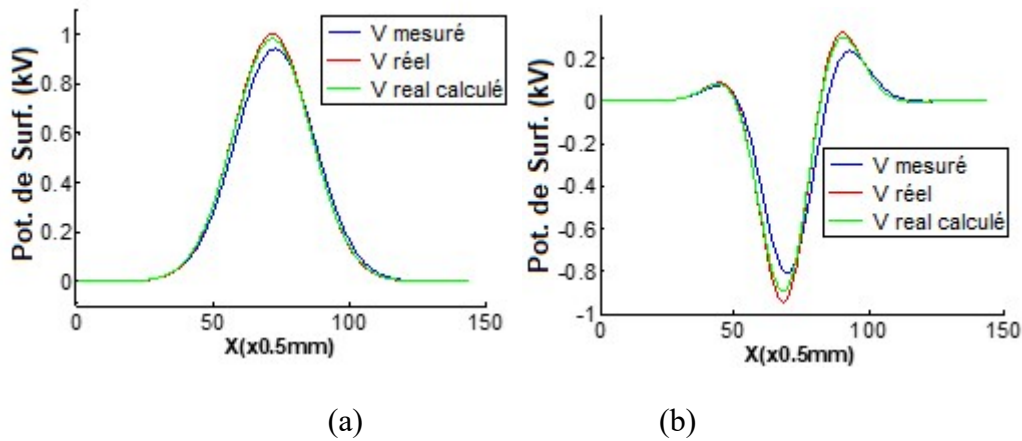


Figure IV.17 : Validation théorique : (a) Gaussienne (b) Gaussienne x cosinus.

Concernant la validation expérimentale, le bruit de mesure est négligeable et les erreurs sont causées par le mauvais alignement des lignes de balayage ce qui nécessite une étape de prétraitement des données collectées.

Les figures IV.18 et IV.19 montrent la validation expérimentale pour les PSF et les PSF inverses obtenues précédemment.

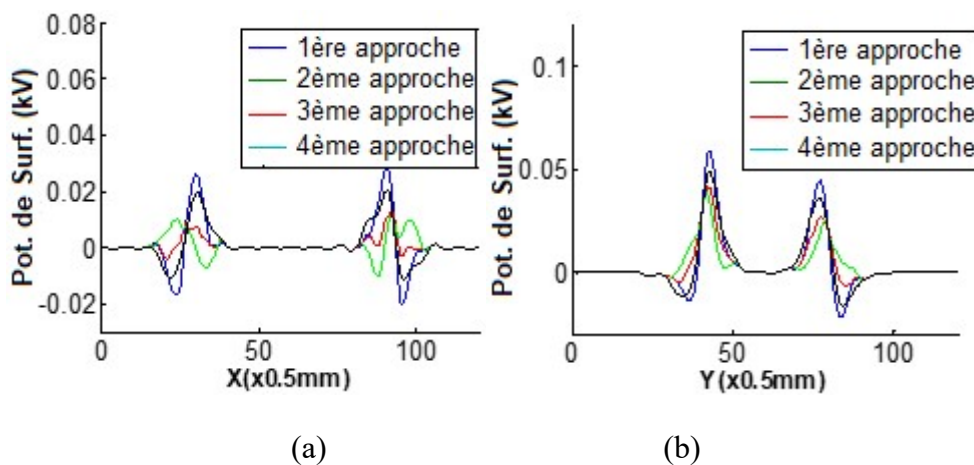


Figure IV.18 : Validation expérimentale pour les PSF (les erreurs : $V_m - V_{m_cal}$)

(a) 1^{ère} expérience (b) 2^{ème} expérience.




Figure IV.19 : Validation expérimentale pour les PSF inverses (les erreurs : $Vr - Vr_cal$)
 (a) 1^{ère} expérience (b) 2^{ème} expérience.

Les résultats présentés dans les figures IV.18 et IV.19 sont satisfaisants vu le passage brusque du potentiel de $0V$ à $-500V$ surtout pour les PSF vu que le potentiel mesuré Vm ne change pas brusquement. Concernant les PSF inverses, l'erreur maximale est proche de la moitié de la valeur du potentiel sur l'échantillon (en valeur absolue) et ceci est dû au fait que le potentiel réel change rapidement. La 4^{ème} approche est la plus mauvaise, car selon la figure IV.19 (b) elle présente la plus grande erreur loin du passage brusque du potentiel réel de $0V$ à $-500V$. En fait, le calcul du potentiel réel par le biais des PSF inverses est déconseillé comme nous allons le voir dans la section suivante concernant la reconstitution.

IV.6 Reconstitution du potentiel réel

Dans ce qui suit, nous allons prendre le modèle discret de la sonde (PSF discrète) présenté par la figure IV.20.

Dans sa forme discrète, la mesure est réalisée par la convolution spatiale à deux dimensions suivante :

$$Vm_{pq} = \sum_{i=0}^{i=n_p-1} \sum_{j=0}^{j=m_p-1} f_{ij} \cdot Vr_{p-\lfloor \frac{n_p}{2} \rfloor + i, q - \lfloor \frac{m_p}{2} \rfloor + j} \quad (IV.10)$$

Cette mesure est prise au point (p, q) où p et q sont les indices des coordonnées x et y après la discrétisation. La PSF notée f est donnée par la matrice dont les éléments sont f_{ij} . Les valeurs du potentiel réel prises dans la formule (IV.10) correspondent aux points les plus proches au point (p, q) . En d'autres termes, ces valeurs sont prises dans un voisinage du point (p, q) de la même taille que la matrice de la PSF.

Le potentiel mesuré V_m , la PSF f et le potentiel réel V_r sont donnés par des matrices de dimension $N \times M$, $n_p \times m_p$ et $n_s \times m_s$ respectivement et $p = 1, \dots, N$, $q = 1, \dots, M$, $N = n_p + n_s - 1$ and $M = m_p + m_s - 1$ et $[n_p/2]$ et $[m_p/2]$ sont les parties entières de $n_p/2$ et $m_p/2$ respectivement.




Figure IV.20 : La PSF de la sonde utilisée.

La mesure est faite selon la figure IV.21. Le disque et le rectangle sont en cuivre et ils sont portés par des supports (PCB) de 50mm x 50 mm de taille. Ils sont connectés à un potentiel égale à -500V.

La sonde se déplace avec une vitesse d'environ 900mm/min sur la trajectoire montrée par la figure IV.21.

La largeur du rectangle est égale à 20 mm alors que le disque a un diamètre égale à 35 mm.

Pour avoir les mesures sur la surface, la symétrie axiale pour le rectangle et la symétrie radiale pour le disque seront utilisées.

Toujours, la sonde est placée sur l'échantillon à une distance (hauteur) égale à 3mm comme recommandé par le fabricant de la sonde et le période d'échantillonnage est de 0.1s.




Figure IV.21 : Deux expériences avec un seul passage et considération de la symétrie (a) un disque de 35 mm de rayon (b) un rectangle de 20 mm de largeur.

L'algorithme de recherche stochastique est appliqué pour trouver le potentiel réel sur la surface de l'échantillon. Ce dernier sera noté par Vr_calc .

La recherche stochastique guidée est utilisée où aléatoirement et itérativement les meilleures valeurs de Vr_calc seront obtenues à partir des meilleures valeurs de l'itération précédentes. A chaque itération, trois matrices pour Vr_calc sont proposées à partir de petits changements des meilleures valeurs de l'itération précédente. La meilleure valeur est celle qui minimise le critère utilisé dans la recherche. Dans ce travail, nous avons utilisé deux critères, le premier est local pour chaque élément de la matrice Vr_calc et le deuxième est global et concerne toute la matrice Vr_calc .

Le critère local est donné comme suit :

$$J_{pq} = |Vm_{pq} - Vm_calc_{pq}| \quad (IV.11)$$

pour l'élément d'indices (p, q) de la matrice Vr_calc .

A chaque itération n , la matrice Vr_calc est calculée élément par élément en utilisant les équations suivantes :

$$Vm_calc_{pq,n} = \sum_{i=0}^{i=n_p-1} \sum_{j=0}^{j=m_p-1} f_{ij} \cdot Vr_calc_{p-\lfloor \frac{n_p}{2} \rfloor+i, q-\lfloor \frac{m_p}{2} \rfloor+j, n} \quad (IV.12)$$

La nouvelle valeur de $Vr_calc_{pq,n}$ est obtenue comme suit

$$Vr_calc_{pq,n, new} = \arg \min_{VR_{pq,n}} J_{pq,n} = \arg \min_{VR_{pq,n}} |Vm_{pq} - Vm_calc_{pq,n}| \quad (IV.13)$$

où

$$VR_{pq,n} = \{Vr_calc_L_{pq,n}, Vr_calc_C_{pq,n}, Vr_calc_R_{pq,n}\} \quad (IV.14)$$

et

$$\begin{cases} Vr_calc_C_{pq,n} = Vr_calc_{pq,n, old} \\ Vr_calc_L_{pq,n} = Vr_calc_{pq,n, old} - r_1 \cdot H_{max} \\ Vr_calc_R_{pq,n} = Vr_calc_{pq,n, old} + r_2 \cdot H_{max} \end{cases} \quad (IV.15)$$

Où H_{max} est le pas maximal de changement de la valeur courante de $Vr_calc_{pq,n}$ est r_1 et r_2 sont aléatoirement choisis dans l'intervalle $[0, 1]$ à chaque utilisation de cette équation.

Le critère local est utilisé pour obtenir la nouvelle valeur de l'élément $Vr_calc_{pq,n}$ de la matrice Vr_calc_n , en choisissant parmi $Vr_calc_C_{pq,n}$, $Vr_calc_L_{pq,n}$ et $Vr_calc_R_{pq,n}$, qui donne le plus petit $J_{pq,n}$.

Pour chaque élément $Vr_calc_{pq,n}$ de la matrice Vr_calc_n , la recherche est répétée itérativement plusieurs fois afin d'avoir les meilleures valeurs.

Le critère global est utilisé pour garder la meilleure matrice entre la nouvelle Vr_calc_n et l'ancienne meilleure Vr_calc déjà trouvée jusqu'à cette itération n . Ce critère est donné comme suit :

$$J = \|Vm - Vm_calc\|_{\infty} \quad (IV.16)$$

et

$$Vr_calc_{best_new} = \arg \min_{VR_n} (J_n, J_{best_old}) \quad (IV.17)$$

$$J_n = \|Vm - Vm_calc_n\|_{\infty} \quad (IV.18)$$

$$Vm_calc_{p,q,n} = \sum_{i=0}^{i=n_p-1} \sum_{j=0}^{j=m_p-1} f_{ij} \cdot Vr_calc_{p-\lfloor \frac{n_p}{2} \rfloor+i, q-\lfloor \frac{m_p}{2} \rfloor+j, n} \quad (IV.19)$$

La distribution du potentiel réel sur la surface de l'échantillon est obtenue par les étapes suivantes :

- Les mesures du potentiel de surface sont collectées le long de la trajectoire prise par la sonde à travers le disque ou le rectangle. Un seul passage suffit.
- Pour avoir des mesures sur la surface hors de la trajectoire, la symétrie radiale est utilisée dans le cas du disque et la symétrie axiale est utilisée pour cas du rectangle.
- A partir des mesures, des échantillons de valeurs du potentiel mesuré Vm , sont obtenus.
- Les échantillons de valeurs de Vm seront utilisés pour l'apprentissage d'un réseau de neurones RBF. Ceci permet d'avoir d'autres valeurs pour le potentiel mesuré Vm sur la surface du matériau.
- En utilisant le réseau RBF, des données Vm_{ij} sont générées à des points (x_i, y_j) bien choisis équidistants l'un au suivant.
- En utilisant les données Vm_{ij} et la PSF de la sonde, le potentiel réel calculé Vr_calc est déterminé en appliquant l'algorithme de recherche stochastique.
- Le potentiel réel calculé Vr_calc est utilisé pour l'apprentissage d'un réseau de neurones artificiels.
- Ce réseau de neurones artificiels donne la distribution réelle calculée du potentiel de surface. Le réseau lisse la distribution du potentiel réel calculé.

La figure IV.22 présente les mesures lors du passage de la sonde sur les deux échantillons.




Figure IV.22 : Le potentiel mesuré sur les trajectoire (a) 1^{ère} expérience (b) 2^{ème} expérience.

L'approximation par un réseau RBF donne les résultats de la figure IV.23.




Figure IV.23 : L'approximation par les réseaux de neurones RBF des potentiels de surface mesurés V_m (a) 1^{ère} expérience (b) 2^{ème} expérience.

La validation théorique est basée sur une distribution réelle du potentiel de surface V_r prise similaire aux expériences précédentes et sur un potentiel mesuré V_m théorique calculé en utilisant une PSF et le potentiel V_r .

Une troisième validation théorique est basée sur un potentiel mesuré théorique de distribution gaussienne donnée comme suit :

$$V_m(x, y) = -0.4 e^{-\left(\frac{(x-x_c)^2+(y-y_c)^2}{s^2}\right)} \tag{IV.20}$$

Où (x_c, y_c) est le centre de l'échantillon et s donne une idée sur l'étalement de cette distribution.

L'application de la recherche stochastique en utilisant le potentiel mesuré V_m et la PSF f donne le potentiel réel calculé V_r_calc illustré dans les figures IV.24, IV.25 et IV.26.

La figure IV.24 (a) donne le résultat de l'application de la recherche stochastique du potentiel réel calculé. On voit bien que la distribution trouvée est très bruitée. L'utilisation du réseau de neurones artificiels conduit à la distribution de la figure IV.24 (b). Cette distribution est lissée et une section montrée à la figure IV.24 (d) illustre la bonne solution. La figure IV.24 (c) présente le critère global utilisé qui descend rapidement vers une valeur minimale proche de zéro.

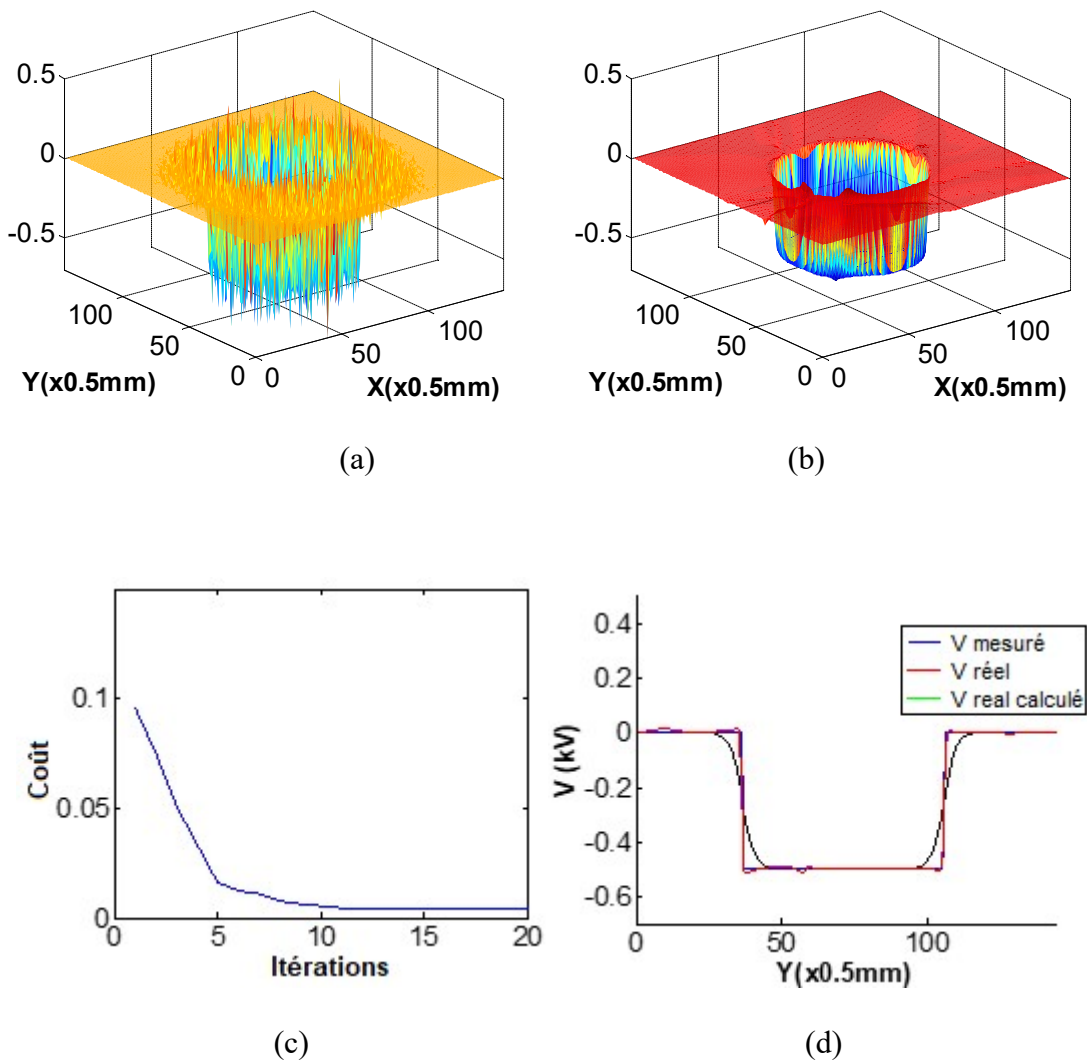


Figure IV.24 : Validation théorique (1^{er} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.

Les mêmes remarques sont données pour la deuxième et la troisième validation théorique.

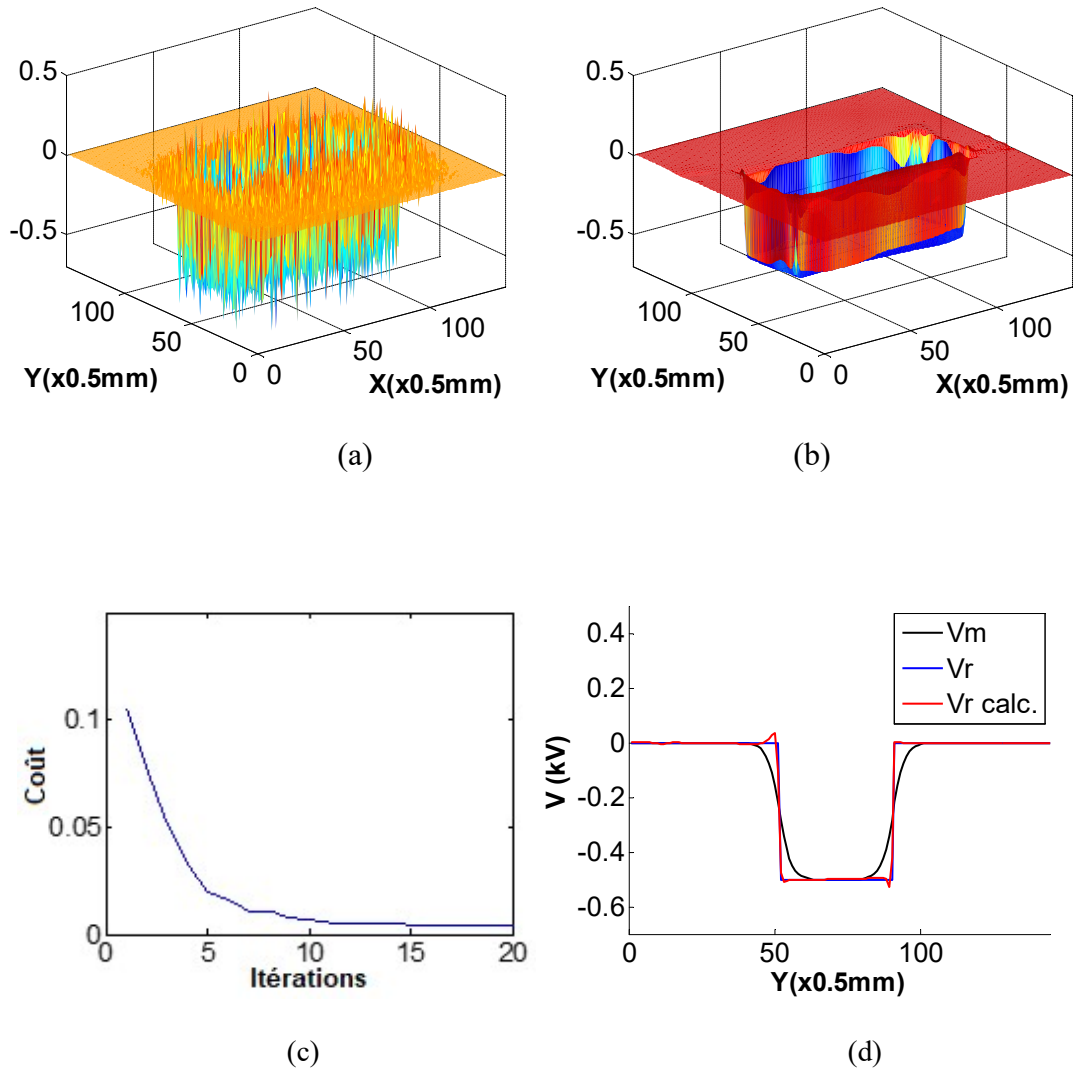


Figure IV.25 : Validation théorique (2^{ème} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.

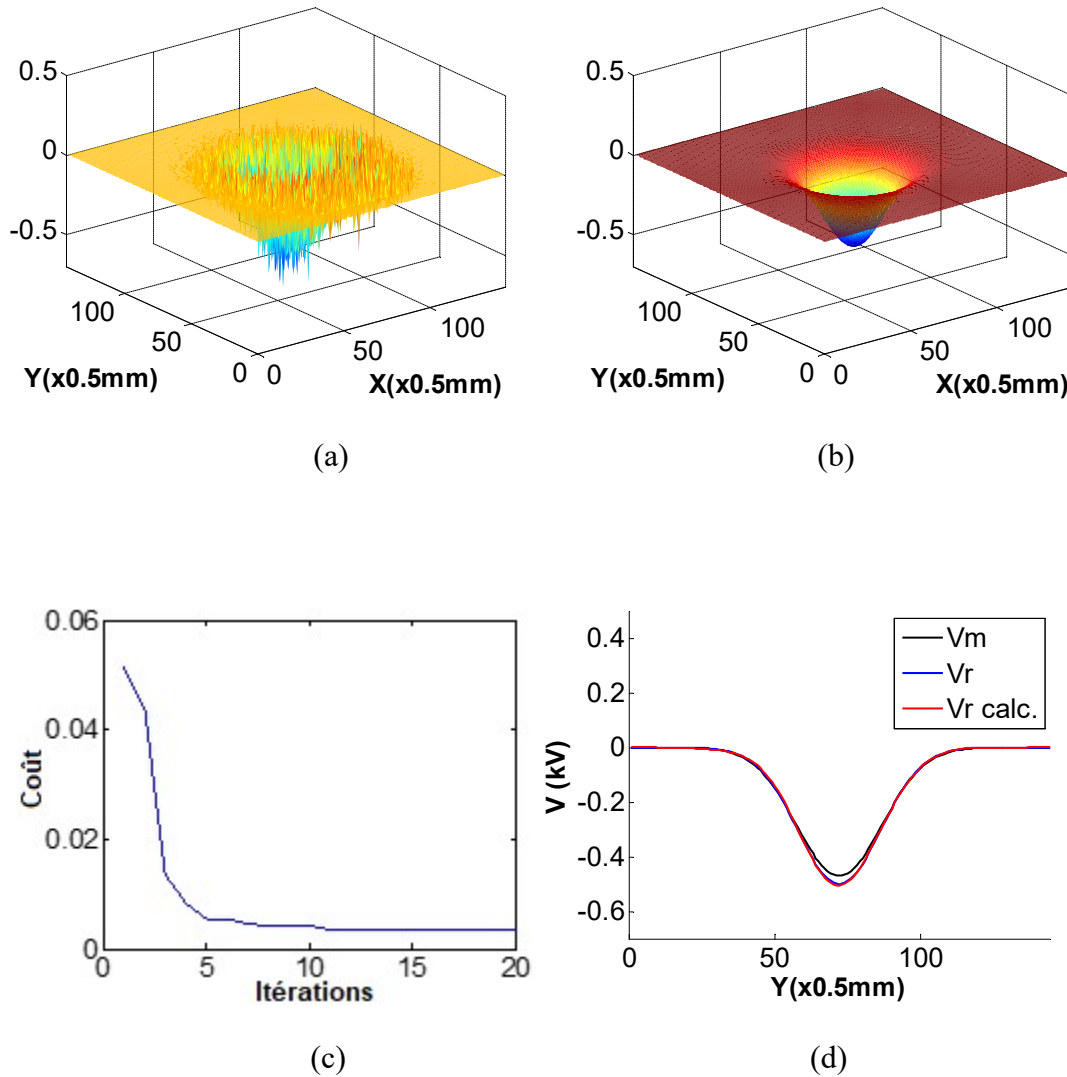


Figure IV.26 : Validation théorique (3^{ème} test) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.

Pour la validation expérimentale, nous appliquons l’algorithme de recherche stochastique en utilisant les données issues des approximations par les réseaux RBF.

Les figures IV.27 et IV.28 illustrent les résultats de cette validation. On voit bien la bonne correspondance entre le potentiel réel et le potentiel réel calculé avec la présence de quelques oscillations localisées à des points bien précis (passage brusque de 0V à -500V).

Pour la figure IV.27, les résultats sont satisfaisants alors que pour la figure IV.28 les résultats sont acceptables vue que l’approximation par le réseau RBF présente un problème dans les côtés gauche et droit du rectangle. En fait, pour l’apprentissage du réseau RBF, nous avons

imposé de valeurs nulles pour le potentiel mesuré hors la surface du rectangle ce qui présente des passages brusque de $0V$ à $-500V$ dans les côtés gauche et droit du rectangle.

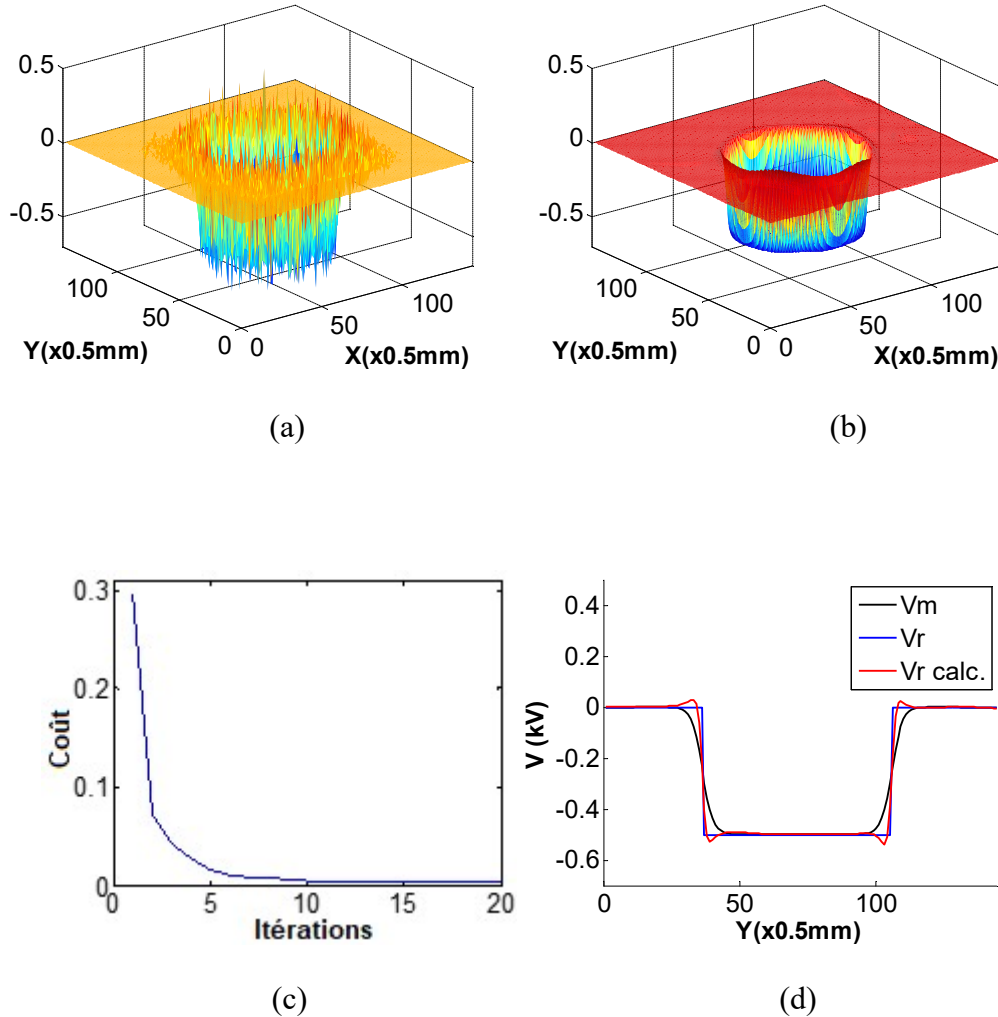


Figure IV.27 : Validation expérimentale (1^{ère} expérience) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.

Le critère tombe rapidement vers 0 ce qui montre la bonne distribution réelle calculée du potentiel de surface.

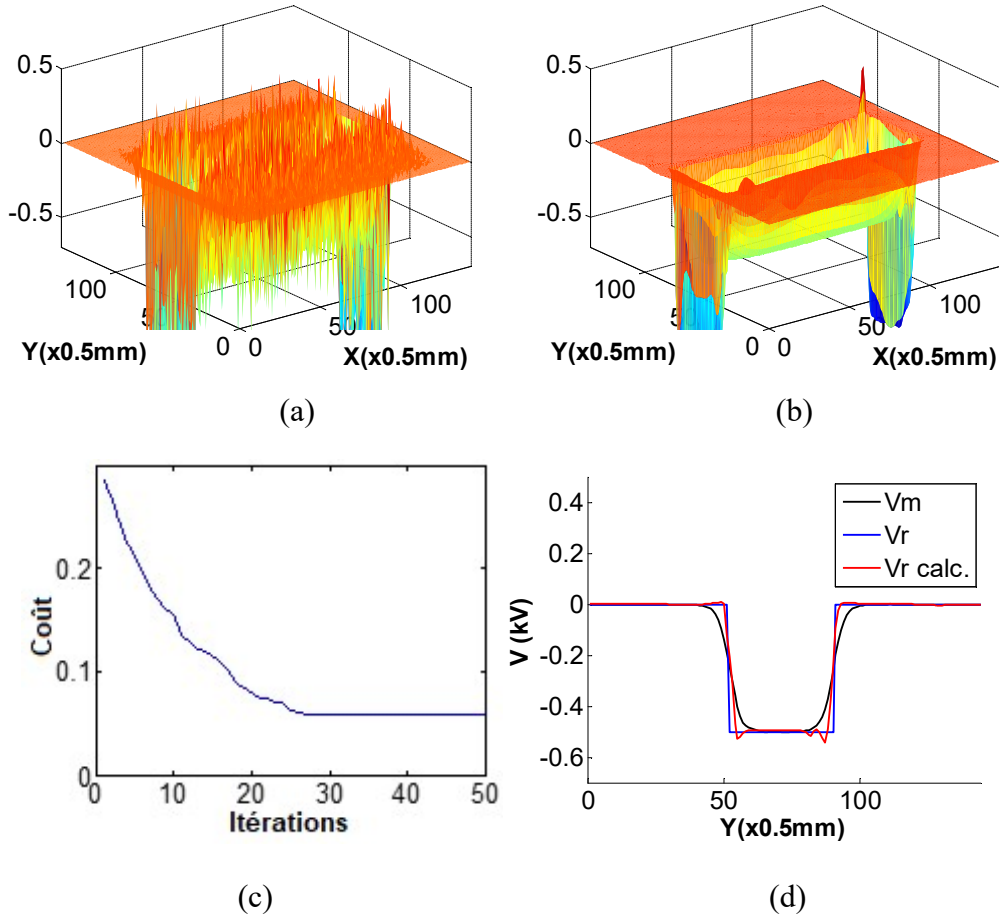


Figure IV.28 : Validation expérimentale (1^{ère} expérience) (a) recherche stochastique (b) lissage par un réseau de neurone (c) évolution du critère en fonction des itérations (d) prise de sections.

La reconstitution par l'utilisation de la PSF inverse est utilisée. Le calcul du potentiel réel est calculé en utilisant la formule suivante :

$$Vr_calc_{pq} = \sum_{i=0}^{i=n_p-1} \sum_{j=0}^{j=m_p-1} f_inv_{ij} \cdot Vm_{p-\lfloor \frac{n_p}{2} \rfloor + i, q-\lfloor \frac{m_p}{2} \rfloor + j} \quad (IV.21)$$

La PSF inverse utilisée est la meilleure calculée auparavant. Elle est présentée sur la figure IV.29. Les résultats sont présentés par la figure IV.30.

Ces résultats montrent l'utilisation de la PSF inverse et la convolution n'est pas adéquate pour la détermination du potentiel réel calculé. En fait, la convolution présente une bande passante limitée et n'arrive pas à suivre les changements rapides ou brusque surtout si la PSF ou la PSF inverse est large (moins localisée).




Figure IV.29 : La PSF inverse.




Figure IV.30 : Prise de sections du potentiel réel calculé en utilisant la PSF inverse (a) 1^{ère} expérience (b) 2^{ème} expérience.

Dans ce qui suit, nous allons appliquer sur les données expérimentales de la section IV.3.

Pour cette distribution, nous ne connaissons pas la distribution réelle du potentiel de surface et on ne peut pas vérifier les résultats. Mais, l'application sur les expériences tests ont validé la méthode de reconstitution proposée.

Les résultats sont présentés dans la figure IV.31. Le critère tend vers une valeur minimale proche de 0. Ceci valide le résultat et le potentiel réel calculé sera considéré comme égale au potentiel réel.

On voit bien une grande différence entre le potentiel mesuré et potentiel réel calculé.

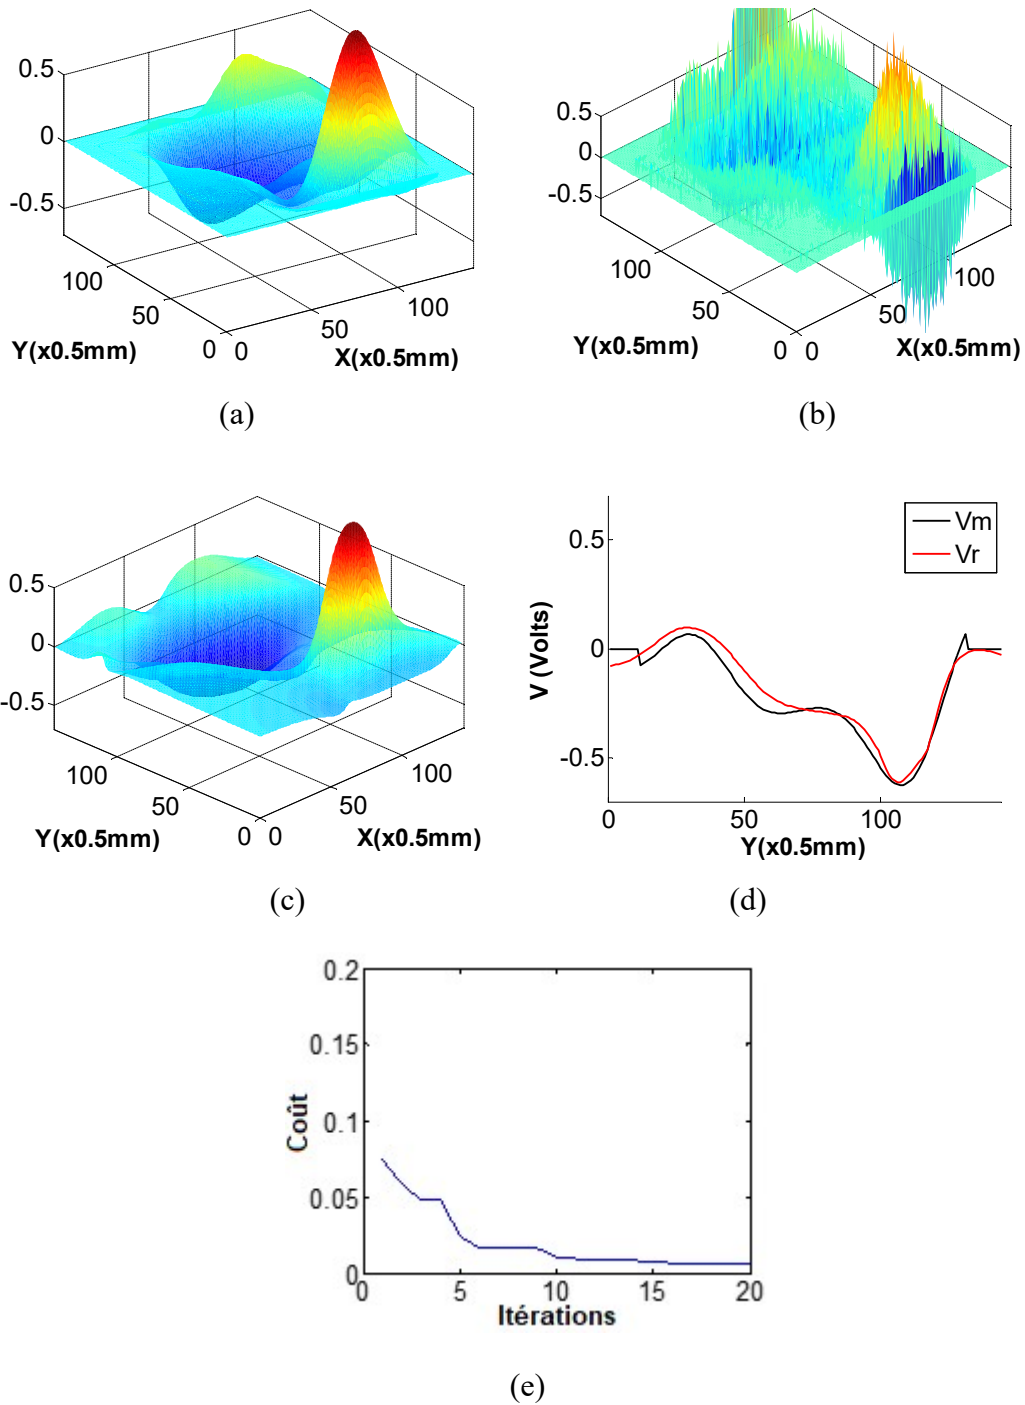


Figure IV.31 : Détermination de la distribution réelle du potentiel sur la surface d'un isolant chargé par tribo-électricité (a) potentiel mesuré représenté par le réseau de neurones RBF (b) potentiel calculé par l'algorithme de recherche stochastique (c) lissage du potentiel réel calculé en utilisant un réseau de neurone MLP (d) prise de sections (e) évolution du critère en fonction des itérations.

IV.7 Etude comparative de différentes approches pour la reconstitution du potentiel réel de surface

La sonde électrostatique auto-compensée, placée à 3mm de hauteur sur l'échantillon, mesure le potentiel au voisinage de sa position. Le balayage de la surface permet d'avoir une estimation approximative moyenne de la distribution du potentiel. Dans le cas de symétrie axiale, le balayage se réduit à un passage le long de cet axe.

La figure IV.32 présente une mesure obtenue expérimentalement.

Pour la validation théorique, nous allons utiliser les données présentées sur la figure IV.33.




Figure IV.32 : Données pratiques (expérimentales).




Figure IV.33 : Données théoriques.

Le potentiel mesuré est lié au potentiel réel par une convolution spatiale à deux dimensions. Le noyau de cette convolution est la fonction caractéristique de la sonde (Point Spread Function PSF). La fonction PSF est présentée sur la figure IV.34.




Figure IV.34 : Fonction caractéristique de la sonde (2d-Point Spread Function PSF).

La figure IV.35 présente la fonction PSF discrète dans le cas de la symétrie axiale.




Figure IV.35 : Fonction caractéristique de la sonde (1d-Point Spread Function PSF).

Les formules continue, discrète et monodimensionnelle qui lient les potentiels mesuré et réel sont données ci-après :

$$V_m(x_s, y_s) = \iint F(x-x_s, y-y_s) \cdot V_r(x, y) dx dy \quad (IV.22)$$

$$V_{m, p, q} = \sum \sum F_{i-p, j-q} \cdot V_{r, i, j} \quad (IV.23)$$

$$V_{m, p} = \sum F_{i-p} \cdot V_{r, i} \quad (IV.24)$$

Afin de pouvoir obtenir le potentiel réel à partir de la mesure, une déconvolution est nécessaire.

Dans ce qui suit, la reconstitution se fait itérativement en se basant sur les méthodes d'optimisation :

- Gradient
- Recherche stochastique
- Essaims de particules (PSO).

Les structures globales des méthodes proposées sont identiques. A chaque itération et au sens d'un certain critère global à minimiser, la meilleure valeur locale du potentiel réel est gardée et utilisée pour le calcul des valeurs locales pour les autres positions et même pour l'itération suivante.

Le calcul de la valeur locale du potentiel réel est basé sur un critère local. C'est la minimisation de ce critère local qui diffère d'une méthode à l'autre.

Les méthodes directes sont basées sur l'utilisation de l'erreur entre la valeur du potentiel local mesuré et sa valeur obtenue par la convolution numérique entre la fonction PSF et le potentiel réel calculé jusqu'à cette itération et cette position. L'équation suivante est utilisée :

$$V_{r i, k} = V_{r i, k-1} + \eta \cdot (V_{m i} - \sum F_{i-p} V_{r p, k-1}) \quad (IV.25)$$

avec i la position, k l'itération et η le pas de changement.

Cette formule est la généralisation des formules obtenues soit par les méthodes du point fixe ou du gradient, appliquées à la fonction suivante :

$$V_{m i} = \sum F_{i-p} V_{r p} \quad (IV.26)$$

Dans ce cas, à chaque itération et pour chaque position, une seule estimation est proposée.

La recherche stochastique guidée sera utilisée pour la reconstitution du potentiel réel. A chaque itération et pour chaque position, la valeur locale du potentiel réel est calculée à partir de la valeur courante V_{rC} comme suit :

$$V_{rL\ i,k} = V_{rC\ i,k-1} - h_{max} \cdot r \quad (IV.27)$$

$$V_{rR\ i,k} = V_{rC\ i,k-1} + h_{max} \cdot r \quad (IV.28)$$

La meilleure entre V_{rL} , V_{rC} et V_{rR} sera la nouvelle V_{rC} . Le pas $h_{max} > 0$ est fixe et r est choisi aléatoirement dans l'intervalle $[0,1]$.

Dans ce cas, à chaque itération et pour chaque position, deux estimations sont proposées et la meilleur est gardée dans 20 essais successifs. A la fin de ces 20 essais, la meilleure valeur est gardée est utilisée pour le calcul des valeurs locales du potentiel réel dans les autres positions et la prochaine itération.

Les méthodes basées sur les essaims de particules PSO font partie des méthodes stochastiques informées où les particules évoluent dans l'espace des solutions en se déplaçant d'une solution à une autre selon les informations issues des autres particules. La particule ayant la meilleure valeur V_{rb} pour le critère utilisé informe les autres qui vont se rapprocher d'elle avec certains pas aléatoires. Le calcul se base sur les formules suivantes :

$$\delta V_{r\ i,p,k} = K \cdot (\delta V_{r\ i,p,k-1} + c \cdot \eta \cdot (V_{r\ best,\ i,k-1} - V_{r\ i,p,k-1})) \quad (IV.29)$$

$$V_{r\ i,p,k} = V_{r\ i,p,k-1} + \delta V_{r\ i,p,k} \quad (IV.30)$$

avec i la position, p le numéro de la particule, k l'itération, $c > 0$ un pas constant, η choisi aléatoirement entre 0 et 1 et K le facteur de constriction.

Un essaim de 20 particules est utilisé avec 20 essais pour proposer une meilleure valeur locale du potentiel réel et ce pour chaque position et à chaque itération.

Les réseaux de neurones artificiels sont des approximateurs universels. L'apprentissage ajuste les paramètres (dits poids) des réseaux de neurones artificiels et permet d'avoir des modèles adéquats. Le bruit de mesure et autres changements rapides seront filtrés et éliminés. C'est cette caractéristique qui nous a conduit à utiliser les réseaux de neurones artificiels.

Pour obtenir le potentiel réel, nous procédons comme suit :

- Prendre la mesure du potentiel sur la surface (distribution spatiale).
- Utiliser un réseau de neurones artificiels pour modéliser cette distribution mesurée avec une bonne approximation.

- Utiliser ce réseau comme substitut (surrogate) pour générer de nouvelles données bien positionnées sur la surface (grille homogène à espacement régulier identique à celui de la PSF discrète).
- Utiliser les méthodes proposées pour calculer la distribution du potentiel réel.
- Utiliser un réseau de neurones artificiels avec un bon choix de sa taille afin d'éviter le sur-apprentissage pour modéliser la distribution du potentiel réel calculé.

Avec ce réseau, nous pouvons calculer le potentiel réel à n'importe quelle position sur la surface.

Afin de tester ces méthodes, une application est conduite sur des données théoriques qui sont obtenues par l'application de la convolution numérique entre la fonction PSF de la sonde et le potentiel réel théorique supposé connu. Cette convolution donne le potentiel mesuré de la figure IV.33.

Les résultats sont présentés par les figures IV.36 pour la méthode directe, IV.37 pour la méthode basée sur les essaims de particules (PSO) et IV.38 pour le cas de la recherche stochastique. Les figures IV.39 et IV.40 présentent respectivement les erreurs de reconstitution et l'évolution des critères en fonction des itérations. Sur la figure IV.40 un zoom est réalisé sur la courbe du critère pour le cas de la méthode basée sur les essaims de particules.




Figure IV.36 : Reconstruction du potentiel réel par la méthode directe à partir des données théoriques.




Figure IV.37 : Reconstruction du potentiel réel par la méthode basée sur PSO à partir des données théoriques.




Figure IV.38 : Reconstruction du potentiel réel par la méthode basée sur la recherche stochastique à partir des données théoriques.




Figure IV.39 : Comparaison entre les erreurs de reconstruction par les méthodes directe, PSO et stochastique en utilisant les données théoriques.




Figure IV.40 : Comparaison entre les critères à minimiser dans la reconstruction par les méthodes directe, PSO et stochastique en utilisant les données théoriques.

L'application sur les données expérimentales, donne les résultats présentés sur la figure IV.41 pour le cas direct, la figure IV.42 pour le PSO et la figure IV.43 pour la recherche stochastique.




Figure IV.41 : Reconstruction du potentiel réel par la méthode directe à partir des données expérimentales.

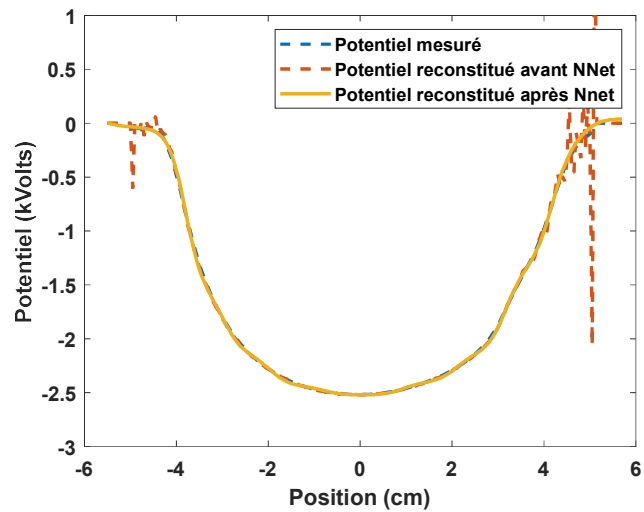


Figure IV.42 : Reconstruction du potentiel réel par la méthode basée sur PSO à partir des données expérimentales.




Figure IV.43 : Reconstruction du potentiel réel par la méthode basée sur la recherche stochastique à partir des données expérimentales.

Les figures IV.44 et IV.45 présentent, respectivement, les différences entre le potentiel mesuré et le potentiel calculé par la convolution dans le cas où le potentiel réel est égal au potentiel réel calculé et l'évolution des critères en fonction des itérations et ce pour les trois méthodes utilisées.




Figure IV.44 : Comparaison entre les reconstructions par les méthodes directe, PSO et stochastique en utilisant les données expérimentales.




Figure IV.45 : Comparaison entre les critères à minimiser dans la reconstruction par les méthodes directe, PSO et stochastique en utilisant les données expérimentales.

Les résultats montrent bien la validité et l'efficacité des méthodes proposées pour la reconstitution du potentiel réel à partir du potentiel mesuré.

De plus, l'utilisation des réseaux de neurones artificiels est bien justifiée comme montré sur les figures IV.36, IV.37 et IV.38 dans le cas de données théoriques et les figures IV.41, IV.42 et IV.43 pour les données expérimentales.

Les erreurs de reconstitution sont très faibles et présentent seulement des pics 10% dans les zones où le potentiel réel change brusquement.

Dans les cas pratiques, ce changement brusque n'est pas présent et le potentiel réel reconstitué est presque égal au potentiel mesuré. Ce résultat justifie l'utilisation de ce type de sonde pour la mesure du potentiel de surface et la considération de cette mesure comme étant le potentiel réel lui-même.

Les figures IV.40 et IV.45 montrent le comportement du critère global utilisé. Tous les critères descendent rapidement ce qui montre que la convergence des méthodes proposées est très rapide. La solution est obtenue au bout de quelques itérations. Cette convergence est améliorée par le fait que le potentiel mesuré est pris comme valeur initiale pour le potentiel réel à reconstruire.

La comparaison entre ces différentes méthodes montre la supériorité de celles basées sur les essais de particules. Les autres méthodes sont aussi très adéquates côté rapidité de calcul et précision.

IV.8 Conclusion

Dans ce chapitre, nous avons présenté la démarche suivie pour la reconstitution du potentiel réel à partir du potentiel mesuré. Différentes approches ont été présentées, testées et comparées. Après la présentation de la procédure de mesure, une expérience nous a permis de prendre des mesures où la sonde se déplaçait sur une trajectoire bien choisie pour le balayage de la surface de l'échantillon. Ensuite, nous avons caractérisé la sonde par la fonction PSF et la PSF inverse en utilisant plusieurs méthodes que nous avons proposées. Nous avons étudié et comparé ces méthodes afin de choisir la meilleure. Une fois la sonde caractérisée par la PSF, nous avons présenté, étudié et comparé plusieurs méthodes utilisées pour la reconstitution du potentiel réel de surface.

La démarche suivie pour la détermination du potentiel réel de surface à partir des mesures est bien structurée. L'utilisation des réseaux de neurones artificiels a garanti le lissage des surfaces mesurée et réelle calculée du potentiel de surface. De plus, la reconstitution du potentiel en utilisant la déconvolution numérique avec la PSF inverse est à éviter vu la bande passante limitée.

Les méthodes proposées sont très efficaces dans la reconstitution rapide du potentiel réel à partir du potentiel mesuré. Elles donnent très rapidement des résultats précis et fidèles. En plus, l'utilisation de ce type de sondes est très justifiée dans le cas où le gradient du potentiel de surface ne présente pas de changements brusques ou rapides.

Conclusion générale

Ce travail entre dans le cadre de la caractérisation des matériaux isolants, électriquement chargés, par la cartographie du potentiel de surface en utilisant des systèmes de positionnement à forte dynamique. Le positionnement et la mesure doivent se faire rapidement afin d'éviter l'effet du déclin du potentiel de surface. Ainsi, il faut bien choisir le système de positionnement et sa commande.

Dans ce travail, plusieurs techniques de commande adaptatives, prédictives, et intelligentes sont proposées. Les algorithmes basés sur l'intelligence artificielle côté logique floue, réseaux de neurones artificiels, neuro-flous, essaims de particules, et colonies d'abeilles artificielles sont combinés avec les techniques de commande automatique pour atteindre l'objectif d'une bonne régulation et poursuite de trajectoires utilisées dans le balayage.

Différents systèmes de positionnement ont été utilisés dans cette étude : moteur asynchrone, moteurs synchrones à aimants permanents, moteurs pas à pas, robot SCARA et robot Delta. Sur ces systèmes, ont été appliquées les stratégies de commande proposées. Des études par simulation concernant l'application de ces stratégies de commande ont été conduites afin d'évaluer leurs performances.

De plus, la cartographie ne peut pas se faire sans un bon système de mesure et d'acquisition ainsi que des algorithmes de reconstitution du potentiel de surface qui donne une image de la distribution des charges électriques sur la surface des matériaux.

Une analyse fonctionnelle a permis de définir les éléments à étudier pour réaliser ce travail. Ainsi, nous nous sommes focalisés à l'étude des composants clés nécessaires dans un système de positionnement rapide et fiable et sa commande basée sur les techniques avancées de l'automatique et de l'intelligence artificielle.

Nous avons commencé par la commande adaptative optimale basée sur la méthode du gradient appliquée à la MAS et vu son efficacité démontrée dans la poursuite de consignes avec de bonnes performances, nous l'avons améliorée par l'utilisation de la logique floue car elle présentait des oscillations à cause de la sensibilité de la méthode du gradient aux bruits et aux changements rapides de différents signaux. En fait, la logique floue a permis de fuzzifier la méthode du gradient et ainsi enlever la sensibilité aux bruits et au changement rapide des signaux. La validité de cette dernière approche a été vérifiée par simulation en l'appliquant à la

MAS et à l'association onduleur-MAS. Les bonnes performances de la dernière technique nous ont conduit à l'appliquer à la commande de la machine synchrone à aimants permanents MSAP et du moteur pas à pas MPP sans grand changement sauf pour les parties concernant les interconnexions entre les différents sous-systèmes. La technique de commande prédictive basée sur les réseaux de neurones artificiels et l'algorithme ABC a été appliquée à la MAS et les performances étaient prometteuses mais l'implémentation doit être faite en utilisant le calcul parallèle ou des FPGA.

Nous avons ensuite utilisé des robots pour le balayage de surface et plusieurs techniques de commandes ont été utilisées et appliquées aux robots SCARA et Delta. Un robot SCARA motorisé par deux MSAP régulés par la commande adaptative optimale basée sur la logique floue et ensuite un robot SCARA motorisé par deux moteurs pas à pas MPP ont été utilisés avec la même technique de commande. Dans les deux cas, les performances étaient acceptables pour les tâches de cartographie du potentiel de surface. Le cas du MPP était très apprécié vu les performances obtenues. La commande guidée par les données (à base de PID et à base de la commande prédictive) a été appliquée à un robot SCARA. De bonnes performances ont été obtenues dans la poursuite de trajectoire. De même, une autre commande prédictive avec des modèles de prédiction à base de réseaux de neurones artificiels et l'algorithme PSO pour l'optimisation a été utilisée, mais cette fois-ci la valeur de la commande a été quantifiée. Les résultats étaient prometteurs mais cette technique nécessite un bon calculateur pour pouvoir l'implémenter. Le robot Delta est léger et rapide et nous l'avons utilisé avec une commande floue et une autre neuro-floue adaptative et vu son modèle complexe nous avons utilisé un réseau de neurones artificiels pour apprendre le MGD et le MGI et ça a montré l'efficacité de la technique de commande mais avec des précautions à prendre de bien faire l'apprentissage des réseaux de neurones car sinon, des erreurs vont apparaître dans la poursuite dans les coordonnées opérationnelles. En plus, nous avons proposé une technique de commande robuste neuro-flou où un régulateur robuste obtenu par la synthèse H_∞ sert à stabiliser le système et ensuite un régulateur neuro-flou adaptatif assure la poursuite d'un modèle de référence.

La démarche suivie pour la reconstitution du potentiel réel à partir du potentiel mesuré a été présentée et différentes approches proposées ont été testées et comparées. La procédure de mesure était suivie et une expérience nous a permis de prendre des mesures où la sonde se déplaçait sur une trajectoire bien choisie pour le balayage de la surface de l'échantillon. Nous avons caractérisé la sonde par la fonction PSF et la PSF inverse en utilisant plusieurs méthodes que nous avons proposées avec comparaison entre ces méthodes afin de choisir la meilleure.

Nous avons présenté, étudié et comparé plusieurs méthodes utilisées pour la reconstitution du potentiel réel de surface. La démarche suivie pour la détermination du potentiel réel de surface à partir des mesures est bien structurée. L'utilisation des réseaux de neurones artificiels a garanti le lissage des surfaces mesurée et réelle calculée du potentiel de surface. La reconstitution du potentiel par la déconvolution numérique avec la PSF inverse est à éviter vu la bande passante limitée.

Les méthodes proposées de la reconstitution rapide du potentiel réel à partir du potentiel mesuré étaient très efficaces et elles donnent très rapidement des résultats précis et fidèles.

En plus, l'utilisation de ce type de sondes est très justifiée dans le cas où le gradient du potentiel de surface ne présente pas de changements brusques ou rapides.

A l'issue de ces travaux, nous pouvons proposer plusieurs types de plateformes destinées à la cartographie du potentiel de surface en se basant sur des structures robotisées (SCARA, Delta et même des robots cartésiens) ou simples (à base de moteurs pas à pas ou moteurs synchrones à aimants permanents et convoyeurs ou n'importe quel support mobile). Ces plateformes seront commandées par l'une des techniques de commande proposées et ainsi l'automatisation de la cartographie peut être couronnée finalement avec un bon pilotage de la plateforme. La cartographie est réalisée rapidement à l'ordre d'une minute maximum et la reconstitution est faite en quelques secondes vu les performances des approches proposées.

En plus, toutes les tâches de dépôt de charges, de mesure ou cartographie et de neutralisation pourront être automatisées et un fonctionnement répétitif de ces tâches peut être obtenu ce qui réduit le temps de les réaliser.

De plus, toutes les techniques de commande proposées peuvent être utilisées pour la commande d'autres types de systèmes (réseaux électriques, photovoltaïque, éolienne, ...).

En fait, l'intégration de l'intelligence artificielle s'avère très encourageante dans la commande, la modélisation, l'identification et en général dans l'automatisation et la conduite des systèmes.

Références bibliographiques

- [1] B. Tabti, "Contribution à la caractérisation des filtres à électret par la mesure du déclin du potentiel de surface", thèse de doctorat, Université de Poitier, 2011.
- [2] C.-S. Wang, "Electrostatic forces in fibrous filters-a review", *Power Technology*, Vol. 118, 200, pp. 166-170.
- [3] A. Jaworek, A. Krupa, T. Czech, "Modern electrostatic devices and methods for exhaust gas cleaning: Abrief review", *Journal of Electrostatics*, Vol. 65, 2007, pp. 133-155.
- [4] T. Hammi, "Etude de méthodes de mesures et réalisation d'un banc de test pour l'évaluation des propriétés électrostatiques des textiles", Thèse de Doctorat, Université des Sciences et Technologies de Lille, 2005.
- [5] T. Oda, J. Ochiai, "Charging characteristics of a nonwoven sheet air filter", *IEEE 6th International Symposium on Electrets, ISE 6 Proceedings*, 1988, pp. 515-519.
- [6] S. Q. Li, J. S. Marshall, "Discrete element simulation of micro-particle deposition on a cylindrical fiber in an array", *Aerosol Science*, Vol. 38, 2007, pp-1031-1046.
- [7] G. M. Sessler, "Electrets: recent developments", *Journal of Electrostatics*, Vol. 51-52, 2001, pp. 137-145.
- [8] E. Motyl, B. Lowkis, "Effect of air humidity on charge decay and lifetime of PP Electret nonwovens", *IBRES & TEXTILES in Eastern Europe*, Vol. 14, No. 5(59), 2006.
- [9] B. Lowkis, E. Motyl, "Electret properties of polypropylene fabrics", *Journal of Electrostatics*, Vol 51-52, 2001, pp.232-238.
- [10] J. van Turnhout, C. van Bachove, J. van Veldhuizen, "Electret fibers for high-efficiency filtration of polluted gases", *Sounderdruck aus Staub-Reinhaltung der Luft*, 36(1), 1976, pp. 36-39.
- [11] J. van Turnhout, J. H. M. Albers, W. J. Hoeneveld, J. W. C. Adams, L. M. van Rossen, "Non-woven electret fiber: a new filtering medium of high efficiency", *Proc. 5th Int. Conf. on Static Electrification*, London, 1979, *Inst. Phys. Conf. Ser.*, No. 48, 1979, pp.337-349.

- [12] J. van Turbhout, P. J. Droppert, M. Wubbenhorst, "PP-based blends for electret filters-an appraisal", VIII International Symposium of Electrets, Paris, 7-9 September 1994, pp. 961-966.
- [13] D. M. Taylor, P. E. Seeker, "Industrial electrostatics: fundamentals and measurements", New York: Wiley, 1994.
- [14] B. Neagoe, H-N. Teodorescu, Y. Prawatya, L. Dascalescu, T. Zeghloul, "Experimental bench for studying the relation between the dynamic characteristics of the frictional motion and the electric potential at the surface of polymer slabs in sliding conformal contact", Tribology International, 111, 2017, pp. 107-115.
- [15] G. S. P. Castle, "Contact charging between insulators", Journal of Electrostatics, 1997.
- [16] L. Calin, L. Caliap, V. Neamtu, R. Morar, A. Iuga, A. Samuila, L. Dascalescu, "Tribocharging of granular plastic mixtures in view of electrostatic separation", IEEE Trans Dielectr Electr Insul, Vol 44, 2008, pp. 1044-1051.
- [17] Z. Rymuza, "Tribology of polymers", Arch. Civ. Mech. Eng., Vol. 7, No. 4, 2007, pp. 177-184.
- [18] D. J. Lacks, R. M. Sankaran, "Contact electrification of insulating materials", J. Phys. D. Appl. Phys., Vol. 44, No. 45, 2011.
- [19] B. Neagoe, Y. Prawatya, T. Zeghloul, D. Souchet, L. Dascalescu, "Laboratory bench for the characterization of triboelectric properties of polymers", J. Phys. Conf. Ser., Vol. 646, 2015.
- [20] B. Tabti, L. Dascalescu, M. Popleanu, A. Antoniu, M. Mekideche, "Factors that influence the corona-charging of fibrous dielectric materials", J. Electrostat. Vol. 63, No. 2/3, 2009, pp. 193-197.
- [21] M. C. Plopeanu, L. Dascalescu, B. Neagoe, A. Bendaoud, P. V. Notingher, "Characterization of two electrode systems for corona-charging of non-woven filter media", J. Electrostat., Vol.71, 2013, pp. 517-523.
- [22] A. Bouteffaha, A. Boudaoud, A. Tilmatine, K. Medles, M. Plopeanu, L. Dascalescu, "Experimental and numerical characterization of corona discharge generated by a triode electrode system", IEEE Trans. Ind. Appl., Vol. 51, No. 3, 2015, pp. 2513-2519.
- [23] T. Sugimoto, H. Ishii, Y. Higashiyama, "Corona charging and current measurement using phi-type corona electrodes", IEEE Trans. Ind. Appl., Vol. 46, No. 3, 2010, pp. 1175-1180.

- [24] Y. E. Prawatya, M. B. Neagoe, T. Zeghloul, L. Dascalescu, "Surface-electric-potential characteristics of tribo- and corona- charged polymers: a comparative study", IEEE Trans. On Industry Applications, Vol 53, n° 3, Mai/Juin 2017.
- [25] B. Yahiaoui, M. Megherbi, A. Smaili, B. Tabti, A. Antoniu, L. Dascalescu, « Distribution of electric potential at the surface of corona-charged polypropylene non-woven fabrics after neutralization», IEEE Trans. Ind. Appl., Vol. 49, No. 4, 2013, pp. 1758-1766.
- [26] M. C. Plopeanu, L. Dascalescu, B. Yahiaoui, A. Antoniu, M. Hulea, P. V. Notingher, "Repartition of electric potential at the surface on nonwoven fabrics for air filtration", IEEE Trans. On Industry applications, Vol. 48, n° 3, Mai/Juin 2012.
- [27] A. Antoniu, B. Tabti, M. C. Plopeanu, L. Dascalescu, "Accelerated discharge of corona-charged non-woven fabrics", IEEE Trans. Ind. Appl., Vol. 46, No. 3, 2010, pp. 1188-1193.
- [28] P. Llovera, P. Molinié, A. Soria, A. Quijano, "Measurements of electrostatic potentials and electric fields in some industrial applications: basic principles", J. Electrostat., vol. 67, no. 2/3, 2009, pp. 457-461.
- [29] M. B. Neagoe, Y. E. Prawatya, T. Zeghloul, L. Dascalescu, "Electric-potential-measurement-based methodology for estimation of electric charge density at the surface of tribocharged insulating slabs", Journal of Electrostatics, Vol. 90, 2017, pp. 123-130.
- [30] T. Takuma, "Principle of surface charge measurement for thick insulating specimens," IEEE Trans. Dielectr. Electr. Insul., Vol. 10, 2003, pp. 285-290.
- [31] R. Kacprzyk, "Measurement of electrical potential of constant charge objects," IEEE Trans Dielectr. Elctctr. Insul. Vol. 19, 2012, pp. 134-139.
- [32] P. Llovera, P. Molinié, "New methodology for surface potential decay measurements- Application to study charge injection dynamics on polypropylene films", IEEE Trans. Dielectr. Electr. Insul., Vol. 11, No. 6, 2004, pp. 1049-1056.
- [33] B. Tabti, M. Mekideche, M. Plopeanu, L. M. Dumitran, L. Herous, L. Dascalescu, "Corona charging and charge decay characteristics of Non-woven filter media", IEEE Trans. Ind. Appl., Vol. 46, No. 2, 2010, pp. 634-640.
- [34] H. Mellouki, L. Herous, B. Neagoe, Y. Prawatya, L. Dascalescu, "Tribo and corona charging decay on polymers plates", The 15th International Conference on Electrical Engineering, October 29-31, 2017, Boumerdes, Algeria.

- [35] P. Molinié, "Charge injection in corona-charged polymeric films: potential decay and current measurements", *J. Electrostat.*, vol. 45, 1999, pp. 265-273.
- [36] M. C. Popleanu, B. Tabti, A. Antoniu, P. V. Notingher, L. M. Dumitran, L. Dascalescu, "Surface potential decay of charged non-woven media for air-filtration", 7th Conf. French Society of Electrostatics, Montpellier, France, 2010.
- [37] A. Antoniu, L. Dascalescu, I.-V. Vacar, M.-C. Plopeanu, B. Tabti, H.-N. L. Teodorescu, "Surface potential versus electric field measurements used to characterize the charging state of nonwoven fabrics", *IEEE Trans. on Industry applications*, Vol. 47, n° 3, Mai/Juin, 2011.
- [38] M. Debska, "Surface potential decay on triglycine sulfate crystal", *J. Electrostat.*, Vol. 63, No. 11, 2005, pp. 1017-1023.
- [39] M. Ieda, G. Sawa, I. Shinhara, "A decay process of surface electric charge across polyethylene film", *Jpn. J. Appl. Phys.*, Vol. 6, 1967, pp. 793-794.
- [40] H. J. Wintle, "Surface-charge decay in insulators with non-constant mobility and with deep trapping", *J. Appl. Phys.*, Vol. 43, no. 7, 1972, pp. 2927-2930.
- [41] D. K. Das Gupta, "Surface charge decay on insulating films", in *Proc. IEEE Int.Symp. Elect. Insul.*, Boston, MA, 1988, pp. 269-299.
- [42] Z. Xu, L. Zhang, G. Chen, "Decay of electric charge on corona charged polyethylene," *J. Phys. D: Appl. Phys.* Vol. 40, 2007, pp. 7085-7089.
- [43] L. Herous, M. Nemamcha, M. Remadnia, L. Dascalescu, "Factors that influence the surface potential decay on a thin film of polyethylene terephthalate (PET)," *J. Electrostat.*, Vol. 67, 2009, pp. 198-202.
- [44] H. T. M. Haenen, "The characteristic decay with time of surface charges on dielectrics", *J. Electrostat.*, vol. 1, 1975, pp.173-185.
- [45] B. Tabti, B. Yahiaoui, B. Bendahmane, L. Dascalescu, "Surface potential decay characteristics of negative-corona-charged fibrous dielectric materials," *IEEE Trans. Diel. Electr. Insul.* Vol. 21, 2014, pp. 829-835.
- [46] G. Chen, Z. Xu, L. W. Zhang, "Measurement of the surface potential decay of corona-charged polymer films using the pulsed electroacoustic method", *Meas. Sci. Technol.* Vol. 18, No. 5, 2007, pp. 1453-1458.

- [47] M. Kachi, L. Herous, M. Nemamcha, M. Remadnia, "Investigation expérimentale du DPS par chargement couronne et tribochargement sur des films de polyethylene téréphtalate (PET)," in: 3rd Int. Conf. Electr. Eng., Algiers, Algeria, 2009, pp. 355-358.
- [48] A. Pedersen, "On the electrostatics of probe measurements of surface charge density," Gaseous Dielectrics V, Oxford, UK: Pergamon Press, 1987, pp. 235-240.
- [49] M. Kachi, M. Nemamcha, B. Tabti, L. Dascalescu, "Comparison between three measurement methods for characterizing the charge state of granular insulating materials", Journal of Electrostatics, Vol. 69, 2011, pp. 394-400.
- [50] A. Fatihou, L. Dascalescu, N. Zouzou, L. M. Dumitran, "Interpretation of surface potential measurements performed with the vibrating capacitive probe of an electrostatic voltmeter", IEEE Ind. Appl. Soc. Annu. Meet, IAS 2014, pp-1-6.
- [51] A. Fatihou, L. Dascalescu, N. Zouzou, M. B. Neagoe, A. Reguig, L. M. Dumitran, "Measurement of surface potential of non-uniformly charged insulating materials using non-contact electrostatic voltmeter", IEEE Trans. on Dielectrics and Electrical Insulation, Vol. 23, n° 4, Aout 2016.
- [52] M. H. Horenstein, "Measuring surface charge with a non-contacting voltmeter," Conf. Rec. IEEE/IAS Ann. Meet, Toronto, Canada, 1993, pp.1811-1816.
- [53] H. T. M. Haenen, "Potential probe measurement analysis and charge distribution determination," J. Electrostat., Vol. 2, 1976/1977, pp. 203-222.
- [54] M. A. Noras, "AC-feedback electrostatic voltmeter measurements: optimal measurement conditions," Application Note 3004, Trek Inc., 2002.
- [55] M. A. Noras, A. Pandey, "Surface charge density measurements", IEEE Ind. Appl. Mag., vol. 16, no. 4, 2010, pp. 41-47.
- [56] M. A. Noras, "Surface charge density measurements, uses and limitations of Kelvin probe-based instruments", IEEE Industry Applications Magazine, Juillet/Aout 2010.
- [57] M. A. Noras, "Non-contact surface charge/voltage measurements: capacitive probe – principal of operation", Trek Inc., Application Note, number 3001, 2002.
- [58] M. A. Noras, "Non-contact surface charge/voltage measurements: fieldmeter and voltmeter methods", Trek Inc., Application Note, number 3002, 2002.

- [59] G. Cohen, S. U. Nanayakkar, J M. Luther, C. Held, R Bennewitz, A. Boag, Y. Rosenwaks, “Reconstruction of surface potential from Kelvin probe force microscopy images”, *Nanotechnology*, 24, 2013.
- [60] T. Machleidt, E. Sparreer, T. Kubertschak, R. Nestler, K-H Franke, “Kelvin probe force microscopy: measurement data reconstruction,” *Proc. SPIE*, 2009.
- [61] E. Strassburg, A. Boag, Y. Rosenwaks, “Reconstruction of electrostatic force microscopy images,” *Rev. Sci. Instrum.*, 2005.
- [62] T. Machleidt, E. Sparrer, D. Kapusi, K.-H. Franke, “Deconvolution of Kelvin probe force microscopy measurements—methodology and application”, *Meas. Sci. Technol.*, 20, 2009.
- [63] L. Qin, X. Zhou, P. Cao, “New control strategy for PMSM driven bucket wheel reclaimers using GA-RBF neural network and sliding mode control”, *Elektronika ir elektrotechnika*, n° 6, 2012, pp. 113-116.
- [64] L. Idkhajine, E. Monmasson, A. Maalouf, “Fully FPGA-based sensorless control for synchronous AC drive using an extended Kalman filter”, *IEEE Trans. Industrial Electronics*, Vol. 59, No. 10, 2012, pp. 3908-3918.
- [65] R. K. Kirshanan, “Electric Motor drives modeling, analysis, and control”, Prentice-hall publications, 2001.
- [66] F. Wang, Z. Ma, W. Gao, X. Zhao, Y. Tian, D. Zhang, C. Liang, “Dynamic modeling and control of a novel XY positioning stage for semiconductor packaging”, *Transaction of the institute of measurement and control*, vol. 37, n° 2, 2015, pp. 177-189.
- [67] T. Cai, M. Zhang, Y. Zhu, C. Hu, “Dynamic modeling and analysis of a 3-DOF ultra-precision positioning stage with air bearing”, *Procedia Eng.* Vol. 16, 2012, pp. 264-270.
- [68] S. Dejima, W. Gao, K. Katakura, et al., “Dynamic modeling, controller design and experimental validation of a planar motion stage for precision positioning”, *Precis Eng.*, vol. 29, 2005, pp. 263-271.
- [69] V. V. Suryawanshi, P. M. Sonawane, S. P. Deshmukh, “Design and development of stepper motor based XY scanning stage”, *International Journal of Innovative Research in science, Engineering and Technology*, vol. 4, n° 9, September 2015.

- [70] Y. Shimizu, Y. Peng, J. Kaneko, T. Azuma, S. Eto, W. Gao, T.-F. Lu, "Design and construction of the motion mechanism of an XY micro-stage for precision positioning", *Sensors and Actuators A* 201, 2013, pp. 395-406.
- [71] R.-F. Fung, Y. -L. Hsu, M.-S. Huang, "System identification of a dual-stage XY precision positioning table", *Precision Engineering*, vol. 33, 2009, pp. 71-80.
- [72] Document technique, "Robot cartésien xyzr", <https://robsytech.fr>, date de consultation 20/09/2025.
- [73] Y.-T. Tseng, J.-H. Liu, "High-speed and precise positioning on an X-Y table", *Control Engineering Practice*, vol.11, 2003, pp. 357-365.
- [74] K. Pietrusewicz, "Multi-degree of freedom robust control of the CNC X-Y table PMSM-based feed-drive module", *Archive of Electrical Engineering*, vol.6, n° 1, 2012, pp. 15-31.
- [75] X. Feng, X. Duan, D. Zhang, W. Liu, A. Sun, "Control system research of 2-DOF precision positioning table for IC packaging", *Advanced Materials Research*, Vols. 211-212, 2011, pp. 761-765.
- [76] J. R. Ryoo, T. -Y. Doh, M. J. Chung, "Compensator design for dual-stage actuator in the track-following servo system of optical disk drives", *IEEE Transactions on Consumer Electronics*, vol. 51(2), 2005, pp. 471-477.
- [77] U. Boettcher, R. A. D. Calafon, F. E. Talke, "Modeling and control of a dual stage actuator hard disk drive", *Journal of Advanced Mechanical Design, Systems and Manufacturing*, vol. 4(1), 2010, pp. 107-118.
- [78] H. Lim, J. W. Seo, C. H. Choi, "Position control of XY table in CNC machining center with non-rigid ballscrew," *Proceedings of the American Control Conference, Chicago (2000)*, pp. 1542-1546.
- [79] A. Hace, K. Jezernik, B. Curk, M. Terbuc, "Robust motion control of XY table for laser cutting machine", *Proceedings of the 1998 24th Annual Conference of the IEEE Industrial Electronics Society, Aachen, Germany, 1998*, pp. 1097-1102.
- [80] F. Wang, X. Zhao, D. Zhang, et al., "Robust and precision motion control for a directly driven XY table", *Proceedings of IMechE, Part C, Journal of Mechanical Engineering Science* 255(5), 2011, pp. 1107-1120.

- [81] S.-C. Mou, C.-H. Sung, "Fuzzy positioning control of the novel single-axis piezoelectric actuated stage", Proceedings of 2012 International Symposium on Computer, Consumer and Control, Taichung, Taiwan, 2012, pp. 771-776.
- [82] Q. S. Xu, Y. M. Li, "Radial basis function neural network control of an XY micropositioning stage without exact dynamic model", Proceedings of 2009 IEEE/ASME International Conference on Advanced Intelligent Mechatronics, Singapore, pp. 498-503, 2009.
- [83] N. H. Giap, J.-H. Shin, W.-H. Kim, "Robust adaptive neural network control for XY table", Intelligent Control and Automation, 2013,4, 293-300.
- [84] F. J. Lin, P. H. Shen, "Robust fuzzy neural network sliding-mode control for two-axis motion control system," IEEE Transactions on Industrial Electronics, vol. 53, no. 4, 2006, pp. 1209-1225.
- [85] Q. Gu, Y. Li, P. Niu, J. Sun, "Optimized design of SoC-based system for multi-axis drive", Elektronika ir elektrotechnika, Vol. 20, n° 7, 2014.
- [86] Y. -S. Kung, R.-F. Fung, T. -Y. Tai, "Realization of a motion control IC for X-Y table based on novel FPGA technology", IEEE Trans. Industrial Electronics, Vol. 56, No. 1, 2009, pp. 43-53.
- [87] Y. -S. Kung, T. -W. Tsui, N.-H. Shieh, "Design and implementation of a motion controller for XYZ table based on multiprocessors SoPC", in 2009 Chinese Control and Decision Conf., Guilin, 2009, pp. 258-268.
- [88] H.-H. Chou, Y-S. Kung, J.-M. Lin, "FPGA-Realization of a multi-axis motion controller", The 14th IFToMM World Congress, Teipei, Taiwan, October 25-30, 2015.
- [89] K. Ohnishi, M. Shibata, T. Murakami, "Motion control for advanced mechatronics", IEEE/ASME Trans. Mechatron., vol. 1, 1996, pp. 56-67.
- [90] F. L. Lewis, D. M. Dawson, C. T. Abdullah, "Robot manipulator control theory and practice," 2nd ed., New York: Marcel Dekker, 2004.
- [91] J. J. E. Slotine, W. Li, "Adaptive manipulator control: a case study", IEEE Trans. Automat. Contr., vol. 33, 1988, pp. 995-1003.
- [92] S. Salcudean, C. An, "On the control of redundant coarse-fine manipulators", In IEEE International Conference on Robotics and Automation, 1989.

- [93] Y. Xu, R. Liu, "Dynamic modeling of SCARA robot based on Udwadia-Kalaba theory", *Advances in Mechanical Engineering*, vol. 9(10), 2017, pp. 1-12.
- [94] Document technique, "Collaborative robotic arms: Z-Arm1832 Collaborative Robotic Arm", <https://www.scic-robot.com>, date de consultation 20/09/2025.
- [95] R. Clavel, "DELTA4, a fast robot with parallel geometry," *Proc. International Symposium on Industrial Robots*, 1998, pp. 92-100.
- [96] Y.-L. Kuo, "Mathematical modeling and analysis of the Delta robot with flexible links", *Computers and Mathematics with Applications*, vol. 71, 2016.
- [97] P. Vischer, R. Clavel, "Kinematic calibration of the parallel delta robot," *Robotica*, vol.16(2), 1998, pp. 207-218.
- [98] Document technique, "Robot Delta 4 axes industriel : MCI Robotics DR4-2-1200", <https://www.leobotics.fr/>, date de consultation 20/09/2025.
- [99] M. A. Laribi, L. Romdhane, S. Zegloul, "Analysis and dimensional synthesis of the DELTA robot for a prescribed workspace," *Mech. Mach. Theory*, vol.42, 2007, pp. 859-870.
- [100] K. Miller, "Experimental verification of modeling of DELTA robot dynamics by direct application of Hamilton's principle," *IEEE International Conference on Robotics and Automation*, vol. 1, 1995, pp.532-537.
- [101] J. Li, J. Wang, W. Chou, Y. Zhang, T. Wang, Q. Zhang, "Inverse kinematics and dynamics of the 3-RRS parallel platform," *IEEE International Conference on Robotics and Automation*, vol. 3, 2001, pp. 2506-2511.
- [102] St. Staicu, D. C. Carp-Ciocardia, "Dynamic analysis of Clavel's delta parallel robot," *IEEE International Conference on Robotics and Automation*, vol. 3, 2003, pp. 4116-4121.
- [103] S. B. Park, H. S. Kim, C. Song, K. Kim, "Dynamics modeling of a delta-type parallel robot," *The 44th International Symposium on Robotics*, 2013, pp. 1-5.
- [104] L. Zhang, Y. Song, "Optimal design of the delta robot based on dynamics," *IEEE International Conference on Robotics and Automation*, 2011, pp. 336-341.
- [105] L. Brezina, M. Holub, L. Cintula, J. Kovar, "Delta robot design," *Solid State Phenom.*, 2013, pp. 9-14.
- [106] F. Asadi, A. Heydari, "Analytical dynamic modeling of Delta robot with experimental verification", *Proc IMechE Part k: J. Multi-body Dynamics*, 2020, pp. 1-8.

- [107] G. W. Lee, F. T. Cheng, "Robust control of manipulators using the computed torque plus H_∞ compensation method," Proc. IEE Control Theory Appl., Vol. 143, No. 1, 1996, pp. 64-72.
- [108] F. Lin, R. D. Brandt, "An optimal control approach to robust control of robot manipulators," IEEE Trans. Robotics and Automation, Vol. 14, No. 1, 1998, pp. 69-77.
- [109] L. Gonzalez, L. Aguilar, " H_∞ robust control design for an arm manipulator," J. Intelligent and Robotic System, Vol. 27, 2000, pp. 21-30.
- [110] B. Yao, M. Al-Majed, M. Tomizuka, « High-performance robust motion control of machine tools: an adaptive robust control approach and comparative experiments », IEEE Trans. on Mechatronics, Vol. 2, n° 2, Juin 1997.
- [111] H. S. Lee, M. Tomizuka, "Robust motion controller design for high-accuracy positioning systems", IEEE Trans. Ind. Electron., vol. 43, 1996, pp. 48-55.
- [112] J. Adamy, A. Flemming, "Soft variable-structure controls: A survey", Automatica, vol. 40, 2004, pp. 1821-1844.
- [113] V. V. Chalam, "Adaptive control system techniques and applications", DEKKER publishers.
- [114] M. Krstic, I. Kanellakopoulos, P. V. Kokotovic, "Nonlinear and adaptive control design", New York: Wiley, 1995.
- [115] K. Tamura, K. Ogata, P. N. Nikiforuk, "Design of nonovershoot MRACS with application to DC servo motor systems," Transactions of the ASME Journal of Dynamics Systems, Measurement, and Control, 113, 1991, pp. 75-81.
- [116] G. Shahgholian, M. Maghsoodi, J. Faiz, "Analysis of speed control in dc motor drive based on model reference adaptive control", Journal of Electric Power and Energy Conversion systems, Vol. 1, n° 2, summer 2016, pp. 66-71.
- [117] B. Seung-Min, K. Tae-Young, "An adaptive PID learning control of DC motors", IEEE/ICSMC, Vol. 3, Orlando, FL, 1997, pp. 2877-2882.
- [118] M. Koksai, F. Yenici, A. N. Asya, "Position control of permanent magnet DC motor by model reference adaptive control", IEEE/ISIE, 2007, pp. 112-117.
- [119] J. Hong, D. S. Bernstein, "Experimental application of direct adaptive control laws for adaptive stabilization and command following," in Proc. Conf. Dec. Contr., Phoenix, AZ, 1999, pp. 779-783.

- [120] S. George, F. Gajendran, "Model reference linear adaptive control of DC drives subjected to disturbances", *Journal of Institution of Engineers (India)*. Vol. 81, 2000, pp. 70-77.
- [121] L. Xu, B. Yao, "Output feedback adaptive robust precision motion control of linear motors", *Automatica*, no.37, 2001, pp. 1029-1039.
- [122] B. Yao, L. Xu, "Adaptive robust motion control of linear motors for precision manufacturing", *Mechatronics*, no. 12, 2002, pp. 595-616.
- [123] S. Domek, "Robust predictive model following control for uncertain nonlinear systems," 8th IEEE International Conference on Methods and Models in Automation and Robotics, Szczecin, 2002, pp. 787-792.
- [124] S. Highghat, S. D. Cairano, D. Konobrytskyi, S. Bortoff, "Coordinated control of a dual-stage positioning system using constrained model predictive control", *Proceedings of the ASME 2104 Dynamic Systems & Control Conference*, Octobre 22-24, 2014, San Antonio, TX, USA.
- [125] D. Lam, C. Manzie, M. C. Good, "Model predictive contouring control for biaxial systems", *IEEE Trans. Contr. Syst. Tech.*, vol. 21(2), 2013, pp. 552-559.
- [126] D. Q. Mayne, J. B. Rawlings, C. V. Rao, P. O. M. Scokaert, "Constrained model predictive control: stability and optimality", *Automatica*, vol. 36(6), 2000, pp. 789-814.
- [127] E. C. Kerrigan, "Robust constraints satisfaction: invariant sets and predictive control", PhD thesis, Dep. Of Engineering, University of Cambridge, Cambridge, UK, 2000.
- [128] J. Maciejowski, "Predictive control with constraints", Prentice Hall, 2002.
- [129] L. Hujun, L. Ning, "Generalized predictive control strategy of boiler-turbine coordination in thermal generating unit", *Control and Decision*, vol. 18, 2013, 31-36.
- [130] V. G. Rao, D. S. Bernstein, "Naïve control of the double integrator", *IEEE Control Systems Magazine*, octobre 2001.
- [131] A. R. Teel, "Global stabilization and restricted tracking for multiple integrators with bounded controls," *Syst. Contr. Lett.*, vol. 18, 1992, pp. 165-171.
- [132] S. P. Bhat, D. S. Bernstein, "Continuous finite-time stabilization of translational and rotational double integrators," *IEEE Trans. Automat. Contr.*, vol. 43, 1998, pp. 678-682.
- [133] F. Tyan, D. S. Bernstein, "Global stabilization of systems containing a double integrator using a saturated linear controller," *Int. J. Robust Nonlinear Contr.*, vol. 9, 1991, pp. 1143-1156.

- [134] D. Elleuch, T. Damak, "Robust Model-free control for robot manipulator under actuator dynamics", *Mathematical Problems in Engineering*, 2020.
- [135] M. Fliess, C. Join, "Model-free control and intelligent PID controllers: towards a possible trivialization of nonlinear control?", *Proceedings of the 15th IFAC Symposium on System Identification*, Saint-Malo, France, July 2009.
- [136] M. Fliess, C. Join, "Model-free control", *International Journal of Control*, Taylor & Francis, vol. 86, no. 12, 2013, pp. 2228-2252.
- [137] C. K. Lin, T. H. Liu, L. C. Fu, C. F. Hsiao, "Model-free predictive current control for interior permanent-magnet synchronous motor drivers based on current difference detection technique", *IEEE Trans. Ind. Electron.*, no. 61, 2013, pp. 667-681.
- [138] O. Kaynak, I. Rudas, "Application of soft computing methodologies in mechatronics", *Proceedings of the First Asian Control Conference*, Tokyo, Japan, 1995, pp. 53-56.
- [139] B. Lantos, "Some application of soft computing methods in systems modeling and control", *Journal of Advanced Computational Intelligence*, Vol.2, no. 3, 1998, pp. 82-87.
- [140] Y. S. Xiao, Q. D. Wu, G. X. Zhou, "Neural network-based parameters identification and adaptive speed control of AC drive system," *Proceedings of the IEEE International Conference on Industrial Technology*, Shanghai, 2-6 December 1996, pp. 118-121.
- [141] P. H. Kim, S. H. Sin, H. L. Baek, G. B. Cho, "Speed control of AC servo motor using neural networks," *Proceedings of the 5th International Conference on Electrical Machines and Systems*, Shenyang, 2001, pp. 691-694.
- [142] K. Hornik, M. Stinchcombe, H. White, "Multilayer feed-forward networks are universal approximators," *Neural networks*, vol. 2, no. 5, 1989, pp. 359-366.
- [143] A. Cozma, D. Pitica, "Artificial neural network and PID based control system for dc motor drives", *IEEE/OPTIM*, 2008, pp. 161-166.
- [144] Support de cours, " Explorez les réseaux de neurones en couches", <https://openclassrooms.com/>, date de consultation 20/09/2025.
- [145] G. L. Plett, "Adaptive inverse control of linear and nonlinear systems using dynamic neural networks," *IEEE Trans. On Neu. Net.*, Vol. 14, No. 2, 2003, pp. 360-373.

- [146] R. J. Prabhu, S. Saravanan, S. C. Vijayakumar, "Adaptive control of stepping motors using artificial neural networks", *International Journal of Engineering Science and Innovative Technology*, vol. 2, no. 4, 2013, pp. 228-232.
- [147] A. Rubaai, R. Kotaru, "Online identification and control of a DC motor using learning adaptation of neural networks," *IEEE Trans. On Ind. Appl.*, Vol. 36, No. 3, 2000, pp. 935-942.
- [148] S. Sabzevari, R. Heydari, M. Mohiti, M. Savaghebi, J. Rodriguez, "Model-free neural network-based predictive control for the robust operation of power converters", *Energies*, Vol.14, 2021.
- [149] H. Moumouh, N. Langlois, M. Haddad, "A novel tuning approach for MPC parameters based on artificial neural network", *Proceedings of the 2019 IEEE 15th International Conference on Control and Automation (ICCA)*, Edinburgh, UK, 16-19 July 2019, 2019, pp. 1638-1643.
- [150] L. Hui, C. Min, T. Ling, "Algorithm research of RBF neural network based on improved PSO », *Fire Control & Command Control*, Vol.37(2), 2012, pp.144-150.
- [151] L. Yongke, Z. Wenzhong, H. Tongdi, "RBF neural network with parameters optimized by particle swarm optimization algorithms of harmonic detection", *Automation & Instrumentation*, no. 6, 2011, pp. 133-136.
- [152] Billel Amiri, "L'architecture d'un réseau de neurones de type RBF", <https://www.researchgate.net/figure/>, date de consultation 20/09/2025.
- [153] W. Hui, L. Hujun, P. Lei, "The study of PSO-RBF neural network generalized predictive control strategy in unit plant", *4th International Conference on Advanced Materials and Information Technology Processing*, 2016.
- [154] L. Lin, L. Jianbing, N. Pengchao, "Optimization approach based on particle swarm for RBF neural network", *Journal of Shandong Electric Power College*, no.13, 2010, pp. 51-53.
- [155] A. A. A. El-Gammal, A. A. El-Samahy, "A modified design of PID controller for dc motor drives using particle swarm optimization PSO", *IEEE/POWERENG*, Lisbon, Portugal, 2009, pp. 419-424.
- [156] X. Wang, J. Xiao, "PSO-based model predictive control for nonlinear processes", *ICNC*, 2005, LNCS 3611, pp. 196-203.

- [157] P. Thepsatorn, A. Numsomran, V. Tipsuwanporn, T. Teanthong, "DC motor speed control using fuzzy logic based on Labview," IEEE/SICE-ICAES, Busan, Oct. 2006, pp. 3617-3620.
- [158] H. Yang, D. Dong, Y. Ren, J. Xu, S. Yang, "Study on fuzzy PID control in double closed-loop dc speed regulation system," IEEE/ICMTMA, Vol. 3, Shanghai, 2011, pp. 465-469.
- [159] Y. Khemissi, A. Abdulwahab, "Control the robot movement by fuzzy logic controller," IEEE/ICCEA, Vol. 1, 2010, pp. 37-41.
- [160] Y. T. Kim, "Adaptive Fuzzy Backstepping control of AC servo system in the presence of nonlinear dynamic effect and mechanical uncertainties," Automation Congress, WAC, Hawaii, 2008, pp. 1-8.
- [161] A. Suresh Kumar, M. Subba Rao, Y. S. K. Babu, "Model reference linear adaptive control of dc motor using fuzzy controller," IEEE/TECON, Hyderabad, 2008, pp.1-5.
- [162] K. Keerthi, M. S. Sathyanarayana, "Fuzzy implementation of model reference adaptive control of dc drives", IJSAT, Mai/Juin 2012.
- [163] F.-J. Lin, "Fuzzy adaptive model-following position control for ultrasonic motor", IEEE Transactions on Power Electronics, Vol. 12, 1997.
- [164] E. Cerruto, A. Consoli, A. Raciti, A. Testa, "Fuzzy adaptive vector control of induction motor drives", IEEE Transactions on Power Electronics, Vol. 12, 1997.
- [165] F. Mrad, G. Deeb, "Comparative analysis of conventional fuzzy logic, and adaptive fuzzy logic controllers", IEEE Transactions, 1999.
- [166] S. Z. Moussavi, M. Alasvandi, Sh. Javadi, "Speed control of permanent magnet DC motor by using combination of adaptive controller and fuzzy controller", International Journal of Computer Applications, vol. 52, 2012, pp. 11-15.
- [167] A. Iqbal, H. Abu-Rub, H. Nounou, "Adaptive fuzzy logic-controlled surface mount permanent magnet synchronous motor drive", Systems Science & Control Engineering, 2:1,2017, pp. 465-475.
- [168] A. Meroufel, M. Massoum, B. Belabbes, "Model reference adaptive fuzzy controller for permanent magnet synchronous motor", Mediamira Science Publisher, vol. 50, no. 1, 2009.
- [169] N. J. Patil, R. H. Chile, L. M. Waghmare, "Fuzzy adaptive controllers for speed control of PMSM drive", International Journal of Computer Applications, vol.1, no. 11, 2010.

- [170] M. Kadjoudj, N. Golea, M. E. Benbouzid, "Fuzzy rule-based model reference adaptive control for PMSM drives", *Serbian Journal of Electrical Engineering*, vol. 4, no. 1, 2007, pp. 13-22.
- [171] Ch. U. M. Rao, B. M. Krishna, A. L. Soundarya, N. K. Kumari, "Field oriented control of PMSM with model reference adaptive control using fuzzy-PI controller", *IJCTA*, vol. 8, no. 1, 2015.
- [172] R. Jahani, H. C. Nejad, H. A. Shayanfar, A. Zare, "Positioning control of PM stepper motor based on type-2 fuzzy robust control", *International Journal on Technical and Physical Problems of Engineering*, vol.2, no. 4, 2010, pp. 19-26.
- [173] G. Mester, S. Pletl, "Application of optimal fuzzy-genetic control for SCARA type robot manipulator", *Proceedings of the 5th International Workshop on Robotics in Alpe-Adria-Danube Region, RAAD'96, Budapest, Hungary, 1996*, pp. 525-528.
- [174] S. Pletl, B. Lantos, "Advanced robot control algorithm based on fuzzy neural and genetic methods", *Jornal of advanced computational intelligence*, Vol. 5, n° 2, 2001.
- [175] R. -J. Wai, P.-C. Chen, "Robust neural fuzzy network control for robot manipulator including actuator dynamics", *IEEE Transactions on International Electronics*, vol. 53, no. 4, 2006, pp. 1328-1349.
- [176] J. -S. R. Jang, C.-T. Sun, "Neuro-fuzzy modeling and control", *Proceedings of the IEEE*, Vol.3, 1995, pp. 378-406.
- [177] S. Z. Moussavi, M. Alasvandi, S. JAvadi, E. Morad, "PMDC Motor speed control optimization by implementing ANFIS and MRAC", *International Journal of Control Science and Engineering*, Vol.4, 2014.
- [178] J. S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system", *IEEE Transactions on Systems, Man and Cybernetics*, vol. 23, 1993, pp. 665-685.
- [179] S.V. Ustun, M. Demirtas, "Modeling and control of V/f-controlled induction motor using genetic-ANFIS algorithm", *International Journal of Energy Conversion and Management (Elsevier)*, vol. 50, 2009, pp. 786-791.
- [180] P. Melin, O. Castillo, "Intelligent control of a stepping motor drive using an adaptive neuro-fuzzy inference system", *International Journal of Information Sciences (Elsevier)*, vol. 170, 2005, pp. 133-151.

- [181] A. Kusagur, S. f. Kodad, B. V. Sankar Ram, “Modeling, design & simulation of an adaptive neuro-fuzzy inference system (ANFIS) for speed control of induction motor”, *International Journal of Computer Applications*, vol. 6, 2010, pp.29-44.
- [182] **A. Melahi**, B. Bendahmane, B. Yahiaoui, “Robust neuro-fuzzy control of high dynamics motors for surface potential cartography”, *Electrotechnic and computer systems*, vol 27, n° 103, 2018.
- [183] **A. Melahi**, M. B. Neagoe, B. Bendahmane, L. Dascalescu, “Using stochastic search algorithms and neural networks for the determination of the actual distribution of the electric potential measured by auto-compensated electrostatic induction probes”, *Journal of Electrostatics*, 118, 2022.
- [184] **A. Melahi**, B. Bendahmane, M. B. Neagoe, L. Dascalescu,” Probe Characterization Using Stochastic Search Algorithms and Radial Basis Functions Neural Networks”, 19th IEEE international Multi-Conference on Systems, Signals and Devices, Mai 06-10, 2022, Setif, Algeria.
- [185] **A. Melahi**, B. Bendahmane, “Robust manipulator control using quantified predictive control based on neural networks and particle swarm optimization”, *EPEE 2022*, Odessa, Ukraine.
- [186] **A. Melahi**, B. Bendahmane, “Predictive control based on neural networks and the bee colony algorithm applied to induction motor”, *EPEE 2023*, Odessa, Ukraine.
- [187] **A. Melahi**, B. Bendahmane, B. Yahiaoui, “Data-driven PID and predictive controllers applied to SCARA robot manipulator”, *EPEE 2024*, Odessa, Ukraine.
- [188] **A. Melahi**, A. Messaoudène, B. Bendahmane, B. Yahiaoui, “Adaptive neurofuzzy control of delta robot with neural networks based kinematics modeling for scanning operations”, *EPEE 2025*, Odessa, Ukraine.

Annexe 1 : Paramètres des systèmes utilisés

1.1. Paramètres de la machine asynchrone :

Résistance d'une phase statorique :	$R_s = 0.485 \Omega$
Résistance d'une phase rotorique :	$R_r = 0.485 \Omega$
Inductance cyclique statorique :	$L_s = 0.0274 H$
Inductance cyclique rotorique :	$L_r = 0.0274 H$
Inductance mutuelle cyclique propre :	$M = 0.0258 H$
Moment d'inertie :	$J = 0.031 \text{ kg.m}^2$
Coefficient de frottement :	$f = 0.081 \text{ N.m.s/rad}$
Nombre de pair de pole :	$p = 2$

1.2. Paramètres du moteur synchrone à aimants permanents :

Résistance statorique :	$R_s = 1.377 \cdot 10^{-1} \Omega$
Inductance (axe directe) :	$L_d = 8.524 \cdot 10^{-4} H$
Inductance (axe en quadrature) :	$L_q = 9.515 \cdot 10^{-4} H$
Moment d'inertie :	$J = 4.8 \cdot 10^{-3} \text{ Kg.m}^2$
Frottement visqueux :	$F_v = 8.5 \cdot 10^{-3} \text{ N.m.s/rad}$
Flux magnétique (aimants permanents) :	$\varphi_m = 9.515 \cdot 10^{-4} \text{ Wb}$
Nombre de paires de pôles :	$p = 4$

1.3. Paramètres du moteur pas à pas :

Résistance statorique :	$R = 10 \Omega$
Inductance statorique :	$L = 0.0011 H$
Nombre de dents du rotor :	$N_r = 50$
Moment d'inertie :	$J = 5.7 \cdot 10^{-6} \text{ Kg.m}^2$
Frottement visqueux :	$F_v = 0.001 \text{ N.m.s/rad}$
Constante du couple :	$K_m = 0.113 \text{ N.m/A}$

1.4. Paramètres du robot SCARA :

Masse du premier bras :	$m_1=15.91 \text{ kg}$
Masse du deuxième bras :	$m_2=11.361 \text{ kg}$
Longueur du premier bras :	$l_1=0.432 \text{ m}$
Longueur du deuxième bras :	$l_2=0.432 \text{ m}$
Coefficient de frottement visqueux du premier bras :	$f_{v1}=0.0085 \text{ N.m.s/rad}$
Coefficient de frottement visqueux du deuxième bras :	$f_{v2}=0.0085 \text{ N.m.s/rad}$
Moment d'inertie du moteur 1 :	$Im_1=0.0048 \text{ kg.m}^2$
Moment d'inertie du moteur 2 :	$Im_2=0.0048 \text{ kg.m}^2$
Rapport de réduction de vitesse pour le premier bras :	$n_1=120$
Rapport de réduction de vitesse pour le deuxième bras :	$n_2=50$

1.5. Paramètres du robot Delta :

Longueur des bras :	$l_1 = 0.26 \text{ m}$
Longueur des avant-bras :	$l_2 = 0.52 \text{ m}$
Distance Centre de la base-Moteurs :	$r = 0.164 \text{ m}$
Disposition des moteurs sur la base :	$\varphi_1 = 0 \text{ rad},$ $\varphi_2 = 2\pi/3 \text{ rad},$ $\varphi_3 = 4\pi/3 \text{ rad}$

Fonctions de transfert des moteurs :

$$G_i(s) = \frac{200}{s^2 + 10s + 100}, i = 1, 2, 3$$

Annexe 2 :

Voltmètre électrostatique (Trek, modèle P-0865)

Avec la sonde (Trek, modèle 3450)



TREK P0865

High-speed, high voltage electrostatic voltmeter for non-contacting surface voltage measurements in the range of 0 to ± 10 kVDC or peak AC.



The Trek® P0865 is a DC stable, precision electrostatic voltmeter for non-contacting surface voltage measurements in the range of 0 to ± 10 kVDC or peak AC. The Trek P0865 employs a field-nulling technique for non-contacting voltage measurement that achieves DC stability and high accuracy even if the probe-to-surface spacing changes. This permits measurements of either stationary or moving surfaces without the need to establish fixed spacing to maintain accuracy.

PRODUCT HIGHLIGHTS

- Zero control for offset nulling
- Easy-to-read LED display
- Precision voltage monitor provides a low-voltage replica of the measured electrostatic voltage for external monitoring purposes, or for use as a feedback signal in a closed-loop system
- Trek 3450 probe assembly includes a sensitive electrode and preamplifier, which is driven to the same potential as the measured value to eliminate arcing there between. A three meter cable permits remote probe positioning.
- Operated on a bench top, or with optional hardware, in a standard 19-inch rack
- NIST-traceable Certificate of Calibration provided with each unit

APPLICATIONS

- Charge accumulation monitoring of the LCD production processes
- Monitoring surface potentials in the electrostatic painting process
- Research and development in the electrophotographic process
- Measuring electrostatic potentials on polymers, rubber, fabrics, and paper

AT A GLANCE

Measurement Range

0 to ± 10 kVDC or peak AC

Measurement Accuracy

Better than $\pm 0.1\%$ of full scale

Speed of Response

Less than 200 ms for a 1 kV step change. Less than 5 ms for a 20 kV step change

Full Signal Bandwidth

DC to better than 50 Hz

©2020 Advanced Energy Industries, Inc.

TECHNICAL DATA

Performance Specifications ¹	
Measurement Range	0 to ±10 kVDC or peak AC
Accuracy	Better than ±0.1% of full scale (as referred to the voltage monitor).
Speed of Response	Less than 200 ms for a 1 kV step change. Less than 5 ms for a 20 kV step change. (10 to 90%)
Full Signal Bandwidth	DC to better than 50 Hz.
Stability	Drift with Time: Less than 100 ppm/hour, noncumulative. Drift with Temperature: Less than 200 ppm/°C.

Voltage Monitor Output ¹	
A BNC output provides a low-voltage replica of the measured voltage.	
Scale Factor	1/1000th of the measured voltage
Output Noise	Less than 20 mV rms ²
Output Impedance	Less than 0.1 Ω.

Voltage Display ¹	
4½ digit LED display.	
Range	0 to ±10,000 V
Resolution	1 V
Zero Offset	Less than ±2 counts, referred to the voltage monitor.
Sampling Rate	3 readings per second

Mechanical Specifications ¹	
Dimensions (H x W x D)	134 x 432 x 432 mm (5.25 x 17 x 17 in)
Weight	15 kg (33 lb)
Voltage Monitor Connector	BNC connector
Ground Receptacle	Green binding post

Operating Conditions ¹	
Temperature	0 to 40°C (32 to 104°F)
Relative Humidity	To 90%, noncondensing
Probe-to-Surface Separation	3 mm ±1 mm (recommended).

Electrical Specifications ¹	
Line Supply	Factory set for one of three nominal AC line voltages: 100 V, 115 V, or 230 VAC [CE compliant], at 48 to 63 Hz (specify when ordering).
AC Line Cord Receptacle	Standard three-prong line cord receptacle with an integral fuse holder

Features ¹	
High Voltage Ready LED	An LED indicator illuminates when the Trek P0865 is ready to make high voltage measurements.
High Voltage On/Off	A two-position toggle switch that turns on and off the high voltage power supply inside the instrument.
Zero Adjust	A 10-turn control to null offsets or other zero errors which occur within the system
Power On/Off	A two-position rocker switch that turns on and off the main power.

¹ All specifications are with a Trek 450 probe at a probe-to-surface separation of 3 mm, ±1 mm

² Measured using the true rms feature of the Hewlett Packard Model 34401A digital multimeter

REFERENCE NUMBERS

Trek P0865	
13424F	Trek P0865 Electrostatic Voltmeter (100 VAC)
13424G	Trek P0865 Electrostatic Voltmeter (115 VAC)
13424K	Trek P0865 Electrostatic Voltmeter (230 VAC)

Optional Accessories	
17218	Trek 3450EC Probe Extension Cable (from unit to probe)
17181	Trek 3460-1 Line Driver
C4062	607RA Full Rack Mount Kit (19 in)

Probes	
Standard Resolution	
17157	Trek3450 (side-viewing)
High Temperature Probes (up to 100°C)	
17284	Trek 3455ET (end-viewing)
17285	Trek 3453ST (side-viewing)

Résumé :

Dans ce travail, le pilotage et la caractérisation de positionnement à forte dynamique pour la cartographie du potentiel de surface ont été conduits étape par étape. D'abord, une présentation de l'état de l'art concernant les électrets, le dépôt de charges par décharge couronne ou par triboélectricité a été réalisée. L'intérêt est porté sur la mesure du potentiel de surface avant que son déclin soit remarqué. Pour cela, plusieurs méthodes de positionnement rapide ont été proposées avec système et commande. Les systèmes proposés pour le positionnement sont les moteurs comme le moteur synchrone à aimants permanents et le moteur pas à pas. De plus, nous avons utilisé des robots SCARA et Delta. Plusieurs techniques de commande ont été proposées et utilisées basées sur les l'automatique avancée et l'intelligence artificielle. Nous avons utilisé la commande adaptative optimale basée sur la logique floue, la commande prédictive basée sur l'algorithme ABC et les réseaux de neurones, la commande prédictive guidée par les données, la commande neuro-floue adaptative, la commande prédictive basée sur le PSO et les réseaux de neurones ainsi que la commande neuro-floue robuste. Pour effectuer la mesure du potentiel, il faut d'abord connaître la sonde utilisée en la caractérisant par sa PSF. Plusieurs méthodes ont été proposées pour la caractérisation de la sonde. Ensuite, la reconstitution du potentiel de surface a été abordée avec la proposition de méthodes et d'algorithmes fiables pour la déterminer avec précision.

Mots clés :

Potentiel de surface, positionnement, MSAP, MPP, robot SCARA, robot Delta, PSO, ABC, logique floue, réseaux de neurones artificiels, commande neuro-floue, commande adaptative, commande prédictive, sonde, PSF, reconstitution.

Abstract :

In this work, the monitoring and characterization of high dynamic positioning for surface potential mapping were conducted step by step. First, a presentation of the state of the art concerning electrets, charge deposition by corona discharge or triboelectricity was carried out. The interest is focused on measuring the surface potential before its decline is noticed. For this, several fast positioning methods have been proposed with system and control. The systems proposed for positioning are motors such as the permanent magnet synchronous motor and the stepper motor. In addition, we used SCARA and Delta robots. Several control techniques were proposed and used based on advanced automation and artificial intelligence. We used optimal adaptive control based on fuzzy logic, predictive control based on ABC algorithm and neural networks, data-driven predictive control, adaptive neuro-fuzzy control, predictive control based on PSO and neural networks as well as robust neuro-fuzzy control. To perform the potential measurement, it is first necessary to know the probe used by characterizing it by its PSF. Several methods have been proposed for the characterization of the probe. Then, the reconstruction of the surface potential was approached with the proposal of reliable methods and algorithms to determine it precisely.

Keywords :

Surface potential, positioning, MSAP, MPP, SCARA robot, Delta robot, PSO, ABC, fuzzy logic, artificial neural networks, neuro-fuzzy control, adaptive control, predictive control, probe, PSF, reconstruction.

ملخص:

في هذا العمل، أُجري توصيف تحديد المواقع ذي الديناميكية العالية لرسم خرائط الجهد السطحي خطوة بخطوة. في البداية، عُرضت أحدث التقنيات المتعلقة بالكهرباء الساكنة، وترسيب الشحنات عن طريق التفريغ الإكليلي، أو كهرباء الاحتكاك. وينصبّ الاهتمام على قياس الجهد السطحي قبل ملاحظة انخفاضه. ولهذا الغرض، اقترحت عدة طرق سريعة لتحديد المواقع باستخدام أنظمة وتحكم. ومن بين الأنظمة المقترحة لتحديد المواقع محركات مثل المحرك المتزامن ذي المغناطيس الدائم والمحرك الخطوي. بالإضافة إلى ذلك، استخدمنا روبوتات SCARA و Delta واقترحنا العديد من تقنيات التحكم التي استُخدمت بالاعتماد على الأتمتة المتقدمة والذكاء الاصطناعي. استخدمنا التحكم التكيفي الأمثل القائم على المنطق الضبابي، والتحكم التنبؤي القائم على خوارزمية ABC والشبكات العصبية، والتحكم التنبؤي القائم على البيانات، والتحكم العصبي الضبابي التكيفي، والتحكم التنبؤي القائم على PSO والشبكات العصبية، بالإضافة إلى التحكم العصبي الضبابي المتين. لإجراء قياس الجهد، من الضروري أولاً معرفة المجس المستخدم من خلال توصيفه باستخدام دالة فرق النقطة PSF. قد اقترحت عدة طرق لتوصيف المجس. بعد ذلك، أُعيد بناء جهد السطح باقتراح طرق وخوارزميات موثوقة لتحديده بدقة.

كلمات مفتاحية:

الجهد السطحي، تحديد المواقع، MSAP، MPP، روبوت SCARA، روبوت Delta، PSO، ABC، المنطق الضبابي، الشبكات العصبية الاصطناعية، التحكم العصبي الضبابي، التحكم التكيفي، التحكم التنبؤي، المسبار، PSF، إعادة البناء.