

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR

ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE SAAD DAHLEB DE BLIDA 1

Institut d'Aéronautique et des études spatiales

Département de construction Aéronautique



MEMOIRE DE FIN D'ETUDE

EN VUE DE L'OBTENTION DU DIPLOME MASTER EN AÉRONAUTIQUE

Option : Avionique

Thème :

Développement d'un système de contrôle adaptatif pour Des UAVs

Présenté par :

MERDOUD Ishak

Encadré par :

BOUDIBA Ouissam

BENTRAD Hocine

Promotion : 2022/2023

Dédicace

*Avec un énorme plaisir et une immense joie que je dédie ce
modeste travail :*

A MES PARENTS ET MES GRANDS PARENTS

En témoignage de mon amour et de ma reconnaissance

A TOUT CEUX QUI ME SENT CHERS.

MERDOUD ISHAK

Remerciements

On remercie *le Dieu* le tout puissant de nous avoir donné la santé et la volonté d'entamer et
De terminer ce mémoire.

J'exprime ma reconnaissance à tous ceux qui m'ont aidé et qui ont contribué de près ou de
loin à la réalisation de ce projet.

Je tiens à exprimer mes remerciements à mes encadreurs Mr BOUDIBA OUISSAM

Et Mr BENTRAD HOCINE pour leurs remarques et encouragements tout au long de mon
stage.

Mes sincères remerciements à messieurs les membres du jury pour l'honneur qu'ils me font
en acceptant de juger ce modeste travail.

Merci à tous et à toutes

Résumé

Ce mémoire se concentre sur la détection de pannes au niveau de la gouverne de profondeur d'un UAV à voilure fixe en vol croisière, visant à garantir la stabilité et le guidage grâce à l'application de l'intelligence artificielle, plus précisément des réseaux neuronaux. Nous développons un système de contrôle basé sur le diagnostic effectué par un réseau neuronal, suivi d'une planification de gain (Gain-Scheduling) pour contrôler le système en présence de défaillances.

Mots clés

Drone, Réseau neurone, planification des gains, contrôle PID, Diagnostique des pannes.

Abstract

This dissertation centers around the detection of faults in the elevator control of a fixed-wing UAV during cruise flight, with the aim of ensuring stability and guidance through the application of artificial intelligence, specifically neural networks. We formulate a control system based on diagnostics performed by a neural network, followed by gain-scheduling for system control in the presence of faults

Key words

UAV, Neural Network, Gain Scheduling, PID Control, Fault Diagnosis.

ملخص

يركز هذا المقال على اكتشاف الأعطال على مستوى تحكم الارتفاع في طائرة بدون طيار ذات أجنحة ثابتة أثناء الرحلة الجوية في وضع الطيران الرحلي، بهدف ضمان الاستقرار والتوجيه من خلال تطبيق الذكاء الاصطناعي، وتحديداً الشبكات العصبية. نحن نطور نظام تحكم يستند إلى التشخيص الذي يُجريه الشبكة العصبية، تليها خطة لتنظيم الزيادة (جدولة الزيادة) للتحكم في النظام في حالة وجود عيوب.

كلمات مفتاحية

طائرة بدون طيار, شبكة عصبية, جدولة الزيادة, التحكم بالانحراف النسبي, تشخيص الأعطال.

Tables Des Matières

Dédicace	2
Remerciements.....	3
Résumé	4
Mots clés.....	4
Abstract.....	4
Key words	4
ملخص.....	4
كلمات مفتاحية	4
Tables Des matières	5
Liste Des Figures.....	11
List Des Tableaux	13
Liste des abréviations.....	13
Nomenclature.....	13
Introduction Générale	15
CHAPITRE I : Généralités Sur Les UAVs.....	14
I.1.Introduction.....	18
I.2. Définition des UAVs	18
I.2.1. Pourquoi un avion sans pilote ?	19
I.2.1.1. Rôles ternes.....	19
I.2.1.2. Rôles Sales	19
I.2.1.3. Rôles dangereux	19

Tables Des Matières

I.2.1.4. Rôles cachés.....	20
I.2.1.5. Rôles de recherche	21
I.2.1.6. Rôles écologiquement critiques	21
I.2.1.7. Des raisons économiques.....	21
I.3.Histoire des UAVs	23
I.4.Classe des systèmes UAVs	25
I.4.1. Short range.....	25
I.4.2. Milieu de gamme	25
I.4.3. Endurance	25
I.5.Conception de base du système d'un UAV	26
I.5.1. Composition du système	27
I.5.1.1. Station de contrôle.....	27
I.5.1.2. La charge utile.....	27
I.5.1.3. La structure de drone	27
I.5.1.4. Systèmes de Navigation.....	27
I.5.1.5. Lancement et récupération d'équipement.....	28
I.5.1.5.1. Lancer l'équipement.....	28
I.5.1.5.2. Récupération d'équipement	28
I.5.1.5. Communications	29
I.5.1.6. Interface	29
I.5.1.7. Interfaçage avec d'autres systèmes	29
I.6. Problème de contrôle des drones	29
I.6.1. Problème de contrôle des drones a voilure fixe d'une façon générale	29
I.6.1.1 Stabilité et contrôle de vol	30
I.6.1.2 Navigation autonome	30
I.6.1.3 Gestion de la charge utile	30
I.6.1.4 Communication et connectivité.....	30
I.6.1.5 Sécurité et réglementation	30

Tables Des Matières

I.6.2 Problèmes de contrôle adaptatif pour les drones à voilure fixe.....	31
I.6.2.1 Modélisation de la dynamique des drones.....	31
I.6.2.2 Adaptation aux fluctuations de masse et de centre de gravité	31
I.6.2.3 Gérer les perturbations externes.....	31
I.7. Introduction au diagnostic des pannes	31
I.7.1. Détection d'erreur.....	32
I.7.2. Identification de la panne	32
I.7.3. Isolation des défauts.....	32
I.7.4. Prévention et correction des erreurs.....	32
I.7.1.1. Méthode de diagnostic des pannes.....	33
I.7.1.1.2. Méthodes basées sur des règles	33
I.7.1.1.3. Méthodes basées sur des modèles	33
I.7.1.1.4. Techniques basées sur les données	33
I.7.1.1.5. Méthodes hybrides.....	33
I.7.1.1.6. Méthodes probabilistes	34
I.7.2.1. Techniques de diagnostic des pannes.....	34
I.7.2.1.1. Analyse de signature.....	34
I.7.2.1.2. Analyse de modèle	34
I.7.2.1.3. Méthode basée sur des seuils	34
I.7.2.1.4. Analyse de redondance	35
I.7.2.1.5. Méthodes basées sur l'apprentissage automatique	35
I.7.2.1.6. Méthodes basées sur les réseaux de neurones	35
I.7.2.1.7. Méthodes basées sur les probabilités	35
I.7.3.1. Approches basées sur les données pour le diagnostic des pannes	35
I.7.3.1.1. Analyse statistique.....	36
I.7.3.1.2. Méthodes de regroupement	36
I.7.3.1.3. Apprentissage automatique supervisé.....	36
I.7.3.1.4. Apprentissage automatique non supervisé	36

Tables Des Matières

I.7.3.1.5. Réseaux de neurones profonds	36
I.7.4.1. Méthodes avancées de diagnostic des pannes	37
I.7.4.1.1. Réseaux de neurones profonds	37
I.7.4.1.2. Méthodes basées sur les réseaux bayésiens	37
I.7.4.1.3. Méthodes d'apprentissage en ligne.....	37
I.7.4.1.4. Approches basées sur des systèmes multi-agents	37
I.7.4.1.5. Méthodes basées sur les réseaux de Petri	38
I.7.4.1.6. Méthodes améliorées basées sur l'apprentissage en profondeur	38
I.7.4.1.7. Méthodes basées sur l'analyse des vibrations	38
I.8. Conclusion	39
CHAPITRE II : DIAGNOSTIQUE DES PANNES EN UTILISENT RÉSEAU NEURONES	40
II.1. INTRODUCTION	41
II.2 Le modèle Dynamic d'un UAV	42
II.2.1 Le modèle Non linéaire d'un UAV	42
II.3. RÉSEAU DE NEURONES	44
II.3.1. Introduction	44
II.3.1.1. Le neurone biologique.....	44
II.3.1.2. Le neurone formel (artificiel)	45
II.3.1.3. Comparaison entre neurone biologique et formel	45
II.3.2. Modèle de réseaux de neurones.....	46
II.3.2.1. Les entrées	46
II.3.2.2. Les poids.....	47
II.3.2.3. Les bias.....	47
II.3.2.4. Les fonctions d'activations.....	47
II.3.2.5. La sortie.....	48
II.3.3.les architectures neuronales.....	49
II.3.3.1. Le réseau neurones non bouclé.....	49
II.3.3.2. Le réseau neurones non bouclé Monocouche	50

Tables Des Matières

II.3.3.3. Le réseau neurones non bouclé multicouche	50
II.3.3.3.1 Le Perceptron Multicouches	51
II.3.3.4. Le réseau de neurones bouclé	52
II.3.3.4.1. Les réseaux à fonction de bases radiales (RBF)	53
II.3.3.5. Le réseau de neurones à connexion complexe	54
II.3.4. La procédure d'entraînement	54
II.3.5. Types d'apprentissage.....	55
II.3.5.1. Apprentissage non supervisé	56
II.3.5.2.Apprentissage semi supervisé.....	56
II.3.5.3. Apprentissage supervisé	56
II.3.5.3.1. Rétropropagation(backpropagation) Lavenberg-Marquardt	57
II.3.5.3.2. L'algorithme de Rétropropagation (backpropagation) Lavenberg-Marquardt.....	58
II.3.5.4. Phase On line	59
II.3.5.5. Phase offline	59
II.4. Diagnostique des pannes sures les UAVs	60
II.4.1 Méthodologie de détection des défauts par les Réseaux neurone sur les paramètres d'un gyroscope et le signal d'entrée	60
II.4.2 Les différentes applications des Réseaux neurone dans la protection des lignes de transmission	61
II.4.3 utilisations d'un Réseaux neurone dans un système de contrôle des UAVs afin de détecter les blocages dans les actionnaires	61
II.5. Technique de contrôle.....	62
II.5.1. Introduction	62
II.5.2. Régulation PID	63
II.5.2.1. Régulateur proportionnelle P	63
II.5.2.2. Régulateur proportionnelle-intégrale PI.....	64
II.5.2.3. Régulateur proportionnelle-intégrale-dérivée PID.....	64
II.5.2.4. Structure de contrôleur PID.....	65

Tables Des Matières

II.5.2.5. Les méthodes utilisées pour déterminer les paramètres du contrôleur PID.....	66
II.5.2.5.1. Méthode par réglages successive	67
II.5.2.5.2. Méthode de Ziegler-Nichols	67
II.6. Contrôle adaptif des systèmes à variation temporelle avec planification des gains	68
II.6.1. INTRODUCTION.....	68
II.6.2 Énoncé du problème	69
II.7. Conclusion.....	73
Chapitre III : Simulation et interprétation des Résultats	75
III.1. Introduction.....	76
III.2 model du drone adéquat.....	76
III.2.1 description générale du drone UAV	78
III.3 stratégies de travaille.....	79
III.3.1. Création de la base de données	79
III.3.2. Conception du réseau neuronal	80
III.3.3. Estimation des fonctions de transfert	80
III.3.4. Simulation sur Matlab/Simulink	80
III.4 bases de donner	81
III.5 Réseau neurone	82
III.5.1 les entrées et les sorties de notre réseau neurone	82
III.5.2 l'apprentissage du réseau neurone.....	83
III.5.3 La structure du réseau neurone	85
III.5.4 performances du réseau neurone	86
III.5.5 résultats d'apprentissage	86

Tables Des Matières

III.6. L'estimation de la fonction de transfert pour le cas sain	87
III.6.1. Le diagramme du système sain en Simulink.....	87
III.6.2. Le résultat de la simulation (scope).....	87
III.7. L'estimation de la fonction de transfert TF pour le défaut 1	88
III.7.1. Le diagramme du système avec défaut 1 en Simulink	89
III.7.2. Le résultat de la simulation (scope 1).....	89
III.8. L'estimation de la fonction de transfert TF pour le défaut 2	90
III.8.1. Le diagramme du système avec défaut 2 en Simulink	91
III.8.2. Le résultat de la Simulation (scope 2)	91
III.9 Représentation du système sain et bloquer sur Simulink	92
III.9.1. Schémas du système de contrôle avec planification de gain	92
III.9.2. Le cas sain.....	93
III.9.2.1 résultats du SCOPE.....	93
III.9.3. Le cas bloquer (défaut 1)	93
III.9.3.1 résultats du SCOPE1.....	94
III.9.4. Le cas bloquer (défaut 2)	94
III.9.4.1 résultats du SCOPE2.....	95
III.10 Conclusion	96
Conclusion générale.....	96
References Bibliographiques.....	96

Liste Des Figures

Figure 1: Exemple d'UAV.	18
Figure 2: Drone militaire.	20
Figure 3: UAV équipé d'une caméra.	22
Figure 4: UAV de Lawrence et Sperry [7]	23
Figure 5: les sous-systèmes d'un drone [6].....	26

Liste Des Figures

Figure 6: système de lancement de drone.....	28
Figure 7: sous-systèmes et interface d'UAV [9]	29
Figure 8: modèle de base d'un neurone formel [2]	45
Figure 9: différent type de fonction d'activations pour le réseau neurones formel [41]......	48
Figure 10: modèle mathématique d'un réseau de neurone formel [42].	49
Figure 11: modèle d'un réseau de neurone non bouclé [41].	50
Figure 12: modèle d'un réseau de neurone non bouclé monocouche [45]......	50
Figure 13: modèle d'un réseau de neurone non bouclé multicouches [45]......	51
Figure 14: Réseau de neurone du Perceptron Multicouche [44]	52
Figure 15: Modèle d'un réseau de neurones bouclée.....	53
Figure 16: Schéma diagramme d'un réseau à base radiale [63].	53
Figure 17: Apprentissage non supervisé [48]	56
Figure 18: Apprentissage supervisé [48]......	57
Figure 19 : phase Online.....	59
Figure 20: Phase offline	60
Figure 21: Diagramme de défauts montrant la méthode RNA.	62
Figure 22: Structure de PID traditionnelle.	65
Figure 23 : Ajustement des paramètres PID par la méthode des réglages successifs.	67
Figure 24: Un schéma des points d'opération de l'espace X_g ($k=12$)	71
Figure 25: drone utiliser pour l'étude (UAV Mistral) [65]	77
Figure 26: les caractéristiques physique et les coefficients aérodynamiques du mode longitudinale.	79
Figure 27: Évaluation des Coefficients Aérodynamiques C_d , C_m , C_l et Angle d'Incidence à l'aide de XFLR5	81
Figure 28: l'entrée du réseau neurone θ	82
Figure 29: les sorties du réseau neurone c_d , c_l , c_m , Delta élévateur	83
Figure 30: l'entrée (input) θ	84
Figure 31: la sortie(output) Delta élévateur.....	84
Figure 32: entraînement du réseau neurone.....	85
Figure 33: l'architecture du réseau neurone	85
Figure 34: graphe qui représente la performance du réseau neurone	86
Figure 35: résultat d'apprentissage	86
Figure 36: schéma du système sain	87
Figure 37: graphe représente la réaction du système sain en fonction du temps (l'angle de tangage).....	87
Figure 38: base de donner qui représentent l'entrée Delta élévateur pour l'estimation de la fonction de transfert.....	88
Figure 39: base de donner qui représentent la sortie θ pour l'estimation de la fonction de transfert avec le défaut	89
Figure 40: schéma du système avec défaut 1 sans changement du gain PID en utilisent (III.5).....	89
Figure 41: graphe représente le comportement du système avec défaut 1 en fonction du temps.....	89
Figure 42: base de donner qui représentent l'entrée Delta élévateur pour l'estimation de la fonction de transfert.....	90
Figure 43: base de donner qui représentent la sortie θ pour l'estimation de la fonction de transfert.....	91
Figure 44: schéma du système défaut 2 sans changement du gain PID en utilisent (III.6).....	91
Figure 45: graphe représente le comportement du système avec défaut 2 en fonction du temps.....	91
Figure 46: schéma représente le système sain et système avec défauts	92
Figure 47: schéma du système lorsque le Delta élévateur est égal à 0.5.....	93
Figure 48: graphe représente la correction du système avec le contrôle de type planification du gain.....	93
Figure 49: schéma du système lorsque Delta élévateur égale à 5.....	94
Figure 50: graphe représente la correction du système avec le contrôle de type planification du gain(défaut 1 , détection et correction).....	94
Figure 51: schéma du système lorsque Delta élévateur égale à 9.....	95

Liste Des Figures

Figure 52: graphe représente la correction du système avec le contrôle de type planification du gain (défaut 2, détection et correction)..... 95

List Des Tableaux

Tableau 1: Table comparaison entre neurone biologique et formel..... 46

Tableau 2: Tableau de ZIEGLER-NICHOLS...... 68

Liste des abréviations

ACP. *l'analyse en composantes principales.*

ACS. *Airborne control station (system).*

AFCS. *Automatic Flight Control System.*

CNN. *Réseaux de neurones convolutifs.*

CS. *Control Station.*

GCS. *Ground control station (or system).*

GPS. *Global positioning system*

HALE. *High Altitude and Long Endurance.*

MALE. *Medium Altitude Long Endurance.*

OTAN. *Organization of Transport and Aircraft*

Navigation.

PID. *Proportionnel Intégral Dérivatif.*

RNA. *Réseau de neurones artificiel.*

RNN. *les réseaux de neurones récurrents.*

SCS. *Shipboard control station (or system).*

SVM. *réseaux de neurones et des machines à vecteurs de support*

TSD. *Terne, Sale et Dangereux.*

UAV. *Unmanned Ariel Vehicle.*

VTUAV. *Vertical Take-off UAV.*

Nomenclature

b [m] : L'envergure.

\bar{c} [m] : La corde aérodynamique moyenne.

φ : L'angle de roulis.

θ : L'angle de tangage.

ψ : L'angle de lacet.

Ω : La vitesse angulaire.

v : La vitesse linéaire.

p : Le poids.

m : La masse d'avion.

g : La gravité.

u : La commande.

C_m : Coefficient aérodynamique de moment de tangage.

C_d : Coefficient aérodynamique de traînée.

C_l : Coefficient aérodynamique de portance.

I : Matrice d'inertie.

I_{xx} [kg.m²] : Moment d'inertie suivant Xb.

I_{yy} [kg.m²] : Moment d'inertie suivant Yb.

I_{zz} [kg.m²] : Moment d'inertie suivant Zb.

p [rad/s] : Vitesse angulaire de roulis.

Nomenclature

q [rad/s] : Vitesse angulaire de tangage.

r [rad/s] : Vitesse angulaire de lacet.

R [N] : La résultante des forces aérodynamique.

S [m²] : Surface de l'aile.

V [m/s] : La vitesse de l'avion.

α [rad] : Angle d'incidence.

δ_a [rad] : Déflexion de la gouverne de gauchissement.

δ_e [rad] : Déflexion de la gouverne de profondeur.

δ_r [rad] : Déflexion de la gouverne de direction.

ρ [Kg/m³] : Densité de l'air.

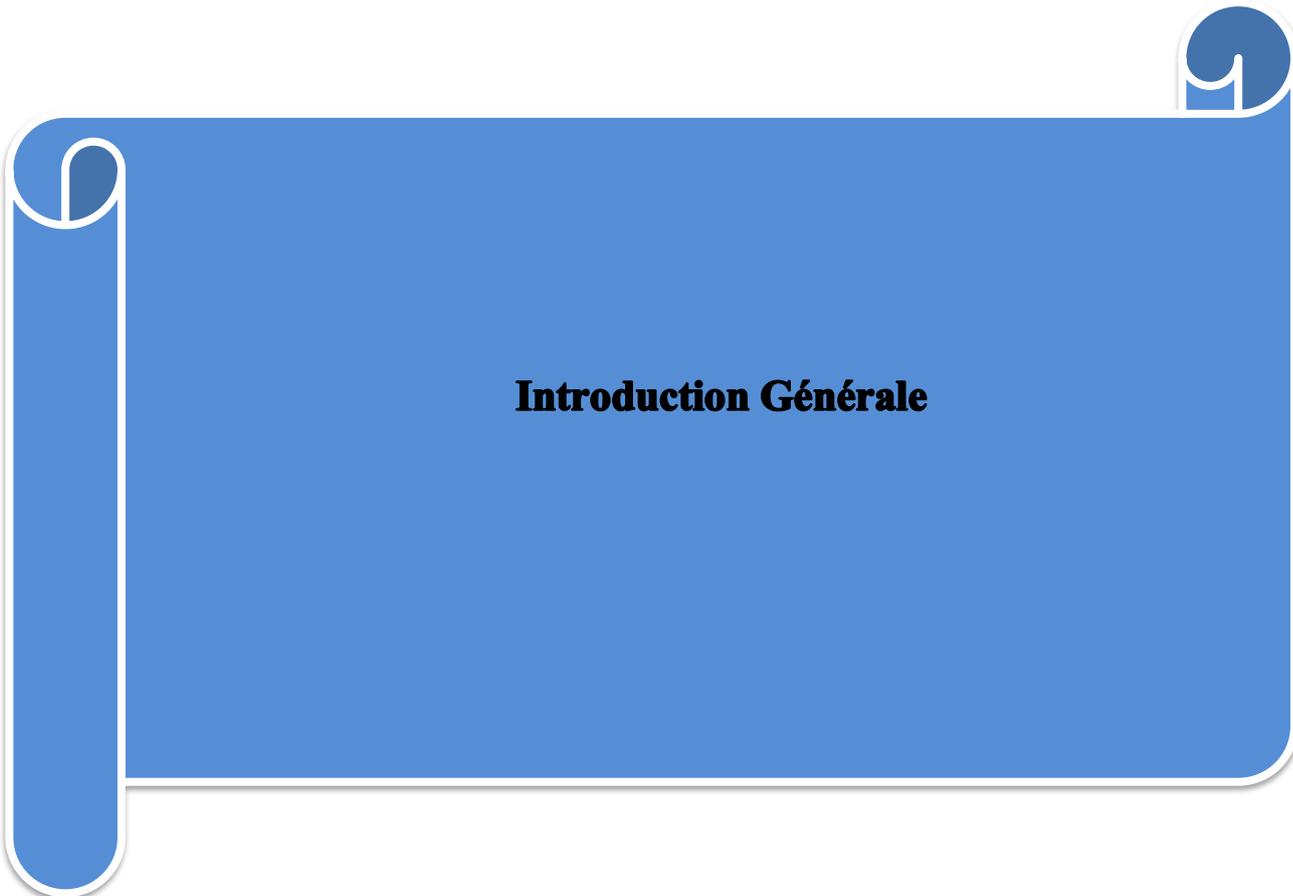
K_{mot} : La constante du couple moteur

β [rad] : Angle de dérapage.

K_p : Gain Proportionnelle.

K_d : Gain Dérivatif.

K_i : Gain Intégral.



Introduction Générale

Introduction General

L'utilisation des drones civils connaît une expansion rapide, suscitant l'intérêt et stimulant les avancées technologiques dans de nombreux domaines à travers le monde. Ces engins volants autonomes sont déjà employés dans diverses applications, et de nouvelles possibilités émergent constamment, laissant présager une évolution continue difficile à anticiper avec précision.

Dans le domaine aéronautique moderne, les avancées technologiques clés portent notamment sur la motorisation, l'aérodynamique et l'avionique embarquée. Cette dernière englobe l'ensemble du matériel et des logiciels intégrés à bord de l'avion, jouant un rôle crucial dans le traitement des informations des capteurs, le pilotage automatique, la gestion du carburant, la communication avec les opérateurs au sol, et bien d'autres fonctions. Les technologies de pilotage et de guidage automatique ont considérablement amélioré la maniabilité des avions.

Le présent mémoire a pour objectif de développer un système de contrôle adaptatif spécifiquement dédié aux drones à voilure fixe. Notre étude se focalisera sur l'utilisation des réseaux neuronaux et de la planification du gain pour parvenir à un système de contrôle intelligent et réactif, permettant de maintenir la stabilité et la performance des UAV, même en présence de situations complexes ou de pannes potentielles.

La structure de cette thèse se décompose en trois chapitres, chacun explorant un aspect spécifique du développement du système de contrôle adaptatif pour UAV à voilure fixe :

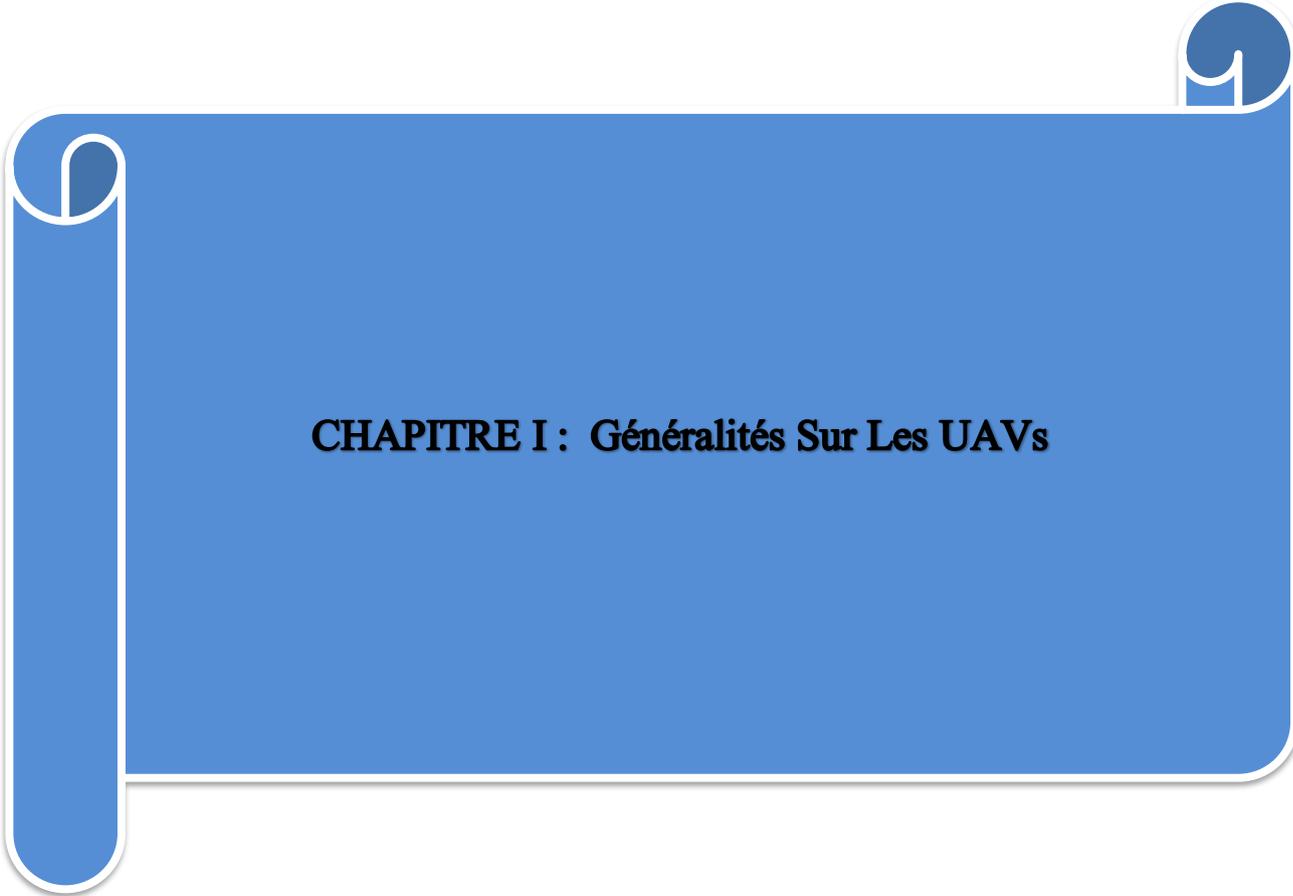
Le chapitre 1 fournira un aperçu général sur les drones, ainsi qu'une analyse des divers problèmes de contrôle auxquels ils peuvent être confrontés.

Le chapitre 2 se concentrera sur les différents éléments qui composent les réseaux neuronaux et sur la planification du gain, deux technologies clés qui seront intégrées dans notre système de contrôle adaptatif.

Le chapitre 3 présentera en détail la conception et les résultats de simulation de notre réseau neuronal dédié au diagnostic des pannes, mettant en évidence l'efficacité et la pertinence de cette approche pour assurer la fiabilité et la sécurité des UAV à voilure fixe.

Enfin, dans notre conclusion générale, nous synthétiserons les principaux résultats obtenus et soulignerons l'importance de notre contribution dans le domaine de l'aéronautique, en mettant en avant les perspectives futures et les applications potentielles de notre système de contrôle adaptatif pour les drones à voilure fixe.

En résumé, ce mémoire s'inscrit dans une démarche d'innovation technologique, visant à développer un système de contrôle intelligent et adaptatif pour les UAV à voilure fixe, ouvrant ainsi la voie à des vols plus sûrs, plus performants et plus fiables dans un avenir où les drones occuperont une place de plus en plus prépondérante dans notre quotidien.

A blue scroll graphic with a white border, featuring a vertical strip on the left side and a circular element at the top right corner. The text is centered within the scroll.

CHAPITRE I : Généralités Sur Les UAVs

I.1.Introduction

Les véhicules aériens sans pilote (UAV) sont de plus en plus impliqués dans des objectifs de mission difficiles, notamment la recherche et le sauvetage, la reconnaissance et d'autres fonctions de collecte de renseignements. Non seulement ces véhicules ont l'avantage de ne pas nécessiter d'humains dans des scénarios instables, mais ils ont également une valeur de production plus élevée que les véhicules transportant des humains. En général, deux types de drones sont produits : les drones télécommandés et les drones autonomes [1].

Les drones télécommandés permettent à un opérateur de contrôler le véhicule pour atteindre les objectifs de la mission, tandis que les drones autopilotés effectuent des tâches de manière autonome selon un ensemble de règles préprogrammées avant le vol.

Le but de cette enquête est de présenter la grande variété de systèmes qui ont émergé au cours des dernières décennies [1,2].

I.2. Définition des UAVs

La définition d'UAV (véhicule aérien sans pilote) varie d'une littérature à l'autre. En ce qui nous concerne, les drones sont de petits avions qui volent sans pilote. Ils peuvent être contrôlés à distance par des humains ou fonctionner de manière autonome ; les véhicules autonomes sont contrôlés par des ordinateurs de bord et peuvent être préprogrammés pour effectuer des tâches spécifiques ou un large éventail de tâches. Dans d'autres littératures, UAV peut faire référence à des aéronefs motorisés ou non motorisés, captifs ou non captifs [3].

Les UAV sont conçus pour ne transporter aucun pilote humain et pour fonctionner via des entrées électroniques déclenchées par le contrôleur de vol ou un système de contrôle de gestion de vol autonome qui ne nécessite pas l'intervention du contrôleur.



Figure 1: Exemple d'UAV.

Les UAVs étaient principalement utilisés dans des applications militaires, mais ils sont récemment déployés dans des applications civiles [1].

I.2.1. Pourquoi un avion sans pilote ?

Les véhicules aériens sans pilote n'existeront que s'ils offrent des avantages par rapport aux avions pilotés. Les systèmes d'aéronefs sont conçus dès le départ pour exécuter une tâche ou une fonction spécifique. Le concepteur doit déterminer le meilleur type d'aéronef pour la tâche (tâche) et, plus précisément, si la tâche (tâche) peut être accomplie avec succès à l'aide d'un équipement avec ou sans pilote. En d'autres termes, il n'est pas possible de conclure que les drones présentent toujours des avantages ou des inconvénients par rapport aux systèmes de vol habités [5].

Cela dépend totalement de ce qu'est le travail. Les opérations militaires qui affectent également les civils impliquent souvent l'utilisation d'UAV dans des travaux sales, sales ou dangereux (TSD). Il y a beaucoup de vrai là-dedans, mais ça ne se passera pas bien. Pour TSD, inclure les services secrets, diplomatiques, de recherche et environnementaux. De plus, les parties économiques de l'exploitation sont souvent la valeur des drones [4].

I.2.1.1. Rôles ternes

Les applications militaires et civiles telles que la surveillance à longue distance peuvent être une expérience unique pour les aviateurs. Et de nombreuses heures de préparation sans sauvetage, cela peut entraîner une perte de concentration et donc une perte de bonnes nouvelles. L'UAV,

La vidéo haute résolution, la télévision à faible niveau de lumière, les caméras à imagerie thermique ou le balayage radar, peuvent être plus efficaces et moins coûteux à exploiter dans de tels rôles [6].

I.2.1.2. Rôles Sales

En outre, applicable aux applications civiles et militaires, la surveillance de l'environnement nucléaire ou la contamination chimique expose les travailleurs aériens à des risques inutiles. Le prochain vol est facile dans le cas du drone [11]. La pulvérisation de produits chimiques toxiques est un autre sale boulot que les drones font maintenant bien.

I.2.1.3. Rôles dangereux

Pour les opérations militaires, où l'investigation de zones bien défendues est requise, le nombre d'avions humains peut voler plus que celui du drone. En raison de sa petite taille et de sa plus grande furtivité, le drone est difficile à détecter pour le système de défense aérienne de l'ennemi et il est de plus en plus difficile de toucher des tirs ou des armes anti-aériennes [4,6].

De plus, dans de telles opérations, la peur d'une attaque peut perturber la concentration des aviateurs sur le travail. La perte de biens est dévastatrice, mais la perte d'aviateurs qualifiés l'est aussi et la misère politique de la capture et de la publicité s'ensuit. Les opérateurs d'UAV ne courent aucun risque et peuvent se concentrer directement, et donc plus efficacement, sur la tâche à accomplir.



Figure 2: Drone militaire.

Par conséquent, le drone offre une plus grande chance de succès dans la mission sans risque de perte de ressources en personnel. Les inspections de lignes électriques et la lutte contre les incendies de forêt sont des exemples d'applications civiles où l'expérience a malheureusement montré que les exploitants d'aéronefs peuvent courir de grands risques.

Les drones peuvent effectuer ces tâches facilement et sans risque pour les opérateurs. Souvent appelé à travailler dans des conditions météorologiques extrêmes dans des zones militaires et civiles. Les employeurs seront prêts à mettre les travailleurs en danger et le travail, bien que nécessaire, ne pourra pas être effectué. De tels essais sont moins applicables aux drones [4].

I.2.1.4. Rôles cachés

Dans les opérations de police militaires et civiles, il y a des rôles où il est impératif de ne pas alerter "Ennemi" (autres forces armées ou criminels) au fait qu'ils ont été détectés.

Toujours dans cette catégorie, la surveillance secrète qui porte atteinte à l'espace aérien des pays dans un temps

Encore une fois, le bas les signatures détectables de l'UAV rend ce type de rôle plus facile à réaliser [6].

I.2.1.5. Rôles de recherche

Les UAVs sont utilisés dans les travaux de recherche et développement dans le domaine aéronautique. À des fins de test, l'utilisation des UAVs en tant que répliques à petite échelle de modèles civils ou militaires projetés d'aéronefs pilotés des essais aériens doivent être effectués, dans des conditions réalistes, à moindre coût et avec moins de risques. Les modifications ultérieures peuvent également être effectuées à moindre coût et plus rapidement que pour un plus grand aéronef piloté et sans qu'il soit nécessaire de modifier l'hébergement ou l'exploitation de l'équipage.

De nouvelles configurations peuvent être utilisées avantageusement pour l'UAV. Ces configurations peuvent ne pas convenir pour contenir un équipage [5,4]



Figure 3 : Prototype d'avion.

I.2.1.6. Rôles écologiquement critiques

Cet aspect concerne principalement les rôles civils. Un UAV causera généralement moins de perturbations environnementales ou la pollution qu'un avion habité poursuivant la même tâche. Il sera généralement plus petit, plus basse masse et consomment moins d'énergie, produisant ainsi des niveaux d'émission et de bruit plus faibles.

Typique de ceux-ci sont les inspections régulières des lignes à haute tension où les habitants peuvent s'opposer au bruit produit et où les animaux de ferme peuvent subir des perturbations à la fois du bruit et de la vue de l'avion volant à basse altitude [5,6].

I.2.1.7. Des raisons économiques

En règle générale, l'UAV est plus petit qu'un avion habité utilisé dans le même rôle, et est généralement considérablement moins cher en premier prix.

Les coûts d'exploitation sont moindres puisque les coûts d'entretien, de carburant et de hangar sont tous moins. Les coûts de main-d'œuvre des opérateurs sont généralement plus bas et l'assurance peut être moins chère, bien que ce soit dépend de circonstances individuelles.

Un cas économique incontestable pour l'UAV est dans un rôle de surveillance locale où les tâches seraient autrement effectuées par un aéronef léger avec un ou deux membres d'équipage. Ici la suppression du l'équipage a un grand effet simplificateur sur la conception et la réduction du coût de l'avion.

Typiquement, pour deux pilotes, disent un pilote et un observateur, l'espace nécessaire pour les accueillir, leurs sièges, leurs commandes et instruments, est de l'ordre de $1,2 \text{ m}^3$ la zone Frontale d'environ $1,5 \text{ m}^2$. Un UAV pour effectuer la même tâche serait exiger seulement $0,015 \text{ m}^3$, comme une estimation généreuse, pour abriter un système de contrôle de vol automatique (AFCS) avec des capteurs et un ordinateur, une caméra TV couleur haute résolution stabilisée et des liaisons de communication radio [11].



Figure 3: UAV équipé d'une caméra.

La surface frontale serait seulement de $0,04 \text{ m}^2$. Les masses devant être portées par l'aéronef habité, ainsi que la structure, le pare-brise, portes, cadres et vitrages totaliseraient au moins 230 kg.

L'équivalent pour l'UAV serait d'environ 10 kg. Si le système de contrôle et le capteur de surveillance (pilote et observateur) et leurs systèmes de soutien (sièges, les affichages, les commandes et la climatisation) sont considérés comme la « charge utile » de l'avion léger, une pénalité d'environ 220 kg de masse « charge utile » par rapport à la petite UAV et ont environ 35 fois la zone frontale avec une traînée corporelle proportionnellement plus grande.

En supposant que la fraction de charge jetable d'un avion léger est typiquement de 40% et de ce 10% est du carburant, alors sa masse brute sera typiquement de l'ordre de 750 kg. Pour l'UAV, sur la même base, son montant brut la masse sera de l'ordre de 35 kg. Ceci est confirmé dans la pratique.

Pour les missions nécessitant le transport de charges utiles plus lourdes telles que le fret ou l'armement,

l'économie de la masse réalisée en retirant l'équipage devient évidemment de moins en moins importante [6].

I.3.Histoire des UAVs

Les premiers UAVs ont été d'abord fabriqués par Lawrence et Sperry (USA) en 1916. Ils ont appelé 'Torpedo aviation' représentée sur la figure 5 et ils étaient capables de parcourir une distance de 30 miles. Il a été rapporté que Lawrence et Sperry ont utilisé un gyroscope pour équilibrer le corps [7].

Les efforts initiaux sur les UAVs dans les années 1980 se sont concentrés sur les UAVs qui avaient des dimensions typiques de 2 m ou 3 m, en partie motivée par la nécessité de porter des capteurs ainsi que l'électronique qui, à cette époque, n'avait pas atteint l'état avancé de miniaturisation.

Au cours des dernières années, il y a eu un intérêt croissant pour la gamme de taille des UAVs jusqu'à des appareils de la taille des insectes à un extrême et jusqu'à l'air moyen taille de transport à l'autre extrémité.

Donc, le recours à des machines volantes non pilotées n'est pas une nouveauté historique.

Depuis les cerfs-volants et les ballons, en passant par les " bombes " volantes, utilisés dans plusieurs conflits dans l'Histoire pour l'observation ou l'attaque, jusqu'aux aéronefs automatisés, ce sont des siècles d'innovations et d'efforts technologiques qui se sont écoulés.

Avec les véhicules Aériens Autonomes (UAV), un nouveau chapitre s'est ouvert pour l'aéronautique, la robotique et la commande, car il ne s'agit pas uniquement de machines contrôlées à distance, mais de véritables systèmes autonomes, capables de s'adapter à l'environnement dans lequel ils évoluent. L'évolution des UAVs aussi appelés " Drones " (faux bourdon) est une évolution logique, résultant du progrès technologique, notamment dans le domaine de l'informatique et de la miniaturisation [10]

Si les UAVs sont à la portée de presque tous pour la conception, la technologie et la production, les algorithmes de commande et d'observation relèvent des recherches évoluées.



Figure 4: UAV de Lawrence et Sperry [7]

Ceci explique la majorité des projets déclarés, à l'étude ou déjà en phase de développement émanant des Etats-Unis, de la France, de la Suède, de l'Allemagne, de l'Italie et du Royaume-Uni...etc, en solo ou en coopération croisée, ces pays ont amorcé le virage vers le développement technologique et accordent une place croissante au concept de véhicule sans pilote et autonome.

Le panel de l'OTAN sur les drones les définit comme : un véhicule aérien motorisé, qui ne transporte pas d'opérateur humain, utilise la force aérodynamique pour assurer sa portance, peut voler de façon autonome ou être piloté à distance, être non réutilisable ou récupérable et qui emporte une charge utile.

Il faut remarquer que les engins balistiques ou semi-balistiques, les missiles de croisière et les projectiles d'artillerie ne sont pas considérés comme des drones [6].

I.4. Classe des systèmes UAVs

Il est pratique d'avoir un schéma généralement accepté pour classer les UAVs plutôt que la classification des aéronefs en général en classes telles que le transport, l'observation, etc.

Classement par gamme et endurance. Les classes de drones comme une étape vers la fourniture de certaines mesures de normalisation à la terminologie UAV. [4,6]

I.4.1. Short range

L'UAV à courte portée était également requis par tous les services et, comme le Drone à courte portée, a eu la mission de jour / nuit, de reconnaissance et de surveillance en haut priorité. Il avait une portée de 150 km. Le temps d'endurance de 8-12 h [5,6].

I.4.2. Milieu de gamme

Le drone de moyenne portée était requis par tous les services. Il exige la capacité d'être lancé au sol ou par air et n'était pas nécessaire pour flâner. Cette dernière exigence laissait entendre que le véhicule aérien était un pénétrateur à grande vitesse.

En fait, l'exigence de vitesse était élevée subsonique. Le rayon d'action était de 650 km et devait être utilisé pour la reconnaissance et la surveillance jour / nuit. Une mission secondaire pour le milieu de gamme était la collecte de données météorologiques [6].

I.4.3. Endurance

L'UAV Endurance était requis par tous les services et, comme son nom l'indique, devait avoir une capacité d'au moins 36 h. Le véhicule aérien devait pouvoir opérer depuis terre ou mer et ont un rayon d'action d'environ 300 km.

La mission était la reconnaissance jour / nuit en premier, et le relais de communication en second lieu. La vitesse n'a pas été spécifiée, mais il devait être en mesure de maintenir la station dans les vents violents qui seront vécus à haute altitudes.

Cependant, HALE, MALE et VTUAV sont de plus en plus adaptés pour transporter air- sol armes afin de réduire le temps de réaction d'une frappe sur une cible découverte par leur reconnaissance.

Couramment utilisés aujourd'hui, étaient liés au rayon d'action en fonctionnement des différentes classes [4].

I.5. Conception de base du système d'un UAV

Un système d'UAV comprend un certain nombre d'éléments, ou sous-systèmes, dont l'aéronef est unique. La structure fonctionnelle technique d'un système typique est illustrée à la figure 6.

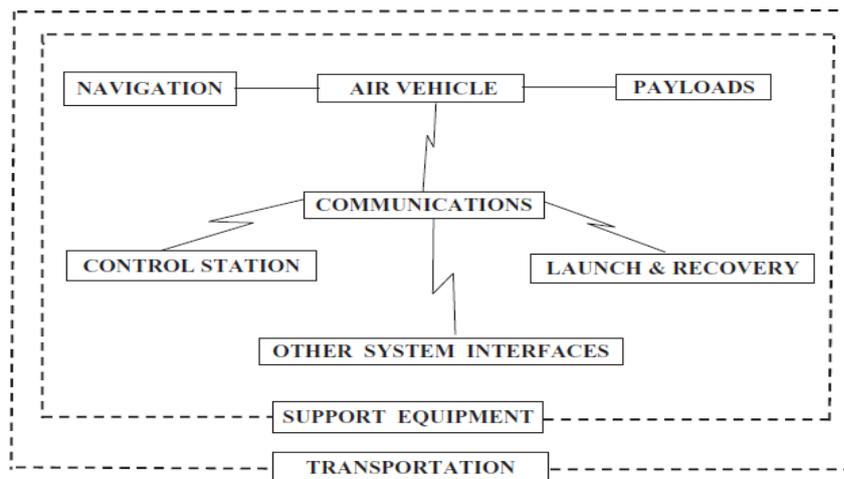


Figure 5: les sous-systèmes d'un drone [6]

Il y a, bien sûr, d'autres facettes d'intégration dans le système plus global, telles que le dédouanement requis pour opérer dans l'espace aérien contrôlé, qui ne sont pas représentés sur cette figure.

Il est toujours plus important de considérer chaque sous-système du système UAV comme faisant partie intégrante de ce système. Aucun sous-système n'est plus important qu'un autre, même si certains, ont un plus grand impact sur la conception des autres sous-systèmes que d'autre. Dans les premiers temps Par exemple, certains aéronefs sans pilote ont été conçus et fabriqués avec indifférence de la façon dont les charges utiles seraient montées, l'avion lancé ou récupéré, les communications effectuées, ou le système maintenu et transporté dans des conditions dans lesquelles le système devait fonctionner.

Des tentatives ultérieures pour construire un système opérationnel autour de lui étaient soit vouées à l'échec, soit dans des compromis inacceptables ou des coûts inacceptables.

I.5.1. Composition du système

On décrit la fonction de chacun des principaux sous-systèmes, en se souvenant toujours qu'ils n'existent pas d'isolement, mais font partie d'un système global [4,5,6,8].

I.5.1.1. Station de contrôle

Habituellement basé sur le sol (GCS), ou à bord du navire (SCS), bien que possiblement aéroporté dans un avion « parent » (ACS), la station de contrôle est le centre de contrôle de l'opération et l'interface homme-machine.

I.5.1.2. La charge utile

Le type et la performance des charges utiles dépendent des besoins de la tâche opérationnelle. Ceux-ci peuvent varier de :

Des sous-systèmes relativement simples consistant en une caméra vidéo non stabilisée avec un objectif fixe masse de 200 g.

Un système vidéo avec une plus grande capacité de portée, employant un objectif à focale plus longue avec zoom installation, gyrostabilisée et d'inclinaison avec une masse de probablement 3 à 4 kg,

I.5.1.3. La structure de drone

Le type et la performance du véhicule aérien / de l'avion sont principalement déterminés par les besoins de la mission opérationnelle.

La tâche de l'avion est principalement de transporter la charge utile de la mission à son point d'application, mais il doit également transporter les sous-systèmes nécessaires à son fonctionnement.

Ces sous-systèmes comprennent la liaison de communication, l'équipement de stabilisation et de contrôle, la centrale électrique et le carburant, alimentations électriques, Structure de base du fuselage et des mécanismes nécessaires pour que l'avion soit lancé, pour mener à bien sa mission, et être récupéré.

I.5.1.4. Systèmes de Navigation

Il est nécessaire que les opérateurs sachent, sur demande, où se trouve l'aéronef à tout moment. Il peut également être nécessaire que l'aéronef « sache » où il se trouve si un vol autonome est requis à tout moment pendant le vol. Cela peut être une partie ou la totalité d'une mission préprogrammée ou comme une capacité de « retour à

la base » d'urgence après la dégradation du système.

Pour un fonctionnement entièrement autonome, c'est-à-dire sans communication entre le CS et le véhicule aérien, un équipement de navigation suffisant doit être transporté dans l'aéronef.

I.5.1.5. Lancement et récupération d'équipement

I.5.1.5.1. Lancer l'équipement

Cela sera nécessaire pour les véhicules aériens qui n'ont pas de capacité de vol vertical, ni avoir accès à une piste de surface et de longueur appropriées. Cela prend généralement la forme d'une rampe le long de laquelle l'avion est accéléré sur un chariot, propulsé par un système spécifique (par air comprimé ou par fusée) jusqu'à ce que l'avion ait atteint une vitesse à laquelle il peut voler.



Figure 6: système de lancement de drone

I.5.1.5.2. Récupération d'équipement

Cela sera également, en générale, nécessaire pour les aéronefs sans capacité de vol, à moins qu'ils ne puissent être ramenés sur un terrain qui permettra un passage à roues ou un atterrissage dérapé.

Il prend généralement la forme d'un parachute, installé dans l'avion, et qui est déployé à une altitude convenable au-dessus de la zone d'atterrissage. De plus, un moyen d'absorption de l'énergie d'impact est nécessaire, comprenant généralement des airbags ou un matériau frangible remplaçable. Une forme alternative de récupération de l'équipement, parfois utilisée, est un grand filet ou, alternativement, un appareil à carrousel dans lequel l'aéronef est volé et attrapé.

I.5.1.5. Communications

L'exigence principale, et probablement la plus exigeante, pour le système de communication est de fournir les liaisons de données (haut et bas) entre le CS et l'avion. Le moyen de transmission est le plus généralement à la fréquence radio, mais les alternatives possibles peuvent être par la lumière sous la forme d'un faisceau laser ou via fibres optiques.

I.5.1.6. Interface

Tous ces éléments, ou sous-systèmes, travaillent ensemble pour atteindre la performance du système global. Bien que certains d'entre eux puissent fonctionner comme des systèmes "autonomes" dans d'autres systèmes décrits, en tant que sous-systèmes, ils doivent pouvoir fonctionner ensemble, et donc une grande attention doit être payée au bon fonctionnement de leurs interfaces.

I.5.1.7. Interfaçage avec d'autres systèmes

Un système d'UAV existe pour effectuer une tâche. Il est peu probable que la tâche puisse être « autonome ». C'est ça peut nécessiter une attribution de tâches à partir d'une source externe au système et rendre compte à cette source ou à une autre source externe.

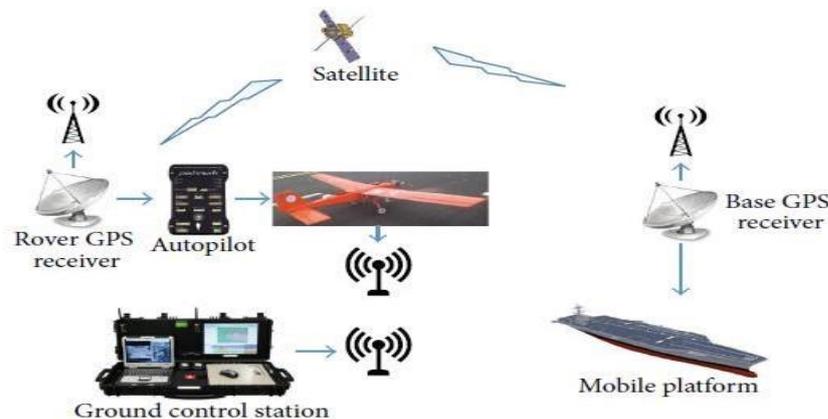


Figure 7: sous-systèmes et interface d'UAV [9]

I.6. Problème de contrôle des drones

I.6.1 Problème de contrôle des drones a voilure fixe d'une façon générale

Les problèmes de contrôle des drones à voilure fixe et des UAVs en général peuvent être variés. Voici quelques-uns des problèmes courants [12,13,14,15,16] :

I.6.1.1 Stabilité et contrôle de vol

Assurer la stabilité et le contrôle précis des drones à voilure fixe peut être compliqué par des facteurs tels que les conditions météorologiques changeantes, les turbulences et les perturbations. Le maintien de la stabilité et du contrôle des drones peut nécessiter des techniques de contrôle avancées telles que le contrôle adaptatif et prédictif.

I.6.1.2 Navigation autonome

La navigation autonome est un défi majeur dans le contrôle des drones à voilure fixe. Cela concerne la capacité du drone à planifier des trajectoires de vol, à éviter des obstacles, à effectuer des manœuvres de suivi de cible, etc. Des algorithmes de navigation avancés et des capteurs de haute précision tels que les systèmes de positionnement global (GPS), le lidar et les caméras sont souvent utilisés pour permettre une navigation autonome efficace.

I.6.1.3 Gestion de la charge utile

Le contrôle des drones à voilure fixe peut également être affecté par la gestion de la charge utile, comme les capteurs embarqués et les charges de mission spécifiques. Il est important de tenir compte des limites de poids, de position et de charge utile lors de la planification et du contrôle d'un vol.

I.6.1.4 Communication et connectivité

Les drones à voilure fixe peuvent nécessiter une communication bidirectionnelle avec les systèmes de contrôle au sol ou d'autres drones. Assurer une connectivité fiable et une communication en temps réel peut être difficile, en particulier dans des environnements complexes ou distants. Maintenir une communication efficace avec les drones nécessite des protocoles de communication robustes et des techniques de transmission appropriées.

I.6.1.5 Sécurité et réglementation

La sécurité est une préoccupation majeure lors du pilotage de drones à voilure fixe. Les drones doivent respecter les réglementations nationales et internationales sur les vols, l'espace aérien et la protection des données. Des mesures de sécurité telles que la détection et l'évitement d'obstacles, le géo repérage virtuel et les dispositifs de parachute d'urgence doivent être envisagées pour minimiser les risques potentiels.

I.6.2 Problèmes de contrôle adaptatif pour les drones à voilure fixe

Le contrôle adaptatif des drones à voilure fixe peut présenter des défis particuliers en raison de la complexité de la dynamique de vol et des variations des conditions environnementales [17,18,19,66].

I.6.2.1 Modélisation de la dynamique des drones

Une modélisation précise de la dynamique des drones à voilure fixe est essentielle pour développer des lois de commande adaptatives efficaces. Cela peut inclure des modèles d'aérodynamique, de propulsion, de stabilité et de contrôle des drones. Une modélisation précise permet de développer des stratégies de contrôle adaptatif adaptées à la dynamique spécifique des drones.

I.6.2.2 Adaptation aux fluctuations de masse et de centre de gravité

Les drones à voilure fixe peuvent subir des fluctuations de masse et de centre de gravité en raison de l'utilisation de capteurs embarqués, de la consommation de carburant ou du déploiement de la charge utile. Le contrôle adaptatif doit pouvoir s'adapter à ces variations pour maintenir des performances de vol optimales.

I.6.2.3 Gérer les perturbations externes

Les drones à voilure fixe sont soumis à des perturbations externes telles que le vent, les turbulences atmosphériques et les fluctuations de la masse d'air. Le contrôle adaptatif doit pouvoir compenser ces perturbations pour maintenir la stabilité et le contrôle du drone.

I.7. Introduction au diagnostic des pannes

Le diagnostic de panne est un processus essentiel dans de nombreux domaines tels que l'industrie, l'automobile, l'aérospatiale et l'électronique. Son objectif principal est de détecter, localiser et identifier les anomalies ou les erreurs au sein d'un système particulier.

Le diagnostic des pannes permet d'assurer le bon fonctionnement, la sécurité et la fiabilité du système. Cela joue un rôle clé dans la réduction des temps d'arrêt, la rationalisation de la maintenance, la réduction des coûts et la prévention des pannes catastrophiques.

Le processus de dépannage comprend généralement les étapes suivantes :

I.7.1. Détection d'erreur

Cette étape vise à détecter des signaux, des actions ou des indicateurs qui indiquent des erreurs ou des anomalies. Cela peut être fait à l'aide de capteurs, de mesures physiques, de données historiques, de modèles mathématiques, etc.

I.7.2. Identification de la panne

Une fois qu'une anomalie est détectée, la cause première de la panne doit être identifiée. Cela comprend l'analyse des données, la comparaison des résultats avec les modèles attendus et l'identification des sources d'erreur possibles.

I.7.3. Isolation des défauts

Après avoir identifié la cause probable du problème, il est important de déterminer l'emplacement exact du problème dans le système. Cela peut nécessiter des méthodes supplémentaires telles que l'analyse de la topologie du système à l'aide de techniques de localisation ou d'outils de diagnostic spéciaux.

I.7.4. Prévention et correction des erreurs

Une fois qu'une erreur a été diagnostiquée et identifiée, des mesures correctives peuvent être prises pour réparer le système et prévenir de futures erreurs. Cela peut inclure des réparations, des remplacements, des ajustements et des mises à niveau du système. Diverses approches et techniques sont utilisées dans le domaine du diagnostic

des pannes, notamment des méthodes basées sur des modèles, des méthodes de base de données, des méthodes probabilistes, des méthodes de traitement du signal et des méthodes d'apprentissage automatique. Ces approches peuvent être adaptées en fonction des spécifications du système. Et à des fins de diagnostic. Les aspects réglementaires, liés à la sécurité, interprétables et la gestion des données doivent également être pris en compte lors du diagnostic des erreurs [20].

I.7.1.1. Méthode de diagnostic des pannes

Différentes méthodes de diagnostic des pannes sont disponibles en fonction du système inspecté, des données disponibles et de l'objectif du diagnostic. Voici quelques-unes des méthodes les plus couramment utilisées :

I.7.1.1.2. Méthodes basées sur des règles

Ces méthodes utilisent des règles et des heuristiques spécifiques pour détecter et diagnostiquer les erreurs. Les règles sont généralement basées sur l'expérience et les connaissances d'experts dans le domaine. Par exemple, vous pouvez activer une règle qui indique un échec lorsqu'une certaine valeur de capteur dépasse un seuil prédéfini.

I.7.1.1.3. Méthodes basées sur des modèles

Ces méthodes utilisent des modèles mathématiques ou physiques du système pour détecter et diagnostiquer les erreurs. Le modèle représente le comportement normal du système et est comparé aux données mesurées en temps réel. Les écarts entre les prédictions du modèle et les mesures peuvent indiquer des erreurs.

I.7.1.1.4. Techniques basées sur les données

Ces techniques utilisent des techniques statistiques ou d'apprentissage automatique pour analyser les données systèmes historiques et en temps réel. Ils recherchent des modèles de comportement inhabituel qui pourraient être liés à des bogues. Les techniques basées sur les données peuvent être utilisées lorsque les modèles du système sont complexes ou inconnus.

I.7.1.1.5. Méthodes hybrides

Les méthodes hybrides combinent plusieurs approches pour améliorer la précision et la robustesse du diagnostic. Par exemple, une approche hybride peut combiner des règles expertes et des techniques d'apprentissage automatique pour détecter et diagnostiquer les erreurs plus efficacement.

I.7.1.1.6. Méthodes probabilistes

Les méthodes probabilistes utilisent des modèles probabilistes pour estimer les probabilités de diverses causes de défaillance. Tenir compte des incertitudes associées aux données mesurées et attribuer des probabilités à diverses hypothèses de défaillance. Les méthodes probabilistes sont souvent utilisées lorsque les informations disponibles sont incomplètes ou incertaines. Il est important de noter que ces méthodes peuvent être ajustées en fonction du système et des objectifs de diagnostic. Certains systèmes peuvent nécessiter une combinaison de plusieurs méthodes pour obtenir un diagnostic plus précis [21].

I.7.2.1. Techniques de diagnostic des pannes

Il existe diverses techniques de diagnostic des pannes qui sont utilisées pour détecter, identifier et identifier les pannes du système. Voici quelques-unes des techniques les plus couramment utilisées :

I.7.2.1.1. Analyse de signature

Cette technique analyse les signatures ou les propriétés des signaux ou des données mesurées pour détecter les anomalies. Cela peut impliquer une analyse statistique des données, l'utilisation de filtres ou de techniques de traitement du signal pour extraire les caractéristiques d'intérêt, ou l'utilisation de méthodes de décomposition et de reconstruction du signal.

I.7.2.1.2. Analyse de modèle

Cette technique utilise un modèle mathématique ou physique du système pour comparer le comportement réel et attendu du système. Les différences entre les prédictions du modèle et les mesures réelles peuvent indiquer la présence d'une erreur. Cette technique est souvent utilisée dans les systèmes où le modèle est bien établi et précis [22].

I.7.2.1.3. Méthode basée sur des seuils

Cette technique utilise des seuils prédéfinis pour détecter les anomalies. Les mesures supérieures ou inférieures aux limites spécifiées sont considérées comme une indication de défaillance. Cette méthode est simple, mais nécessite une connaissance approfondie du système pour définir correctement les seuils.

I.7.2.1.4. Analyse de redondance

Cette technique est basée sur la redondance des capteurs ou des composants au sein du système. En comparant les mesures de différents capteurs ou en analysant les résultats de différents composants en parallèle, les écarts peuvent être détectés et les erreurs identifiées [23].

I.7.2.1.5. Méthodes basées sur l'apprentissage automatique

Ces méthodes utilisent des algorithmes d'apprentissage automatique pour tirer des enseignements des données historiques et faire des prédictions sur les défaillances. L'apprentissage automatique peut être utilisé pour reconnaître des modèles complexes et des relations non linéaires entre les variables mesurées et les défauts.

I.7.2.1.6. Méthodes basées sur les réseaux de neurones

Les réseaux de neurones sont des modèles mathématiques inspirés du fonctionnement du cerveau humain. Ils peuvent être utilisés pour diagnostiquer les erreurs en apprenant à partir des données d'entrée et en fournissant des prédictions et des classifications sur les erreurs [24].

I.7.2.1.7. Méthodes basées sur les probabilités

Ces méthodes utilisent des modèles probabilistes pour estimer les probabilités de diverses causes de défaillance. Les incertitudes associées aux données mesurées sont prises en compte et des probabilités sont affectées aux hypothèses de défaillance. Il est important de noter que ces techniques peuvent être utilisées individuellement ou en combinaison, selon les caractéristiques du système, la nature des données et les objectifs de diagnostic [25].

I.7.3.1. Approches basées sur les données pour le diagnostic des pannes

Une approche basée sur les données est une technique de diagnostic des pannes qui utilise des techniques statistiques ou d'apprentissage automatique pour analyser les données systèmes historiques et en temps réel. Ils sont populaires car ils peuvent détecter des modèles complexes et des relations non linéaires entre les métriques et les déficiences. Voici quelques approches de dépannage basées sur les données :

I.7.3.1.1. Analyse statistique

Cette approche utilise des techniques statistiques telles que l'analyse de séries chronologiques, l'analyse en composantes principales (ACP) et l'analyse de corrélation. Le but est de détecter un comportement anormal ou des écarts par rapport à la norme dans les données mesurées.

I.7.3.1.2. Méthodes de regroupement

Ces méthodes regroupent les données de mesure en fonction de la similarité ou de la distance. Le regroupement de données peut aider à identifier des modèles de comportement similaire et à identifier des valeurs aberrantes ou des clusters distincts qui peuvent indiquer des erreurs [26].

I.7.3.1.3. Apprentissage automatique supervisé

Cette approche utilise des algorithmes d'apprentissage automatique supervisé tels que des arbres de décision, des réseaux de neurones et des machines à vecteurs de support (SVM). Apprenez à classer ou à prévoir les erreurs en fonction de nouvelles données à l'aide de données d'apprentissage étiquetées.

I.7.3.1.4. Apprentissage automatique non supervisé

Cette approche utilise des algorithmes d'apprentissage automatique non supervisés tels que : Classification non supervisée, détection d'anomalies, etc. Inspectez les structures et les modèles de données sans annotations pour détecter les comportements anormaux et les déviations.

I.7.3.1.5. Réseaux de neurones profonds

Les réseaux de neurones profonds tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones

récurrents (RNN) sont utilisés pour le diagnostic des pannes.

Il peut capturer des caractéristiques complexes et reconnaître des modèles temporels ou spatiaux dans les données mesurées. Il est important de noter que ces approches nécessitent des données fiables, de haute qualité et représentatives du système pour des résultats précis. De plus, la mise en œuvre réussie de ces approches nécessite une connaissance préalable du système et une bonne préparation des données [27].

I.7.4.1. Méthodes avancées de diagnostic des pannes

Les méthodes avancées de diagnostic des pannes sont des approches plus sophistiquées et spécialisées pour détecter, identifier et isoler les pannes du système. Des technologies de pointe telles que l'intelligence artificielle, l'apprentissage automatique et les réseaux de neurones sont souvent utilisées pour améliorer la précision et l'efficacité des diagnostics. Voici quelques méthodes de dépannage avancées :

I.7.4.1.1. Réseaux de neurones profonds

Les réseaux de neurones profonds tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN) sont utilisés pour le diagnostic des erreurs.

Il peut capturer des caractéristiques complexes et reconnaître des modèles temporels ou spatiaux dans les données mesurées.

I.7.4.1.2. Méthodes basées sur les réseaux bayésiens

Les réseaux bayésiens sont des modèles probabilistes qui utilisent des probabilités conditionnelles pour représenter les relations entre les variables. Ils peuvent être utilisés pour diagnostiquer les erreurs en tenant compte des incertitudes de mesure et en évaluant les probabilités de diverses sources d'erreurs.

I.7.4.1.3. Méthodes d'apprentissage en ligne

Ces méthodes permettent un diagnostic d'erreur en temps réel en apprenant en permanence à partir de nouvelles données. Ceux-ci sont particulièrement utiles pour les systèmes dynamiques qui changent avec le temps.

I.7.4.1.4. Approches basées sur des systèmes multi-agents

Ces approches utilisent des systèmes multi-agents pour le diagnostic des erreurs. Chaque agent représente un composant ou un sous-système du système global et interagit avec d'autres agents pour échanger des informations et prendre des décisions de diagnostic.

I.7.4.1.5. Méthodes basées sur les réseaux de Petri

Les réseaux de Petri sont des modèles mathématiques permettant de représenter et d'analyser des systèmes à événements discrets. Ils peuvent être utilisés pour le diagnostic d'erreur en modélisant les états du système et en analysant les transitions entre ces états.

I.7.4.1.6. Méthodes améliorées basées sur l'apprentissage en profondeur

Ces méthodes combinent des techniques d'apprentissage en profondeur et d'apprentissage par renforcement pour effectuer un diagnostic d'erreur. Ceux-ci permettent au système d'apprendre à prendre des décisions de diagnostic en maximisant les récompenses spécifiques en fonction des résultats obtenus.

I.7.4.1.7. Méthodes basées sur l'analyse des vibrations

L'analyse des vibrations est une méthode de diagnostic de panne couramment utilisée pour détecter les anomalies dans les machines et les équipements. Des capteurs de vibrations sont utilisés pour mesurer les vibrations et des techniques analytiques avancées sont utilisées pour identifier les défauts. Il est important de noter que ces techniques avancées nécessitent souvent des données de haute qualité et une quantité suffisante de données pour produire des résultats fiables. En outre, une mise en œuvre réussie nécessite une connaissance approfondie du système et une expertise dans l'utilisation de la technologie de pointe [28].

I.8. Conclusion

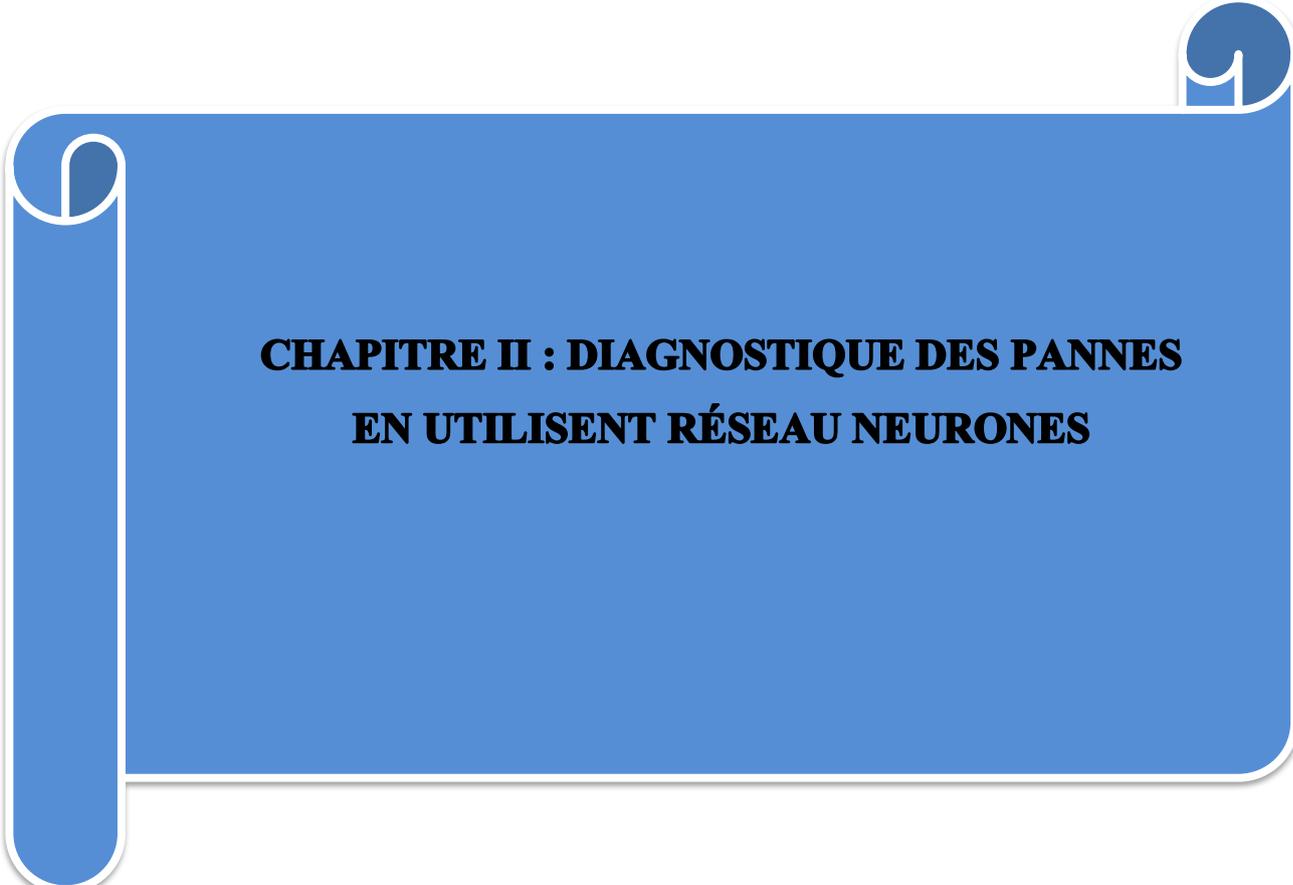
Au terme de ce premier chapitre, nous avons tracé un aperçu essentiel sur les UAV, en mettant en lumière leur évolution historique, les différentes classes de systèmes existantes et les bases fondamentales de leur conception.

L'utilisation croissante et exponentielle des véhicules aériens sans pilote (UAV) dans un avenir proche nous pousse à viser une augmentation significative de leur niveau de performance, de fiabilité, d'efficacité et d'efficience. Pour atteindre ces objectifs ambitieux, il est crucial de relever des défis critiques tels que la sécurité des opérations, l'intégration dans l'espace aérien national, la fonctionnalité en conditions normales et perturbées, la flexibilité opérationnelle, l'optimalité et l'adaptation autonome.

Le processus de conception de tels systèmes autonomes requiert l'appui d'outils de simulation adéquats à toutes les étapes et à tous les niveaux. Pour répondre aux besoins de missions toujours plus complexes et de niveaux d'autonomie élevés, les conceptions actuelles et futures d'UAV devront être de plus en plus sophistiquées et complexes, intégrant des informations embarquées à différents niveaux, permettant une détermination du statut en temps réel, une prise de décision et une navigation adaptative et contrôlée.

Nous avons également examiné les problèmes de contrôle adaptatif spécifiques aux UAV, ainsi que différentes techniques et approches de diagnostic des pannes. Ces aspects sont cruciaux pour assurer le bon fonctionnement et la sécurité des UAV, en leur permettant de détecter, isoler et réagir aux défaillances éventuelles de manière proactive.

Ce premier chapitre jette ainsi les bases indispensables pour aborder les prochains volets de notre mémoire, où nous explorerons en profondeur les aspects spécifiques du développement d'un système de contrôle adaptatif pour les UAV à voilure fixe. Grâce à une compréhension approfondie des UAV, des problèmes de contrôle adaptatif et des techniques de diagnostic des pannes, nous sommes désormais mieux équipés pour relever les défis futurs et contribuer au perfectionnement des UAV autonomes, sûrs et efficaces.



**CHAPITRE II : DIAGNOSTIQUE DES PANNES
EN UTILISANT RÉSEAU NEURONES**

II.1. INTRODUCTION

Dans le domaine en constante évolution des Véhicules Aériens Non Habités (UAV), la sécurité, la fiabilité et l'efficacité opérationnelle sont des aspects cruciaux pour garantir leur bon fonctionnement. La détection précoce et précise des pannes potentielles est une préoccupation majeure pour assurer des vols sans encombre et réduire les risques d'incidents. Dans ce deuxième chapitre de notre mémoire, nous aborderons un domaine de recherche prometteur qui offre des solutions avancées pour le diagnostic des pannes sur les UAV : l'utilisation des réseaux neuronaux.

La première partie de ce chapitre sera consacrée à l'étude approfondie du modèle dynamique de notre UAV. Comprendre les caractéristiques et les paramètres qui influencent son comportement en vol est essentiel pour mettre en place des techniques de diagnostic fiables et adaptées. Nous explorerons les forces aérodynamiques, les contraintes mécaniques, les interactions avec l'environnement et tous les autres facteurs qui contribuent à la dynamique de notre UAV.

Ensuite, nous nous concentrerons sur les réseaux neuronaux, une approche révolutionnaire d'apprentissage machine inspirée par le fonctionnement du cerveau humain. Nous examinerons en détail leur architecture, qui comprend plusieurs couches de neurones interconnectées, ainsi que leur procédure d'entraînement. Comprendre comment ces réseaux sont formés et optimisés nous permettra de mieux exploiter leur potentiel pour le diagnostic des pannes sur les UAV.

Un élément clé de cette section sera également l'étude des différents types d'apprentissage des réseaux neuronaux. L'apprentissage supervisé, non supervisé et par renforcement sont autant de méthodes qui peuvent être exploitées pour détecter et caractériser les défaillances éventuelles de notre système UAV, en utilisant des données d'entraînement appropriées.

Dans la troisième partie de ce chapitre, nous aborderons le sujet central du diagnostic des pannes sur les UAV à l'aide des réseaux neuronaux. Nous explorerons comment cette approche novatrice permet de détecter et d'isoler efficacement les défaillances, fournissant ainsi une capacité de surveillance en temps réel pour assurer un vol plus sûr et plus fiable.

Par la suite, nous étudierons une technique de contrôle classique et bien établie : le PID (Proportionnel Intégral Dérivé). Ce contrôleur a largement fait ses preuves dans le domaine de l'automatique et est souvent utilisé pour stabiliser et contrôler les UAV. Nous analyserons son fonctionnement et son application dans le contexte de

Enfin, la dernière partie de ce chapitre portera sur les concepts de contrôle adaptatif, en mettant l'accent sur la planification des gains. Nous verrons comment cette approche avancée de contrôle permet d'ajuster dynamiquement les paramètres du système en fonction des variations de l'environnement et des conditions de vol, garantissant ainsi des performances optimales et une réactivité accrue.

En somme, ce chapitre vise à explorer en profondeur le diagnostic des pannes en utilisant les réseaux neuronaux dans le contexte de notre UAV. En combinant une connaissance approfondie de la dynamique de notre système avec des techniques avancées d'apprentissage machine et de contrôle, nous aspirons à améliorer considérablement la sécurité, la fiabilité et les performances de notre UAV pour des opérations aériennes plus sûres et plus efficaces.

II.2 Le modèle Dynamic d'un UAV

En utilisant la loi de Newton, l'équation de force est obtenue comme [64]

$$F = m \cdot \vec{a} = m \cdot \vec{V}_T \dot{\quad} \quad (II.1)$$

Dans le cas de la carrosserie, l'accélération du centre de masse est exprimée par

$$\{V_T \dot{\quad}\}_b = V_T \dot{\quad} + \{\vec{\Omega}\}_b \cdot V_T \quad (II.2)$$

Où a indique que la coordonnée est définie dans le cadre du corps, de plus, l'équation de force de Newton est définie dans le cadre du corps comme

$$\{\vec{F}\}_a = [V_T \dot{\quad} + \{\vec{\Omega}\}_b \cdot V_T] \quad (II.3)$$

Où Ω est la vitesse angulaire du cadre du corps défini comme trouvé dans le modèle cinématique

$$\{\vec{\Omega}\}_B = \begin{bmatrix} 0 & -r & q \\ r & 0 & -p \\ -q & p & 0 \end{bmatrix} \quad (II.4)$$

II.2.1 Le modèle Non linéaire d'un UAV

$$\begin{pmatrix} \dot{p} \\ \dot{q} \\ \dot{r} \end{pmatrix} = \begin{pmatrix} \frac{J_z}{\Gamma} & 0 & \frac{J_{xz}}{\Gamma} \\ 0 & \frac{1}{J_y} & 0 \\ \frac{J_{xz}}{\Gamma} & 0 & \frac{J_x}{\Gamma} \end{pmatrix} \left[\begin{pmatrix} 0 & r & -q \\ -r & 0 & p \\ q & -p & 0 \end{pmatrix} \begin{pmatrix} J_x & 0 & -J_{xz} \\ 0 & J_y & 0 \\ -J_{xy} & 0 & J_z \end{pmatrix} \begin{pmatrix} p \\ q \\ r \end{pmatrix} + \begin{pmatrix} l \\ m \\ n \end{pmatrix} \right] =$$

$$\begin{pmatrix} \frac{J_z}{\Gamma} & 0 & \frac{J_{xz}}{\Gamma} \\ 0 & \frac{1}{J_y} & 0 \\ \frac{J_{xz}}{\Gamma} & 0 & \frac{J_x}{\Gamma} \end{pmatrix} \left[\begin{pmatrix} J_{xz}pq + (J_y - J_z)qr \\ J_{xz}(r^2 - p^2) + (J_z - J_x)pr \\ (J_x - J_y)pq - J_{xz}qr \end{pmatrix} + \begin{pmatrix} l \\ m \\ n \end{pmatrix} \right] \quad (\text{II.5})$$

$$\begin{pmatrix} \dot{} \\ u \\ \dot{} \\ v \\ \dot{} \\ w \end{pmatrix} = \begin{pmatrix} rv - qw \\ pw - ru \\ qu - qv \end{pmatrix} + \frac{1}{m} \begin{pmatrix} f_x \\ f_y \\ f_z \end{pmatrix} \quad (\text{II.6})$$

$$\begin{pmatrix} f_x \\ f_y \\ f_z \end{pmatrix} = \begin{pmatrix} -mg \sin\theta \\ mg \cos\theta \sin\varphi \\ mg \cos\theta \cos\varphi \end{pmatrix} + \frac{1}{2} \rho V_a^2 S \begin{pmatrix} C_x(\alpha) + C_{X_q}(\alpha) \frac{c}{2V_a} q + C_{X_{\delta_e}}(\alpha) \delta_e \\ C_{Y_0} + C_{Y_\beta} \beta + C_{Y_p} \frac{b}{2V_a} p + C_{Y_r} \frac{b}{2V_a} r + C_{Y_{\delta_a}} \delta_a + C_{Y_{\delta_r}} \delta_r \\ C_z(\alpha) + C_{z_q}(\alpha) \frac{c}{2V_a} q + C_{z_{\delta_e}}(\alpha) \delta_e \end{pmatrix} + \frac{1}{2} \rho S_{prop} C_{prop} \begin{pmatrix} (k_{motor} \delta_t)^2 - V_a^2 \\ 0 \\ 0 \end{pmatrix} \quad (\text{II.7})$$

$$\begin{pmatrix} l \\ m \\ n \end{pmatrix} = \frac{1}{2} \rho V_a^2 S \begin{pmatrix} b [C_{l_0} + C_{l_\beta} \beta + C_{l_p} \frac{b}{2V_a} p + C_{l_r} \frac{b}{2V_a} r + C_{l_{\delta_a}} \delta_a + C_{l_{\delta_r}} \delta_r] \\ c [C_{m_0} + C_{m_\alpha} \alpha + C_{m_q} \frac{c}{2V_a} q + C_{m_{\delta_e}} \delta_e] \\ b [C_{n_0} + C_{n_\beta} \beta + C_{n_p} \frac{b}{2V_a} p + C_{n_r} \frac{b}{2V_a} r + C_{n_{\delta_a}} \delta_a + C_{n_{\delta_r}} \delta_r] \end{pmatrix} + \begin{pmatrix} -k_{T_p} (k_\Omega \delta_t)^2 \\ 0 \\ 0 \end{pmatrix} \quad (\text{II.8})$$

$$\begin{pmatrix} f_x \\ f_y \\ f_z \end{pmatrix} = \begin{pmatrix} -mg \sin\theta \\ mg \cos\theta \sin\varnothing \\ mg \cos\theta \cos\varnothing \end{pmatrix} + \frac{1}{2} \rho V_a^2 S \begin{pmatrix} C_X(\alpha) + C_{X_q}(\alpha) \frac{c}{2V_a} q + C_{X_{\delta_e}}(\alpha) \delta_e \\ C_{Y_0} + C_{Y_\beta} \beta + C_{Y_p} + C_{Y_r} \frac{b}{2V_a} r + C_{Y_{\delta_a}} \delta_a + C_{Y_{\delta_r}} \delta_r \\ C_z(\alpha) + C_z(\alpha) \frac{c}{2V_a} q + C_{\delta_e}(\alpha) \delta_e \end{pmatrix} + \frac{1}{2} \rho S_{prop} C_{prop} \begin{pmatrix} (k_{motor} \delta_t)^2 - V_a^2 \\ 0 \\ 0 \end{pmatrix} \quad (\text{II.9})$$

$$\begin{pmatrix} 1 \\ m \\ n \end{pmatrix} = \frac{1}{2} \rho V_a^2 S \begin{pmatrix} b[C_{l_0} + C_{l_\beta} \beta + C_{l_p} \frac{b}{2V_a} p + C_{l_r} \frac{b}{2V_a} r + C_{l_{\delta_a}} \delta_a + C_{l_{\delta_r}} \delta_r] \\ c[C_{m_0} + C_{m_\alpha} \alpha + C_{m_q} \frac{c}{2V_a} q + C_{m_{\delta_e}} \delta_e] \\ b[C_{n_0} + C_{n_\beta} \beta + C_{n_p} \frac{b}{2V_a} p + C_{n_r} \frac{b}{2V_a} r + C_{n_{\delta_a}} \delta_a + C_{n_{\delta_r}} \delta_r] \end{pmatrix} + \begin{pmatrix} -k_{T_p} (k_\Omega \delta_t)^2 \\ 0 \\ 0 \end{pmatrix} \quad (\text{II.10})$$

II.3. RÉSEAU DE NEURONES

II.3.1. Introduction

Les réseaux de neurones artificiels sont un outil bien adapté pour les problèmes de perception, de classification, de prédiction et contrôle. Leur utilisation s'inscrit particulièrement dans les méthodologies de contrôle en l'absence de modèle du procédé. Leur utilisation est principalement guidée par leur propriété suivante [2] :

- Capacités d'apprentissage,
- Parallélisme dans le traitement,
- Adaptable aux non-linéarités des systèmes,
- Rapidité du traitement

II.3.1.1. Le neurone biologique

Les réseaux neuronaux (Haykin (1994), Kosko (1992)) sont fortement inspirés des processus biologiques impliqués dans le traitement de l'information, notamment le système nerveux et son unité de base, le neurone. Dans ce modèle, le neurone reçoit plusieurs signaux provenant d'autres neurones via ses dendrites. Chaque signal est multiplié par un coefficient de pondération spécifique. Ces signaux sont ensuite agrégés dans le corps de la cellule, appelé soma. Lorsque le signal composite atteint un seuil donné, un signal appelé potentiel d'action est généré et transmis le long de l'axone, qui agit comme le canal de sortie du neurone [1].

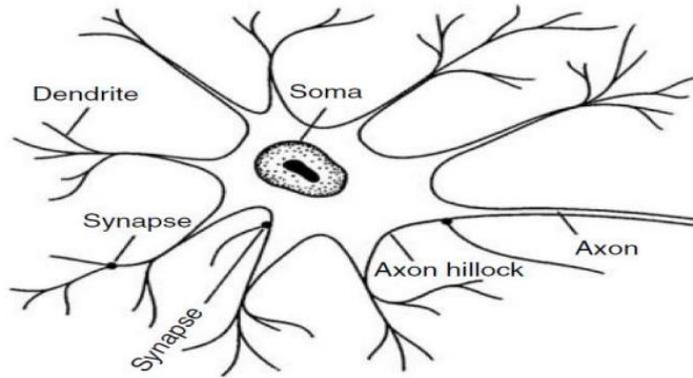


Figure II.1: Schéma simplifié d'un neurone biologique [1]

II.3.1.2. Le neurone formel (artificiel)

Warren McCulloch et Walter Pitts ont décrit le premier modèle formel d'un neurone informatique élémentaire (McCulloch et Pitts 1943). Cependant, le modèle utilise plusieurs simplifications drastiques permettant uniquement l'état binaire 0 et 1, opère sous une hypothèse à temps discret et les opérations synchrones de tous les neurones dans un réseau plus grand [41].

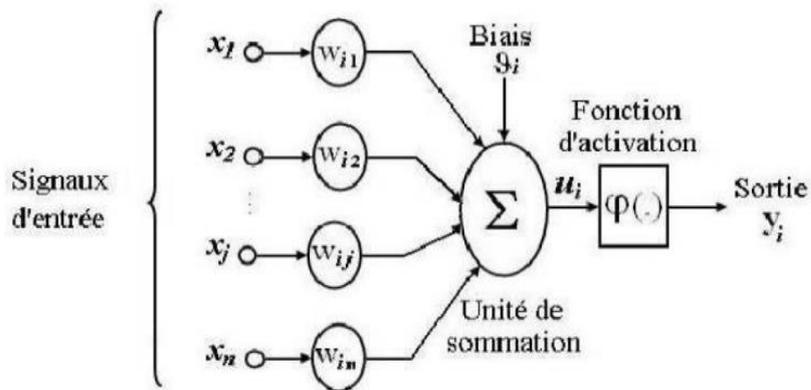


Figure 8: modèle de base d'un neurone formel [2]

II.3.1.3. Comparaison entre neurone biologique et formel

Tableau 1:Table comparaison entre neurone biologique et formel

Neurone biologique	Neurone artificiel
Synapses	Poids de connexions
Axones	Signal de sortie
Dendrite	Signal d'entrée
Somma	Fonction d'activation

II.3.2. Modèle de réseaux de neurones

Les poids et les seuils sont fixés dans le modèle. Chaque neurone est constitué d'un élément de traitement avec des connexion d'entrée synaptique et une seule sortie. La première étape est un processus où les entrées x_1, x_2, \dots, x_n multiplié par leurs poids respectifs w_1, w_2, \dots, w_n sont additionnées par le neurones.

Une valeur de seuil b , appelé Bias, joue un rôle important pour certains modèles de neurones et doit être explicitement mentionnées comme paramètre distinct du modèle neuronal.

Afin de permettre des conditions d'entrée variable et leur effet sur la sortie, il est généralement nécessaire d'inclure une fonction d'activation non-linéaire $f(.)$ dans l'agencement des neurones. C'est ainsi que des niveaux d'amplification adéquate peuvent être utilisée si nécessaire pour des petits signaux d'entrée, ce qui évite de conduire la sortie à des limites inacceptable. Un certain nombre de fonction d'activation sont utilisées avec différents réseaux de neurones. Le processus de sommation résultant peut être affiché comme : [42]

$$Net = (X_1 \cdot W_1 + X_2 \cdot W_2 + \dots + X_n \cdot W_n) + b \quad (\text{II.11})$$

$$y = f(net) \quad (\text{II.12})$$

II.3.2.1. Les entrées

Chapitre II

Les entrées de réseau sont le vecteur \mathbf{X} .

Elles peuvent être :

- Réelles
- Booléenne
- Binaire (0,1) ou bipolaire (-1,1)

$$X = \begin{bmatrix} x1 \\ x2 \\ \cdot \\ \cdot \\ \cdot \\ x_m \end{bmatrix} \quad (\text{II.13})$$

II.3.2.2. Les poids

Les poids de réseau sont définis par la matrice de poids \mathbf{W} .

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,m} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,m} \\ \cdot & \cdot & \cdots & \cdot \\ \cdot & \cdot & \cdots & \cdot \\ \cdot & \cdot & \cdots & \cdot \\ w_{n,1} & w_{n,2} & \cdots & w_{n,m} \end{bmatrix} \quad (\text{II.14})$$

II.3.2.3. Les bias

Les biases sont définis par le vecteur de bias \mathbf{b} .

$$b = \begin{bmatrix} b1 \\ b2 \\ \cdot \\ \cdot \\ \cdot \\ b_m \end{bmatrix} \quad (\text{II.15})$$

II.3.2.4. Les fonctions d'activations

Cette fonction permet de définir l'état interne de neurone en fonction de son entrées totale, citons à titre exemple quelque fonction souvent utilisées :

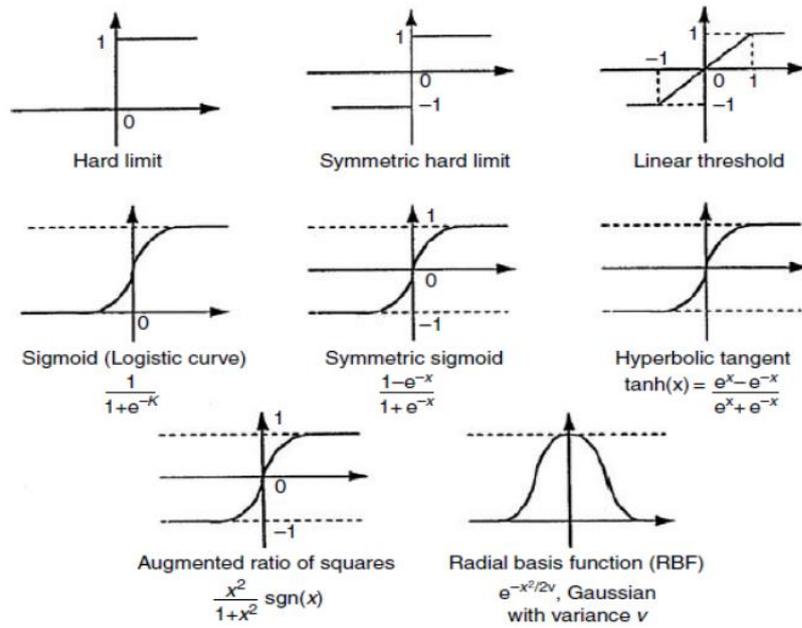


Figure 9: différents type de fonction d'activations pour le réseau neurones formel [41].

Il est remarqué que les équations décrivant le comportement des neurones formels ne prennent pas en compte la notion de temps. En d'autres termes, la plupart des modèles de réseau de neurones actuels sont conçus comme des systèmes à temps discret, où le comportement des composants ne varie pas au fil du temps [43].

II.3.2.5. La sortie

La sortie Y de réseau peut être écrite sous la forme d'un vecteur

$$Y = f(W.X + b) \quad (II.16)$$

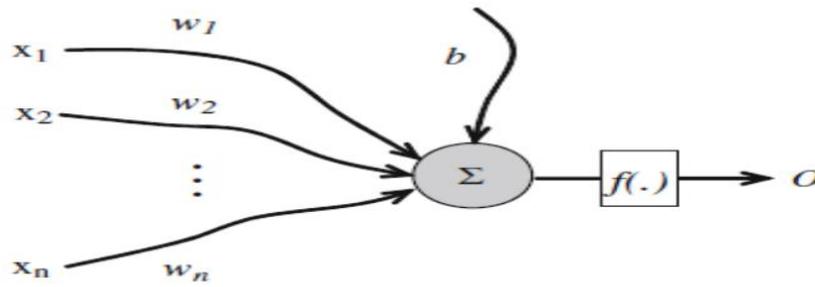


Figure 10: modèle mathématique d'un réseau de neurone formel [42].

II.3.3.les architectures neuronales

L'architecture du réseau de neurone n'est souvent que partiellement imposée par la tâche à réaliser : les entrées et les sorties du réseau, peuvent être fixées en fonction de celle-ci par le concepteur, ainsi que le type et la connectivité des neurones, mais le nombre de neurones ne peut être fixé à priori, et il est en générale ajusté selon le succès de l'apprentissage

Une fois l'architecture du réseau fixée, le but de l'apprentissage est l'estimation des poids synaptiques, pour remplir au mieux la tâche à laquelle le réseau est destiné [43].

On appelle apprentissage, l'opération par laquelle le réseau de neurones acquiert la capacité de faire certaines tâches en modifiant ses paramètres internes, (connections) en utilisant un algorithme d'adaptation paramétrique, appelé algorithme d'apprentissage. On dit que le réseau a appris la paire entrée sortie (x_i, y_i) , si il répond avec y_i si x_i est présenté comme entrée ; la paire (x_i, y_i) , représente un échantillon d'une fonction $f \in R^n$. [44].

II.3.3.1. Le réseau neurones non bouclé

Un réseau neurones non bouclé ou réseau unidirectionnel (Feedforward network) est représenté par un ensemble de neurones connectés entre eux telle que l'information circule des couches d'entrée vers des couches de sortie à travers d'éventuelle couche intermédiaire sans retour en arrière. La figure illustre un RNA non bouclé [45].

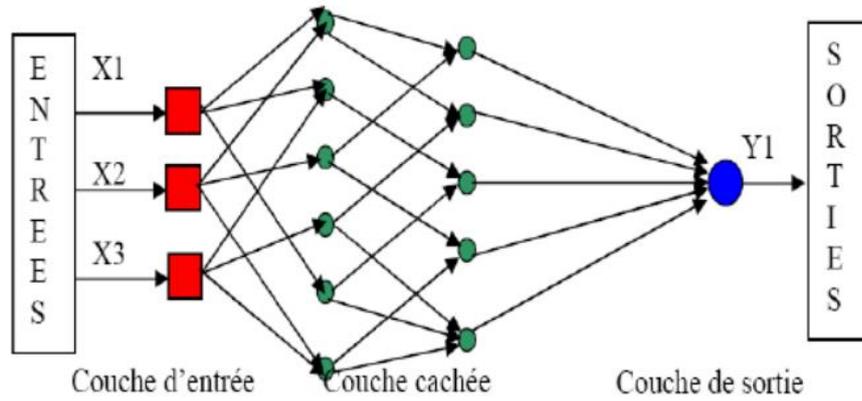


Figure 11: modèle d'un réseau de neurone non bouclé [41].

II.3.3.2. Le réseau neurones non bouclé Monocouche

Dans ce réseau spécifique, nous trouvons une couche d'entrée qui reçoit les stimuli à traiter via des nœuds sources. Cette couche projette ensuite ses informations vers une couche de sortie constituée de neurones (nœuds de calcul) qui transmettent les résultats du traitement vers l'environnement extérieur.

Le réseau proactif présenté ici est un réseau monocouche comprenant 4 nœuds en entrée et 3 nœuds en sortie. Le terme "monocouche" est utilisé pour décrire la couche de sortie [41.45].

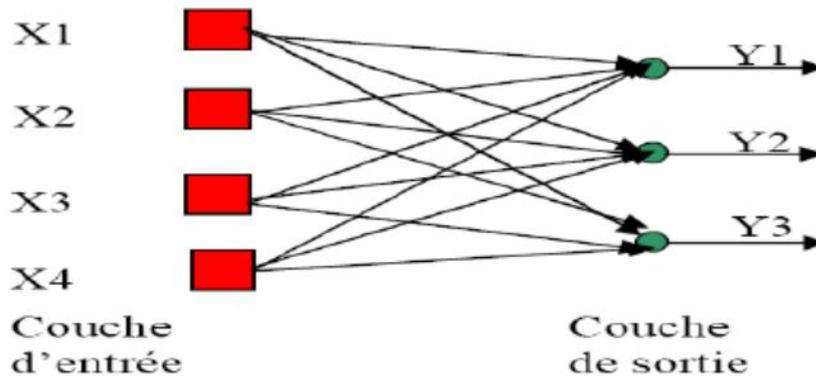


Figure 12: modèle d'un réseau de neurone non bouclé monocouche [45].

II.3.3.3. Le réseau neurones non bouclé multicouche

Le réseau proactif de ce type présente une caractéristique importante : la présence d'une ou plusieurs couches cachées, dont les nœuds de calcul sont appelés neurones cachés. Ces couches cachées s'interposent entre l'entrée

Du réseau et la sortie. Leur rôle consiste à effectuer un prétraitement des signaux d'entrée provenant du milieu extérieur, reçus par la couche d'entrée, et à transmettre les résultats correspondants à la couche de sortie, où les réponses finales du réseau seront déterminées [41.43].

Ce rôle de prétraitement permet au réseau, en ajoutant une ou plusieurs couches cachées, d'extraire davantage de propriétés statiques que celles obtenues par un réseau similaire ayant moins de couches cachées. Cette capacité est particulièrement utile pour réaliser des fonctions plus complexes que de simples séparations linéaires [45].

Dans l'illustration, nous pouvons observer un réseau avec une seule couche cachée, comprenant 4 unités d'entrée, 3 unités cachées et 2 unités de sortie.

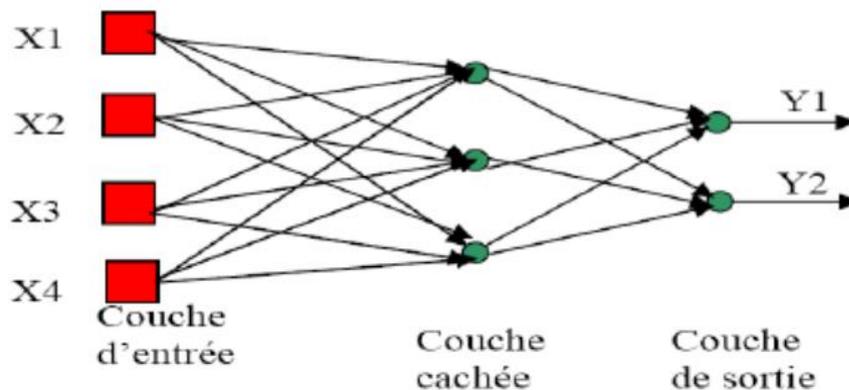


Figure 13: modèle d'un réseau de neurone non bouclé multicouches [45].

Ce réseau est dit complètement connecté dans le sens que chaque nœud d'une couche est connecté à tous les nœuds de la couche adjacente suivante. Si éventuellement, des connexions manquaient entre des neurones et deux couches voisines, le réseau serait dit partiellement connecté.

II.3.3.3.1 Le Perceptron Multicouches

Le perceptron multicouche est un type de réseau de neurones artificiels organisé en couches, où l'information circule dans une seule direction, de la couche d'entrée vers la couche de sortie.

Dans l'illustration, nous pouvons voir un exemple de réseau comprenant une couche d'entrée, deux couches cachées et une couche de sortie. La couche d'entrée est une couche virtuelle associée aux entrées du système, ne contenant aucun neurone. Les couches suivantes sont des couches de neurones [46].

La fonction de Perceptron multicouches :

$$y_i = \sigma\left(\sum_{l=1}^L w_{il} \sigma\left(\sum_{j=1}^n v_{lj} x_j + v_{l0}\right) + w_{i0}\right); i = 1, 2, \dots, m \quad (\text{II.17})$$

La fonction de la couche cachée :

$$Z_l = \sigma\left(\sum_{j=1}^n v_{lj} x_j + v_{l0}\right) \quad (\text{II.18})$$

Dans le cas général, les sorties des neurones de la dernière couche correspondent toujours aux sorties du système. Un perceptron multicouche peut avoir un nombre quelconque de couches et un nombre donné de neurones (ou d'entrées) par couche.

Ces neurones sont connectés entre eux par des connexions pondérées. Les poids de ces connexions déterminent le fonctionnement du réseau et permettent une transformation non linéaire de l'espace des entrées vers l'espace des sorties.

La création d'un perceptron multicouche pour résoudre un problème donné implique de déterminer la meilleure application possible, définie par un ensemble de données d'apprentissage composé de paires de vecteurs d'entrées et de sorties souhaitées. Cette détermination peut se faire, entre autres, grâce à des algorithmes de rétropropagation (Parizeau 2004).

Le modèle de perceptron multicouche se caractérise par une architecture globale où tous les neurones contribuent à la sortie après la phase d'apprentissage. Cette caractéristique lui confère de meilleures propriétés en classification, ce qui le rend particulièrement intéressant pour une utilisation en contrôle [43].

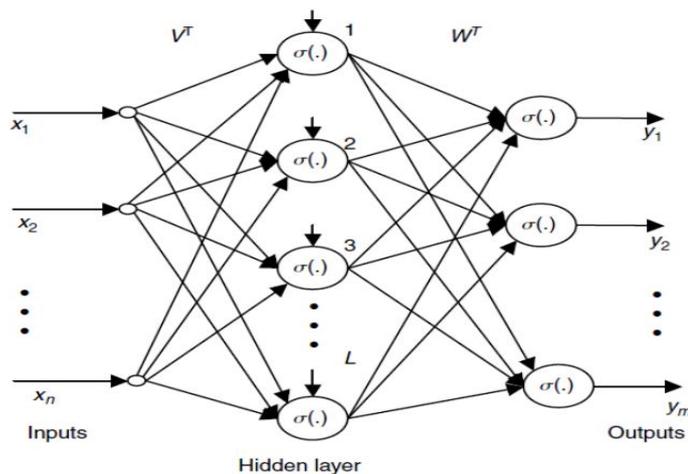


Figure 14: Réseau de neurone du Perceptron Multicouche [44]

II.3.3.4. Le réseau de neurones bouclé

Les réseaux récurrents, également connus sous le nom de réseaux récurrents, partagent une structure similaire à celle des réseaux unidirectionnels, mais ils sont enrichis par des connexions entre les éléments de la même couche ou vers des couches antérieures. Ces réseaux possèdent une puissance remarquable car leur fonctionnement est séquentiel et adopte un comportement dynamique [45].

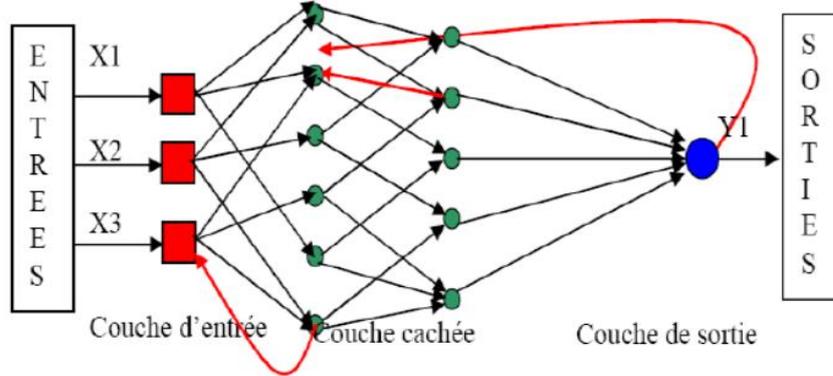


Figure 15: Modèle d'un réseau de neurones bouclée.

II.3.3.4.1. Les réseaux à fonction de bases radiales (RBF)

Les réseaux de neurones à fonction de bases radiales sont aussi des réseaux à propagation unidirectionnelle. Ils sont caractérisés par une unique couche cachée, constituée de fonctions noyaux gaussiennes, comme représenté dans l'illustration [46].

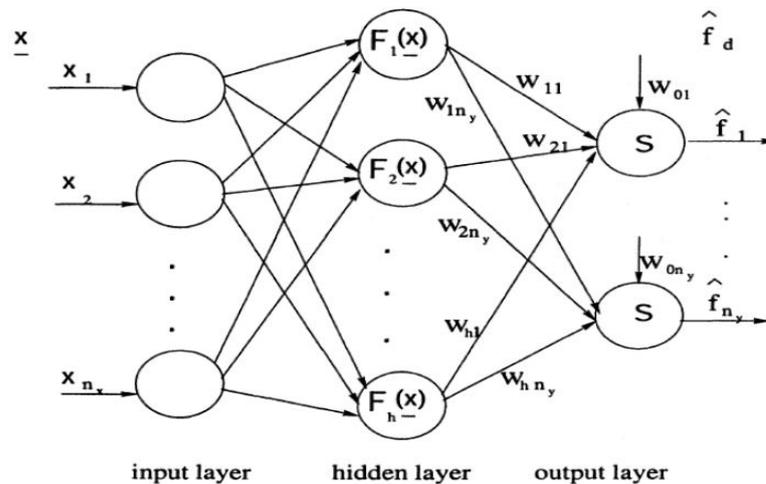


Figure 16: Schéma diagramme d'un réseau à base radiale [63].

$$\sigma_j(x) = \sum_{k=1}^n -(x_k + u_{jk})/P_{jk} \quad (\text{II.19})$$

Ces réseaux se distinguent principalement par leur capacité à fournir une représentation locale de l'espace grâce aux fonctions noyaux gaussiennes. Les effets de ces fonctions noyaux sont limités à des zones spécifiques. En d'autres termes, ils offrent une vision ciblée et restreinte de l'information dans certaines régions de l'espace.

II.3.3.5. Le réseau de neurones à connexion complexe

Dans la catégorie des réseaux à connexions complexe se trouve tous les réseaux qui ne trouvent pas leur place dans les deux catégories précédemment citées. Nous pouvons les mentionner [41,45] :

- SOM (Self Organizing Map)
- LVQ (Learning Vector Quantization)
- ART (Adaptative Resonance Theory)
- RCE (Restricted Coulomb Energy)
- Les réseaux probabilistes, etc

II.3.4. La procédure d'entraînement

Les informations d'entraînement sont encodées sous forme d'un vecteur appelé patron d'entrée, qui est transmis aux neurones d'entrée du réseau. La réponse du réseau est représentée par les valeurs d'activation de ses neurones de sortie, formant le patron de sortie.

Dans le cas d'un apprentissage supervisé, on dispose également du comportement désiré que le réseau doit apprendre, exprimé sous la forme d'un patron de référence. L'apprentissage s'étend généralement sur une période relativement longue pendant laquelle les patrons d'entrée (et éventuellement les sorties désirées) sont présentés au réseau à de nombreuses reprises.

Le processus d'apprentissage du réseau consiste à ajuster, à chaque itération, les poids et les biais afin de minimiser la somme des carrés des erreurs en sortie. La méthode de rétropropagation est utilisée, reposant sur la technique du gradient.

À chaque étape d'apprentissage **K**, l'objectif est de minimiser la variance de l'erreur en sortie du réseau [47].

- **ÉTAPE 1** : Initialiser les poids **W** et les seuils interne **b** des neurones à des petites valeurs aléatoires
- **ÉTAPE 2** : Calculer le vecteur d'entrée et de sortie désirée correspondant.

- **ÉTAPE 3** : Calculer la sortie du réseau.
- **ÉTAPE 4** : Calculer l'erreur de sortie.
- **ÉTAPE 5** : Calculer l'erreur dans les couches.
- **ÉTAPE 6** : Calculer le gradient de l'erreur par rapport aux poids.
- **ÉTAPE 7** : Ajuster les poids.

A chaque présentation d'un stimulus $\mathbf{n} \times \mathbf{K}$, on réalise les 2 étapes successives suivantes :

1. Le passage du stimulus de l'entrée vers la sortie du réseau

2. La rétropropagation de l'erreur dans le réseau pour la mise à jour des matrices de poids et de bias afin de réduire l'erreur entre la sortie obtenue et la cible recherchée.

L'algorithme de la rétropropagation, va donc réaliser l'apprentissage du réseau en modifiant les poids des connexions 'neurone par neurone' en commençant par la couche de sortie le critère d'apprentissage étant la minimisation de la racine de l'erreur quadratique moyenne.

II.3.5. Types d'apprentissage

Les types d'apprentissage connexionniste, se répartissent en trois familles :

- Apprentissage non supervisé.
- Apprentissage semi supervisé.
- Apprentissage supervisé.

II.3.5.1. Apprentissage non supervisé

Dans un apprentissage non supervisé, la règle d'apprentissage du réseau ne dépend pas du comportement global de la sortie du réseau, mais plutôt du comportement local des neurones et des relations d'intercorrélations entre ces neurones [41]. En d'autres termes, l'apprentissage se focalise sur les interactions locales entre les neurones plutôt que sur un comportement global prédéterminé.

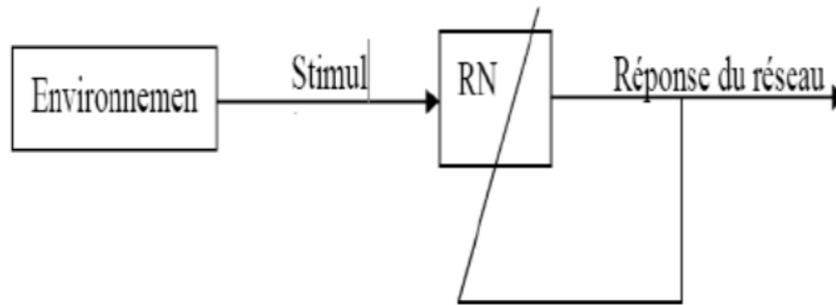


Figure 17: Apprentissage non supervisé [48]

II.3.5.2. Apprentissage semi supervisé

Les techniques d'apprentissage semi-supervisé, également connues sous le nom de "Reinforcement Learning", sont utilisées lorsque nous ne disposons pas d'un comportement de référence précis, mais plutôt d'une évaluation qualitative du comportement du système (par exemple, correct ou incorrect).

Un exemple marquant de cette approche a été étudié par G. Samuel en 1959, lorsqu'il développa un réseau pour jouer aux échecs. Ce jeu représente un problème typique d'apprentissage semi-supervisé, car le système n'a accès qu'à l'évaluation finale de la partie pour corriger l'ensemble de ses mouvements.

Le réseau doit alors apprendre à comprendre les coups qui ont conduit à l'échec ou au succès des parties qu'il a jouées en utilisant des fonctions d'évaluation pour choisir parmi les différents mouvements possibles [48,44].

Ces fonctions comportent un ensemble de paramètres qui sont affinés par apprentissage en fonction des parties gagnées et perdues, permettant ainsi au réseau de s'améliorer progressivement.

II.3.5.3. Apprentissage supervisé

Dans ce cas, le but d'apprentissage, est d'inculquer un certain comportement de référence au réseau.

On associe alors, à chaque patron d'entrée t_I une sortie désirée t_D qui spécifie les valeurs de sortie désirée, l'apprentissage se déroule de la façon suivante : un patron est présenté aux neurones d'entrée, puis l'activation se propage à travers le réseau.

La réponse des neurones de sortie, est alors comparée aux valeurs désirées ; ceci détermine l'erreur du réseau t_E pour le patron donné.

L'on procède alors, à une modification des poids, qui vise à réduire l'erreur ainsi calculée en répartissant l'erreur sur chaque poids du réseau, en fonction de la part qu'il l'a joué dans la production de réponse erronée [41,49].

L'apprentissage supervisé peut se reformuler plus précisément comme la recherche des poids qui minimise l'erreur de sortie pour l'ensemble des patrons.

Cette recherche s'effectue généralement par une série d'approximation successive, où l'ensemble des patrons est présenté plusieurs fois au réseau, et où les poids synaptiques sont modifiées de façon à améliorer graduellement le comportement global du réseau :

F est une fonction qui calcule la modification à apporter aux poids W , en fonction de l'erreur E , et d'une constante n (souvent appelé pas d'apprentissage); en générale, les règles d'apprentissage supervisé sont des formes de descente de gradient.

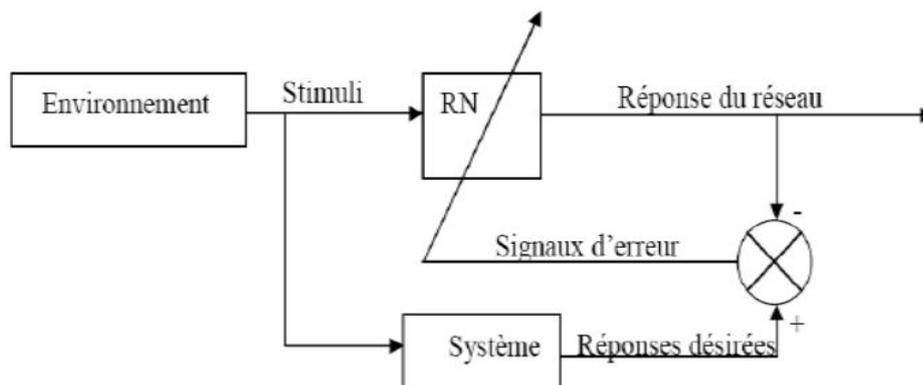


Figure 18: Apprentissage supervisé [48].

II.3.5.3.1. Rétropropagation(backpropagation) Lavenberg-Marquardt

La Rétropropagation(backpropagation) Lavenberg-Marquardt est un algorithme d'optimisation utilisé pour entraîner des réseaux neuronaux à rétropropagation dans le cadre de l'apprentissage supervisé. Il n'est pas

considéré comme un type d'apprentissage distinct, mais plutôt comme une méthode d'optimisation appliquée à l'apprentissage supervisé.

L'algorithme de Rétropropagation(backpropagation) Lavenberg-Marquardt est l'un de ces algorithmes d'optimisation qui peut être utilisé pour ajuster les paramètres du réseau neuronal afin de minimiser l'erreur de prédiction.

Ainsi, Rétropropagation(backpropagation) Lavenberg-Marquardt **est** un outil spécifique utilisé dans le cadre de l'apprentissage supervisé pour améliorer l'entraînement des réseaux neuronaux et obtenir une meilleure convergence vers les résultats souhaités [50,51].

II.3.5.3.2. L'algorithme de Rétropropagation (backpropagation) Lavenberg-Marquardt

Comme les méthodes quasi-Newton, l'algorithme Levenberg-Marquardt a été conçu pour approcher la vitesse d'entraînement du second ordre sans avoir à calculer la matrice hessienne. Lorsque la fonction de performance a la forme d'une somme de carrés (comme c'est typique dans les réseaux de formation propagation directe), alors la matrice hessienne peut être approximée comme

$$H = J^T J \quad (\text{II.20})$$

Et le gradient peut être calculé comme

$$g = J^T e \quad (\text{II.21})$$

Où (J) est la matrice jacobienne qui contient les premiers dérivés des erreurs de réseau par rapport aux poids et aux préjugés, et (e) est un vecteur d'erreur de réseau. La matrice jacobienne peut être calculée à l'aide d'une technique standard de propagation arrière qui est beaucoup moins complexe que le calcul de la matrice hessienne.

L'algorithme de Levenberg-Marquardt utilise cette approximation de la matrice hessienne dans la mise à jour de Newton suivante :

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (\text{II.22})$$

Lorsque le μ scalaire est zéro, c'est juste la méthode de Newton, en utilisant la matrice hessienne approximative. Lorsque μ est grand, cela devient une descente gradient avec une petite taille de pas. La méthode de Newton est plus rapide et plus précise près d'un minimum d'erreur, donc l'objectif est de passer à la méthode Newton le plus rapidement possible. Ainsi, μ est diminué après chaque étape réussie (réduction de la fonction de

performance) et n'est augmenté que lorsqu'une étape provisoire augmenterait la fonction de performance. De cette façon, la fonction de performance est toujours réduite à chaque itération de l'algorithme. [52]

II.3.5.4. Phase On line

Dans ce schéma on représente la phase apprentissage Online ou l'entrée est la trajectoire désirée, on élimine les perturbations.

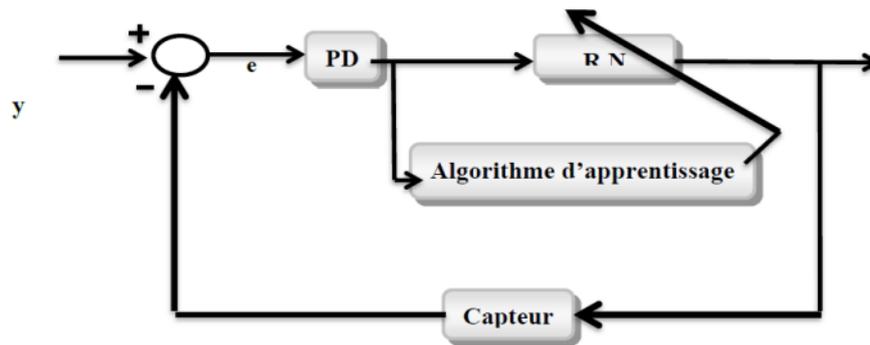


Figure 19 : phase Online.

PD : Est une commande proportionnelle dérivée.

RN : Le réseau de neurones à architecture proposée.

II.3.5.5. Phase offline

La deuxième approche d'apprentissage (qui est en générale employée), est dite 'offline ' ou différée. Dans ce cas, l'apprentissage s'effectue à part, sur un échantillon de patrons présélectionnés durant l'apprentissage, ces patrons seront chacun présenté plusieurs fois au réseau; une présentation du corpus entier, s'appelle cycle ou époque d'apprentissage.

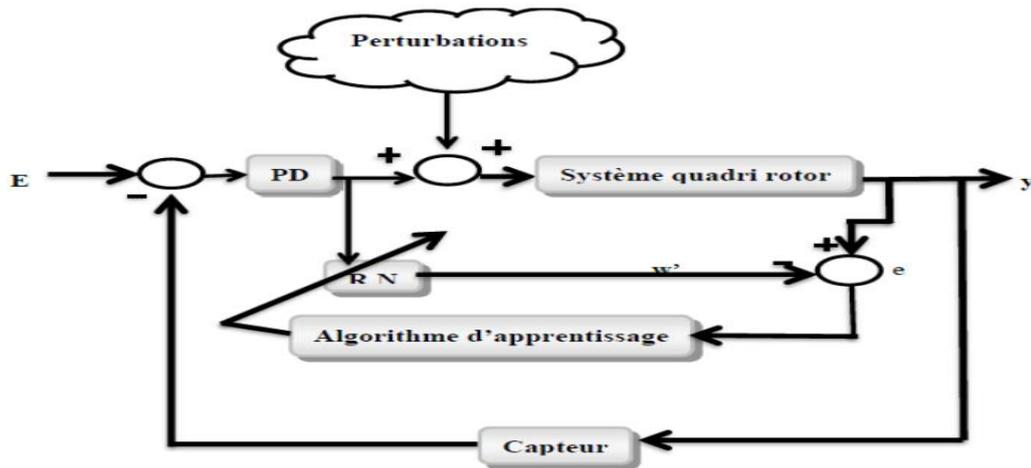


Figure 20: Phase offline

II.4. Diagnostic des pannes sûres les UAVs

II.4.1 Méthodologie de détection des défauts par les Réseaux neurone sur les paramètres d'un gyroscope et le signal d'entrée

Dans un UAV, la prévalence potentielle de défauts est toujours prise en compte, et il est essentiel que l'opérateur du UAV soit pleinement informé de l'état de l'appareil. Cela permet à l'opérateur de prendre des décisions éclairées concernant les actions correctives nécessaires et d'effectuer les travaux de réparation pour éliminer les défauts. Par conséquent, cette section détaille les procédures à suivre pour la détection des défauts et la réussite de l'analyse et du diagnostic des défauts des lignes de transmission [29]. Pour détecter les défauts, il est primordial de comprendre la nature et les caractéristiques de ces derniers, ainsi que les méthodes utilisées pour leur détection. Les relais de détection de défaut conventionnels étaient traditionnellement appliqués aux paramètres du gyroscope et au signal d'entrée [30].

Les systèmes de détection de défauts conventionnels étaient basés sur des réglages de paramètres et des limiteurs pour différents angles de blocage de défaut et pouvaient être plus précisément décrits comme des limiteurs de protection destinés à déclencher le réseau en conséquence. Cependant, pour une détection plus intelligente des défauts, nous avons introduit le réseau de neurones artificiels (RNA) en tant que détecteur de défauts. Cette section explique en détail la méthodologie de détection et de diagnostic des défauts, démontrant ainsi que les RNA peuvent être utilisés comme outils de détection de défauts.

II.4.2 Les différentes applications des Réseaux neurone dans la protection des lignes de transmission

Les réseaux neuronaux ont été utilisés pour la localisation des défauts assez récemment [35] et ont pris une importance significative depuis que Sobajic et Pao ont utilisé des réseaux neuronaux pour la prédiction du temps de compensation critique [36]. Une large utilisation des réseaux de neurones a commencé à la fin des années 80 et au début des années 90. Les réseaux neuronaux sont généralement utilisés pour obtenir une plus grande efficacité dans la détection, la classification et la localisation des défauts. De nombreuses recherches ont été effectuées et une littérature abondante a été publiée dans le domaine de la localisation des défauts à l'aide de réseaux de neurones. Certaines techniques et résultats importants qui ont été publiés sont brièvement discutés ici. Une majorité des travaux mentionnés ici ont utilisé la technique du perceptron multicouche à feed-forward.

Kulicke et Dalstein [37] ont utilisé des réseaux de neurones pour la détection des défauts sur les lignes de transmission et ont également différencié les défauts avec et sans arc. Une nouvelle technique de détection et de localisation de défauts à haut débit utilisant des réseaux de neurones a été proposée par Rikalo, Sobajic et Kezunovic [38]. Chen et Maun ont largement étudié les techniques de localisation de défauts à une seule extrémité basées sur des réseaux neuronaux, tandis que Song a utilisé des réseaux de neurones pour la localisation des défauts sur des lignes compensées en série. D'autres travaux pertinents dans le domaine de la localisation des défauts à l'aide de réseaux de neurones artificiels peuvent être trouvés dans ces références [39].

II.4.3 utilisations d'un Réseaux neurone dans un système de contrôle des UAVs afin de détecter les blocages dans les actionnaires

L'efficacité du détecteur de défaut RNA dépend de la précision de son entrée mesures et sur l'efficacité des données d'apprentissage. Les données d'entraînement doivent être bien gérées, filtrées et mises à l'échelle de manière appropriée, pour permettre l'application des méthodes intelligentes telles que RNA [34]. Ce processus est représenté graphiquement par la figure 22 :

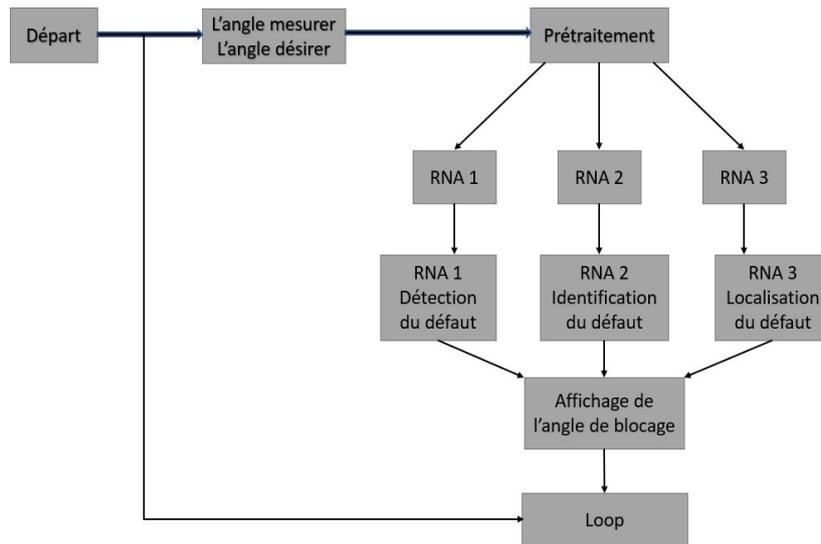


Figure 21: Diagramme de défauts montrant la méthode RNA.

La figure montre trois approches générales, à savoir la détection des défauts RNA1, l'identification des défauts par RNA2 et localisation des défauts par les RNA3. Fondamentalement, la formation de la structure du RNA pour chaque méthode est la même, cependant leur application respective diffère en termes de production et d'informations traitées. À la fin du RNA avec succès, une commande de déclenchement est donnée au circuit disjoncteur pour déclencher la ligne de transmission, et aussi un signal confirme l'emplacement du défaut. Ce processus est exécuté de manière itérative dans le détecteur de défaut par les RNA.

II.5. Technique de contrôle

II.5.1. Introduction

Pour piloter et gérer un avion, divers algorithmes de contrôle peuvent être utilisés pour construire des lois de commande. Cependant, ces approches montrent des performances moins bonnes lorsque l'aéronef s'éloigne de ses points d'équilibre. De plus, la présence de perturbations peut déstabiliser ces véhicules. Pour pallier ces problèmes, on peut recourir à des techniques adaptatives pour maintenir un système stable [53].

La synthèse d'une loi de commande pour un système multivariable implique d'abord d'approximer le comportement dynamique du système à commander à l'aide d'équations mathématiques, puis de spécifier les objectifs du comportement souhaité du système en termes de stabilité et de performance [54]. Dans cette optique, nous allons présenter une technique de commande courante, le régulateur PID.

II.5.2. Régulation PID

Un asservissement est un algorithme conçu pour atteindre rapidement et limiter l'écart par rapport à une valeur de consigne, quelles que soient les perturbations externes. Son principe général consiste à comparer la consigne avec l'état du système afin de le corriger efficacement.

Dans le cas de la régulation (ou asservissement), l'objectif est d'agir de manière à ce qu'une mesure soit égale à

Une consigne donnée. Si l'on cherche à atteindre cette consigne, on parle de poursuite ou d'asservissement. Si l'objectif est d'éliminer les perturbations pour maintenir une valeur constante, on parle de régulation [54].

Il existe plusieurs types de régulateurs :

II.5.2.1. Régulateur proportionnelle P

Dans le cas d'un contrôle proportionnel, l'erreur est virtuellement amplifiée d'un certain gain constant qu'il conviendra de déterminer en fonction du système.

$$u(t) = K_p \cdot \varepsilon(t) \quad (\text{II.23})$$

Ce qui en Laplace donne

$$u(s) = K_p \cdot \varepsilon(s) \quad (\text{II.24})$$

L'idée ici est d'accroître l'impact de l'erreur sur le système de sorte qu'il réagisse plus rapidement aux changements de consignes. Plus la valeur de K_p (le gain proportionnel) est élevée, plus la réponse du système est rapide.

L'action proportionnelle applique une correction immédiate à chaque écart entre la mesure et la consigne. Plus grande est la perturbation, plus importante sera la correction apportée. Cependant, cette composante seule ne permet pas une grande précision, notamment dans un système à faible inertie [54]. En d'autres termes, l'action proportionnelle peut permettre une réponse rapide, mais elle peut manquer de précision dans certaines situations, notamment lorsque le système a une faible inertie.

II.5.2.2. Régulateur proportionnelle-intégrale PI

Au contrôle proportionnel, nous pouvons ajouter l'intégration de l'erreur, Dans ce cas nous obtenons une régulation PI (proportionnelle et intégrée). L'erreur entre la consigne et la mesure est ici intégrée par rapport au temps et multipliée par une constante qu'il faudra aussi déterminer en fonction du système.

$$u(t) = K_p \cdot \varepsilon(t) + K_i \int_0^t \varepsilon(\tau) d\tau \quad (\text{II.25})$$

Ce qui en Laplace donne

$$u(s) = K_p \cdot \varepsilon(s) + K_i \frac{\varepsilon(s)}{s} \quad (\text{II.26})$$

La composante intégrale, quant à elle, joue un rôle essentiel en compensant l'erreur statique du système. En conséquence, elle rend le système plus stable en régime permanent. Plus la valeur de K_i (le gain intégral) est élevée, plus l'erreur statique est corrigée rapidement.

L'action intégrale apporte une notion de temps d'intégration à la correction, qui est généralement exprimée en

Secondes. Cette action est complémentaire à l'action proportionnelle et permet de stabiliser le système dans le temps. Dans le cas de l'action proportionnelle, plus l'erreur mesurée est constante, plus la correction reste constante [55]. En d'autres termes, l'action intégrale agit sur l'accumulation d'erreurs constantes pour les corriger de manière progressive, ce qui contribue à une meilleure stabilité globale du système.

II.5.2.3. Régulateur proportionnelle-intégrale-dérivée PID

Pour mettre en place un contrôle PID, nous devons ajouter un autre terme. Celui-ci implique de dériver l'erreur entre la consigne et la mesure par rapport au temps, puis de le multiplier par une constante ' K_d ' également [55]. En ajoutant cette composante dérivée, le contrôle PID devient complet et permet de réagir non seulement à l'erreur actuelle (composante proportionnelle) et aux erreurs accumulées dans le temps (composante intégrale), mais aussi à la variation de l'erreur au fil du temps. Cette dérivation contribue à une meilleure réactivité du système face aux changements rapides et permet de l'ajuster en fonction des évolutions de l'erreur.

$$u(t) = K_p \cdot \varepsilon(t) + K_i \int_0^t \varepsilon(\tau) d\tau + K_d \frac{d\varepsilon(t)}{dt} \quad (II.27)$$

Ce qui en Laplace donne

$$u(s) = K_p \cdot \varepsilon(s) + K_i \frac{\varepsilon(s)}{s} + K_d \cdot \varepsilon(s) \cdot s \quad (II.28)$$

II.5.2.4. Structure de contrôleur PID

La commande par régulation PID est largement adoptée dans l'industrie, représentant plus de 90% des architectures de commande. La plupart de ces régulateurs se composent principalement des actions proportionnelle et intégrale.

Dans le domaine industriel, les régulateurs PID sont les plus utilisés, et leur succès s'explique par plusieurs raisons [55] :

- Structure simple
- Haute performance dans plusieurs processus.

Dans la robotique, les techniques PID représentent les bases du contrôle. La structure traditionnelle PID est composée de trois facteurs, présenté dans la figure 23 et l'équation suivante (II.29)

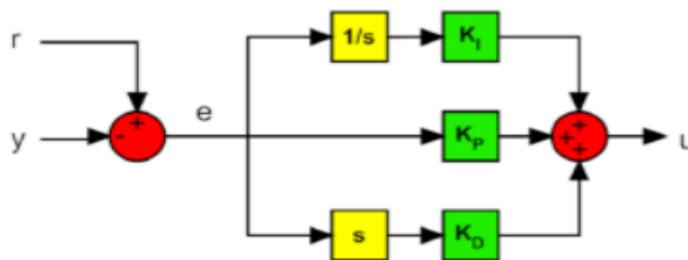


Figure 22: Structure de PID traditionnelle.

Les blocs '1/s' et 's' représentent respectivement les opérations d'intégration et de dérivation.

$$u(t) = K_p \cdot e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt} \quad (\text{II.29})$$

Où :

u : La variable générique contrôlée.

e : l'erreur entre la tache r et la sortie du processus y .

K_p : Coefficient proportionnelle.

K_i : Coefficient intégrale.

K_d : Coefficient dérivé.

Dans le domaine de Laplace, La structure PID traditionnelle peut s'écrire sous la forme suivante :

$$u(s) = \left(K_p + \frac{K_i}{s} + sK_d \right) e(s) \quad (\text{II.30})$$

Étant donné que cette fonction n'est pas physiquement appropriée en raison du caractère dérivable du terme, elle n'est pas réalisable. Après une certaine fréquence, la contribution de la composante dérivée doit être

atténuée pour filtrer le bruit hors de la bande passante. Pour cette raison, un pôle est ajouté dans le dérivateur réel, comme indiqué dans l'équation [56]. Cette modification permet de rendre le dérivateur physiquement réalisable tout en évitant les problèmes liés à une réponse non filtrée dans les hautes fréquences.

$$u(s) = \left(K_p + \frac{k_i}{s} + \frac{sK_d}{1 + \frac{sK_d}{kK_p}} \right) e(s) \quad (\text{II.31})$$

II.5.2.5. Les méthodes utilisées pour déterminer les paramètres du contrôleur PID

Dans la pratique, il existe une variété de méthodes qu'on peut utiliser pour déterminer les paramètres (proportionnelle, intégral et dérivé) d'un contrôleur on va citer les méthodes les plus utilisées.

II.5.2.5.1. Méthode par réglages successive

La démarche manuelle de réglage est la suivante :

- Régler le gain P jusqu'à la limite des oscillations ;
- Ajouter l'action intégrale (action faible au départ : T_i grand);
- Diminuer T_i jusqu'à la limite de l'instabilité;
- Ajouter l'action Dérivée pour limiter les dépassements;
- Augmenter progressivement T_d .

Le schéma de la figure 24 illustre cette méthode :

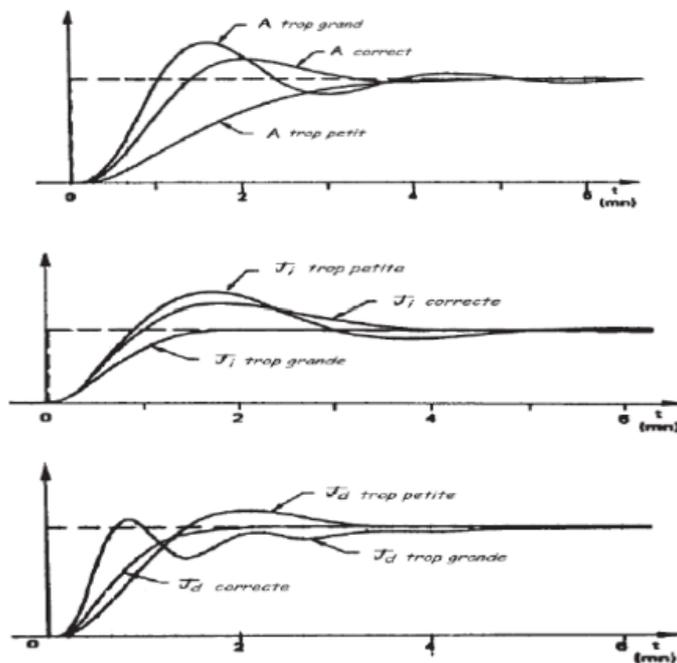


Figure 23 : Ajustement des paramètres PID par la méthode des réglages successifs.

II.5.2.5.2. Méthode de Ziegler-Nichols

Chapitre II

Diagnostic Des Pannes En Utilisant Réseau Neurones

La méthode Ziegler-Nichols est une approche heuristique pour régler un régulateur PID. Elle a été développée par G. Ziegler et Nathaniel B. Nichols. La méthode décrite ici est basée sur la génération d'oscillations maintenues en boucle fermée. Pour commencer, l'action intégrale et l'action dérivée sont annulées. Ensuite, l'action proportionnelle est augmentée jusqu'à ce que le signal en sortie de la boucle fermée oscille de manière soutenue. On enregistre alors ce gain maximum, appelé gain critique (K_u). La période d'oscillation de ce signal est notée T_u .

Les paramètres du régulateur, à savoir K_p (le gain proportionnel), T_i (le temps intégral) et T_d (le temps dérivé), sont ensuite choisis en se référant au tableau 2 [55]. Cette méthode permet d'ajuster les paramètres du régulateur PID de manière heuristique en se basant sur les caractéristiques d'oscillation obtenues expérimentalement.

Tableau 2:Tableau de ZIEGLER-NICHOLS.

Type de contrôle	K_p	T_i	T_d
P	$0.5 K_u$	--	--
PI	$0.45 K_u$	$T_u/1.2$	--
PD	$0.8 K_u$	--	$T_u/8$
PID	$0.8 K_u$	$T_u/2$	$T_u/8$

II.6. Contrôle adaptif des systèmes à variation temporelle avec planification des gains

II.6.1. INTRODUCTION

L'une des méthodes populaires de conception de commandes non linéaires est la planification des gains 'gain scheduling' [57], [58] et elle a été utilisée dans un large éventail d'applications, notamment la commande de vol [59], [60], la commande de processus [61] et la commande de turbines éoliennes [62]. L'idée principale qui sous-tend l'approche de planification des gains est de décomposer la tâche de conception de la commande non linéaire en une famille de méthodes de conception de la commande linéaire et de planifier cette famille de

contrôleurs linéaires sur la base du signal de commande de manière à garantir que le système non linéaire d'origine suive la dynamique souhaitée. Lorsque la variable programmée pour le gain varie lentement, les résultats de stabilité des systèmes presque invariants dans le temps peuvent être utilisés pour établir la stabilité du système linéaire sous-jacent à variation temporelle en boucle fermée et donc pour évaluer les propriétés de stabilité du système non linéaire d'origine [57], [58]. Souvent, le problème de commande non linéaire évoqué ci-dessus est confronté à une autre difficulté, à savoir la présence d'incertitudes dues à des erreurs de modélisation, à une aérodynamique inconnue, ainsi qu'à des anomalies dans les données d'entrée de la commande. Les actionneurs sont souvent affectés par un certain nombre de facteurs, notamment la saturation de la commande, la dégradation de l'efficacité de la commande ou les défaillances de la commande. Il est donc important qu'un contrôleur à gain programmé conçu à l'aide des procédures décrites dans [57], [58] soit capable de faire face de manière adéquate à l'une ou à l'ensemble des incertitudes mentionnées ci-dessus.

II.6.2 Énoncé du problème

Nous considérons une plante non linéaire de la forme

$$\dot{X} = F(X) + G(X)U \quad (\text{II.32})$$

Où $X \in \mathcal{R}^n$ est l'état du système et $U \in \mathcal{R}^m$ représente l'entrée de contrôle. On suppose que le système peut être écrit comme suit

$$\begin{aligned} \dot{X}_p &= f(X_p, X_g) + g(X_p, X_g)U_1 \\ \dot{X}_g &= h(X_g, U_2) \end{aligned} \quad (\text{II.33})$$

Où l'état du système X est divisé en deux composantes vectorielles, $X_p \in \mathcal{R}^{n_p}$ and $X_g \in \mathcal{R}^{n_g}$, de sorte que la première représente la sortie contrôlée à variation rapide, par rapport à la composante d'état lente X_g . Cette dernière deviendra la variable programmée en fonction du gain. On suppose également que l'on dispose de suffisamment d'informations sur la non-linéarité h pour qu'un contrôleur en boucle extérieure, $U_2 = hc(X_g, X_{gc})$, puisse être choisi de manière à ce que $X_g(t)$ suive $X_{gc}(t)$, son signal de commande souhaité, et qu'il satisfasse à l'hypothèse suivante :

Hypothèse 1. $X_{gc}(t)$ est continuellement différentiable et varie lentement, c'est-à-dire que

$$\|\dot{X}_{gc}(t)\| < \varepsilon_1, \forall t \geq t_0 \quad (\text{II.34})$$

Le problème est de concevoir U_1 dans (II.33) de telle sorte que le contrôleur garantisse que le système en boucle fermée a des solutions globalement bornées en présence d'incertitudes paramétriques dans f et g . Afin de contrôler le système non linéaire dans (II.33) pour des conditions initiales arbitraires et une grande famille de

signaux de commande, nous considérons une famille de points de fonctionnement dans le voisinage de $X_g(t)$ comme suit

$$\sigma_g = \{X_{g,1}, X_{g,2}, \dots, X_{g,k}\} \quad (\text{II.35})$$

La dimension de $X_{g,i}$ est n_g et sa composante est $X_{gr,i}$.

Définition 1. $X_{g,i}$ et $X_{g,j}$ sont des points de fonctionnement séparés si $X_{gr,i} \neq X_{gr,j}$ for $1 \leq i, j \leq k$ and $1 \leq r \leq n_g$.

Dans la figure 25, $X_{g,1}$ et $X_{g,2}$ ne sont pas des points de fonctionnement séparés puisqu'ils ont tous deux la même vitesse, mais $X_{g,1}$ et $X_{g,5}$ sont des points de fonctionnement séparés.

Hypothèse 2. Il existe k points de fonctionnement qui satisfont à la condition suivante pour tous les points de fonctionnement séparés $X_{g,i}$ et $X_{g,j}$

$$\max_{1 \leq i \leq k} \left[\min_{1 \leq j \leq k} \|X_{g,i} - X_{g,j}\| \right] < \varepsilon_2 \quad (\text{II.36})$$

Cette hypothèse implique que sur l'enveloppe opérationnelle, un grand nombre de points opérationnels sont nécessaires pour que les points d'opération adjacents soient suffisamment proches. Pour chaque point de fonctionnement congelé $X_{g,i}$, nous pouvons obtenir une famille d'états d'équilibre et d'entrée

$$\sigma_p = \{X_p(X_{g,1}), X_p(X_{g,2}), \dots, X_p(X_{g,k})\} \quad (\text{II.37})$$

$$\sigma_u = \{U_1(X_{g,1}), U_1(X_{g,2}), \dots, U_1(X_{g,k})\} \quad (\text{II.38})$$

C'est donc

$$f(X_p(X_{g,i}), X_{g,i}) + g(X_p(X_{g,i}), X_{g,i})U_1(X_{g,i}) = 0$$

Et σ_g , σ_p et σ_u sont tabulés hors ligne. En utilisant une interpolation linéaire dans σ_p et σ_u , nous pouvons construire les trajectoires souhaitées de l'état et de l'entrée ($X_p^*(t)$, $U_1^*(t)$).

$$\begin{aligned} X_p^*(t) &= X_p(X_{g,i}) + M_i(X_g(t) - X_{g,i}) \\ U_1^*(t) &= U_1(X_{g,i}) + N_i(X_g(t) - X_{g,i}) \end{aligned} \quad (\text{II.39})$$

Où M_i et N_i sont des matrices constantes qui cartographient X_g en X_p et U respectivement. En utilisant ces trajectoires, nous linéarisons la plante en (II.42) environ $(X_g(t), X_p^*(t), U_1^*(t))$ comme

$$\dot{x}_p = A_p(t)x_p + B_p(t)u + \varepsilon_x(t) \quad (II.40)$$

Où $x_p = X_p - X_p^*(t)$, $u = U - U_1^*(t)$ et

$$A_p(t) = \frac{\partial f}{\partial X_p} \Big|_{(X_p^*(t), X_g(t))} + \frac{\partial g}{\partial X_p} \Big|_{(X_p^*(t), X_g(t))} U_1^*(t)$$

$$B_p(t) = g(X_p^*(t), X_g(t))$$

$$\varepsilon_x(t) = f(X_p^*(t), X_g(t)) + g(X_p^*(t), X_g(t))U_1^*(t) - \dot{X}_p^*(t) + O(x_p^2)$$

La proposition suivante quantifie les variations lentes admissibles dans $X_g(t)$, qui est la variable de planification du gain

La proposition 1. Selon les hypothèses 1 et 2

$$\|\varepsilon_x(t)\| \leq a\varepsilon_1 + b\varepsilon_2 \quad (II. 41)$$

Où a et b sont des constantes positives. La preuve. En raison des limites de l'espace, la preuve est omise.

Remarque 1. En faisant ε_1 et ε_2 suffisamment petits, ε_x peut être fait arbitrairement petit. En d'autres termes, si la variable de planificateur de gain varie assez lentement et que les points d'opération sont suffisamment proches les uns des autres, ε_x peut être rendu arbitrairement petit.

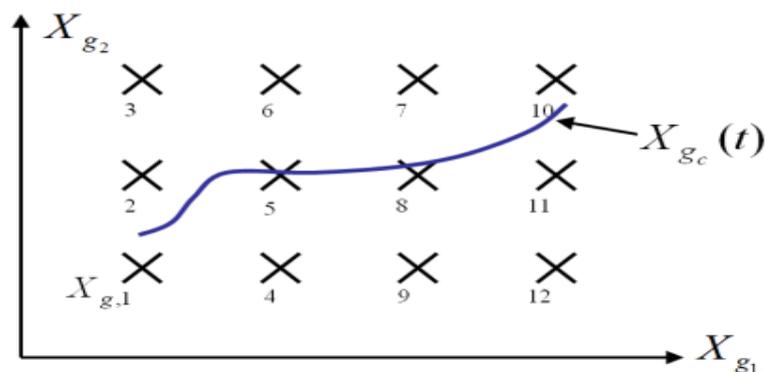


Figure 24: Un schéma des points d'opération de l'espace X_g ($k=12$)

Le problème que nous examinons dans ce document est le contrôle du système dans (II.30) soumis aux hypothèses 1 et 2 en présence d'incertitudes introduites en raison d'anomalies de contrôle. En particulier, nous supposons que la dynamique non linéaire dans (II.33) est de la forme

$$\dot{X}_p = f(X_p, X_g) + g(X_p, X_g)\Lambda U_1 \quad (II.42)$$

Où Λ est une matrice diagonale inconnue avec des entrées diagonales non zéro, et représente une perte d'efficacité dans l'entrée de contrôle. En linéarisant la dynamique non linéaire dans (II.42) sur la même trajectoire dans (II.29), nous obtenons

$$\dot{x}_p = A_{p\lambda}(t)x_p + B_p(t)\Lambda(u + d(t)) + \varepsilon_x(t) \quad (II.43)$$

Où

$$A_{p\lambda}(t) = \left. \frac{\partial f}{\partial X_p} \right|_{(x_p^*(t), x_g(t))} + \left. \frac{\partial g}{\partial X_p} \right|_{(x_p^*(t), x_g(t))} \Lambda U_1^*(t)$$

$$d(t) = (I - \Lambda^{-1})U_1^*(t)$$

Et $d(t)$ est la perturbation d'entrée due à Λ . Par conséquent, lorsqu'il n'y a pas d'incertitude dans l'entrée de contrôle, c'est-à-dire $\lambda = I$, $d(t)$ devient zéro. Le problème est de concevoir une augmentation adaptative d'un contrôleur de planification de gain de base pour l'usine dans (II.43) sous les hypothèses 1 et 2 de manière à ce que la stabilité de la boucle fermée et le suivi soient maintenus en présence d'incertitudes du système.

II.7. Conclusion

Dans ce deuxième chapitre nous a immergés dans le passionnant domaine du diagnostic des pannes sur les Véhicules Aériens Non Habités (UAV) en utilisant les réseaux neuronaux. Nous avons abordé plusieurs aspects clés de cette approche novatrice, en commençant par une étude approfondie du modèle dynamique de notre UAV, suivi d'une exploration détaillée des réseaux neuronaux et de leurs différentes composantes, ainsi que des techniques de contrôle avancées.

Dans la première partie de ce chapitre, nous avons examiné attentivement les équations du modèle dynamique de notre UAV. Ces équations mathématiques décrivent la dynamique de notre système en vol, prenant en compte les forces aérodynamiques, les contraintes mécaniques et les interactions avec l'environnement. Cette connaissance fondamentale de la dynamique de l'UAV est essentielle pour développer des stratégies efficaces de diagnostic des pannes, car elle nous permet de déterminer les paramètres clés à surveiller et à analyser.

Ensuite, nous nous sommes plongés dans l'univers fascinant des réseaux neuronaux, explorant leur architecture complexe, leur procédure d'entraînement et les différents types d'apprentissage qu'ils peuvent adopter. Ces réseaux, inspirés du fonctionnement du cerveau humain, offrent des capacités impressionnantes pour la détection et la caractérisation des défaillances sur notre UAV. En les entraînant avec des jeux de données pertinents et en les optimisant, nous pouvons obtenir des modèles de diagnostic puissants et adaptatifs, capables de surveiller en temps réel l'état de notre système aérien.

Dans la troisième partie de ce chapitre, nous avons abordé spécifiquement le diagnostic des pannes sur les UAV à l'aide des réseaux neuronaux. Nous avons étudié comment ces modèles peuvent détecter et isoler les défaillances potentielles, fournissant ainsi une capacité de surveillance proactive pour améliorer la sécurité et la fiabilité de notre UAV. Grâce à leur capacité d'apprentissage à partir de données réelles, les réseaux neuronaux peuvent également s'adapter à des situations imprévues et des conditions de vol changeantes, ce qui en fait des outils précieux pour les opérations aériennes critiques.

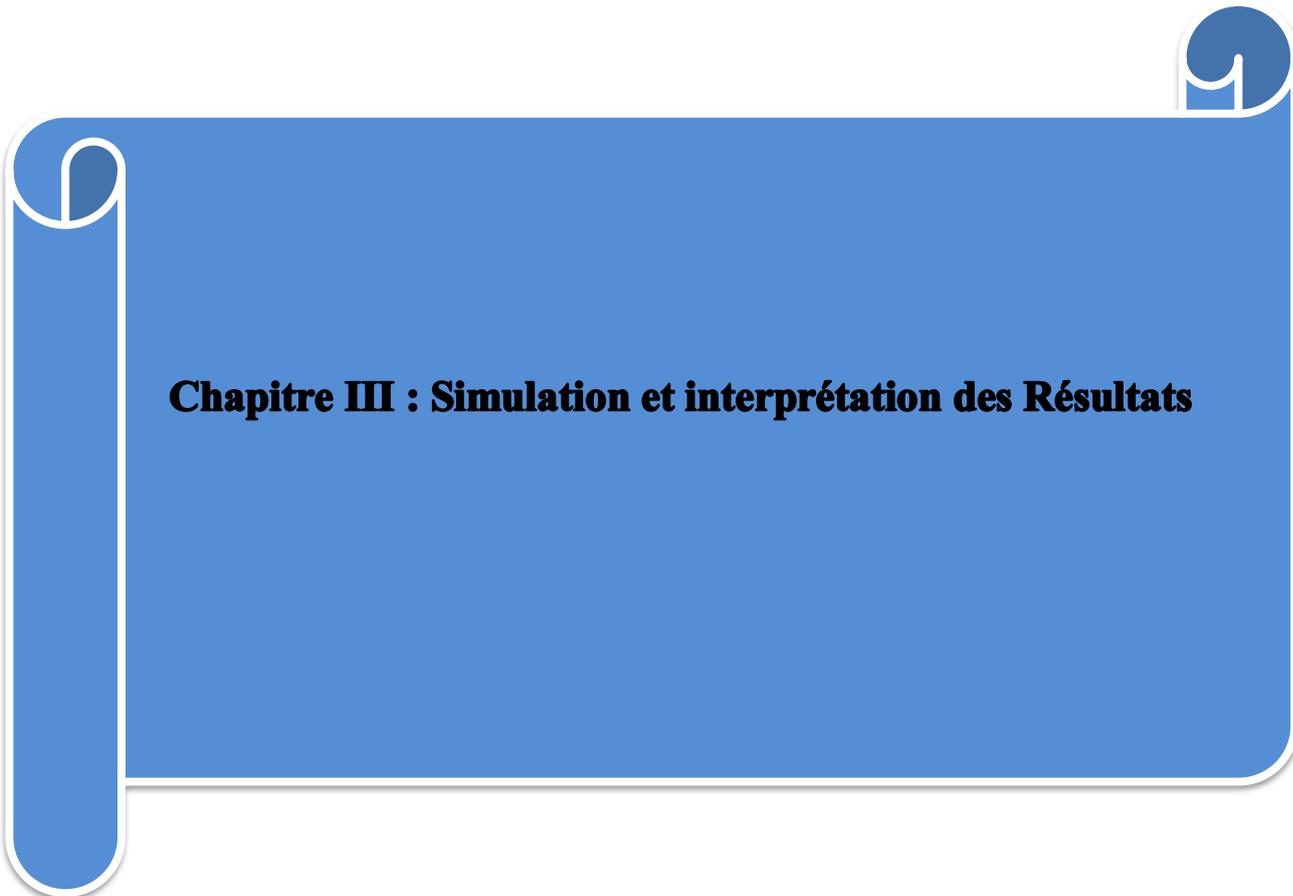
Dans la quatrième partie, nous avons exploré une technique de contrôle classique et largement utilisée : le PID (Proportionnel Intégral Dérivé). Ce contrôleur a démontré son efficacité pour stabiliser et contrôler les UAV, jouant un rôle essentiel dans la réduction des erreurs et des perturbations lors du vol.

Enfin, la dernière partie de ce chapitre nous a entraînés vers le concept de contrôle adaptatif avec planification

des gains. Cette approche avancée nous a permis de comprendre comment ajuster dynamiquement les

paramètres du système en fonction des changements environnementaux et des variations du UAV, garantissant ainsi des performances optimales et une réactivité accrue.

En somme, ce chapitre nous a fait plonger dans le monde passionnant du diagnostic des pannes sur les UAV en utilisant les réseaux neuronaux. Grâce à cette approche, nous avons acquis des outils puissants pour améliorer la sécurité, la fiabilité et l'efficacité de notre système aérien. En combinant les connaissances du modèle dynamique, l'apprentissage profond des réseaux neuronaux et les stratégies avancées de contrôle adaptatif, nous sommes mieux équipés pour relever les défis futurs du domaine des UAV et garantir des vols plus sûrs et plus performants.

A blue graphic element resembling a scroll, with a vertical strip on the left and a horizontal strip extending to the right. The top corners are curled up, and the bottom corners are rounded. The text is centered within the horizontal strip.

Chapitre III : Simulation et interprétation des Résultats

III.1. Introduction

Le présent chapitre revêt une importance capitale dans notre démarche, car nous allons nous concentrer sur la conception et l'implémentation d'un réseau neuronal innovant. Ce dernier est conçu pour exploiter les données collectées par le biais de XFLR5 et ainsi détecter avec précision les blocages de l'élévateur sur un UAV en mode longitudinal. Le réseau neuronal que nous développerons représente une avancée significative dans le domaine de la sécurité aérienne et de l'autonomie des UAV, en offrant une capacité de détection des défauts en temps réel.

La méthodologie adoptée pour cette conception repose sur l'utilisation d'un outil de modélisation et de simulation bien connu, à savoir MATLAB/SIMULINK. Ce choix se justifie par la puissance et la flexibilité de cet environnement de développement, qui nous permettra de créer et de tester efficacement notre réseau neuronal avant de le mettre en œuvre sur des données réelles.

Ce chapitre se déroulera de la manière suivante :

Dans un premier temps, nous exposerons les étapes clés de la conception du réseau neuronal, en mettant l'accent sur les choix architecturaux et les caractéristiques spécifiques du modèle. Ensuite, nous présenterons les résultats de nos simulations, illustrant la performance du réseau dans la détection des blocages de l'élévateur. Ces résultats seront analysés en profondeur et discutés pour mettre en évidence les forces et les limites de notre approche.

Nous sommes convaincus que la combinaison des données provenant de XFLR5 et de l'intelligence artificielle des réseaux neuronaux offre une perspective prometteuse pour améliorer la sécurité et la fiabilité des UAV. En développant un système de détection précoce des blocages de l'élévateur, nous contribuons ainsi à accroître la confiance dans l'utilisation de ces engins dans des applications critiques, tout en ouvrant la voie à de nouvelles opportunités dans le domaine de l'aéronautique autonome.

III.2 model du drone adéquat

Pour cette étude, nous avons choisi un drone équipé de double servo-moteur, ce choix permettra de guider et de commander l'UAV en cas de blocage au niveau de l'élévateur. Cette configuration assure une fonctionnalité optimale de notre modèle, sauf dans le cas où l'UAV dispose de double servo-moteur qui agissent de manière indépendante au niveau des ailerons. La figure ci-dessous présente le drone spécifiquement utilisé pour notre recherche.

La sélection de ce drone particulier s'avère essentielle pour les besoins de notre étude, car sa conception permet une manœuvrabilité efficace et un contrôle adapté en cas de défaillance au niveau de l'élève. La configuration à double servo-moteur offre une redondance opérationnelle, ce qui est crucial pour assurer la sécurité et la stabilité du système dans des conditions diverses.

En utilisant ce modèle de drone adapté, nous sommes en mesure d'explorer en détail les performances aérodynamiques et les réponses du système aux situations de blocage, ce qui enrichit notre compréhension des contrôles adaptatifs et contribue à des améliorations significatives dans le domaine des UAV à voilure fixe.

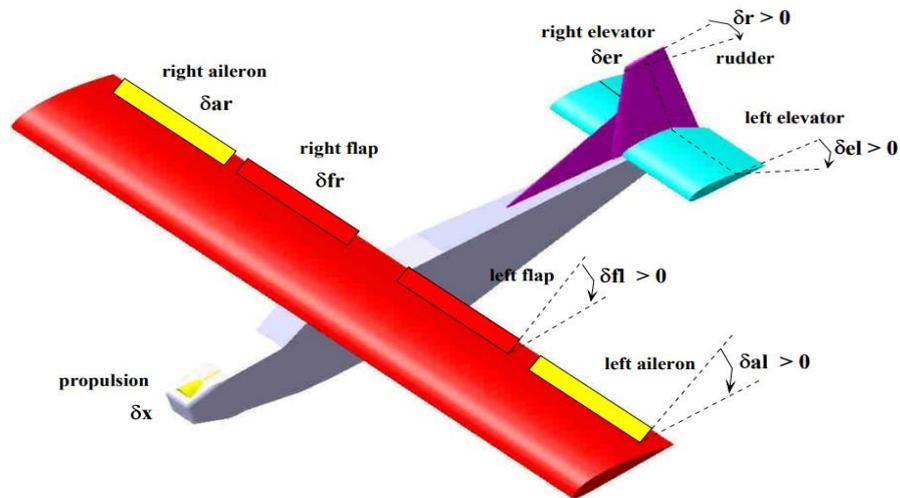


Figure 25: drone utiliser pour l'étude (UAV Mistral) [65]

δr : représente l'action générée par la gouverne de direction.

δel : représente l'action générée par la gouverne de profondeur.

δf : représente l'action générée par les volets.

δar : représente l'action générée par l'aileron droit.

δal : représente l'action générée par l'aileron gauche.

Le fonctionnement du système de compensation dans le cas où il y aura un problème ou un défaut ou dans le cas d'un système sain et comme suit

$$\begin{cases} \delta a = \delta ar + \delta al \\ \delta a = \delta ar - \delta al \end{cases} \quad (III.1)$$

S'il Ya pas un défaut on a les deux ailerons qui travaille séparément pour faire la manouvre roulis

$$\delta a = \delta ar - \delta al \quad (\text{III.2})$$

S'il Ya un défaut (un blocage des actionnaires) les ailerons droite et gauche travaille en coordination dans le même sens

$$\delta a = \delta ar - \delta al \quad (\text{III.3})$$

III.2.1 description générale du drone UAV

Le sujet d'étude concerne un micro drone aérien sans pilote (UAV) de type aile fixe, appartenant à la catégorie des mini-UAV. Ce drone présente une configuration spécifique avec un profil d'aile NACA 2412, qui est largement utilisé dans l'aéronautique pour ses caractéristiques aérodynamiques favorables.

La Figure 3.1 illustre les caractéristiques physiques et les coefficients aérodynamiques associés au mode longitudinal de ce drone. Cette représentation graphique permet de visualiser et d'analyser les paramètres essentiels liés à son comportement dans l'axe longitudinal.

Dans le contexte scientifique de cette étude, il est primordial de comprendre ces caractéristiques pour appréhender le comportement de l'UAV en vol. L'utilisation d'un profil d'aile NACA 2412 suggère que le drone a été conçu pour bénéficier d'une portance et d'une traînée optimales dans diverses conditions de vol.

La Figure 27 permet ainsi d'examiner les données relatives à la portance, à la traînée, au moment de tangage, et à d'autres coefficients aérodynamiques cruciaux. Ces informations fournissent une base solide pour l'analyse et la modélisation du comportement de l'UAV, ce qui est essentiel pour optimiser ses performances et sa stabilité lors de missions spécifiques.

Longitudinal					
Parameter	Value	Coef.	Value	Lateral Coef.	Value
m	1.56 kg	C_{L_0}	0.09167	C_{Y_0}	0
J_x	0.1147 kg m ²	C_{D_0}	0.01631	C_{l_0}	0
J_y	0.0576 kg m ²	C_{m_0}	-0.02338	C_{n_0}	0
J_z	0.1712 kg m ²	C_{L_α}	3.5016	C_{Y_β}	-0.07359
J_{xz}	0.0015 kg m ²	C_{D_α}	0.2108	C_{l_β}	-0.02854
S	0.2589 m ²	C_{m_α}	-0.5675	C_{n_β}	-0.00040
b	1.4224 m	C_{L_q}	2.8932	C_{Y_p}	0

Longitudinal					
Parameter	Value	Coef.	Value	Lateral Coef.	Value
c	0.3302 m	C_{D_q}	0	C_{l_p}	-0.3209
S_{prop}	0.0314 m ²	C_{m_q}	-1.3990	C_{n_p}	-0.01297
ρ	1.2682 kg/m ³	$C_{L_{\dot{\alpha}}}$	0.2724	C_{Y_r}	0
k_{motor}	20	$C_{D_{\dot{\alpha}}}$	0.3045	C_{l_r}	0.03066
k_{T_p}	0	$C_{m_{\dot{\alpha}}}$	-0.3254	C_{n_r}	-0.00434
k_Ω	0	C_{prop}	1.0	$C_{Y_{\dot{\alpha}}}$	0
e	0.9	M	50	$C_{l_{\dot{\alpha}}}$	0.1682
		α_0	0.4712	$C_{n_{\dot{\alpha}}}$	-0.00328
		ϵ	0.1592		
		C_{D_p}	0.0254		

Figure 26: les caractéristiques physique et les coefficients aérodynamiques du mode longitudinale.

III.3 stratégies de travail

Nous mettons en œuvre une méthodologie en deux étapes pour la détection des blocages de l'élévateur d'un UAV en mode longitudinal. La première étape consiste à créer une base de données contenant des coefficients tels que le coefficient de traînée (c_d), le coefficient de portance (c_l), le moment de tangage (c_m) et le Delta de l'élévateur, enregistrés à différents angles d'attaque de l'UAV. La deuxième étape comprend la conception et l'utilisation d'un réseau neuronal pour estimer les angles d'élévateur (θ) à partir des données fournies dans la base de données.

III.3.1. Création de la base de données

Nous commençons par rassembler les données de vol de l'UAV en utilisant le logiciel XFLR5. Ces données incluent les coefficients de traînée, de portance et de moment de tangage, ainsi que les valeurs de l'angle d'attaque (Delta) de l'élévateur pour différentes configurations de vol.

En utilisant ces données, nous construisons une base de données structurée contenant des enregistrements pour chaque configuration de vol, comprenant les valeurs des coefficients (c_d , c_l , c_m) et l'angle d'attaque de l'élévateur (Delta).

Pour évaluer la performance du réseau neuronal, nous divisons cette base de données en trois ensembles : un ensemble sain (sans blocage), et deux ensembles avec des blocages dans l'angle d'élévateur (thêta), représentant ainsi différentes conditions de vol.

III.3.2. Conception du réseau neuronal

Nous procédons ensuite à la création du réseau neuronal. L'objectif principal du réseau est de générer l'angle d'élévateur (thêta) en fonction des coefficients (c_d , c_l , c_m) et de l'angle d'attaque de l'élévateur (Delta) fournis en entrée.

Le réseau est configuré avec une architecture appropriée, en prenant en compte le nombre de couches, le nombre de neurones par couche et les fonctions d'activation adaptées à la tâche de régression de l'angle d'élévateur.

Nous utilisons la base de données saine pour entraîner le réseau neuronal, ajustant ainsi les poids et les biais pour minimiser l'erreur de prédiction entre les valeurs d'angle d'élévateur réelles et celles prédites par le réseau.

III.3.3. Estimation des fonctions de transfert

Après avoir entraîné le réseau neuronal avec succès, nous procédons à l'évaluation de ses performances en utilisant les deux autres ensembles de données, ceux avec des blocages dans l'angle d'élévateur (thêta).

Pour chaque ensemble avec blocage, nous effectuons une linéarisation du système en utilisant la planification des gains PID. Cela nous permet de déterminer les fonctions de transfert pour chaque configuration avec blocage, en considérant l'angle d'attaque de l'élévateur (Delta) en entrée et l'angle d'élévateur estimé par le réseau neuronal.

III.3.4. Simulation sur Matlab/Simulink

Nous réalisons enfin des simulations sur Matlab/Simulink en fournissant l'angle d'attaque de l'élévateur avec un blocage (thêta) en entrée.

Le réseau neuronal est utilisé pour estimer l'angle d'élévateur correspondant, et les fonctions de transfert associées sont appliquées pour obtenir les valeurs de l'angle d'attaque de l'élévateur (Delta) résultant de la simulation.

En mettant en œuvre cette méthodologie, nous visons à démontrer l'efficacité du réseau neuronal dans la détection précise des blocages de l'élévateur pour un UAV en mode longitudinal. Les résultats obtenus à partir des simulations sur Matlab/Simulink serviront de validation de notre approche et permettront d'évaluer la performance et la robustesse du réseau neuronal dans des conditions réelles de vol.

III.4 bases de donner

XFLR5 est employé pour effectuer le calcul des coefficients aérodynamiques et construire une base de données, comme illustré dans la figure présentée ci-dessous :

	Alpha	Cl	Cd	Cm	KTr_top	KTr_bot	Cl/Cd	1 ³ /2/c	qrt(Cl)	XCp	HMom	Cdp	Cpmn	Re
1	-2.000	0.025	0.007	-0.055	0.827	0.358	3.434	0.538	0.157	2.529	0.000	0.002	-0.828	638,341
2	-1.500	0.076	0.008	-0.056	0.853	0.618	9.884	2.730	0.276	0.987	0.000	0.003	-0.681	362,029
3	-1.000	0.123	0.008	-0.053	0.849	0.797	15.171	5.314	0.350	0.687	0.000	0.003	-0.557	285,517
4	-0.500	0.177	0.009	-0.051	0.838	0.918	19.824	8.331	0.420	0.541	0.000	0.004	-0.517	237,955
5	0.000	0.301	0.011	-0.065	0.841	0.987	28.372	15.565	0.549	0.465	0.000	0.005	-0.598	182,284
6	0.500	0.378	0.011	-0.070	0.822	1.000	34.095	20.952	0.615	0.434	0.000	0.005	-0.659	162,729
7	1.000	0.423	0.011	-0.068	0.793	1.000	37.166	24.171	0.650	0.409	0.000	0.005	-0.708	153,760
8	1.500	0.469	0.012	-0.066	0.764	1.000	39.811	27.272	0.685	0.388	0.000	0.005	-0.764	145,975
9	2.000	0.516	0.012	-0.064	0.735	1.000	42.033	30.204	0.719	0.371	0.000	0.006	-0.830	139,161
10	2.500	0.564	0.013	-0.063	0.707	1.000	43.863	32.939	0.751	0.357	0.000	0.006	-0.913	133,163
11	3.000	0.612	0.013	-0.061	0.680	1.000	45.348	35.468	0.782	0.345	0.000	0.006	-1.018	127,858
12	3.500	0.660	0.014	-0.059	0.652	1.000	46.556	37.813	0.812	0.335	0.000	0.007	-1.148	123,119
13	4.000	0.708	0.015	-0.057	0.623	1.000	47.540	39.993	0.841	0.326	0.000	0.007	-1.300	118,871
14	4.500	0.755	0.016	-0.055	0.593	1.000	48.354	42.019	0.869	0.317	0.000	0.008	-1.471	115,077
15	5.000	0.802	0.016	-0.053	0.559	1.000	49.043	43.913	0.895	0.310	0.000	0.009	-1.666	111,681
16	5.500	0.848	0.017	-0.051	0.523	1.000	49.681	45.739	0.921	0.303	0.000	0.009	-1.866	108,617
17	6.000	0.893	0.018	-0.048	0.484	1.000	50.265	47.503	0.945	0.297	0.000	0.010	-2.107	105,815

Figure 27: Évaluation des Coefficients Aérodynamiques Cd, Cm, Cl et Angle d'Incidence à l'aide de XFLR5

III.5 Réseau neurone

L'objectif de cette étude consiste à créer une base de données en rassemblant les coefficients aérodynamiques c_m , c_d , c_l et le paramètre d'incidence θ (alpha) obtenus à l'aide du logiciel de simulation aérodynamique XFLR5. Par la suite, nous mettrons en œuvre cette base de données dans l'environnement de programmation et de calcul scientifique Matlab afin de concevoir un réseau neuronal spécialisé.

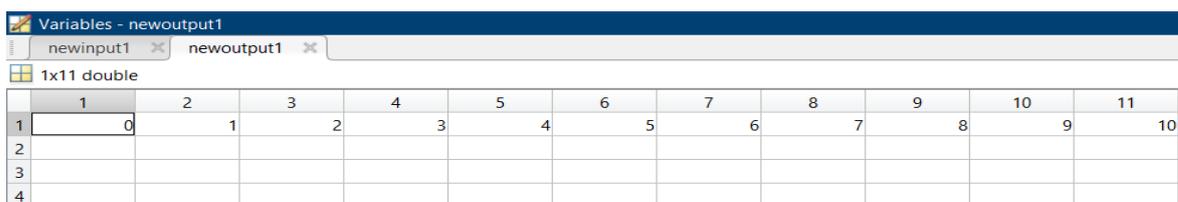
Dans cette démarche, XFLR5 sera utilisé pour effectuer des simulations approfondies visant à déterminer les valeurs des coefficients aérodynamiques c_m , c_d et c_l pour différentes valeurs du paramètre d'incidence θ (alpha). Cette approche nous permettra d'obtenir une série de données complètes et précises reflétant le comportement aérodynamique du système d'étude.

Par la suite, en utilisant Matlab, nous mettrons en place un réseau neuronal sophistiqué. Ce réseau sera entraîné à partir de la base de données aérodynamiques pour établir des relations complexes entre les coefficients aérodynamiques et le paramètre d'incidence. En effet, l'objectif de ce réseau neuronal est de capturer les caractéristiques intrinsèques du comportement aérodynamique du véhicule en fonction de diverses conditions d'incidence.

Cette approche innovante de modélisation par réseau neuronal ouvre des perspectives prometteuses pour l'analyse et l'optimisation des performances aérodynamiques des véhicules aériens sans pilote. En combinant les données issues des simulations XFLR5 avec les puissantes capacités de Matlab en matière de traitement de données et d'apprentissage automatique, nous pourrions approfondir notre compréhension des facteurs clés influençant la stabilité et l'efficacité de ces systèmes aériens.

III.5.1 les entrées et les sorties de notre réseau neurone

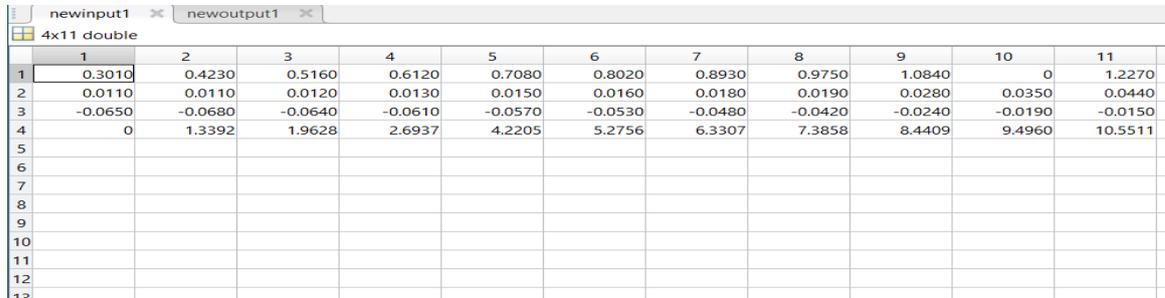
- L'entrée représente l'angle de tangage θ (alpha) comme le montre la figure 29 :



	1	2	3	4	5	6	7	8	9	10	11
1	0	1	2	3	4	5	6	7	8	9	10
2											
3											
4											

Figure 28: l'entrée du réseau neurone θ

- Les sorties représente les coefficients aérodynamiques c_l, c_d, c_m et Delta élévateur comme montre la figure 30:



	1	2	3	4	5	6	7	8	9	10	11
1	0.3010	0.4230	0.5160	0.6120	0.7080	0.8020	0.8930	0.9750	1.0840	0	1.2270
2	0.0110	0.0110	0.0120	0.0130	0.0150	0.0160	0.0180	0.0190	0.0280	0.0350	0.0440
3	-0.0650	-0.0680	-0.0640	-0.0610	-0.0570	-0.0530	-0.0480	-0.0420	-0.0240	-0.0190	-0.0150
4	0	1.3392	1.9628	2.6937	4.2205	5.2756	6.3307	7.3858	8.4409	9.4960	10.5511
5											
6											
7											
8											
9											
10											
11											
12											
13											

Figure 29: les sorties du réseau neurone c_d, c_l, c_m , Delta élévateur

III.5.2 l'apprentissage du réseau neurone

Nous avons mis en œuvre un programme en utilisant la boîte à outils Neural-Network Toolbox disponible dans le logiciel Matlab® (version R2022b). Tout au long de cette étude, nous avons rigoureusement suivi les étapes requises pour charger les données préexistantes dans le concepteur de réseaux neuronaux de Matlab.

Dans un premier temps, les coefficients aérodynamiques (C_l, C_d, C_m) ont été utilisés pour enrichir la base de données. Cependant, lors des étapes ultérieures de traitement, nous avons décidé de n'utiliser que les valeurs de coefficient d'élévation (Delta) en tant que sortie (output) du réseau neuronal, et les valeurs d'angle d'incidence (θ) comme entrée (input) pour l'apprentissage.

En conséquence, le réseau neuronal a été formé en utilisant la méthode d'apprentissage supervisé, qui consiste à entraîner le réseau sur un ensemble de données bien étiqueté, où les valeurs de Delta servent de cibles à prédire en fonction des différentes valeurs d'angle d'incidence θ en tant que variables d'entrée.

Le processus de développement de ce réseau neuronal a permis de créer un modèle sophistiqué capable de fournir des prédictions précises des valeurs de coefficient d'élévation (Delta) en fonction des valeurs d'angle d'incidence θ . Cette approche ciblée offre de nouvelles perspectives dans le domaine de l'aéronautique en permettant d'optimiser les performances aérodynamiques grâce à une meilleure compréhension des relations entre les paramètres d'entrée et de sortie du réseau.

La représentation comme la montre la figure 31 et 32 suivantes :

	1	2	3	4	5	6	7	8	9	10	11	12
1	0	1	2	3	4	5	6	7	8	9	10	
2												

Figure 30: l'entrée (input) thêta

	1	2	3	4	5	6	7	8	9	10	11
1	0	1.3392	1.9628	2.6937	4.2205	5.2756	6.3307	7.3858	8.4409	9.4960	10.5511
2											

Figure 31: la sortie(output) Delta élévateur

Pour le processus d'entraînement de notre réseau neuronal, nous avons opté pour l'utilisation de la boîte à outils Neural-Network Toolbox sur Matlab, en mettant en œuvre la méthode de Lavenberg-Marquardt (trainlm). Cette approche a été choisie en raison de ses propriétés de convergence rapide et de son efficacité pour les problèmes complexes d'apprentissage.

Lors de l'entraînement du réseau, nous avons généré un script d'apprentissage détaillé, qui a été utilisé pour superviser le processus et enregistrer les résultats pertinents. Les performances du réseau ont été rigoureusement évaluées en utilisant des métriques appropriées pour mesurer la précision et la fiabilité des prédictions.

Pour faciliter la visualisation des résultats obtenus lors de l'entraînement, nous avons également créé des graphiques informatifs. Les figures suivantes illustrent ces graphiques, fournissant ainsi un aperçu visuel de l'évolution de l'apprentissage et de la performance du réseau neuronal au fil des itérations.

En utilisant cette approche méthodique, nous avons pu parvenir à un réseau neuronal bien entraîné et performant, capable de fournir des prédictions précises pour les valeurs de sortie en fonction des entrées données. Ces résultats sont d'une importance capitale pour améliorer notre compréhension du comportement aérodynamique du système étudié et ouvrent des perspectives prometteuses pour l'optimisation des performances dans le domaine de l'aéronautique.

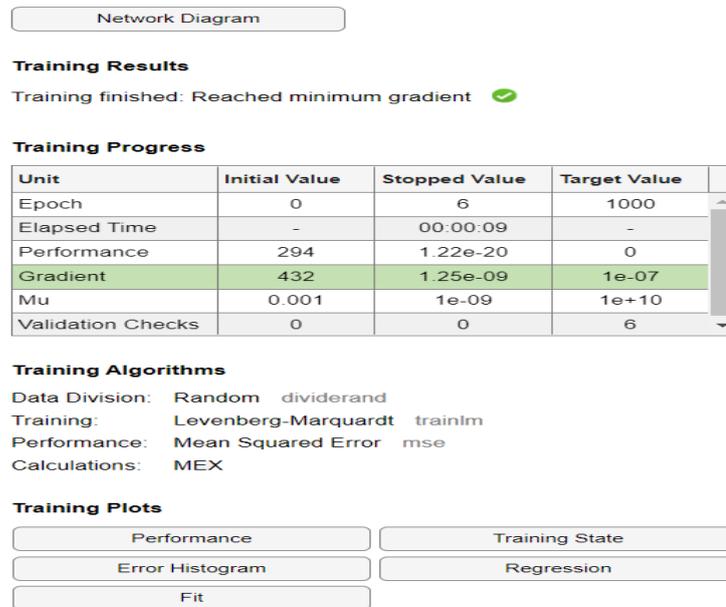


Figure 32: entraînement du réseau neurone

III.5.3 La structure du réseau neurone

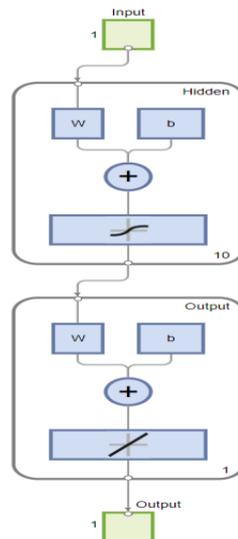


Figure 33: l'architecture du réseau neurone

La configuration du réseau neuronal consiste en une architecture à 10 couches cachées, où une seule entrée et une seule sortie sont présentes.

III.5.4 performances du réseau neurone

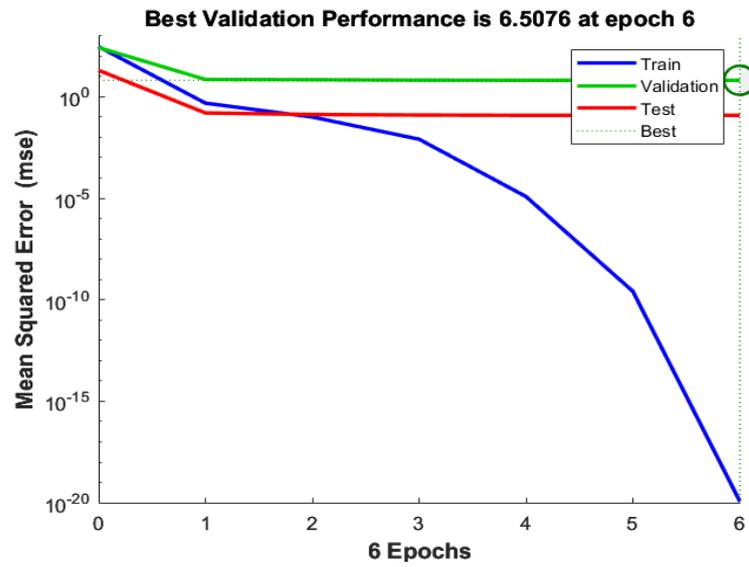


Figure 34: graphe qui représente la performance du réseau neurone

Une observation notable est la diminution de l'erreur, ce qui indique une performance satisfaisante du réseau neuronal.

III.5.5 résultats d'apprentissage

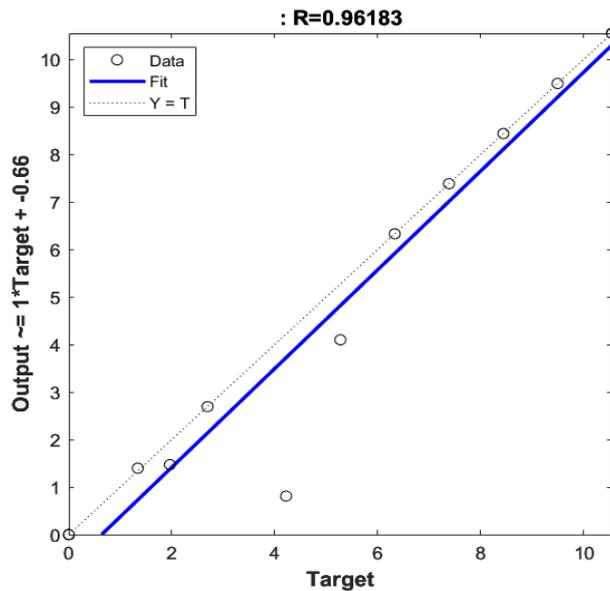


Figure 35: résultat d'apprentissage

L'observation révèle une faible erreur, démontrant ainsi un apprentissage réussi et de qualité du réseau neuronal.

III.6. L'estimation de la fonction de transfert pour le cas sain

Par l'application des équation (II.5) après linéarisation du système par le développement de Taylor d'après Linéarisation autour d'un point

$$V=30, p=r=q=\vartheta = \theta = \psi \neq 0$$

La fonction de transfert en régime croisière

$$G(s) = \frac{\theta}{\delta e} = \frac{3.0376s + 0.3906}{s^2 + 2.5491s + 0.4568} \quad (III.4)$$

III.6.1. Le diagramme du système sain en Simulink

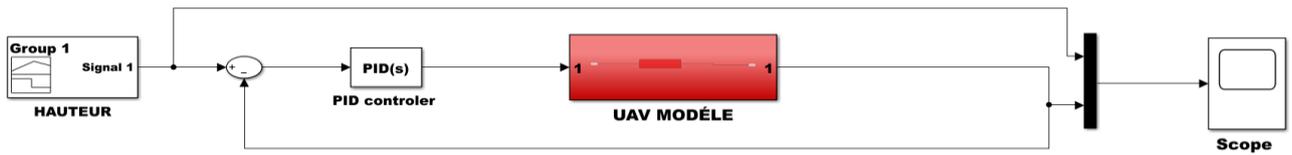


Figure 36: schéma du système sain

III.6.2. Le résultat de la simulation (scope)

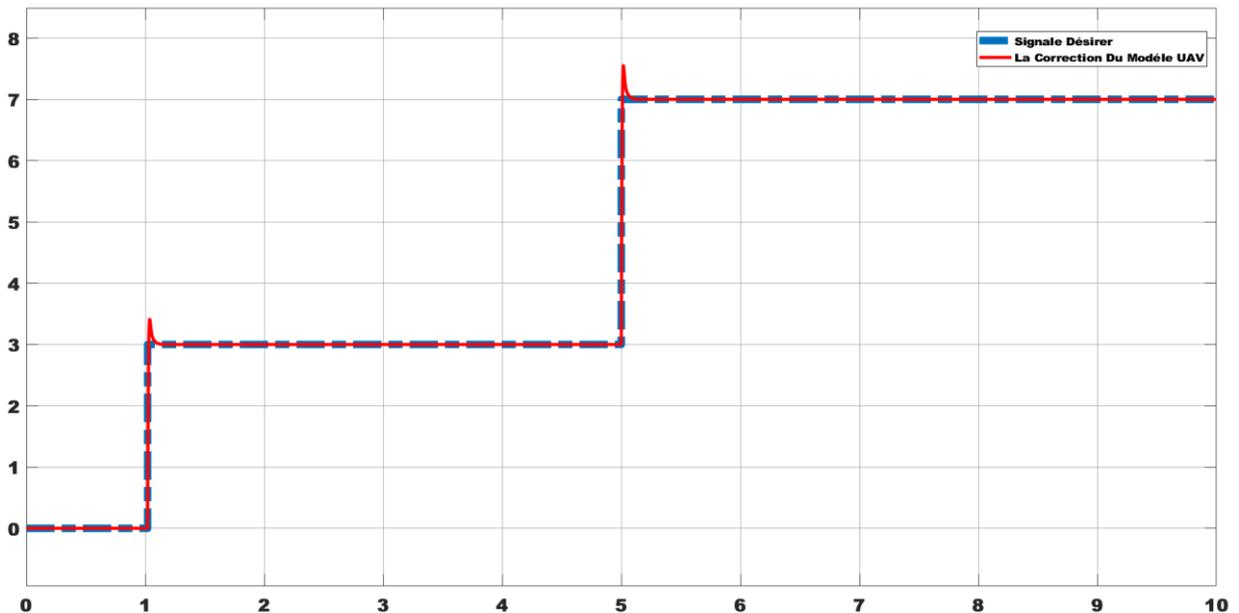


Figure 37: graphe représente la réaction du système sain en fonction du temps (l'angle de tangage)

Le graphe illustre le comportement du système sans défaut, montrant deux tangages distincts exécutés à des moments différents.

III.7. L'estimation de la fonction de transfert TF pour le défaut 1

Par l'application des équation (II.5) après linéarisation du système par le développement de Taylor d'après Linéarisation autour d'un point

$$V=30, p=r=q=\vartheta = \theta = \psi \neq 0$$

Sachent que le défaut 1 c'est un blocage de la gouverne de profondeur a la position 1 degré

La fonction de transfert en régime croisière avec ce défaut 1 est comme suit

$$G1(s) = \frac{\theta}{\delta e(\text{défaut } 1)} = \frac{0.5919s+0.1647}{s^2+7.4838e-05s+0.3738} \quad (III.5)$$

On considère qu'on a un blocage(défaut1) lorsque θ est inférieur ou égale à cinq

Pour l'estimation de la fonction de transfert on utilise une base de données qui consiste d'une seule entrée Delta élévateur(input)et une seule sortie(output) θ comme présentée en 39 et 40 :

	1	2	3	4	5	6	7	8	9	10	11
1	0	1.3392	1.9628	2.6937	4.2205	5.2756	5.2756	5.2756	5.2756	5.2756	5.2756
2											

Figure 38: base de données qui représente l'entrée Delta élévateur pour l'estimation de la fonction de transfert.

Variables - newoutput5											
newoutput5											
1x11 double											
	1	2	3	4	5	6	7	8	9	10	11
1	0	1	2	3	4	5	6	7	8	9	10
2											

Figure 39: base de donner qui représentent la sortie θ pour l'estimation de la fonction de transfert avec le défaut .

III.7.1. Le diagramme du système avec défaut 1 en Simulink

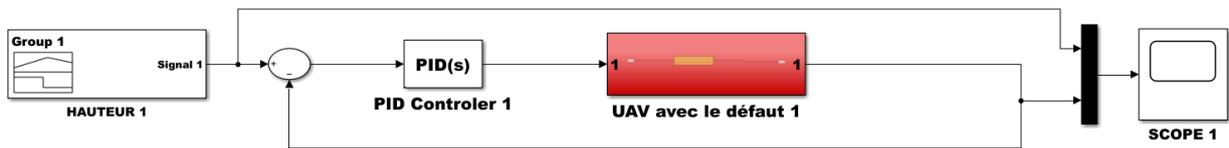


Figure 40: schéma du système avec défaut 1 sans changement du gain PID en utilisant (III.5)

III.7.2. Le résultat de la simulation (scope 1)

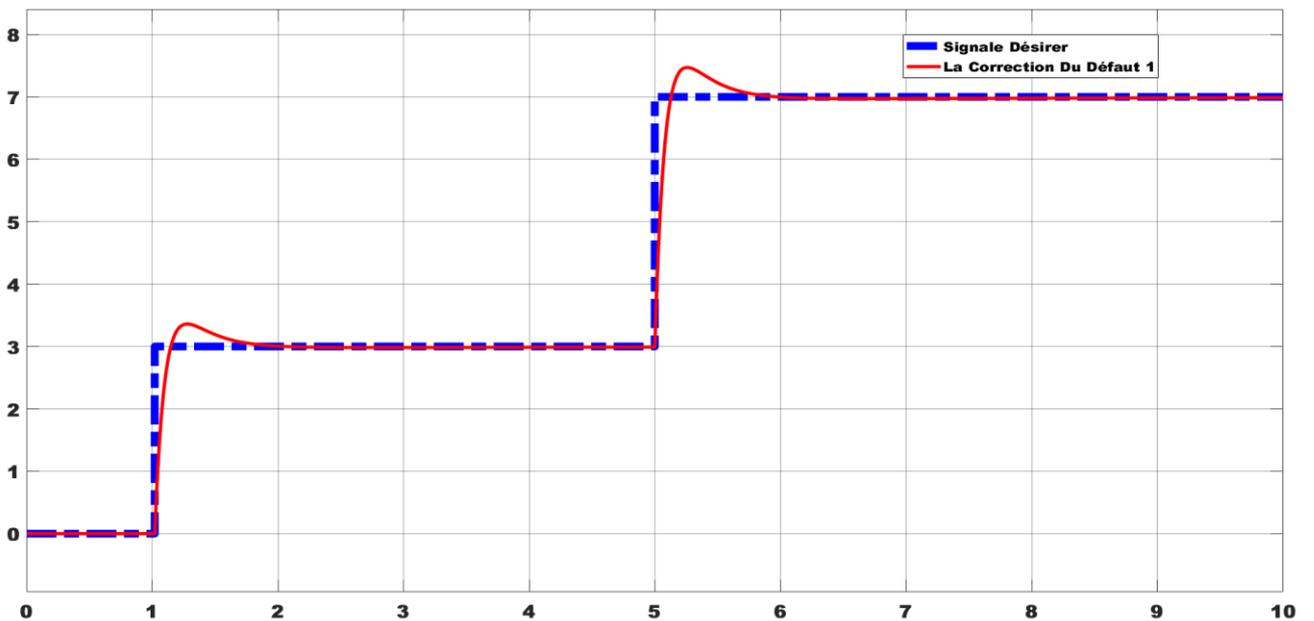


Figure 41: graphe représente le comportement du système avec défaut 1 en fonction du temps

Le signal en bleu représente le signal désiré, tandis que le signal en rouge représente le comportement du système avec défaut 1 via l'actionneur (aileron).

Le temps de réponse lent observé dans ce contexte est caractérisé par des dépassements significatifs et des erreurs statiques considérables.

III.8. L'estimation de la fonction de transfert TF pour le défaut 2

Par l'application des équation (II.5) après linéarisation du système par le développement de Taylor d'après Linéarisation autour d'un point

$$V=30, p=r=q=\vartheta = \theta = \psi \neq 0$$

Sachent que le défaut 2 c'est un blocage de la gouverne de profondeur a la position 2 degré
La fonction de transfert en régime croisière avec ce défaut est comme suit

$$G2(s) = \frac{\theta}{\delta e(\text{défaut } 2)} = \frac{0.5382s+0.0698}{s^2+0.2367s+0.1373} \quad \text{(III.6)}$$

On considère qu'on a un blocage(défaut2) lorsque θ est supérieur ou égale à neuf.

Pour l'estimation de la fonction de transfert on utilise une base de données qui consiste d'une seule entrée Delta élévateur(input)et une seule sortie(output) θ comme présenter en 43 et 44 :

	1	2	3	4	5	6	7	8	9	10	11
1	0	1	2	3	4	5	6	7	8	9	9
2											

Figure 42: base de données qui représentent l'entrée Delta élévateur pour l'estimation de la fonction de transfert.

	1	2	3	4	5	6	7	8	9	10	11
1	0	1	2	3	4	5	6	7	8	9	10
2											
3											

Figure 43: base de donner qui représentent la sortie θ pour l'estimation de la fonction de transfert.

III.8.1. Le diagramme du système avec défaut 2 en Simulink

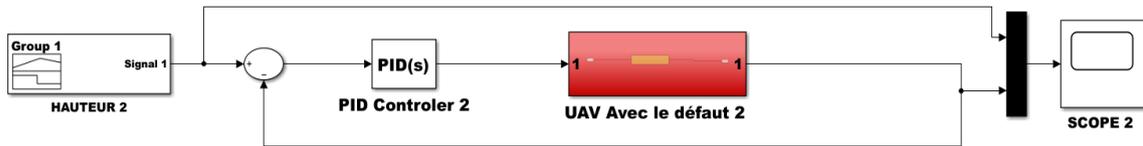


Figure 44: schéma du système défaut 2 sans changement du gain PID en utilisant (III.6)

III.8.2. Le résultat de la Simulation (scope 2)

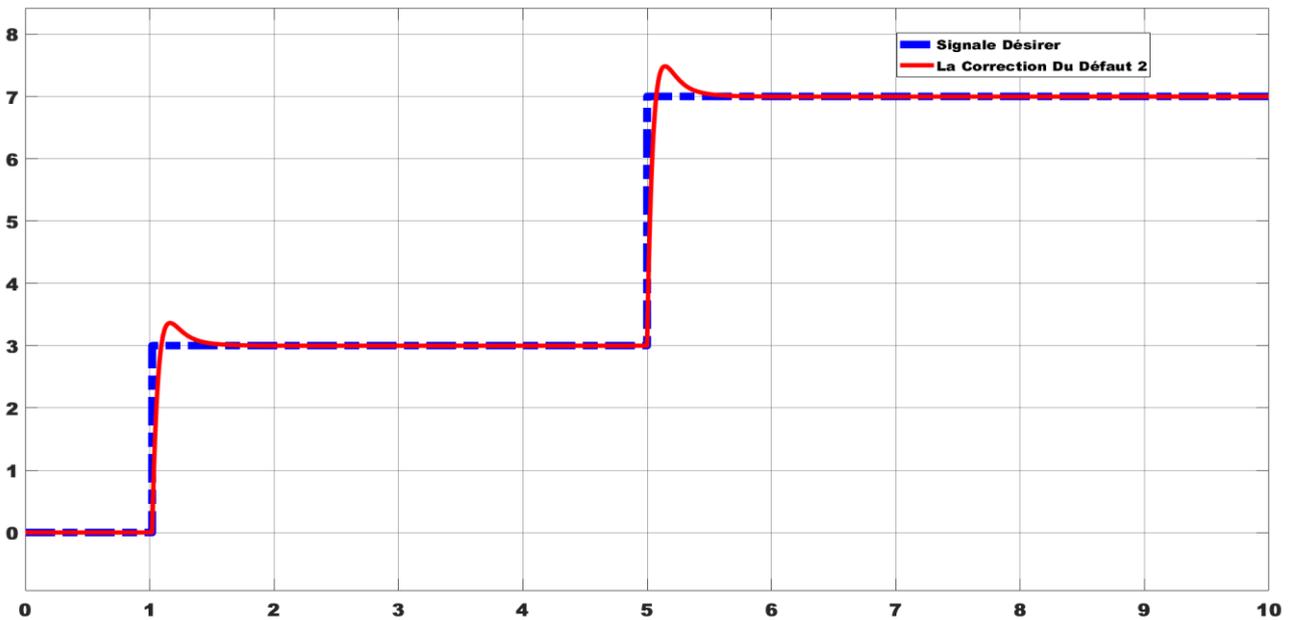


Figure 45: graphe représente le comportement du système avec défaut 2 en fonction du temps.

Le signal en bleu représente le signal désiré, tandis que le signal en rouge représente le comportement du système avec défaut 2 via l'actionneur (aileron).

Le temps de réponse lent observé dans ce contexte est caractérisé par des dépassements significatifs et des

erreurs statiques considérables.

III.9 Représentation du système sain et bloquer sur Simulink

Nous utilisons la sortie du réseau neuronal, à savoir le coefficient d'élévation (Delta), pour déterminer dans quel scénario du système nous nous trouvons. Si la valeur de Delta est inférieure ou égale à un, alors nous sommes dans le cas du système sain. Si Delta est supérieure à un et inférieure ou égale à cinq, alors cela indique un blocage, spécifiquement le défaut 1. Enfin, si Delta dépasse cinq, cela correspond au blocage associé au défaut 2.

Chaque cas sera ensuite représenté individuellement dans la simulation, permettant ainsi d'observer et d'analyser le comportement du système sous différentes conditions.

Les différents cas représenter sont :

- Le cas sain.
- Le cas bloquer (défaut 1).
- Le cas bloquer (défaut 2).

III.9.1. Schémas du système de contrôle avec planification de gain

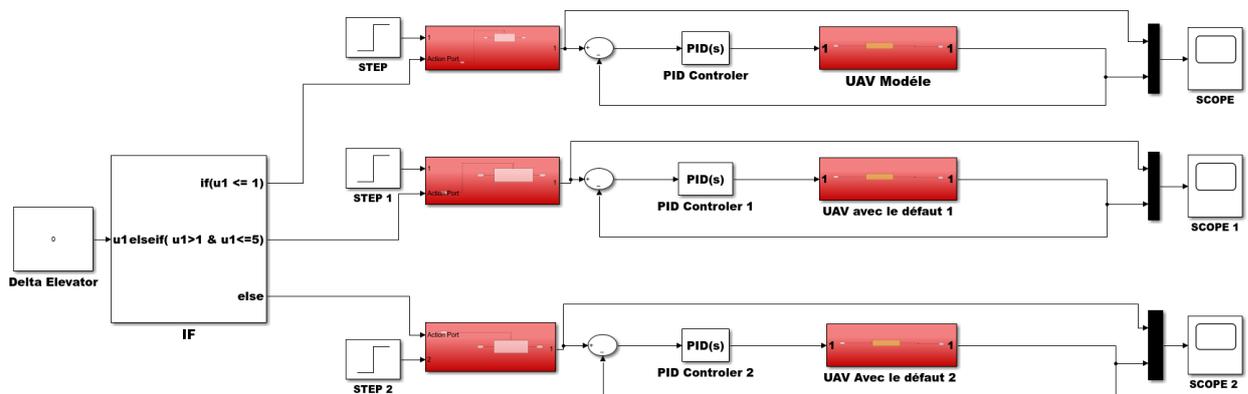


Figure 46: schéma représente le système sain et système avec défauts

III.9.2. Le cas sain

On suppose une valeur de Delta élévateur inférieur ou égale à 1 est on fait la simulation figure 48

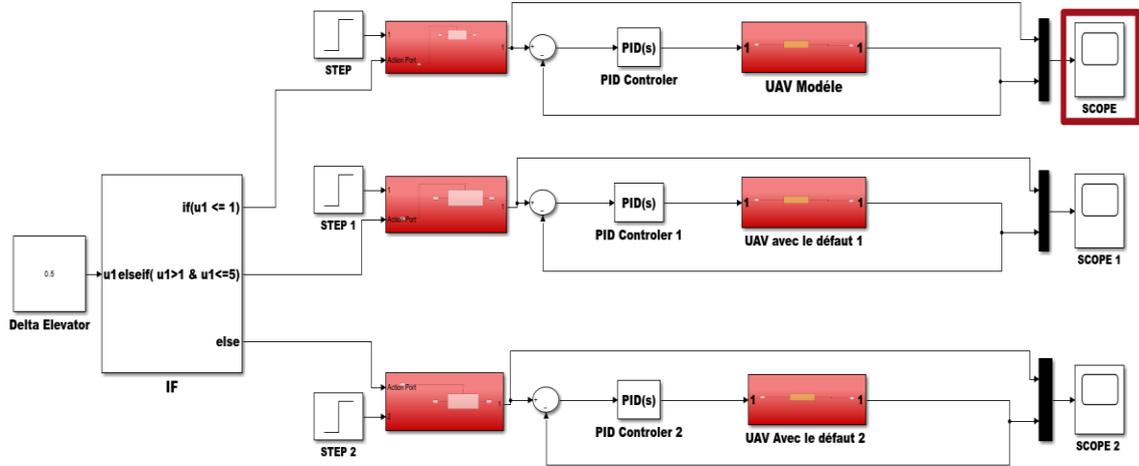


Figure 47: schéma du système lorsque le Delta élévateur est égal à 0.5

III.9.2.1 résultats du SCOPE

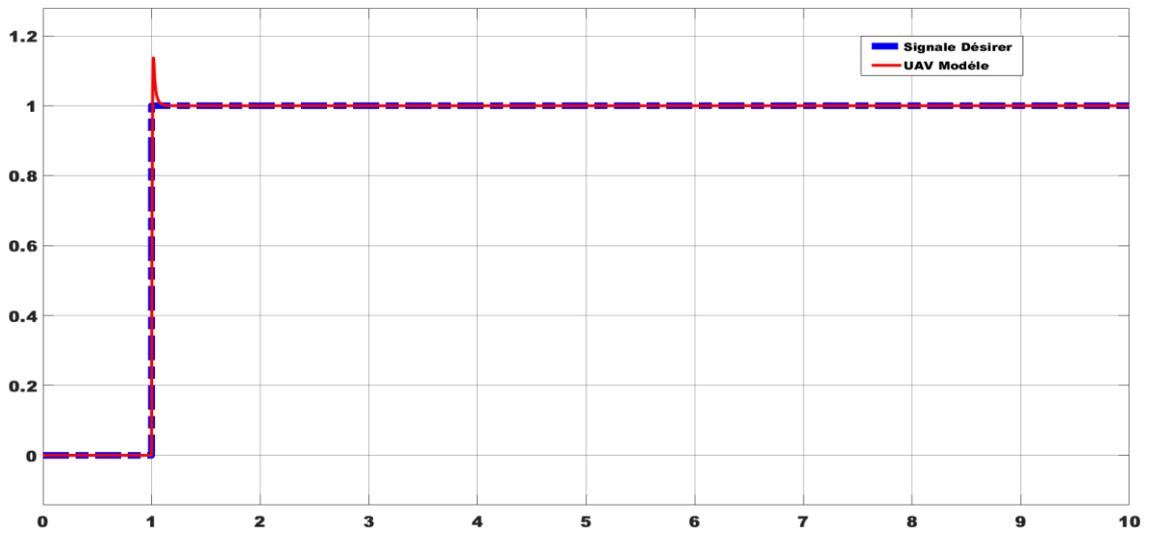


Figure 48: graphe représente la correction du système avec le contrôle de type planification du gain

Il est notable que le modèle se rétablit après 1 seconde, et cela correspond à l'utilisation de la même fonction de transfert que celle du premier système (sain).

III.9.3. Le cas bloquer (défaut 1)

On suppose une valeur de Delta élévateur supérieure à un est inférieur ou égal à cinq est on fait la simulation figure 50

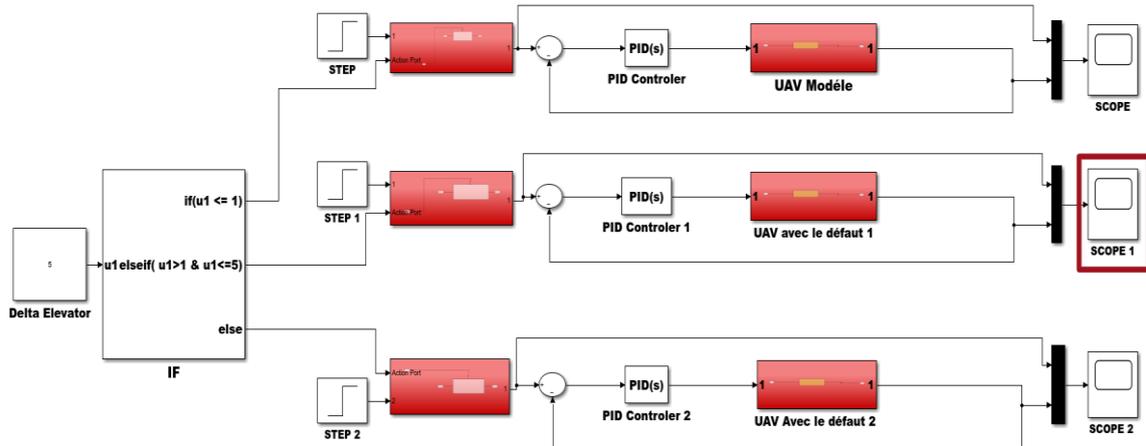


Figure 49: schéma du système lorsque Delta élévateur égale à 5

III.9.3.1. Résultats du SCOPE1

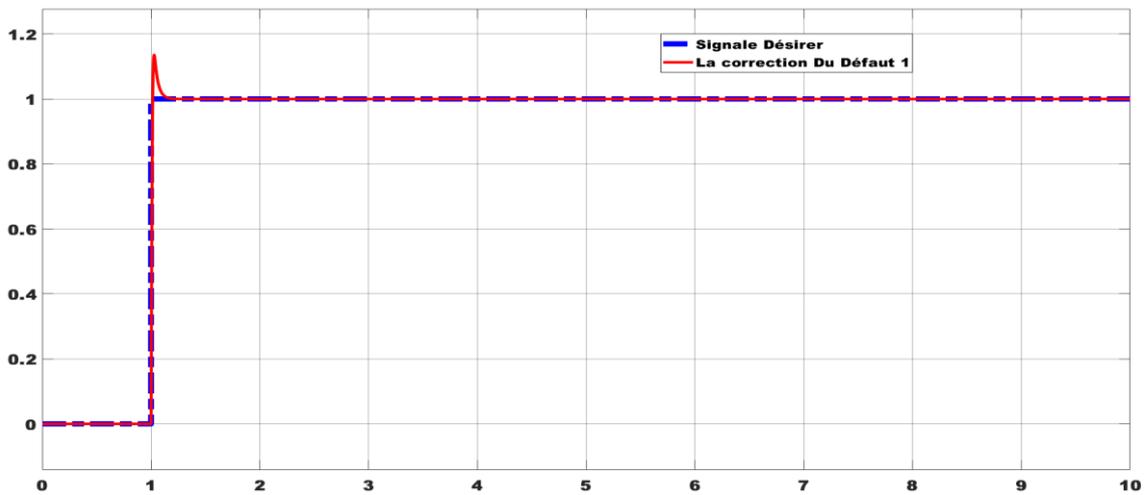


Figure 50: graphe représente la correction du système avec le contrôle de type planification du gain (défaut 1, détection et correction)

Le modèle se rétablit après 1 secondes, et cela correspond à l'utilisation de la fonction de transfert du deuxième système (avec défaut 1).

III.9.4. Le cas bloquer (défaut 2)

On suppose une valeur de Delta élévateur supérieure à 5 est on fait la simulation figure 52 :

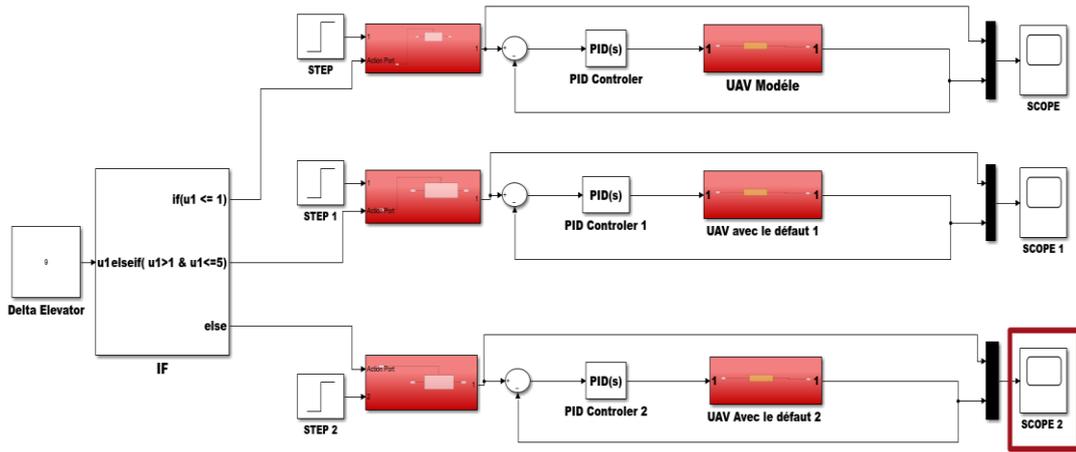


Figure 51:schéma du système lorsque Delta élévateur égale à 9

III.9.4.1 Résultats du SCOPE 2

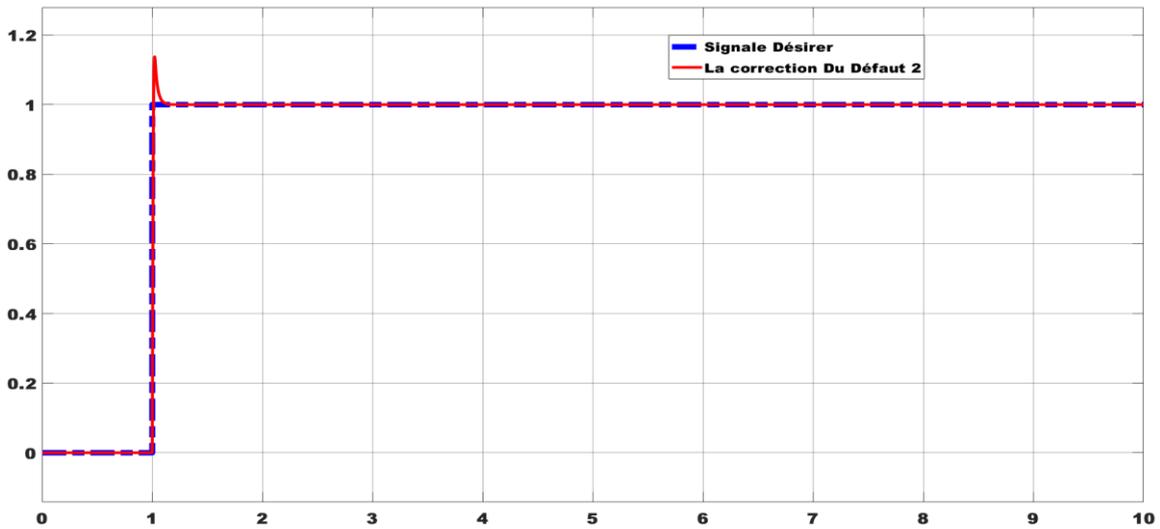


Figure 52:graphe représente la correction du système avec le contrôle de type planification du gain(défaut 2 ,
détection et correction)

Il est observé que le modèle se rétablit après 1 seconde, en utilisant la fonction de transfert du troisième système (avec défaut 2).

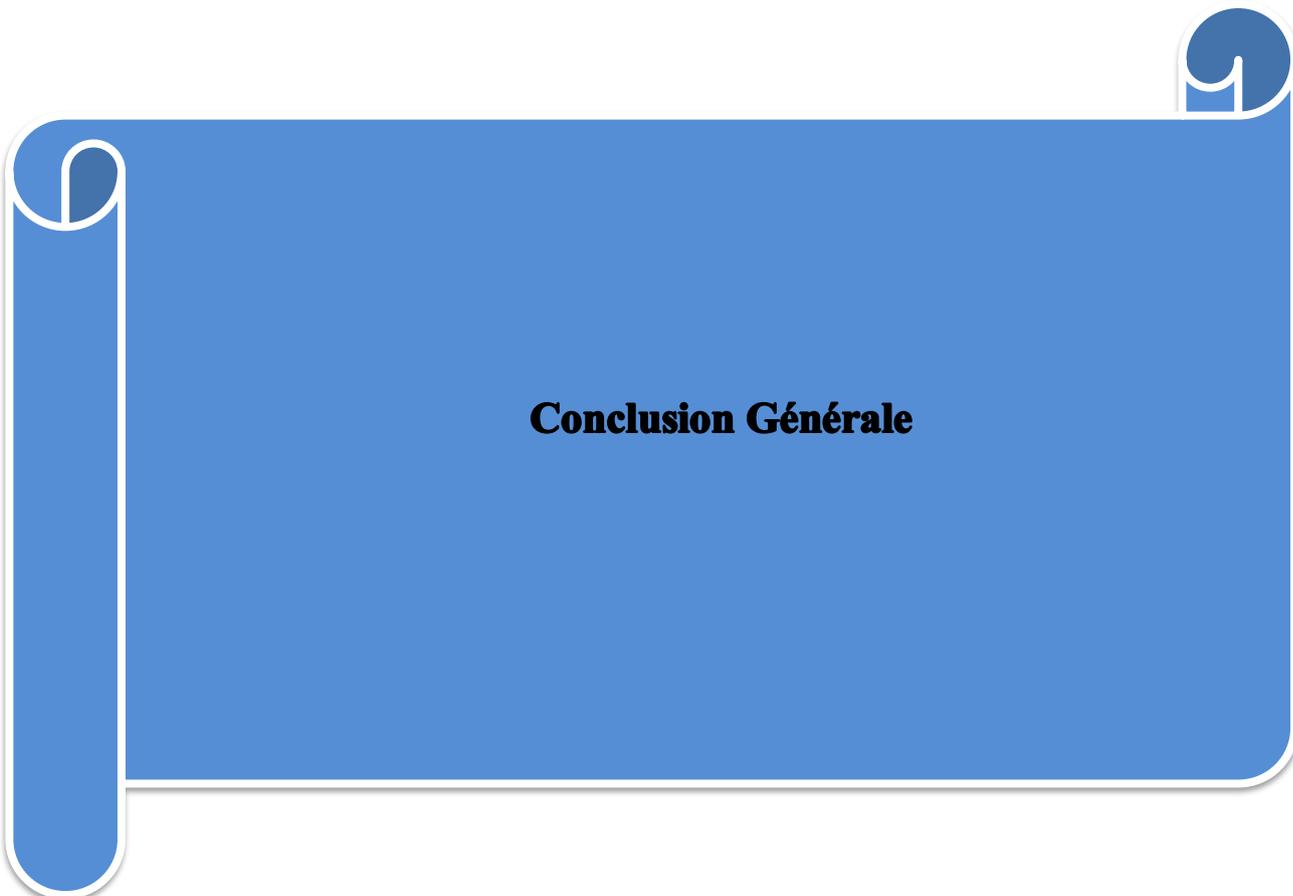
III.10 Conclusion

En conclusion de ce chapitre, nous avons mis en œuvre une approche novatrice combinant l'utilisation d'un réseau neuronal pour le diagnostic et la planification des gains pour la détection des défauts, notamment l'angle de blocage.

Les résultats obtenus sont extrêmement prometteurs, démontrant l'efficacité remarquable de la méthode de contrôle par planification de gain. Cette approche permet au système de s'adapter rapidement aux conditions changeantes et d'identifier avec précision la présence de défauts potentiels.

La combinaison du réseau neuronal et de la planification des gains offre une solution puissante et robuste pour assurer la stabilité et les performances optimales de l'UAV, même en présence de pannes. La rapidité et la précision de la détection de défauts constituent des atouts essentiels pour garantir la sécurité et la fiabilité des opérations aériennes.

En résumé, ce chapitre a mis en évidence l'efficacité de notre approche de contrôle adaptatif, et les résultats obtenus sont très encourageants. Cette avancée significative représente une contribution importante pour améliorer la sûreté et la performance des UAV à voilure fixe, ouvrant ainsi la voie à de nouvelles perspectives dans le domaine de l'aéronautique et de l'automatisation des systèmes aériens.



Conclusion Générale

Conclusion Générale

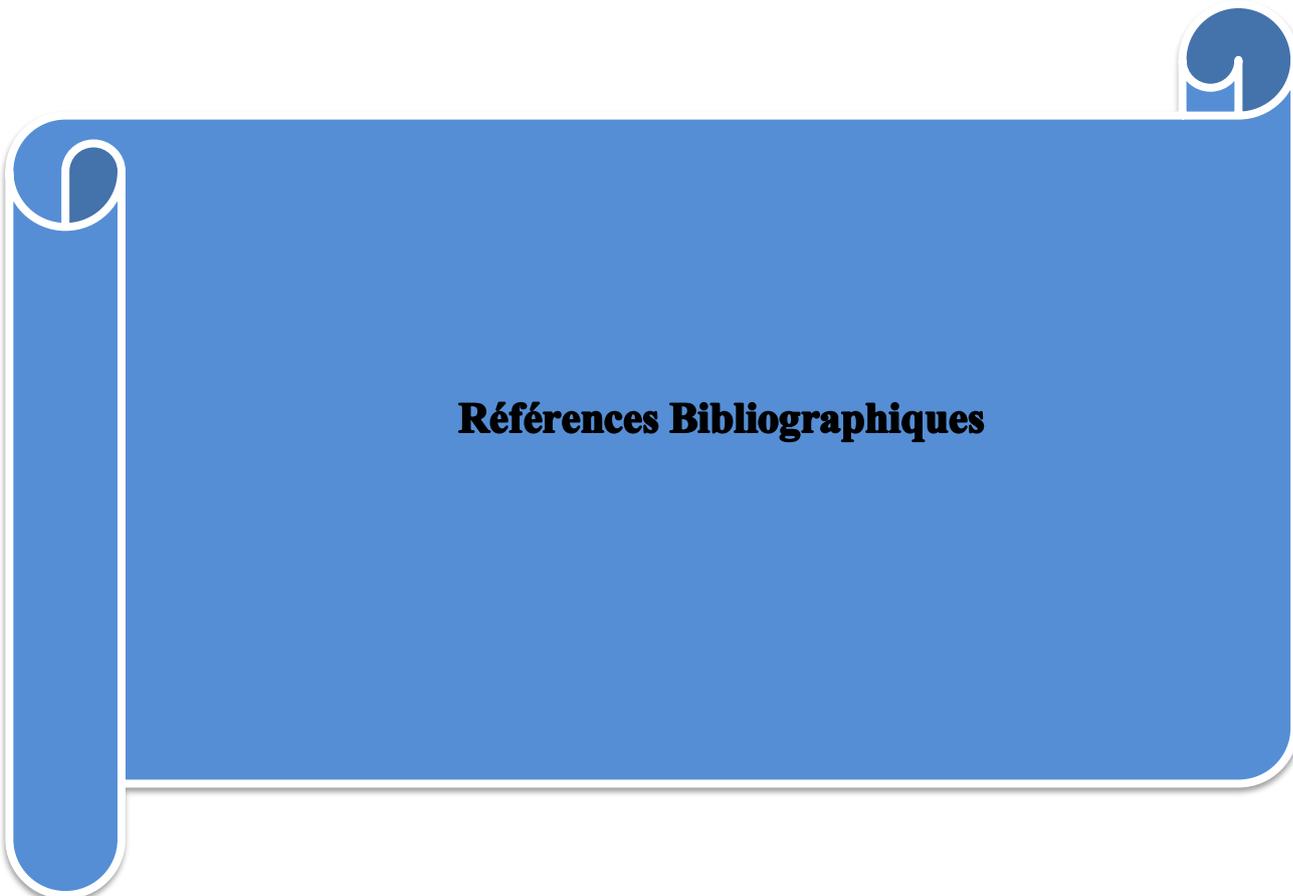
Dans le premier chapitre, nous avons étudié les UAV à voilure fixe ainsi que les différents types de pannes susceptibles de survenir lors du contrôle de ces appareils. Ces informations ont permis de mieux appréhender les défis auxquels sont confrontés les opérateurs et les ingénieurs en aéronautique lors de l'utilisation de ces systèmes.

Le deuxième chapitre a porté sur l'utilisation des réseaux neuronaux pour le diagnostic des pannes et la Planification des gains PID. Les réseaux neuronaux se sont avérés être une approche prometteuse pour améliorer la précision du diagnostic des pannes et pour optimiser les paramètres de contrôle PID afin de garantir des performances optimales des UAV à voilure fixe.

Enfin, le troisième chapitre a été consacré à la simulation et à l'interprétation des résultats obtenus grâce à une base de données utilisant des réseaux neuronaux pour le diagnostic des pannes au niveau de la gouverne de profondeur. Les résultats ont été concluants, montrant une efficacité et une rapidité accrues dans la détection et la résolution des pannes, contribuant ainsi à accroître la fiabilité et la sécurité des UAV à voilure fixe.

Ce mémoire a donc permis de démontrer l'importance de l'intégration des réseaux neuronaux dans le domaine de l'aéronautique, en particulier pour le diagnostic des pannes et la planification des gains PID. Les résultats obtenus ouvrent la voie à de nouvelles perspectives d'amélioration des systèmes de contrôle et de maintenance des UAV, favorisant ainsi leur utilisation dans des contextes toujours plus exigeants.

En conclusion, ce travail de recherche a contribué à enrichir les connaissances dans le domaine de l'aéronautique et à explorer de nouvelles approches technologiques pour une meilleure gestion des UAV à voilure fixe. Il offre des perspectives passionnantes pour des applications futures dans l'industrie aéronautique, en visant une amélioration continue de la fiabilité, de l'efficacité et de la sécurité des systèmes aéronautiques autonomes.



Références Bibliographiques

Références Bibliographiques

- [1]. Shoaib Ahmed, Adam Asif, Hiba Ashraf, Mohsin Ahmed, Shujah Rizvi ‘Design and Manufacturing of 6 Hours Endurance UAV’, Afghanistan, DHA Suffa University, 2017.
- [2]. N.M. Jodeh, P.A. Blue, A.A. Waldron, “Development of small unmanned aerial vehicle research platform: Modeling and simulating with flight test validation”, *AIAA Modeling and Simulation Technologies Conference and Exhibit*, no. 2006-6261, 2006.
- [3]. Mark Willis Bailey. ‘Unmanned aerial vehicle path planning and image processing for orthoimagery and digital surface model generation’. 2012.
- [4]. R.A. Frampton and J.M. Keir Dstl, UK Ministry of Defence. ‘Autonomy and its Application to Unmanned Systems’. (Proceedings of the 1st Moving Autonomy Forward Conference, 21–22 June 2006, De Vere Belton Woods Hotel, Grantham, UK, Muretex Ltd.).
- [5]. Robert Frampton FRAeS, Dstl, UK Ministry of Defence. ‘UAV Autonomy’. (Defence Codex – The Journal for Defence Engineering and Science, Issue 1, Summer 2008, UK Ministry of Defence.).
- [6]. Reg Austin, ‘UAVS DESIGN, DEVELOPMENT AND DEPLOYMENT’, *John Wiley & Sons Ltd, The Atrium, Southern Gate, Chichester, West Sussex, PO19 8SQ, United Kingdom*, 2010.
- [7]. A. Azzam and Xinhua Wang, ‘Quad rotor arial robot dynamic modeling and configuration stabilization. In Informatics in Control, Automation and Robotics (CAR)’, 2010 2nd International Asia Conference on, volume 1.
- [8]. R.G. Austin. ‘A Comparison of a Configuration’, *AGARD Canada*, 1968.
- [9]. Shuo Wang, Ziyang Zhen, Ju Jiang, and Xinhua Wang, ‘Flight Tests of Autopilot Integrated with Fault-Tolerant Control of a Small Fixed-Wing UAV’, College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China, Key Laboratory of Internet of Things and Control Techniques of Jiangsu Province, Nanjing 210016, China, 2015.
- [10]. DIY Drones. (2010, September 20). Ardupilot Mega Wiki, Introduction. Retrieved August 10, 2011, from DIY

Références Bibliographiques

Drones:<http://code.google.com/p/ardupilotmega/wiki/Introduction>.

- [11]. P. Brisset. "Drones civils Perspectives et réalités". Ecole Nationale de l'Aviation Civile, Toulouse, France, 2004.
- [12]. Gao, J., Sun, J., & Duan, X. (2019). Optimization of long-endurance unmanned aerial vehicle (UAV) based on swarm intelligence algorithm. In Proceedings of the 2019 8th International Conference on Industrial Technology and Management (ICITM) (pp. 50-54). IEEE.
- [13]. Lee, T. (2019). UAVs for industrial inspection: Challenges and future directions. *Robotics and Computer-Integrated Manufacturing*, 57, 261-279.
- [14]. Wang, H., Duan, Z., Li, G., & Chen, C. (2018). A survey on control and perception techniques in aerial robotics. *IEEE Access*, 6, 45412-45429.
- [15]. Koprulu, M., & Yildirim, O. (2018). An overview of autonomous fixed-wing UAVs: Concepts, capabilities, and challenges. *Progress in Aerospace Sciences*, 98, 31-44.
- [16]. Behera, A., & Swain, A. K. (2019). Modeling and control of small fixed-wing unmanned aerial vehicle: a review. *SN Applied Sciences*, 1(10), 1244.
- [17]. Hovakimyan, N., & Cao, C. (2010). Adaptive control of fixed-wing UAVs: An overview. *Annual Reviews in Control*, 34(2), 219-228.
- [18]. Yang, S., Zhan, Y., Jiang, B., Wang, Y., & He, J. (2019). Robust adaptive control for fixed-wing UAVs with uncertainties and disturbances. *Aerospace Science and Technology*, 87, 41-53.
- [19]. Su, Y., Niu, Y., Liu, H., & Sun, S. (2018). Adaptive control for a small fixed-wing UAV in the presence of wind gusts. *Aerospace Science and Technology*, 74, 11-20.
- [20]. Blanke, M., Kinnaert, M., Lunze, J., & Staroswiecki, M. (2016). *Diagnosis and fault-tolerant control* Springer.
- [21]. Patton, R. J., Chen, J., & Zhang, J. (2016). *Fault diagnosis in dynamic systems: Theory and applications*. Springer.

Références Bibliographiques

- [22]. Isermann, R. (2011). Fault-diagnosis systems: An introduction from fault detection to fault tolerance. Springer.
- [23]. Lee, J., & Verma, A. K. (2013). Data-driven techniques for fault detection and diagnosis in chemical processes springer.
- [24]. Liu, D., Zhang, W., & Yang, F. (2017). Intelligent fault diagnosis and prognosis for engineering systems. CRC Press.
- [25]. Huang, B., & Wang, Q. (2017). Data-driven modeling, filtering and fault detection of complex systems. Springer.
- [26]. Isermann, R. (2005). Model-based fault diagnosis and detection: Tools and techniques. Springer.
- [27]. Vachtsevanos, G., Lewis, F. L., Roemer, M. J., Hess, A. H., & Wu, B. (2006). Intelligent fault diagnosis and prognosis for engineering systems. Wiley-Inter science.
- [28]. Pecht, M., & Kim, J. R. (Eds.). (2017). Prognostics and health management of electronics.
- [29] Anamika Y, Thoke A.S, Transmission line fault distance and direction estimation using artificial neural network, International Journal of Engineering, Science and Technology, Vol. 3, No. 8, pp. 110-121, 2011.
- [30] Reddy M.J. and Mohanta D. K, A comparative study of artificial neural network (ANN) and fuzzy information system (FIS) approach for digital relaying of transmission line faults, AIML journal, vol.6, no. 4, pp. 1-7.
- [34] Reddy M.J.B, Mohanta D.K, "Performance Evaluation of an Adaptive- NetworkBased Fuzzy Inference System Approach for Location of Faults on Transmission Lines Using Monte Carlo Simulation", in Fuzzy Systems, vol.16, no.4, pp. 909 - 919, Aug. 2008
- [35] El-Sharkawi M, Niebur D, "A tutorial course on artificial neural networks with Applications to Power systems", IEEE Publ. No. 96TP 112-0, 1996.
- [36] Pao YH, Sobajic DJ, "Autonomous Feature Discovery of Clearing time assessment", Symposium of Expert System Applications to Power Systems, Stockholm – Helsinki, Aug 1988, pp. 5.22-5.27.

Références Bibliographiques

- [37] Dalstein T, Kulicke B, “Neural network approach to fault classification for high- speed protective relaying”, *IEEE Transactions on Power Delivery*, vol. 4, 1995, pp.1002 – 1009.
- [38] Kezunovic M, Rikalo I, Sobajic DJ, “Real-time and Off-line Transmission Line Fault Classification Using Neural Networks”, *Engineering Intelligent Systems*, vol. 10, 1996, pp. 57-63.
- [39] Bouthiba T, “Fault location in EHV transmission lines using artificial neural networks”, *Int. J. Appl. Math. Comput. Sci.*, 2004, Vol. 14, No. 1, pp. 69-78.
- [41]. S. Chen and S.A. Billings, ‘Neural networks for nonlinear dynamic system modelling and Identification’, *Int. J. Control*, vol. 56, no 2, pp. 319-346, 1992.
- [42]. Howard Demuth, Mark Beale, ‘Neural Network Toolbox for Use with MATLAB®’, *copyright by The MathWorks, Inc 1992 – 2000.*
- [43]. F. L. Lewis, J. Campos, R. Selmic, ‘Neuro-Fuzzy Control of Industrial Systems with Actuator Nonlinearities’, *Society for Industrial and Applied Mathematics Philadelphia*, 2002.
- [44]. K.S. Narendra and K. Parthasarathy, ‘Identification and control of dynamic systems using neural networks’, *IEEE Trans. Neural Networks*, pp. 14-27, 1990.
- [45]. Amit, Daniel J, ‘Neural network counting chimes’, *Proceeding National Academy of Science USA* 85, 2141–2145. (1988).
- [46]. F. Mrabti et H. Seridi, ‘Comparaison de méthodes de classification réseau RBF, MLP et RVFLNN’, *Damascus University Journal, Syrie*, vol. 25, no 2, pp. 119-129, 2009.
- [47]. M. Krstić, I. Kanellakopoulos, and P. V. Kokotović, ‘Nonlinear and adaptive control Design’, *Ed. John Wiley and Sons, New York*, 1995.
- [48]. C. Touzet, ‘Les réseaux de neurones artificiels : Introduction au connexionnisme’, *Ed. Scribd, San Francisco, USA*, 1992.

Références Bibliographiques

- [49]. Bernard Widrow, 'A Hybrid Approach Based on Fuzzy Logic, Neural Networks and Genetic Algorithms', *Springer, California*, October 10, 2013.
- [50] D. W. Marquardt. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters." *Journal of the Society for Industrial and Applied Mathematics*, Vol. 11, No. 2, 1963.
- [51] G. Cybenko. "Approximation by Superpositions of a Sigmoidal Function." *Mathematics of Control, Signals, and Systems*, Vol. 2, No. 4, 1989.
- [52] Levenberg-Marquardt backpropagation - MATLAB trainlm (mathworks.com).
- [53] Guanrong Chen, Trung Tat, "Introduction to Fuzzy Sets, Fuzzy Logic, and Fuzzy Control Systems". University of Houston, Clear Lake Houston, Texas.
- [54] K. SABER, "Modélisation et commande d'un mini-hélicoptère drone", Master's thesis, Université de SKIKDA, 2013.
- [55] D. ROSS, E. DEGUINE and M. CAMUS, "Asservissement par PID", Université de Lille 1, 2010.
- [56]. T. BRESCIANI, "Modelling Identification and Control of a Quadrotor Helicopter. Lund University", October 2008.
- [57] W. J. Rugh and J. S. Shamma, "Research on gain scheduling," *Automatica*, vol. 36, pp. 1401-1425, 2000.
- [58] D. J. Leith and W. E. Leithead, "Survey of gain-scheduling analysis and design," *International Journal of Control*, vol. 73, no. 11, 1001- 1025.
- [59] L. H. Lee and M. Spillman, "Control of slowly varying LPV systems: an application to flight control," *Proceedings of the Conference on Decision and Control*, San Diego, CA, 1997.
- [60] R. A. Nichols, R. T. Reichert, and W. J. Rugh, "Gain scheduling for H_∞ controllers: a flight control example," *IEEE Transactions on Control System Technology*, vol. 1, no. 2, pp. 69-78, 1993.
- [61] S. J. Qin and G. Borders, "Multi-region fuzzy logic control system with auxiliary variables," *IEEE Transactions on Fuzzy Systems*, vol. 2, no. 1, pp. 74-89, 1994.

Références Bibliographiques

[62] D. J. Leith and W. E. Leithead, "Appropriate realisation of gain scheduled controllers with application to wind turbine regulation," *International Journal of Control*, vol. 65, pp. 223-248, 1996.

[63] T. Dieks and S. Jagannathan, 'Neural networks out feedback of a quadrotor UAV', *Proc Of IEEE*, 47th CDC, pp 3633-3639, Mexi, Dec., 2008.

[64] AUTOPILOT AND GUIDANCE FOR ANTI-TANK IMAGING INFRARED GUIDED MISSILES submitted by ALİ ERDEM ÖZCAN in partial fulfillment of the requirements for the degree of Master of Science in Electrical and Electronics Engineering Department, Middle East Technical University.

[65] Diagnostic et Tolérances aux défauts : application a un drone François BATEMAN 12 Hassan NOURA 3 Mustapha OULADSINE 21 Laboratoire des Sciences de l'Information et des Systèmes Université Paul Cézanne, Aix Marseille III, France, UMR CNRS 61682 Ecole de l'air, Salon de Provence 3 United Arab Emirates University Department of Electrical Engineering P.O. Al-Ain, UAE 19 mars 2008.

[66] Boudiba o, Firsove s, Designing adaptive PID controller non-sensitive to changes in aerodynamic characteristics of an unmanned aerial vehicle, *eastern-European journal of enterprise technologies*.