

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE



ECOLE NATIONALE POLYTECHNIQUE
Laboratoire de Commande des Processus



Mémoire de Magister

Spécialité : Automatique

Option : Automatique des Systèmes Industriels

Présenté par :

SELATNIA Mourad

Ingénieur d'Etat en Automatique de l'ENP

Thème :

**IDENTIFICATION ET COMMANDE PAR RESEAUX DE NEURONES
D'UNE COLONNE D'ABSORPTION**

Présenté devant le jury composé de :

M^r. M. BOUCHERIT
M^r. R. ILLOUL
M^r. A. SELATNIA
M^r. D. BOUKHETALA
M^r. H. CHEKIREB

Professeur, ENP
Maître de conférence, ENP
Professeur, ENP
Professeur, ENP
Professeur, ENP

Président
Rapporteur
Examineur
Examineur
Examineur

Mémoire préparé au Laboratoire de Commande des Processus
10, Avenue Hassen Badi, BP 182, EL-Harrach, Alger, Algérie

Dédicaces

Je dédie ce présent travail

*A ma très chère **Mère***

*A mon chère **Père***

*A ma très chère Femme **Dalila** et mon adorable fils **FADI***

*Ainsi qu'à mes frères **Tahar** , **Karim** et **Ammar***

Et à la mémoire de mes cousines

Remerciements

Le travail présenté dans ce mémoire a été effectué au Laboratoire de Commande des Processus (L.C.P) du département du Génie Electrique de l'Ecole Nationale Polytechnique d'Alger sous la direction de Monsieur **Rachid Illoul**, chargé de cours à l'ENP que je tiens à remercier du fond du cœur pour la proposition du sujet, pour sa contribution dans ce travail, sa disponibilité et pour ses précieux conseils tout au long de ce travail.

Je tiens également à remercier Monsieur **Ammar Selatnia** pour son aide et ses conseils.

J'exprime aussi mes sincères remerciements et mes grâces à tous **les Enseignants** du département du Génie Electrique et particulièrement ceux de l'Automatique pour leur aide et orientation tout au long de ce travail. .

J'adresse également mes vifs remerciements aux membres du jury qui m'ont fait l'honneur d'accepter d'évaluer ce travail.

TABLE DES MATIERES

INTRODUCTION GENERALE.....	1
CHAPITRE 1	
Modélisation et Simulation en boucle ouverte et Reg PI de la colonne d'absorption	
1.1 Introduction.....	5
1.2. Description et Fonctionnement de la colonne d'absorption.....	5
1.3. Transfert de matière avec réaction chimique.....	8
1.3.1. Principe.....	8
1.3.2. Bilan de matière en phase liquide dans le sens transversal.....	9
1.3.3. Expression de C_{AL} et des densités de flux en phase liquide.....	10
I.3.3.1. Cas d'une réaction de pseudo premier ordre.....	10
I.3.3.2. Cas d'une réaction du deuxième ordre.....	14
1.3.4. Expression de Kishinevskii.....	17
1.3.5. Bilan de matière dans le sens longitudinal.....	18
1. 4. Simulation dynamique de la colonne d'absorption.....	23
1.4.1. Equations aux dérivées partielles EDP.....	23
1.4.2. Description de la fonction pdepe.....	23
1.5. Simulation en boucle ouverte de la colonne d'absorption.....	25
1.6 Simulation avec régulateur PI de la colonne d'absorption	30
1.7 Interprétation des résultats	
En boucle ouverte.....	36
En boucle fermée.....	36
1.8. Conclusion.....	37

CHAPITRE 2**Théorie et Apprentissage des Réseaux de Neurones**

2.1. Introduction.....	38
2.2. Le neurone biologique.....	39
2.3 Les réseaux de neurones artificiels.	40
2.3.1. le modèle formel d'un neurones.....	40
2.3.1.a la fonction de seuil.....	42
2. 4 Réseaux de neurones et approximateurs universels.....	43
2.5 L'apprentissage de réseaux de neurones	44
2.5.1.Apprentissage supervisé.....	44
2.5.2.Apprentissage non supervisé.....	44
2.5.1.Surapprentissage.....	45
2.6 Architecture des réseaux de neurones artificiels.....	46
2.6.1.RNA à propagation directe.....	46
2.6.2. les réseaux de neurones bouclés.....	47
2.7 Algorithmes d'apprentissage.....	48
2.7.1. Algorithme de rétropropagation.....	49
2.7.4. Algorithme de Back-propagation avec Momentum.....	55
2.7.6. Méthode d'optimisation du second ordre.....	56
2.7.7. Algorithme de Newton.....	58
2.7.8. Algorithme de Gauss-Newton.....	58
2.7.9. Algorithme de Levenberg-Marquardt.....	58
2.8 Conclusion.....	60

CHAPITRE 3

Identification par Réseaux de Neurones de la colonne d'absorption

3.1. Introduction.....	61
3.2. Les étapes de Modélisation Neuronale.....	62
3.2.1. Acquisition des données.....	62
3.2.2. Période d'échantillonnage.....	62
3.2.3. Validation du modèle neuronale.....	62
3.2.4. Modélisation neuronale.....	63
3.3 Identification Neuronale de la colonne d'absorption.....	63
3.4 Résultats de la Modélisation de la colonne d'absorption.....	64
3.5 Critère de performance.....	69
3.6 Conclusion.....	70

CHAPITRE 4**Stratégies de Commande Neuronale de la colonne d'absorption**

4.1. Introduction.....	71
4.2. Commande par équivalence certaine de la colonne d'absorption.....	72
4.2.1 Description de la commande par équivalence.....	72
4.2.2 Application à la commande de la colonne d'absorption.....	75
4.2.3 Résultat de simulation.....	76
4.3. Commande prédictive neuronale de la colonne d'absorption	81
4.3.1 Principe de la commande prédictive neuronale.....	81
4.3.2 Algorithme pour la commande prédictive neuronale	82
4.3.3 Simulation pour un échelon de perturbation sur la concentration de gaz	84
4.3.4 Simulation avec régulateur PI de fin de course.....	86
4.4. Commande neuronale NARMA de la colonne d'absorption.....	91
4.4.1 Principe de la commande NARMA.....	91
4.4.2. Application de la commande NARMA à la colonne d'absorption	92
4.4.3 Simulation pour un échelon de perturbation sur la concentration de gaz	94
4.4.4 Simulation avec régulateur PI de fin de course.....	96
4.5. Interprétation.....	101
Conclusion Générale.....	103
Bibliographie	105

Nomenclature

A, B	CO ₂ , MEA
R	-CH ₂ -CH ₂ -OH
a	Aire interfaciale par unité de volume du garnissage ($m^2.m^{-3}$)
C_{Ag}, C_{AL}	Concentration du CO ₂ dans la phase gazeuse et dans la phase liquide (mol / m^3)
$C_{BL}(x)$	Concentration du composé B dans la phase liquide (mol / m^3)
C_{ge}, C_{Be}	Concentration du CO ₂ dans la phase gazeuse et de la MEA dans la phase liquide à l'entrée de la colonne ($mol.m^{-3}$).
C_{gs}, C_{Bs}	Concentration du CO ₂ dans la phase gazeuse et de la MEA dans la phase liquide à la sortie de la colonne ($mol.m^{-3}$).
C_{Bli}	Concentration de la MEA dans la phase liquide à l'interface gaz-liquide ($mol.m^{-3}$)
C_{Ali}, C_{Agi}	Concentration du CO ₂ dans la phase liquide et dans la phase gazeuse à l'interface gaz-liquide ($mol.m^{-3}$).
G, L	Débit volumique de la phase gazeuse et liquide ($m^{-3}.s^{-1}$)
U_g, U_l	Vitesse d'écoulement du gaz et du liquide ($m.s^{-1}$)
F_A	Le flux du composé CO ₂ transféré de la phase gazeuse vers la phase liquide ($mol.m^{-3}.s^{-1}$)
N_A	Flux de matière du composé A transféré vers la phase liquide dans le cas du transfert de matière avec réaction chimique ($mol/m^2.s$)
N'_A	Flux sans réaction chimique ($mol/m^2.s$)
k_L	Coefficient de transfert de matière dans la phase liquide (m/s)
k	Constante de vitesse de réaction ($m^3 / mol.s$)
k'	Constante de la réaction de pseudo premier ordre

k_A	Coefficient de transfert de matière du composé A dans la phase liquide, pour le cas de transfert de matière sans réaction chimique (m/s)
k_{AG}	Coefficient de transfert de matière du composé A dans la phase gazeuse (m/s)
k_{AL}	Coefficient de transfert de matière du composé A dans la phase liquide (m/s)
D_{Al}	Coefficient de diffusion du CO_2 dans la phase liquide ($m^2.s^{-1}$)
D_{BL}	Coefficient de diffusion du composé B dans la phase liquide (m^2/s)
r_A	Vitesse de la réaction ($mol/m^3.s$)
δ_L	Épaisseur du film coté liquide (m)
Ha	Nombre adimensionnel appelé nombre de Hatta
J	Nombre adimensionnel
E	Facteur d'accélération
S	Section de la colonne (m^2)
dz	Hauteur d'une tranche de la colonne d'absorption
ζ_L	Rétention liquide
m	Pente de la droite d'équilibre physique entre phases
ν_A	Coefficient stœchiométrique du composé A
ν_B	Coefficient stœchiométrique du composé B
ν_P	Coefficient stœchiométrique du composé P

Introduction Générale

Ces dernières années des mesures indispensables sont prises pour la réduction des consommations d'énergie et le développement des énergies renouvelables [IFP03]. La capture et le stockage géologique du CO₂ s'avère une option incontournable tant que les combustibles fossiles seront exploités.


La possibilité de capturer et de stocker durablement le CO₂ dans des formations géologiques apparaît comme une voie prometteuse sur le moyen et le long terme. Elle comprend quatre principales étapes : la capture, la compression, le transport et le stockage du CO₂ [WEC04].

Les techniques de capture du CO₂ appartiennent à trois catégories générales : la séparation précombustion; l'oxycombustion ; et la séparation postcombustion.

La précombustion : Le principe de la capture en *précombustion* se base sur les quatre étapes suivantes:

La production du gaz de synthèse : le reformage à la vapeur ou oxydation partielle à l'oxygène des hydrocarbures produit un gaz de synthèse composé principalement de CO et de H₂. Cette étape correspond pour le charbon à une gazéification;

La production d'hydrogène : Transformation du CO en CO₂ et de la vapeur en hydrogène par la réaction de conversion de shift :




Capture : le CO₂ est séparé de l'hydrogène;

Combustion : l'hydrogène pur est utilisé comme combustible.

L'oxycombustion : quand un carburant fossile (le charbon, le pétrole et le gaz naturel) est brûlé dans l'air, la fraction du CO₂ dans le gaz produit est de 3-15%, en fonction du contenu en élément carbone du carburant et de la quantité d'air supplémentaire nécessaire pour le procédé de combustion. La séparation de CO₂ du reste des gaz de combustion (surtout du N₂) par des moyens chimiques ou physiques est chère en termes de capital et d'énergie. Une alternative est de brûler le carburant avec de l'oxygène pur ou enrichi, ainsi le gaz de combustion contiendra surtout du CO₂ et de l'eau. Le procédé de séparation ne sera plus le même dans ce cas : on doit séparer l'oxygène et l'azote de l'air. L'air est alors séparé en oxygène liquide, azote gazeux, argon et autres ingrédients mineurs de l'air (ce sont des produits dérivés commerciaux).

La postcombustion : cette technique se base sur l'absorption chimique du CO₂ par un solvant dans une colonne d'absorption où le gaz à traiter et la solution de solvant circulent à contre-courant. C'est le procédé de capture le plus répandu dans le secteur pétrolier lors du traitement des gaz acides (contenant de l'H₂S et/ou du CO₂) et dans l'industrie.

Le principe du processus est le suivant : du gaz chargé de CO₂ circule dans la colonne du bas vers le haut (ascendant). Une solution aqueuse de liquide de lavage circule par gravité sur le garnissage utilisé pour améliorer la surface de contact entre phases. Lors du contact entre phase liquide et gazeuse, le CO₂ passe de la phase gazeuse vers la phase liquide ; cette diffusion est accélérée par réaction chimique du CO₂ avec le liquide de lavage dans la phase liquide. Le liquide de lavage est ainsi considéré comme un absorbant. Ce liquide va se charger en gaz carbonique et nous aurons donc en tête de la colonne le gaz épuré. Le liquide chargé en CO₂ qui sort en bas de la colonne sera chauffé vers 100-120 °C ; la réaction qui avait lieu à basse température :



sera ainsi inversée, on régénérera le solvant qui sera réinjecté dans la colonne et le CO₂ pur se dégageant de la solution sera facilement récupéré.

Une large variété d'alkanolamine est disponible dans l'industrie, les plus connus sont le monoéthanolamine (MEA), le diéthanolamine (DEA), le di-2- propanolamine (DIPA), et le methydiéthanolamine (MDEA). A noter que les amines primaires et secondaires comme le MEA et la DEA sont très réactives et se distinguent par un taux d'absorption de CO₂ très élevé ce qui explique le fait que leur utilisation soit la plus répandue [IDE06] ; dans notre étude nous utiliserons le MEA.

Modélisation des Colonnes d'Absorption

La modélisation des colonnes d'absorption n'est pas un sujet nouveau [BEZ07]. Les modèles de ce type de réacteur sont bien connus et disponibles dans les ouvrages de génie chimique. Son utilisation à des fins de commande est par contre beaucoup moins fréquente compte tenu de la complexité de ce type de modèle et la présence de fortes non-linéarité. En effet, le modèle d'une colonne d'absorption en transitoire est composé d'équations aux dérivées partielles non linéaires. Ce type de modèle est appelé modèle à paramètres répartis car les variables du système ne sont plus seulement fonction du temps mais également de l'espace [HAD06].

Le modèle non linéaire à paramètres répartis d'une colonne d'absorption à l'avantage d'être valide pour tous les points de fonctionnement dans la mesure où l'ensemble des variables opératoires sont incluses dans le modèle. De plus, ce type de modèle permet de tenir compte directement de l'information disponible sur le procédé. En effet, les paramètres hydrodynamiques et la cinétique de réaction apparaissent explicitement dans le modèle.

Peu d'études ont été menées sur la modélisation et la commande des colonnes d'absorptions. Van Der Weg ([VAN76]) a présenté des travaux sur la modélisation en supposant que la concentration en absorbant était suffisamment élevée pour la supposer constante tout le long de la colonne, ce qui n'est pas le cas de notre colonne d'absorption.

Commande des Colonnes d'Absorption

L'analyse des travaux antérieurs montre que beaucoup de développements ont été accomplis dans la commande des colonnes d'absorption. Crosby [CRO76] a étudié la performance d'un contrôleur d'état sur une colonne à garnissage. Roffel [ROF76] a développé un contrôleur de sortie sous optimal avec contrainte inégalité sur l'état. Darwish et Fantin [DAR80] ont utilisé une commande décentralisée avec placement de pôles. Petrovsky [PET80] a développé un régulateur multivariable PI. Najim [NAJ91] a développé un régulateur auto-ajustable dans le cas de l'absorption de CO₂ par une solution de diéthanolamine. Il a ultérieurement repris le problème avec une commande prédictive [NAJ95]. Finalement, Illoul, Selatnia et Boulrouah [ILL02] appliquent une commande prédictive généralisée linéaire ainsi qu'une commande neuro-floue [ILL04] à un premier modèle de colonne d'absorption. Haddouche a appliqué une commande par équivalence certaine neuronale [HAD06] basée sur les réseaux de neurones à la colonne d'absorption pilote et enfin Bezzaoucha [BEZ07] a appliqué une commande basée sur la logique Floue.

Dans la commande des systèmes répartis, plusieurs approches ont été considérées afin de commander ce genre de systèmes. Ray [Ray81] propose de scinder ces approches en deux grandes catégories: les stratégies de pré-approximation et les stratégies de post-approximation. Les approches par pré-approximation utilisent une approximation préalable des équations aux dérivées partielles (EDPs) en équations différentielles ordinaires (EDOs). L'algorithme de commande est donc conçu en utilisant cette approximation. Dans les stratégies de post-approximation la conception de la loi de commande est faite directement à partir du modèle à paramètres répartis.

Les stratégies de pré-approximation se distinguent par le type d'approximation utilisé. En effet, des techniques analytiques ou numériques doivent être utilisées pour permettre la transformation des EDPs en un nombre suffisamment restreint d'EDOs pour que l'approximation du modèle permette la conception de loi de commande. Parmi les techniques numériques, notons la technique de collocation orthogonale [VIL78] qui permet d'obtenir un nombre restreint d'équations. Cette dernière méthode a été appliquée avec succès par Olafadehan [OLA04] pour la résolution d'équations aux dérivées partielles décrivant l'absorption dans une colonne à garnissage.

De point de vue commande, les techniques de commande pour les systèmes non linéaire reposait classiquement sur la théorie de l'automatique linéaire et la linéarisation de la dynamique du système (approximation de premier ordre) autour d'un point de fonctionnement, ce qui permet d'utiliser les outils de la commande linéaire pour la synthèse d'une loi de commande assurant les performances recherchées [SLO91]. Grâce à sa facilité d'implantation et de mise en oeuvre, cette approche a remporté un grand succès auprès des industriels mais l'utilisation de modèles ou de régulateurs linéaires est justifiée et efficace seulement lorsque le procédé reste très près de son point de fonctionnement en toute circonstance [VEN02]. La nécessité d'atteindre de hautes performances dans des domaines ou points de fonctionnement sont relativement larges, a imposé la prise en compte de la dynamique globale non linéaire des processus pour la synthèse de la commande.

Intérêt de l'identification neuronale dans la synthèse d'une loi de commande neuronale d'une colonne d'absorption

La première étape pour l'analyse d'un système afin de le commander, consiste à se doter d'un bon modèle mathématique. Cela signifie que l'on doit disposer d'un modèle réalisant un compromis entre sa fidélité de comportement qualitatif et quantitatif et sa simplicité de mise en oeuvre à des fins d'analyse et de synthèse. Le deuxième terme de ce compromis implique que l'étape de modélisation entraîne obligatoirement des approximations et des simplifications afin de permettre une analyse des propriétés du modèle qui ne soit pas trop complexe et une procédure de synthèse de commande efficace. L'une des formes les plus répondues de représentation des systèmes non linéaires sont les réseaux de neurones qui sont des approximateurs non linéaires universels [HAG96]. L'intérêt d'une structure d'identification se trouve justifié l'obtention d'un modèle neuronal de la colonne d'absorption qui servira plus tard à la synthèse de la loi de commande.

Organisation du mémoire

Les travaux présentés dans cette thèse portent sur l'utilisation des techniques des réseaux de neurones dans un but d'identification et de commande. Nous présenterons les trois stratégies de commande neuronale destinées à piloter la colonne d'absorption tels que la commande par équivalence certaine, la commande prédictive neuronale(Nnpc) et la commande NARMA(Non linéaire Autoregressive Moving Average).

La thèse est organisée en quatre chapitres. Le premier est consacré à la modélisation du comportement dynamique de notre système à partir des principes fondamentaux concernant le transfert de matière et les équations du bilan de matière. Nous présenterons également les résultats de simulation en boucle ouverte.

Nous traitons également dans ce chapitre, la régulation classique avec un contrôleur PI, et ce dans le but de comparer les résultats donnés par une approche classique de commande avec ceux donnés par des approches de commande avancées telle que les réseaux de neurones.

Le deuxième chapitre est consacré à l'étude des réseaux de neurones. Nous exposerons les principales notions relatives aux réseaux de neurones, leurs applications ainsi que les algorithmes d'apprentissage de ces derniers.

Le troisième chapitre est consacré à l'identification par réseaux de neurones de la colonne d'absorption qui constitue une étape importante pour définir une stratégie de commande assurant les performances désirées.

Le quatrième chapitre, traite les différentes stratégies envisagées pour la commande neuronale de la colonne d'absorption et une étude comparative entre l'approche classique (régulation PI) et l'approche avancée offerte par les réseaux de neurones est développée.

Chapitre 1

Modélisation et Simulation de la Colonne d'Absorption

1.1. Introduction

Les colonnes d'absorption du CO₂ par des solutions aqueuses de monoéthanol (MEA) sont largement utilisées comme unités de séparation dans l'industrie chimique. Les principales applications sont l'industrie de fabrication de l'ammoniac et les unités de traitement de gaz naturel. La colonne d'absorption utilisée dans notre étude est une colonne à garnissage..

Dans ce chapitre, nous développerons en premier lieu un modèle mathématique décrivant le fonctionnement en régime dynamique de la colonne d'absorption à garnissage opérant à contre courant [PIN84],[VAN76]. Ce dernier est élaboré à partir des bilans de matière dans chaque phase gazeuse et liquide. On obtient ainsi un système aux paramètres répartis et fortement non linéaire. Puis, nous simulerons le comportement de ce système en boucle ouverte ainsi qu'en boucle fermée avec un régulateur Proportionnel Intégral, et ceci pour différentes valeurs des perturbations possibles ainsi que pour un changement de consigne.

La simulation de notre colonne d'absorption est effectuée à l'aide du logiciel MATLAB 7.5 et plus particulièrement de la routine pdepe qui permet de simuler les équations aux dérivées partielles unidimensionnelles.

1.2. Description et Fonctionnement de la colonne d'absorption Pilote

La colonne d'absorption utilisée dans notre étude est une colonne en garnissage en verre, mesurant 1,26 m de hauteur et 75 mm de diamètre intérieur. La colonne possède deux tronçons superposés dont la hauteur est de 63 cm chacun et dont le but est de recentrer le liquide et de permettre la prise d'échantillons liquides et gazeux, chaque tronçon contient des grains de garnissage. Le choix du garnissage, qui est un élément essentiel, est dicté par la surface de contact offerte entre le gaz et le liquide utilisé, le calcul des pertes de charge et son prix. Les garnissages peuvent être de formes variées (anneaux, selles...), de matériaux différents (céramique, verre, métal...) et être rangés ou disposés en vrac. La colonne fonctionne en circuit ouvert ou fermé. Dans notre étude, le garnissage est disposé en vrac et est du type anneaux de Raschig, de dimension caractéristique de 10mm destiné à améliorer la surface de contact entre phases. La pression et la température de travail sont respectivement de 1,2 bars et de 25°C. L'amplitude des perturbations en composition du CO₂ dans le mélange à traiter est de l'ordre de 10 à 20 %. Cette colonne est utilisée pour réduire la concentration du CO₂ à une valeur désirée [SED04].

La circulation du liquide à travers toute la colonne est assurée à l'aide d'une pompe qui refoule des débits compris entre 5 et environ 260 l/h. Quant à l'échantillonnage, il est assuré grâce au robinet de prélèvement placé en aval de la colonne d'absorption. Les débits des différents fluides sont contrôlés par des débitmètres, qui ont été préalablement étalonnés.

En ce qui concerne l'alimentation de l'installation en CO₂ et en air, le dispositif est équipé d'un compresseur qui assure l'alimentation en air, quant au CO₂, il provient d'une bouteille conçue spécialement pour les usages industriels [SED04].

Cette colonne est utilisée pour réduire la concentration du CO₂ dans le mélange gazeux à une valeur désirée. Le débit en entrée du mélange gazeux est de 11.222 m³/h et sa concentration en entrée est de 5.79 10⁻³ mol/l de CO₂.

Principe de la colonne d'absorption

Dans la colonne d'absorption, du gaz chargé de CO_2 circule du bas vers le haut (ascendant). Une solution aqueuse de liquide de lavage, ici la MEA circule à contre-courant, par gravité sur le garnissage. Lors du contact entre phase liquide et gazeuse sur la surface des anneaux de Raschig, le CO_2 passe de la phase gazeuse vers la phase liquide ; cette diffusion est accélérée par réaction chimique du CO_2 avec la MEA dans la phase liquide. La MEA est ainsi considéré comme un absorbant. Ce liquide va se charger en gaz carbonique et nous aurons donc en tête de la colonne le gaz épuré. Par mesure d'économie, la MEA est régénérée (épurée du CO_2 quelle contient) par élévation de température (110°C) puis recyclée dans le pilote. Le débit de MEA et la concentration du CO_2 dans le mélange gazeux sont respectivement sélectionnés comme variables de commande et de sortie [SED04].



Figure 1.1. Colonne d'absorption

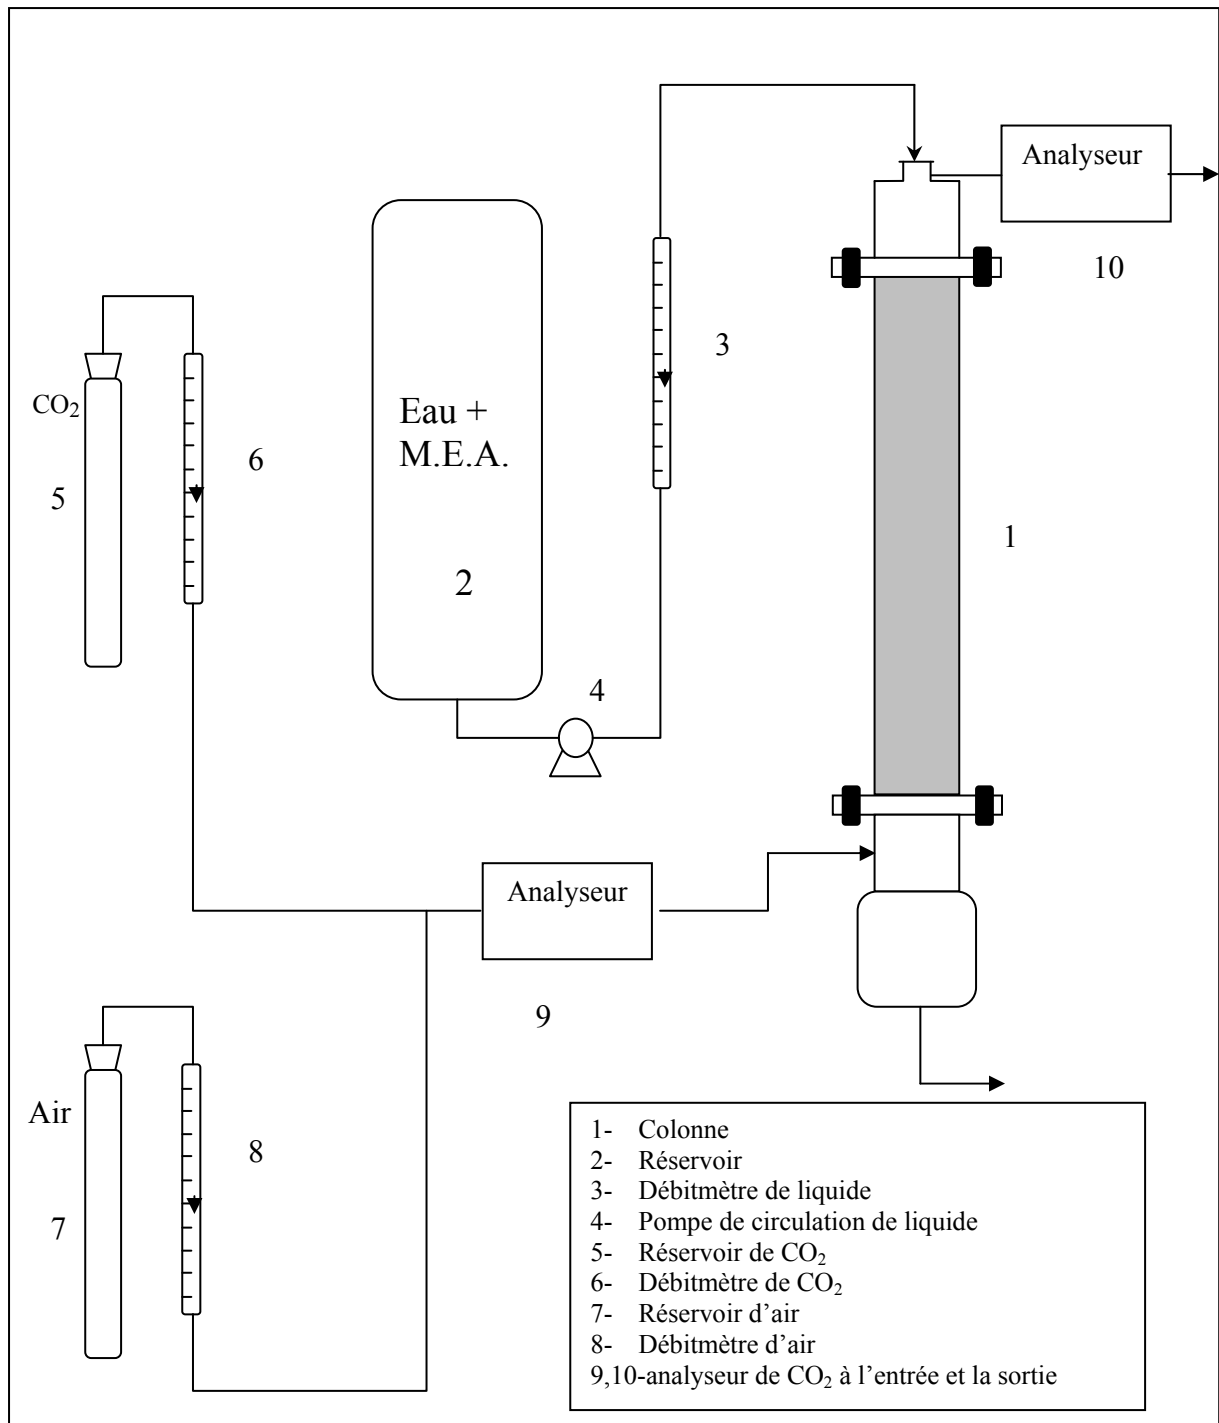


Figure 1.2. Schéma de la colonne d'absorption


1.3. Transfert de matière avec réaction chimique

1.3.1. Principe


L'absorption d'un gaz accompagnée d'une réaction chimique dans la phase liquide permettra d'améliorer l'efficacité de séparation (par exemple l'absorption du CO₂ dans une solution aqueuse de soude. amine ...etc.), et la sélectivité de séparation (par exemple l'absorption du CO₂ et H₂S dans des solutions d'éthanolamine). [SED04]

Une absorption avec réaction chimique va accélérer le transfert du soluté de la phase gazeuse vers la phase liquide.

La réaction envisagée est la suivante :



Au cours de laquelle le soluté (A) réagit avec le réactif (B) en solution pour donner le produit (P) d'après les réactions suivantes :



Cette réaction a un double effet :

- L'augmentation de la capacité d'absorption du liquide puisque le réactif fait disparaître le soluté absorbé et la force motrice du transfert est donc accrue.
- L'accroissement de la vitesse avec laquelle le soluté franchit l'interface pour passer dans le liquide, le coefficient de transfert de matière augmente par conséquent.

Ce dernier effet est pris en compte dans les expressions du flux spécifique d'absorption en multipliant le coefficient de transfert de matière en phase liquide sans réaction chimique par un facteur appelé facteur d'accélération, noté **E**.

Le flux spécifique d'absorption avec réaction chimique s'écrira donc :

$$Fa = N_A \cdot a = E \cdot k_L \cdot a \cdot (C_{ALi} - C_{AL}) \quad (1.1)$$

Avec :

Fa : Le flux volumique d'absorption du composé A ($mol/m^3 \cdot s$)

N_A : Flux surfacique du composé A, pour les cas du transfert de matière avec réaction chimique ($mol/m^2 \cdot s$)

a : Aire interfaciale (m^2 / m^3)

C_{ALi} : Concentration du composé A à l'interface coté liquide (mol / m^3)

C_{AL} : Concentration du composé A dans la phase liquide (mol / m^3)

k_L : Coefficient de transfert de matière dans la phase liquide (m/s)

Comme toute opération de transfert de matière, l'absorption avec réaction chimique peut être décomposée en plusieurs étapes [SED04]:

- Transfert de A de la phase gazeuse vers l'interface gaz/liquide ;
- Transfert de A de l'interface vers la phase liquide ;
- Transfert du réactif B de la phase liquide vers le site réactionnel ;
- Réaction entre A et B ;




Figure 1.3. Profils des concentrations pour le transfert de matière avec réaction chimique dans le sens transversal

1.3.2. Bilan de matière en phase liquide dans le sens transversal

Le bilan de matière pour le composé (A) pour une tranche fine d'épaisseur dx dans le sens transversal, et pour une section unitaire d'aire interfaciale, en appliquant la loi de FICK relative à la diffusion moléculaire dans les milieux quasi-immobile, s'écrit : [ABE02]

$$\begin{array}{l} \text{Flux de A entrant} \\ \text{à l'abscisse } x \end{array} + \begin{array}{l} \text{Quantité de A apparaissant} \\ \text{ou disparaissant par} \\ \text{unité de temps} \end{array} = \begin{array}{l} \text{Flux de A sortant} \\ \text{à l'abscisse } x + dx \end{array}$$

$$-D_{AL} \left[\frac{dC_{AL}(x)}{dx} \right]_{x+dx} + v_A r_A dx = -D_{AL} \left[\frac{dC_{AL}(x)}{dx} \right]_{x} \quad (1.2)$$

v_A : Coefficient stœchiométrique du composé A.

La diffusion du composé A peut être réalisée par convection forcée ou par une différence de concentration. Dans le cas envisagé, il s'agit d'une diffusion par différence de concentration qui obéit à la loi de FICK, exprimant la loi de diffusion dans un milieu immobile et à volume constant.

FICK a établi que le flux de diffusion est proportionnel au gradient de concentration. Cette loi est dérivée de la loi de Fourier sur la conduction de la chaleur.

Le flux est donné par la loi suivante :

$$J = -D.S.\text{grad } C$$

C est la concentration de l'espèce diffusante.

D est le coefficient de diffusion en m^2/s , $D = D_{AL}$.

S section en m^2 .

grad C est le gradient de la concentration, et le signe “-” indique que, physiquement, le flux de diffusion se fait toujours dans le sens contraire du gradient, donc de la zone la plus concentrée en soluté vers celle la moins concentré en soluté.

dx étant très petit, nous avons donc:

$$\frac{\left[\frac{dC_{AL}(x)}{dx} \right]_{x+dx} - \left[\frac{dC_{AL}(x)}{dx} \right]_{x}}{dx} = \frac{d \left[\frac{dC_{AL}(x)}{dx} \right]}{dx} = \frac{d^2 C_{AL}(x)}{dx^2} \quad (1.3)$$

L'égalité (I.2) devient alors :

$$D_{AL} \left[\frac{d^2 C_{AL}(x)}{dx^2} \right] + v_A r_A = 0 \quad (1.4)$$

Avec les conditions aux limites :


$$\begin{cases} x = 0 & ; & C_{AL}(0) = C_{ALi} \\ x = \delta_L & ; & C_{AL}(\delta_L) = C_{AL} \end{cases} \quad (1.5)$$

L'intégration de l'équation (I.4) est plus ou moins complexe suivant la forme de l'équation de vitesse.

1.3.3. Expression de C_{AL} et des densités de flux en phase liquide :

1.3.3.1. Cas d'une réaction de pseudo premier ordre ($C_{BL}(x)$ est constant)

Soit la réaction d'ordre 1 par rapport à chacun des deux réactifs : A et B :



La vitesse de réaction peut s'écrire de la manière suivante : [BOU01]

$$r_A = kC_{AL}(x)C_{BL}(x) = k'C_{AL}(x) \quad (1.6)$$

Avec $k' = kC_{BL}(x)$ en supposant $C_{BL}(x)$ constant

Où :

r_A : Vitesse de la réaction ($mol / m^3.s$)

k : Constante de vitesse de réaction ($m^3 / mol.s$)

k' : Constante de la réaction de pseudo premier ordre ;

$C_{AL}(x)$: Concentration du composé A dans la phase liquide (mol / m^3)

$C_{BL}(x)$: Concentration du composé B dans la phase liquide (mol / m^3)

En considérant que $\mathcal{V}_A = -1$ l'équation (I.4) s'écrira donc comme suit :

$$D_{AL} \left[\frac{d^2 C_{AL}(x)}{dx^2} \right] - k C_{AL}(x) C_{BL}(x) = 0 \quad (1.7)$$

En supposant que D_{AL} ; k et C_{BL} sont constantes en phase liquide, c'est-à-dire :

$$C_{BL}(x) = C_{Be} = \text{constante.}$$

L'équation (I.7) devient :

$$D_{AL} \left[\frac{d^2 C_{AL}(x)}{dx^2} \right] - k C_{AL}(x) C_{BL} = 0 \quad (1.8)$$

Avec les conditions aux limites :

$$\begin{cases} x = 0 & ; & C_{AL}(0) = C_{ALi} \\ x = \delta_L & ; & C_{AL}(\delta_L) = C_{AL} \end{cases} \quad (1.9)$$

La solution générale de l'équation (I.8) s'écrit :

$$C_{AL}(x) = \beta_1 \exp(\alpha x) + \beta_2 \exp(-\alpha x) \quad (1.10)$$

$$\text{Avec } \alpha = \left[\frac{kC_{BL}}{D_{AL}} \right]^{\frac{1}{2}}$$

Les conditions aux limites permettant de calculer les coefficients β_1 et β_2 :

$$\begin{cases} \beta_1 + \beta_2 = C_{ALi} \\ \beta_1 \exp(\alpha \delta_L) + \beta_2 \exp(-\alpha \delta_L) = C_{AL} \end{cases} \quad (1.11)$$

En résolvant ces deux équations et en remplaçant dans l'équation (I.10), la concentration $C_{AL}(x)$ en phase liquide aura pour expression :

$$C_{AL}(x) = \frac{C_{AL} \operatorname{sh}(\alpha x) + C_{ALi} \operatorname{sh}(\alpha(\delta_L - x))}{\operatorname{sh}(\alpha \delta_L)} \quad (1.12)$$

Et le gradient de $C_{AL}(x)$ s'exprime alors par :

$$\frac{dC_{AL}(x)}{dx} = \frac{\alpha C_{AL} \operatorname{ch}(\alpha x) - \alpha C_{ALi} \operatorname{ch}(\alpha(\delta_L - x))}{\operatorname{sh}(\alpha \delta_L)} \quad (1.13)$$

On en déduit le flux traversant l'interface :

$$[N_A]_{x=0} = -D_{AL} \left[\frac{dC_{AL}(x)}{dx} \right]_{x=0} = \frac{D_{AL} \alpha \delta_L \operatorname{ch}(\alpha \delta_L)}{\delta_L \operatorname{sh}(\alpha \delta_L)} \left\{ C_{ALi} - \frac{C_{AL}}{\operatorname{ch}(\alpha \delta_L)} \right\} \quad (1.14)$$

On peut également exprimer le flux à l'autre extrémité du film, pour $x = \delta_L$:

$$[N_A]_{x=\delta_L} = -D_{AL} \left[\frac{dC_{AL}(x)}{dx} \right]_{x=\delta_L} = k_A \frac{\alpha \delta_L}{\operatorname{th}(\alpha \delta_L)} \left\{ \frac{C_{ALi}}{\operatorname{ch}(\alpha \delta_L)} - C_{AL} \right\} \quad (1.15)$$

$$\text{Avec } k_A = \frac{D_{AL}}{\delta_L}$$

Le terme $(\alpha \delta_L)$ représente un nombre adimensionnel, appelé nombre de HATTA (Ha), qui est défini par la formule suivante :

$$\alpha \delta_L = Ha = \frac{\sqrt{k C_{BL} D_{AL}}}{k_A} \quad (1.16)$$

Avec :

D_{AL} : Coefficient de diffusion du composé A dans la phase liquide (m^2 / s)

δ_L : Epaisseur du film coté liquide (m)

k_A : Coefficient de transfert de matière du composé A dans la phase liquide, pour le cas de transfert de matière sans réaction chimique (m / s)

On peut alors exprimer la vitesse d'absorption de A, par unité de temps et par unité d'aire interfaciale, en présence de réaction chimique en fonction du nombre de HATTA :

$$[N_A]_{x=0} = k_A \frac{Ha}{th(Ha)} \left\{ C_{ALi} - \frac{C_{AL}}{ch(Ha)} \right\} \quad (1.17)$$

On sait que le flux sans réaction chimique a pour formule :

$$[N'_A]_{x=0} = k_A (C_{ALi} - C_{AL}) \quad (1.18)$$

Considérons la grandeur E comme étant le rapport des flux avec et sans réaction chimique, c'est à dire :

$$E = \frac{[N_A]_{x=0}}{[N'_A]_{x=0}} = \frac{Ha}{th(Ha)} \frac{1 - \frac{\lambda}{ch(Ha)}}{1 - \lambda} \quad (1.19)$$

$$\text{Avec } \lambda = \frac{C_{AL}}{C_{ALi}}, \quad \lambda \text{ très petit}$$

A partir de cette relation, on peut dire que si $Ha \geq 0.3$ alors $E \neq 1$.

Pour examiner la valeur du flux de A à $x = \delta_L$, puis rapporter sa valeur à celle du flux à $x=0$, on fait le rapport suivant :

$$J = \frac{[N_A]_{x=\delta_L}}{[N_A]_{x=0}} = \frac{1 - \lambda ch(Ha)}{ch(Ha) - \lambda} \quad (1.20)$$

Suivant les valeurs du nombre de HATTA, en utilisant les rapports E et J , trois cas se rencontrent :

1. $Ha < 0.3 \rightarrow$ Réaction lente :

$ch(Ha)$ et J tendent vers 1, il n'y a pratiquement pas de réaction dans le film, celle-ci se déroule essentiellement au cœur de la phase liquide. Dans ce cas :

$$[N_A]_{x=0} \approx [N'_A]_{x=0} = k_A (C_{ALi} - C_{AL}) \quad (1.21)$$

C'est-à-dire : $E \approx 1$.

2. $0.3 < Ha < 5 \rightarrow$ cas intermédiaire : on utilise l'expression (I.19).

3. $Ha > 5 \rightarrow$ réaction rapide :

La valeur de $\lambda = C_{AL} / C_{ALi}$ sera faible et tend vers zéro car C_{AL} tend vers zéro, la réaction se passera quasi entièrement dans le film liquide. Dans ce cas :

$$J = \frac{1}{ch(Ha)} \quad \text{et} \quad E \approx Ha \quad (1.22)$$

Le flux d'absorption par unité d'aire interfaciale pourra être calculé avec la formule suivante :

$$[N_A]_{x=0} \approx C_{ALi} \cdot k_A \cdot Ha = C_{ALi} \sqrt{k C_{BL} D_{AL}} \quad (1.23)$$

1.3.3.2. Cas d'une réaction du deuxième ordre

Les relations précédentes ont pu être établies en considérant que $C_{BL}(x)$ était constante dans le film, c'est-à-dire que : $C_{BL}(x) \approx C_{BL}$ et donc : $\frac{dC_{BL}(x)}{dx} = 0$ (1.24)

Nous devons envisager le cas où cette hypothèse n'est pas vérifiée. Dans ce cas, il n'est pas possible d'obtenir une expression analytique pour $[N'_A]_{x=0}$. On peut toutefois obtenir une solution numérique [SED04].

L'expression (I.4) s'écrit pour les composés A et B de la manière suivante :

$$D_{AL} \left[\frac{d^2 C_{AL}(x)}{dx^2} \right] + \nu_A k C_{AL}(x) C_{BL}(x) = 0 \quad (1.25.a)$$

$$D_{BL} \left[\frac{d^2 C_{BL}(x)}{dx^2} \right] + \nu_B k C_{AL}(x) C_{BL}(x) = 0 \quad (1.25.b)$$

On utilise les conditions aux limites suivantes pour les intégrations :

$$x = 0 \quad C_{AL} = C_{ALi} \quad \frac{dC_{BL}(x)}{dx} = 0 \quad (1.26)$$

$$x = \delta \quad C_{AL}(\delta) = C_{AL} \quad C_{BL}(\delta) = C_{BL} \quad (1.27)$$

Remarque

La relation (I.26) résulte du non transfert du composé considéré vers la phase gazeuse, c'est-à-dire il n'y a pas désorption du CO_2 .

En combinant les équations (I.25.a) et (I.25.b) on obtient :

$$\frac{d^2 C_{BL}(x)}{dx^2} = \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \frac{d^2 C_{AL}(x)}{dx^2} \quad (1.28)$$

En intégrant deux fois et en utilisant les conditions aux limites, on obtient :

$$\frac{d C_{BL}(x)}{dx} = \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \frac{d C_{AL}(x)}{dx} + C1 \quad (1.29)$$

$$\text{pour } x=0, \frac{d C_{BL}(x)}{dx} = 0, \text{ alors : } \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \frac{d C_{AL}(x)}{dx} \Big|_{x=0} + C1 = 0 \Rightarrow$$

$$C1 = - \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \frac{d C_{AL}(x)}{dx} \Big|_{x=0} \quad (1.30)$$

$$\frac{d C_{BL}(x)}{dx} = \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \left(\frac{d C_{AL}(x)}{dx} - \frac{d C_{AL}(x)}{dx} \Big|_{x=0} \right) \quad (1.31)$$

$$\Rightarrow C_{BL}(x) = \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \left(C_{AL}(x) - x \frac{d C_{AL}(x)}{dx} \Big|_{x=0} \right) + C2 \quad (1.32)$$

Avec: $C_{BL}(\delta) = C_{BL}$, donc :

$$\begin{aligned} \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \left(C_{AL}(\delta) - \delta \frac{d C_{AL}(x)}{dx} \Big|_{x=0} \right) + C2 &= C_{BL} \Rightarrow \\ C2 &= C_{BL} - \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \left(C_{AL}(\delta) - \delta \frac{d C_{AL}(x)}{dx} \Big|_{x=0} \right) \end{aligned} \quad (1.33)$$

Donc :

$$\begin{aligned} C_{BL}(x) &= C_{BL} + \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \left[(\delta - x) \frac{d C_{AL}(x)}{dx} \Big|_{x=0} - C_{AL}(\delta) + C_{AL}(x) \right] \Rightarrow \\ C_{BL}(x) &= C_{BL} \left\{ 1 + \frac{\nu_B}{\nu_A} \frac{D_{AL}}{D_{BL}} \frac{C_{AL}(x) - C_{AL}(\delta)}{C_{BL}} \left(1 + \frac{(\delta - x) \frac{d C_{AL}(x)}{dx} \Big|_{x=0}}{C_{AL}(x) - C_{AL}(\delta)} \right) \right\} \end{aligned} \quad (1.34)$$

$$\text{Mais : } [N'_1]_{x=0} = \frac{D_{AL}}{\delta} (C_{ALi} - C_{AL})$$

$$[N_1]_{x=0} = -D_{AL} \left[\frac{dC_{AL}(x)}{dx} \right]_{x=0}$$

Et donc :

$$E = \frac{[N_1]_{x=0}}{[N'_1]_{x=0}} = - \left(\frac{dC_{AL}(x)}{dx} \right)_{x=0} \cdot \frac{\delta}{C_{ALi} - C_{AL}} \quad (1.35)$$

L'expression (1.34), s'écrit pour $x=0$ à l'interface et en utilisant (1.35) :

$$C_{BLi} = C_{BL} \left\{ 1 + \frac{v_B}{v_A} \frac{D_{AL}}{D_{BL}} \frac{C_{ALi}}{C_{BL}} (1 - \lambda)(1 - E) \right\} \quad (1.36.a)$$

En introduisant l'expression :

$$N_2 = \frac{1}{2} \frac{D_{BL}}{D_{AL}} \frac{C_{BL}}{C_{ALi}}$$

$$C_{BLi} = C_{BL} \left\{ 1 + \frac{(1 - \lambda)(1 - E)}{N_2} \right\} \quad (1.36.b)$$

Pour pouvoir exprimer $[N_1]_{x=0}$ il faut disposer du terme $\left[\frac{dC_{AL}(x)}{dx} \right]_{x=0}$, on peut y parvenir en écrivant que le flux interfaciale répondant à l'équation (I.7) avec $C_{BL}(x) = C_{BLi}$ pratiquement constant près de l'interface, car : $\left(\frac{dC_{BL}(x)}{dx} \right)_{x=0} = 0$ (d'après 1.26)

Donc on peut écrire :

$$D_{AL} \left(\frac{d^2 C_{AL}(x)}{dx^2} \right) = -v_A k C_{BLi} C_{AL}(x) \quad \text{pour } x \text{ voi sin de } 0 \quad (1.37)$$

On remarque que cette expression est très similaire à (1.8) où l'on a remplacé C_{BL} par C_{BLi} .

Avec les mêmes conditions aux limites que celles sur $C_{AL}(x)$ données dans (I.9) et de manière similaire, on obtient alors :

$$[N_1]_{x=0} = k_A \frac{\frac{\sqrt{-v_A k C_{BLi} D_{AL}}}{k_A}}{\text{th} \left(\frac{\sqrt{-v_A k C_{BLi} D_{AL}}}{k_A} \right)} \left[C_{ALi} - \frac{C_{AL}}{\text{ch} \left(\frac{\sqrt{-v_A k C_{BLi} D_{AL}}}{k_A} \right)} \right] \quad (1.38)$$

On remarque que cette équation est identique à la relation (1.17) à la différence que C_{BL} a été remplacé par C_{BLi} .

Le facteur d'accélération peut donc s'écrire en utilisant (1.16) et (1.36.b) :

$$E = \frac{[N_1]_{x=0}}{[N'_1]_{x=0}} = \frac{Ha \sqrt{1 - \frac{(E-1)(1-\lambda)}{N_2}}}{th \left[Ha \sqrt{1 - \frac{(E-1)(1-\lambda)}{N_2}} \right]} \frac{1 - \frac{\lambda}{ch \left[Ha \sqrt{1 - \frac{(E-1)(1-\lambda)}{N_2}} \right]}}{1 - \lambda} \quad (1.39)$$

1.3.4. Expression de Kishinevskii [KIS79]

Afin de résoudre l'équation (1.38), et pouvoir calculer le flux local F_A du composé A transféré de la phase gazeuse vers la phase liquide, nous avons une expression fournie par Kishinevskii qui est de la forme suivante :

$$E = 1 + \frac{Ha}{A} [1 - \exp(-0.65 Ha \sqrt{A})] \quad (1.40)$$

Avec :

$$A = \frac{Ha}{N_2} + \exp\left(\frac{0.68}{Ha} - \frac{0.45}{N_2} Ha\right) \quad (1.41)$$

L'algorithme qui permet d'obtenir E de manière itérative est le suivant [SED04] :

- Nous commençons par calculer le nombre de Hatta (Ha) :

$$Ha = \frac{\sqrt{k C_{BL} D_{AL}}}{k_{AL}} \quad (1.42)$$

- Puis, nous estimons une valeur de E en posant $E(1) = Ha$ et nous calculons ainsi C_{ALi} et N_2 :

$$C_{ALi} = \frac{K_{Ag} C_{Ag}}{E(i) K_{Al} + m K_{Ag}} \quad (1.43.a)$$

$$N_2 = \frac{1}{2} \frac{D_{Bl}}{D_{Al}} \frac{C_{Bl}}{C_{Ali}} \quad (1.43.b)$$

- Nous estimons E (i+1) à partir de (1.40) et (1.41) :

Si la valeur de $E(i+1)$ est différente de $E(i)$, nous poursuivons le calcul itératif jusqu'à ce que $E(i+1) \approx E(i)$. La valeur de $E(n)$ est alors prise comme valeur de E .

Le flux N_A transféré de la phase gazeuse vers la phase liquide est donné par :

$$N_A = E_{(final)} K_{Al} C_{Ali(final)} \quad (1.44)$$

Le flux est calculé à partir de :

$$F_A = a E_{(final)} K_{Al} C_{Ali(final)} \quad (1.45)$$

L'Aire inter faciale a est calculée d'après la formule de Onda et Col :

$$a = 469,1[1 - \exp(-3,3.U_L^{0,4})] \quad (1.46)$$

1.3.5. Bilan de matière dans le sens longitudinal

Dans le but d'alléger la structure du modèle et simplifier le traitement numérique, nous avons adopté les hypothèses suivantes [SEL02] :

- Il n'y a pas de résistance en phase gazeuse,
- Toutes les propriétés physiques du gaz et du liquide sont constantes le long de la colonne et au cours du temps,
- Le processus est isotherme.
- Réaction rapide entre le CO_2 et la MEA ($Ha > 5$).
- La dispersion axiale est négligeable dans la phase gazeuse et dans la phase liquide.

Dans ces conditions, les équations du modèle se réduisent à l'écriture des bilans de matière partiels dans chaque phase, auxquelles s'ajoutent les relations traduisant les conditions aux limites et d'équilibre.

Puisque, nous nous intéressons à l'évolution de la concentration du CO_2 et de la MEA le long de la colonne d'absorption, nous avons effectué le bilan de matière sur le CO_2 dans la phase gazeuse et dans la phase liquide sur un élément (dz) et le bilan de matière sur la MEA en phase liquide (figure 1.4).

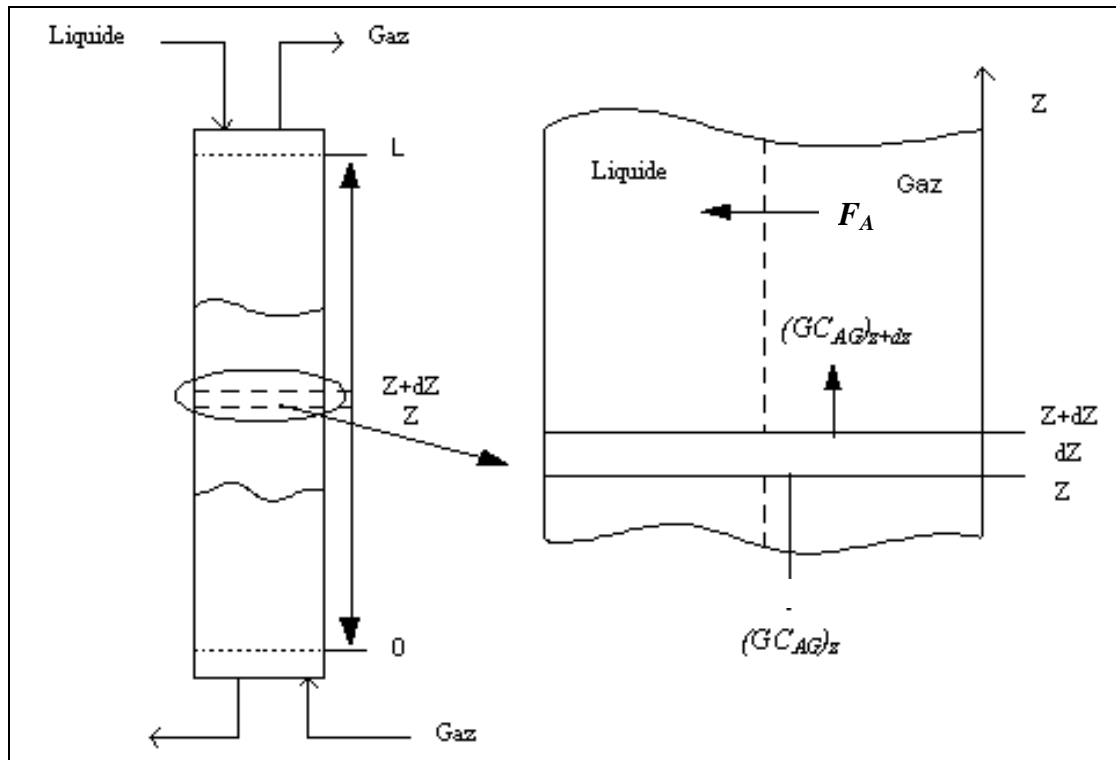


Figure 1.4. Bilan de matière sur une tranche élémentaire (dz) dans le sens longitudinal

- Le bilan de matière pour le CO_2 dans la phase gazeuse pour une tranche élémentaire de hauteur dz et de largeur $(z+dz)$ s'écrit [SED04] :

Quantité de soluté à l'entrée (z) = quantité de soluté à la sortie ($z+dz$) + quantité de soluté transféré de la phase liquide à la phase gazeuse + accumulation

Ce qui donne:

$$(GC_{Ag})_z = (GC_{Ag})_{z+dz} + F_a S dz + S \frac{dC_{Ag}}{dt} dz \quad (1.47)$$

Or :

$$(GC_{Ag})_{z+dz} = (GC_{Ag})_z + \frac{d}{dz} (GC_{Ag}) dz \quad (1.48)$$

En remplaçant dans (I.47), on obtient :

$$U_g \frac{dC_{Ag}}{dz} + F_A = - \frac{dC_{Ag}}{dt} \quad (1.49)$$

$U_g = G/S$ (m/s) étant la vitesse moyenne d'écoulement. On suppose que G est constant tout le long de la colonne d'absorption.

- Dans la phase liquide, le CO₂ réagit avec le monoéthanolamine (MEA) suivant la formule : [TON92], [PIN93]



La vitesse r_A de cette réaction (mol/m³.s) a la forme suivante: $r_A = k C_{Al}C_{Bl}$

$$\text{Avec : } \text{Log}_{10} k = 10,99 - \frac{2152}{T} \quad (1.51)$$

T : Température (K)

k : Constante de la vitesse de la réaction (l/mol.s)

En tenant compte de l'expression de r_A , le bilan de matière pour le CO₂ dans la phase liquide donne:

Quantité de soluté à l'entrée (z) = quantité de soluté à la sortie (z+dz) + quantité de soluté transféré de la phase gazeuse à la phase liquide + quantité de soluté apparaissant ou disparaissant par unité de temps+ accumulation

$$(LC_{Al})_z = (LC_{Al})_{z+dz} + F_A S dz - [k C_{Al} C_{Bl}] S dz + S \frac{dC_{Al}}{dt} dz \quad (1.52)$$

$$\text{Or: } (LC_{Al})_{z+dz} = (LC_{Al})_z + \frac{d}{dz} (LC_{Al})_z \quad (1.53)$$

$$\frac{d}{dz} (LC_{Al})_z + F_A \cdot S \cdot dz - (k \cdot C_{Al} \cdot C_{Bl}) \cdot S \cdot dz + S \frac{dC_{Al}}{dt} dz = 0 \quad (1.54)$$

D'où:

$$U_l \frac{dC_{Al}}{dz} + F_A - [k C_{Al} C_{Bl}] + \frac{dC_{Al}}{dt} = 0 \quad (1.55)$$

$U_l = L/S$ (m/s) étant la vitesse moyenne d'écoulement du flux liquide.

D'une manière générale, la réaction entre le CO₂ et le MEA est considérée comme une réaction rapide (nombre de Hatta > 5) [TRA84], ce qui implique qu'il n'y a pas d'accumulation du CO₂ dans la phase liquide et pas de variation en fonction du temps, on peut donc écrire :

$$\begin{cases} \frac{dC_{Al}}{dz} = 0 \\ \frac{dC_{Al}}{dt} = 0 \end{cases} \Rightarrow F_A = [k C_{Al} C_{Bl}] \quad (1.56)$$

Ce qui veut dire que le CO₂ transférée dans la phase liquide réagit totalement avec la MEA.

- Le bilan de matière sur la MEA dans la phase liquide, en tenant compte du coefficient stoechiométrique de la réaction (1.50) et du fait que la MEA ne peut pas passer dans la phase gazeuse, donne :

$$(LC_{Bl})_z = (LC_{Bl})_{z+dz} - 2[k C_{Al} C_{Bl}] S dz - S \frac{dC_{Bl}}{dt} dz \quad (1.57)$$

$$(LC_{Bl})_{z+dz} = (LC_{Bl})_z + \frac{d}{dz}(LC_{Bl})_z \quad (1.58)$$

$$\frac{d}{dz}(LC_{Bl})_z - 2(k C_{Al} C_{Bl}) S dz - S \frac{dC_{Bl}}{dt} dz = 0 \quad (1.59)$$

D' où:

$$U_l \frac{dC_{Bl}}{dz} - 2 [k C_{Al} C_{Bl}] = \frac{dC_{Bl}}{dt} \quad (1.60)$$

En tenant compte de (1.56), on obtient :

$$U_l \frac{dC_{Bl}}{dz} - 2 F_A = \frac{dC_{Bl}}{dt} \quad (1.61)$$

Les bilans de matière sur le CO₂ et la MEA dans les phases liquide et gazeuse se réduisent aux équations suivantes :

- Bilan sur le CO₂ dans la phase gazeuse :

$$U_g \frac{dC_{Ag}}{dz} + F_A = - \frac{dC_{Ag}}{dt} \quad (1.62)$$

- Bilan de la MEA dans la phase liquide :

$$U_l \frac{dC_{Bl}}{dz} - 2 F_A = \frac{dC_{Bl}}{dt} \quad (1.63)$$

- Expression de F_A :

$$F_A = [Na] a \quad (1.64)$$

$$[Na] = E.[N'a] = E.k_{AL}.(C_{Al} - C_{Al}) \quad \text{avec : } C_{Al} \approx 0 \quad (\text{réaction rapide}) \quad (1.65)$$

Donc :

$$F_A = a E K_{Al} C_{Ali} \quad (1.66)$$

En admettant que l'équilibre est établi à l'interface gaz - liquide et pour des faibles concentrations du CO₂, nous pouvons écrire :

$$C_{Agi} = m. C_{Ali} \quad (1.67)$$

$$[N_A] = k_{AG} (C_{Ag} - m.C_{Ali}) = E.k_{Al}.C_{Ali} \quad (1.68)$$

$$D' où: C_{Ali} = \frac{K_{Ag} C_{Ag}}{E K_{Al} + m K_{Ag}} \quad (1.69)$$

Il faut finalement tenir compte des conditions aux limites qui sont pour le gaz la concentration du CO₂ en bas de la colonne ou concentration d'entrée C_{Age} et pour le liquide la concentration de la MEA en haut de la colonne ou concentration d'entrée C_{Ble}.

Notre colonne d'absorption est finalement décrite par le système d'équations aux dérivées partielles suivantes:

$$\begin{cases} U_g \frac{dC_{Ag}}{dz} + F_A = -\frac{dC_{Ag}}{dt} \\ U_l \frac{dC_{Bl}}{dz} - 2 F_A = \frac{dC_{Bl}}{dt} \end{cases} \quad (1.70.a)$$

F_A étant donné par (I.66),

Avec les conditions aux limites suivantes:

$$\begin{cases} C_{Ag}|_{z=0} = C_{Age} \\ C_{Bl}|_{z=h} = C_{Ble} \end{cases} \quad (1.70.b)$$

Les valeurs des différents paramètres utilisés lors de la simulation sont données dans le tableau suivant :

$S = 0,0044 \text{ m}^2$
$m = 1,18$
$\log_{10}(k) = 10,99 - 2152/T$
$k = 5,9 \text{ m}^3 \cdot \text{mol}^{-1} \cdot \text{s}^{-1}$
$D_{Al} = 1,51 \cdot 10^{-9} \text{ m}^2 \cdot \text{s}^{-1}$
$D_{Bl} = 1,1 \cdot 10^{-9} \text{ m}^2 \cdot \text{s}^{-1}$
$K_{Ag} = 5,81 \cdot 10^{-2} \cdot (U_G)^{0.7}$
$K_{Al} = 2 \cdot 10^{-2} \cdot (U_L)^{0.67}$
$a = 469,1 [1 - \exp(-3,3 \cdot U_L^{0.4})]$

Tableau 1.1. Paramètres du modèle pour T=25°C

1. 4. Simulation dynamique de la colonne d'absorption

1.4.1. Equations aux dérivées partielles EDP

Les équations aux dérivées partielles sont utilisées dans les modèles mathématiques de nombreux phénomènes physiques, là où il y a propagation de grandeurs physiques, comme par exemple, le transfert de la chaleur, la dynamique des fluides, la propagation des ondes, etc. [RAP01]. Ce type de modèle mathématique relie certaines variables et leurs dérivées à d'autres variables représentant l'espace et/ou le temps :

Dans les systèmes à paramètres localisés, les variables dépendent uniquement du temps, on considère donc que tous les paramètres peuvent être ramenés en un point, par exemple, quand on étudie la température d'un fluide dans un récipient, cette dernière est supposée être uniforme dans tout le récipient à un instant donné. On peut étudier le changement de la température comme une fonction du temps basé sur le débit du fluide. Le modèle simplifié dépend ainsi seulement d'une variable, le temps et des dérivées du temps. Les équations du modèle sont des équations différentielles ordinaires. [RAP01]

Dans les systèmes à paramètres répartis, les variables dépendent non seulement du temps mais aussi de leur position dans l'espace, ces systèmes sont décrits par des jeux d'équations aux dérivées partielles. Pour le même exemple que précédemment, on peut considérer cette fois-ci que la température varie selon la position dans le récipient, et sera donc fonction des coordonnées d'espace et de temps. Les dérivées qui occurrent dans ces types de modèles sont des dérivées partielles par rapport aux variables spatiales et temporelles. [BEZ07]

Les équations différentielles qui font appel à des dérivées partielles sont donc appelées les équations aux dérivées partielles (Partial Differential Equations). Si une dépendance par rapport au temps est présente, les modèles sont appelés modèles dynamiques, sinon ce sont des modèles stationnaires. [RAP01]

L'ordre d'une équation différentielle est défini comme étant le plus grand ordre de différentiation présent dans cette équation. En général, l'ordre le plus utilisé dans les modèles est le deuxième ordre. Le domaine de définition i.e. la région géométrique dans laquelle l'EDP est définie, est dans la plus part des cas une région fermée dans l'espace définie par des variables indépendantes [RAP01]. Les conditions aux limites dans un problème d'EDP spécifient le comportement du modèle aux limites du domaine et contiennent souvent des dérivées du premier ordre.

1.4.2. Description de la fonction pdepe de MATLAB

La fonction pdepe résout les EDPs dynamiques de type elliptique et parabolique dans un espace unidimensionnel, la variable dépendante U peut être aussi bien scalaire que vectorielle.

La discrétisation de l'espace permet d'obtenir des EDO ordinaires à partir des équations aux dérivées partielles initiales. Le maillage d'espace correspondant sur $[a, b]$ sera défini par le vecteur xmesh avec xmesh(1)=a et xmesh(m)=b.

La résolution des EDOs résultant de la discrétisation de l'espace sera effectuée sur l'intervalle de temps $[t_0, t_f]$ avec également un maillage de temps donné par le vecteur tspan, avec tspan(1)= t_0 et tspan(n)= t_f .

La forme générale des équations pdepe est : [MAT 7.5]

$$C(x, t, u, \frac{\partial u}{\partial x}) \frac{\partial u}{\partial t} = x^{-m} \frac{\partial}{\partial x} (x^m f(x, t, u, \frac{\partial u}{\partial x})) + s(x, t, u, \frac{\partial u}{\partial x}) \quad (1.71)$$

Pour $t=t_0$ et tout x , les composants de la solution satisfont la condition initiale de la forme :

$$U(x, t_0) = u_0(x) \quad (1.72)$$

Sur les limites de l'intervalle $[a, b]$ ($x=a$ ou $x=b$), et pour tout t , les conditions aux limites sont de la forme :

$$p(x, t, u) + q(x, t) f(x, t, u, \frac{\partial u}{\partial x}) = 0 \quad (1.73)$$

A noter que des deux coefficients p et q , il n'y a que p qui dépend de u .

Dans l'appel de : sol=pdepe(m,pdefun,icfun,bcfun,xmesh,tspan) :

- m correspond aux coordonnées cartésiennes ($m=0$), cylindriques ($m=1$) ou sphériques ($m=2$).
- xmesh définit le maillage dans l'espace
- tspan définit le maillage dans le temps
- l'équation aux dérivées partielles en elle-même est définie par les trois fonctions c , f , et s de l'équation (I.71) calculées par la fonction pdefun. Elle est sous la forme :

$$[c, f, s] = pdefun(x, t, u, dudx) \quad (1.74)$$

La condition initiale est calculée par la fonction *icfun*, qui est sous la forme :

$$U=icfun(x) \quad (1.75)$$

Les conditions aux limites sont données par *bcfun*, elles sont sous la forme :

$$[pl,ql,pr,qr]=bcfun(xl,ul,xr,ur,t) \quad (1.76)$$

On a pour *p* et *q* de l'équation (1.73) deux paires de vecteurs colonnes, *pl* et *ql* évalués sur la limite gauche $x_l=a$, même chose pour *pr* et *qr* sur la limite droite $x_r=b$.

ul est la solution approchée en $x_l=a$ et *ur* est la solution approchée en $x_r=b$.

Pdepe retourne la solution comme un tableau multidimensionnel *sol*. [MAT 7.5]

$U_i = \text{sol}(j, k, i)$ est une approximation de la $i^{\text{ème}}$ composante du vecteur solution *u*.

où *j* est l'indice correspondant au temps et *k* à l'espace.

L'élément $u_i(j,k) = \text{sol}(j,k,i)$ correspond à u_i évalué à $t = \text{tspan}(j)$ et $x = \text{xmesh}(k)$

$U_i = \text{sol}(j, :, i)$ approche le composant *i* de la solution à l'instant $\text{tspan}(j)$ et pour tous les points du maillage de l'espace .

$U_i = \text{sol}(:, k, i)$ approche le composant *i* de la solution pour la position $x = \text{xmesh}(k)$ pour tous les points du maillage de temps .

1.5. Simulation en boucle ouverte de la colonne d'absorption :

Les résultats en régime dynamique sont présentés dans les figures ci-dessous. Les paramètres de notre simulation en boucle ouverte sont les suivant :

La température de fonctionnement est de 25°C

La concentration de CO₂ en entrée est de 5.79 mole/m³.

La valeur obtenue en régime permanent au bout de 10 secondes : 3.996 mole/m³.

Débit de gaz nominal : 1.9255 l/s

Débit de liquide nominal : 0.0213 l/s

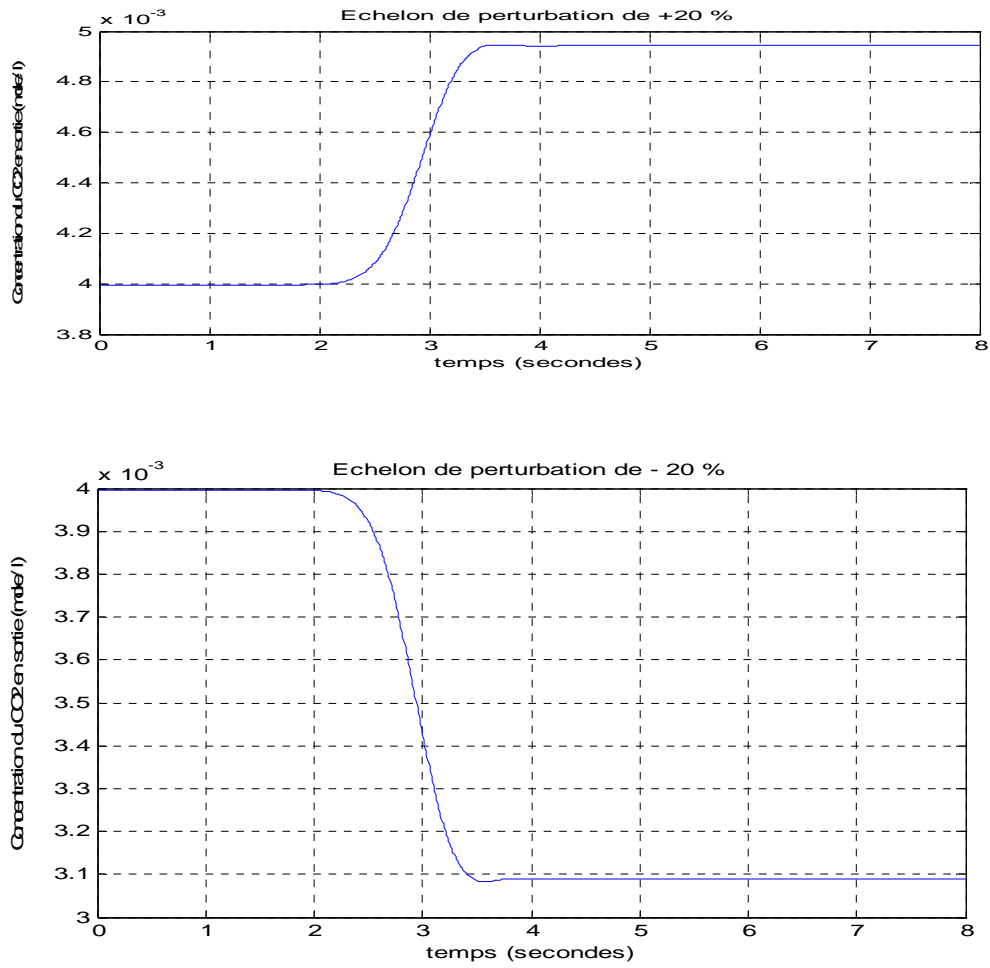


Figure 1.5. Concentration du CO₂ en sortie pour un échelon de perturbation de +/- 20 % sur la concentration de gaz en entrée




Figure 1.6. Echelon de perturbation de + 15 % sur C_{Be}

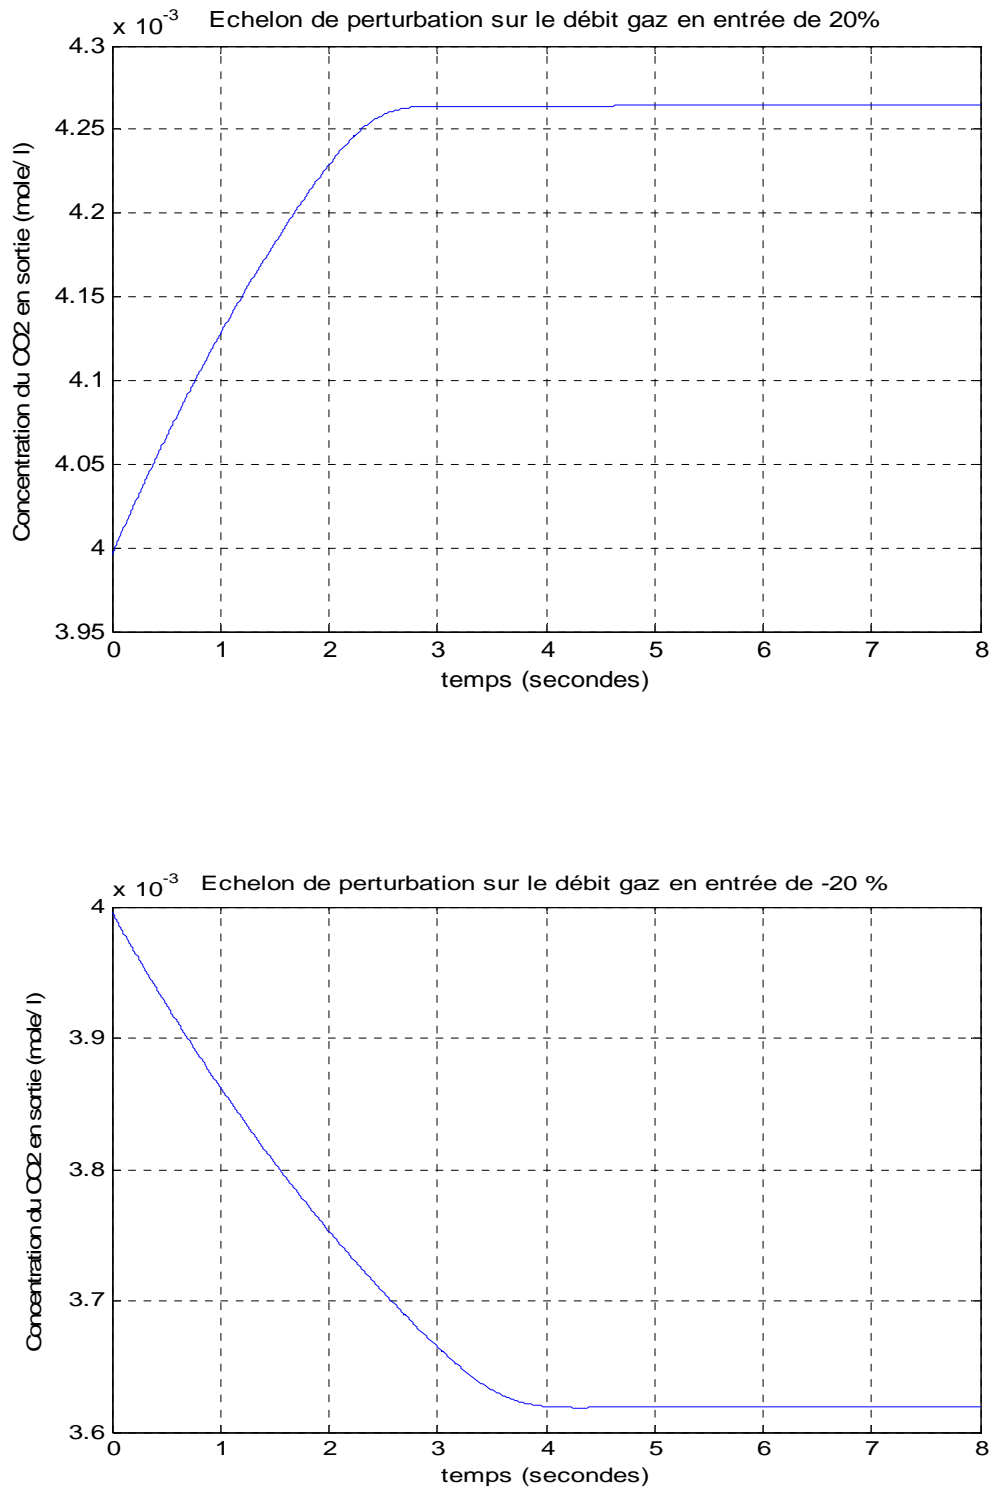


Figure 1.7. Echelon de perturbation de +/- 20 % sur le débit de gaz en entrée

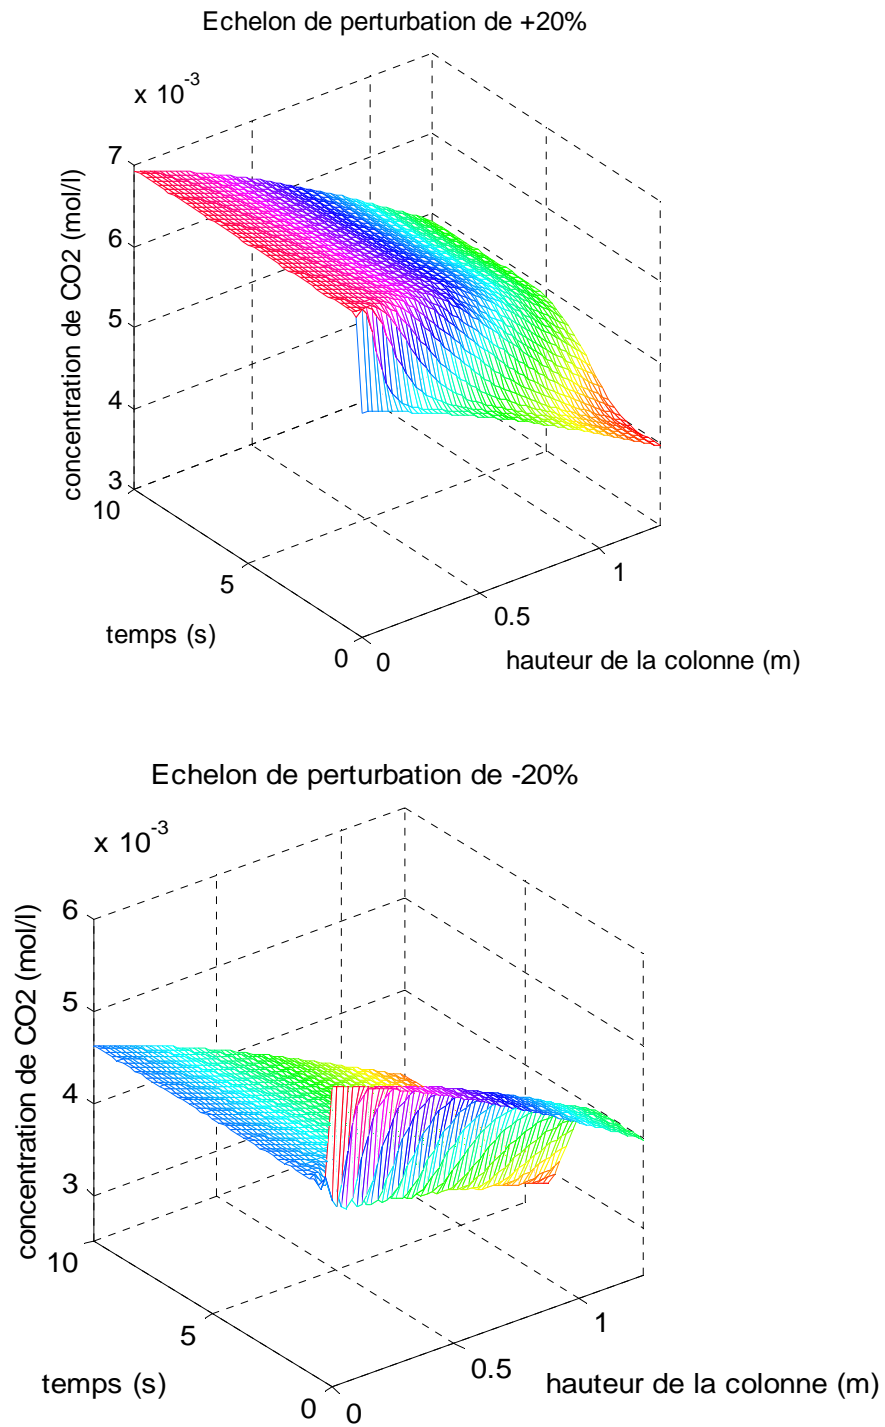
Evolution de la concentration de CO₂ le long de la colonne en fonction du temps

Figure 1.8. Evolution de la concentration de CO₂ le long de la colonne pour un échelon de perturbation de +/- 20 % sur la concentration de gaz en entrée


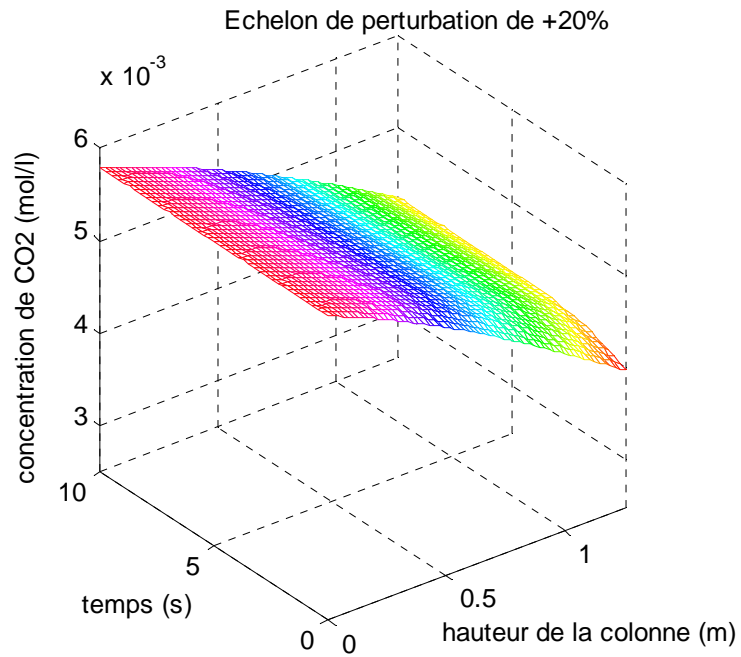


Figure 1.9. Evolution de la concentration de CO₂ le long de la colonne pour un échelon de perturbation de +/- 20 % sur le débit de gaz en entrée

1.6 Simulation avec régulateur PI de la colonne d'absorption :

Nous avons appliqué une Régulation PI à la colonne d'absorption. Une commande échantillonnée est choisie Pour faciliter la simulation. La période d'échantillonnage choisie est égale à 0.5 seconde, la teneur régulée moyenne en sortie est de $3.996 \cdot 10^{-3}$ mole de CO_2 par litre de gaz pour le point de fonctionnement.

Les perturbations appliquées au système sont :

- Echelon de perturbation sur la concentration de gaz en entrée
- Echelon de perturbation sur le débit de gaz en entrée
- Echelon de perturbation sur la concentration de gaz en entrée et le débit de gaz
- Nous présenterons également un changement de la consigne.

Les paramètres du régulateur PI sont choisis de manière empirique :

$$\begin{cases} K_p = 2,2 \times 10^{-6} & [K_p] = \frac{m^6}{mole \cdot s} \\ T_I = 0,5 & (\text{secondes}) \end{cases}$$

a. Echelon de perturbation sur la concentration de gaz en entrée




Figure 1.10. Concentration en sortie du CO_2 et débit du liquide de lavage pour un échelon de perturbation de +10 %




Figure 1.11. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de +20 %

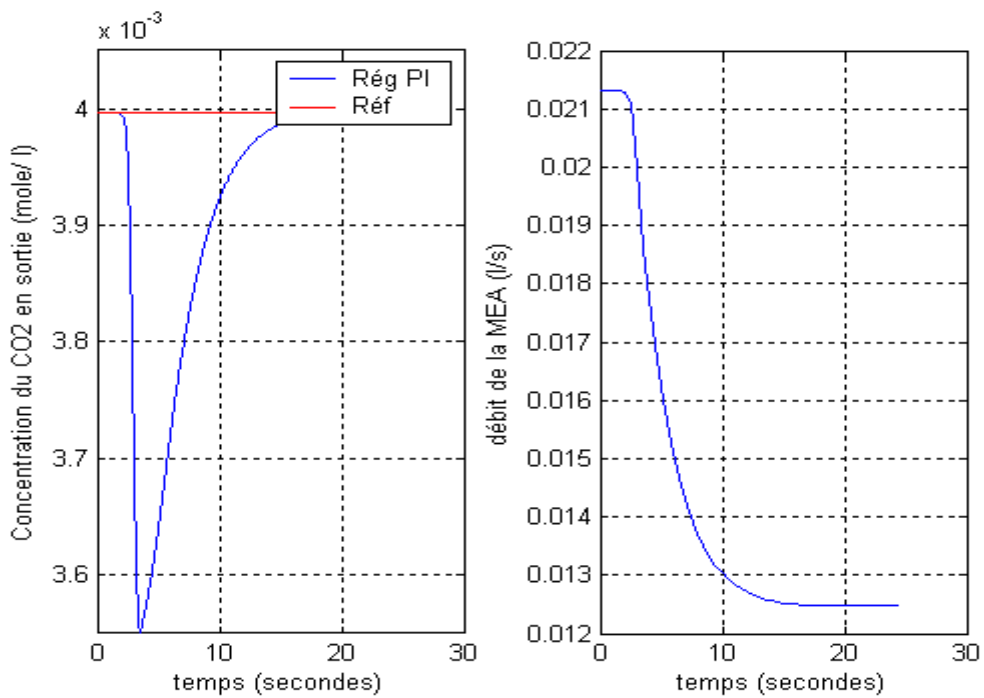


Figure 1.12. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de -10 %

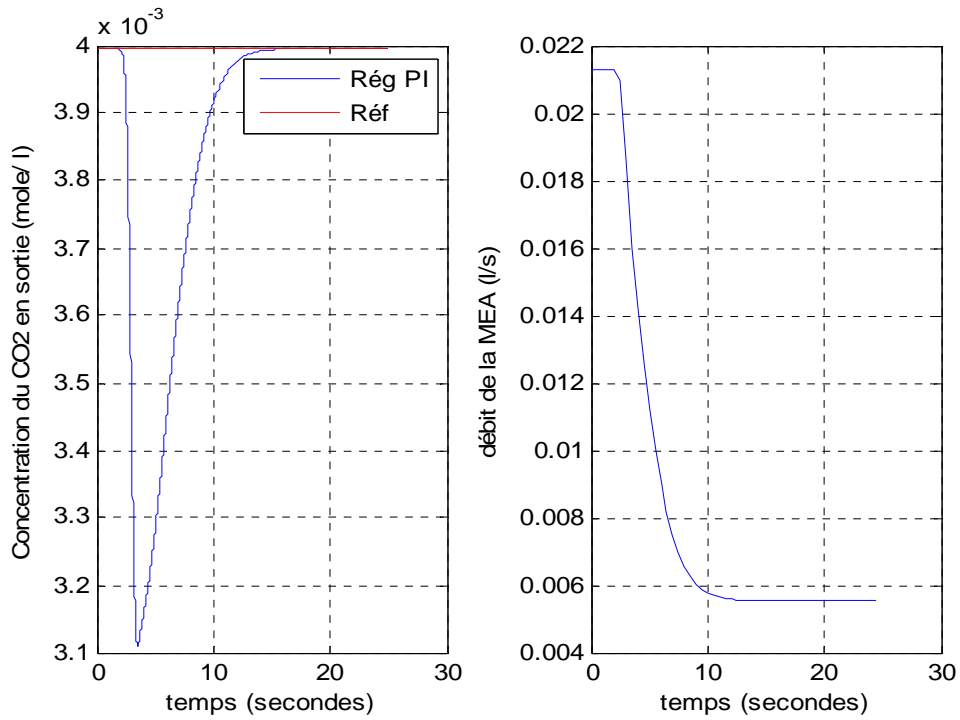


Figure 1.13. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de -20 %

b. Echelon de perturbation sur le débit de gaz en entrée

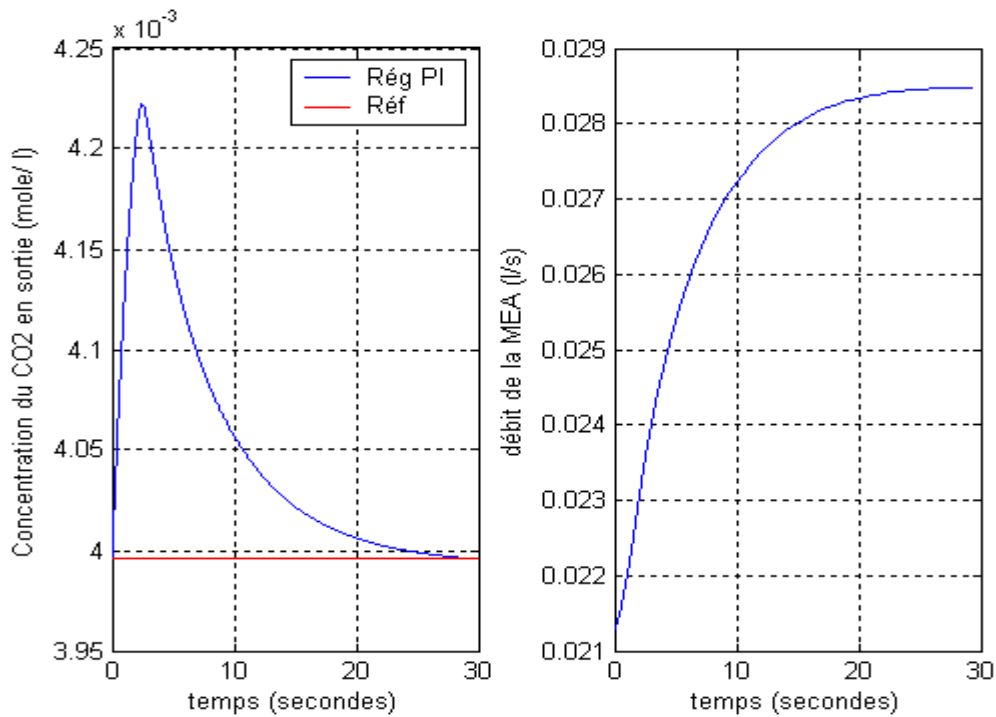


Figure 1.14. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de +20 %




Figure 1.15. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de -20 %




Figure 1.16. Concentration en sortie du CO₂ et débit du liquide de lavage pour un échelon de perturbation de +15 %

c. Echelon de perturbation sur la concentration de gaz en entrée et sur le débit de gaz




Figure 1.17 Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de +15% sur la concentration de CO₂ en entrée de la colonne et de +10% sur le débit de gaz en entrée




Figure 1.18 Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de -15% sur la concentration de CO₂ en entrée de la colonne et de -10% sur le débit de gaz en entrée

d. Variation de consigne




Figure 1.19. Concentration en sortie du CO₂ et débit du liquide de lavage pour une variation de consigne de $3.996 \cdot 10^{-3}$ à $4.5 \cdot 10^{-3}$ mole/l




Figure 1.20. Concentration en sortie du CO₂ et débit du liquide de lavage pour une variation de consigne de $3.996 \cdot 10^{-3}$ à $3.0 \cdot 10^{-3}$ mole/l

1.7 Interprétation des résultats

En boucle ouverte

En appliquant une entrée échelon de perturbation sur la concentration ainsi que sur le débit de gaz en entrée, la concentration à la sortie de la colonne augmente si le signe de l'échelon est positif, ou descend si le signe de l'échelon est négatif pour atteindre une valeur fixe.

Le système est donc stable et a une dynamique importante mais qui reste tout à fait normal pour un procédé chimique.

Le système présente un temps mort en réponse à un échelon de perturbation sur la concentration dû à la propagation du gaz le long de la colonne d'absorption (fig 1.5),(fig 1.8).

Le système ne présente pas de temps mort pour les perturbations sur le débit de gaz (fig 1.7),(fig 1.9).

On remarque sur la figure (I.6) que la dynamique du CO₂ est très lente pour une perturbation sur la concentration de MEA de +15%. De plus, quand la concentration de C_{BE} varie en entrée, les variations de concentrations du CO₂ sont minimales (de $3.996 \cdot 10^{-3}$ mole/l à $3.74 \cdot 10^{-3}$ mole/l. Ceci explique que nous n'avons pas envisagé dans la partie régulation des échelons de perturbation sur la concentration de MEA, car sa dynamique est trop lente pour faire varier la concentration en gaz de manière significative.

En boucle fermée avec régulateur PI

Nous nous sommes intéressés à l'évolution de la concentration de CO₂ en haut de la colonne en fonction des perturbations intervenant sur la concentration de CO₂ en entrée de la colonne ainsi que sur le débit de gaz, nous avons également imposé un changement de consigne. Les résultats de simulation sont illustrés par les figures (fig 1.10) à (fig 1.20).

Ces figures, montrent la robustesse de la régulation PI choisie pour les perturbations appliquées à notre système, ainsi la régulation est assurée que ce soit sur les perturbations sur les concentrations ou le débit de gaz.

Le système présente en régulation un très net comportement asymétrique dû à la forte non linéarité de la sortie par rapport à la commande choisie qui est le débit du liquide de lavage.

Les résultats obtenus en simulation sont satisfaisants, le régulateur PI annule l'erreur en régime établi suite à la présence de perturbations sur les concentrations du gaz ou le débit du MEA.

1.8. Conclusion

Au cours de ce chapitre, nous avons analysé en premier lieu le mode de fonctionnement de la colonne d'absorption, puis à partir des principes fondamentaux concernant le transfert de matière et des équations de bilan de matière, nous avons développé un modèle mathématique dynamique décrivant le processus d'absorption de CO_2 dans une colonne à garnissage opérant à contre courant. Le modèle obtenu est non linéaire et régi par des équations aux dérivées partielles. Il se distingue des modèles décrivant les processus d'absorption précédents par la prise en compte du cas d'une réaction du deuxième ordre, les relations décrivant le système ont pu être établies en considérant que $C_{BL}(x)$ n'était pas constante dans le film ni le long de la colonne.

Les simulations numériques de la réponse à un échelon de perturbation pour différentes amplitudes que ce soit sur les concentrations ou bien sur les débits ainsi que pour la poursuite de consigne, nous ont permis d'étudier les différents aspects structurels de notre système ainsi que les propriétés de ce modèle. Une analyse du modèle ainsi simulé conduit aux conclusions suivantes :

- Le système est stable en boucle ouverte,
- Le système est non linéaire,
- Le système présente un temps mort sur les perturbations en concentration dû à la propagation du gaz le long de la colonne d'absorption,

Les résultats obtenus en simulation en boucle fermée avec le régulateur PI sont satisfaisants, la sortie du système suit la référence, et ce pour différents types de perturbations.

Chapitre 2

Théorie et Apprentissage des Réseaux de Neurones

2.1 Introduction

Les réseaux de neurones artificiels, ou réseaux neuromémitiques présentent une alternative puissante aux algorithmes de calcul classique car ils possèdent de très bonnes aptitudes à la résolution des problèmes non linéaires. Sous le terme de réseaux de neurones, on regroupe aujourd'hui un certain nombre de modèles dont l'intention est d'imiter certaines des fonctions du cerveau humain en reproduisant certaines de ses structures de base. Historiquement, les origines de cette discipline sont très diversifiées. En 1943, McCulloch et Pitts étudièrent un ensemble de neurones formels interconnectés et montrèrent leurs capacités à calculer certaines fonctions logiques.

En 1949, Hebb, dans une perspective psychophysiologique, souligna l'importance du couplage synaptique dans les processus d'apprentissage. C'est en 1958 que Rosenblatt décrivit le premier modèle opérationnel de réseaux de neurones mettant en œuvre les idées de Hebb, McCulloch et Pitts : le perceptron, inspiré du système visuel, capable d'apprendre à calculer certaines fonctions logiques en modifiant ses connexions synaptiques. Ces modèles suscitèrent l'intérêt de plusieurs chercheurs avant que Minsky et Papert en 1969 ne démontrèrent leur limites théoriques.

Le renouveau actuel des réseaux de neurones est dû à des contributions originales comme celle de Hopfield en 1982 [JOD94], qui a montré l'analogie des réseaux de neurones avec certains systèmes physiques, ce qui a permis de leur appliquer un formalisme riche et bien maîtrisé. Plus récemment, en 1985, de nouveaux modèles mathématiques ont permis de dépasser les limites du perceptron. Les premières applications pratiques des réseaux de neurones ont alors vu le jour.

Dans ce chapitre, nous présentons brièvement quelques notions générales sur le neurone biologique, ensuite les caractéristiques du neurone artificiel, puis l'algorithme d'apprentissage pour un RNA.

2.2 Le neurone biologique

Les neurones sont les cellules de base du système nerveux. Ces cellules sont responsables de la réception et de la transmission des influx nerveux (impulsions électriques), et forment donc un réseau. Un neurone est composé d'un corps cellulaire qui contient un noyau, d'un axone et d'un ou plusieurs dendrites (figure 2.1). Les dendrites sont les parties multi-ramifiées qui reçoivent les influx nerveux. Les axones sont les structures allongées qui transmettent les influx à partir du corps cellulaire. Les neurones transmettent leurs influx à travers des connexions nerveuses appelées synapses par l'intermédiaire d'un neuromédiateur (neurotransmetteur) chimique tel que l'acétylcholine. Cette substance chimique est délivrée par de minuscules vésicules qui se trouvent à l'extrémité de l'axone, quand l'influx nerveux les atteint, les neurotransmetteurs se diffusent alors dans la fente synaptique et excitent les dendrites de la cellule suivante pour créer un nouvel influx nerveux dans cette cellule. Le mécanisme se reproduit tout au long de la chaîne de neurones et l'influx nerveux se propage uniquement dans une seule direction [ALL07].

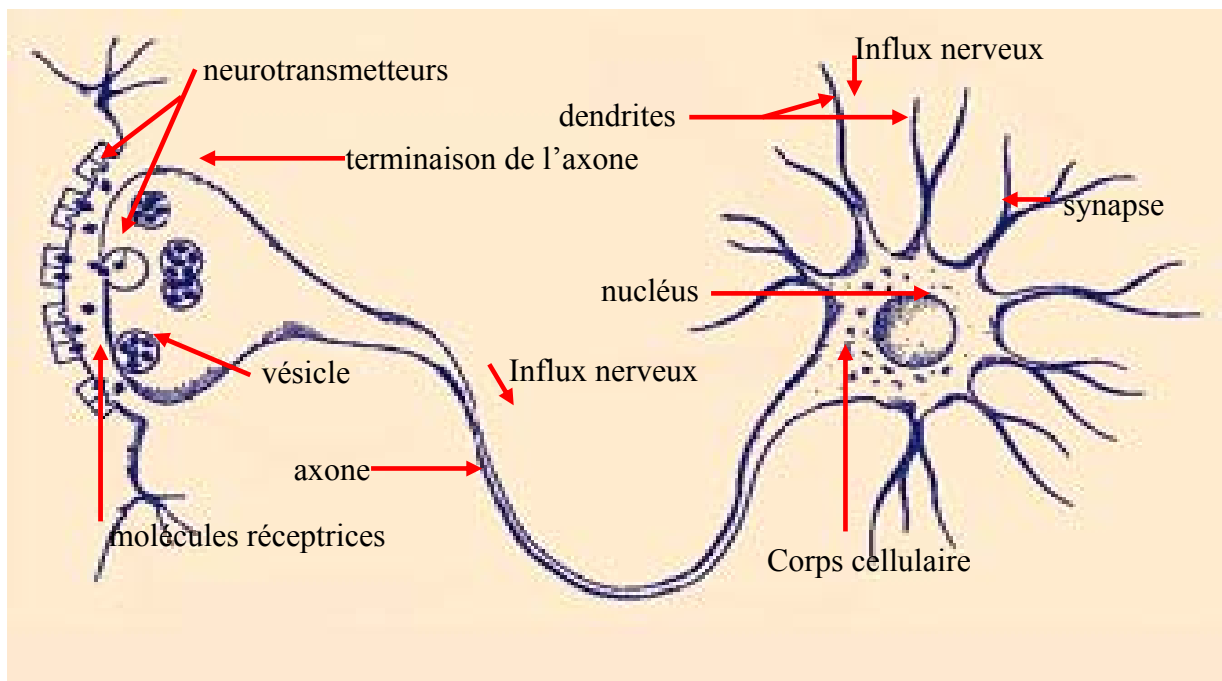


Figure 2.1 : Neurone biologique

Si l'on observe le sens de circulation de l'influx nerveux, on constate que l'information au niveau de chaque neurone est soumise à deux unités de traitements :

- la synapse où le signal transmis par les arborisations terminales des axones subit une modulation. Cette modulation est réalisée par le fait que l'excitation du neurone récepteur n'est effectuée que si la quantité du neurotransmetteur qui se fixe sur l'autre coté de l'espace synaptique (membrane post synaptique) dépasse un certain seuil. La synapse obéit donc à la loi du tout ou rien en réalisant une fonction seuil.

- le corps cellulaire effectue une sommation de tous les signaux reçus depuis les synapses via les dendrites.

2.3 Les réseaux de neurones artificiels

Les réseaux de neurones artificiels sont des modèles mathématiques inspirés de la structure et du comportement des neurones biologiques. Ils sont composés d'unités interconnectées que l'on appelle neurones formels ou artificiels, recevant des informations provenant du milieu extérieur ou d'autres neurones. Les neurones sont connectés entre eux au moyen de synapses dont les poids modulent les informations transmises vers d'autres neurones ou vers la sortie. Ces poids sont déterminés par apprentissage.

2.3.1 Le modèle formel d'un neurone [HER94],[JOD94], [FRE92]

C'est le résultat de l'analogie directe qu'ont faite MacCulloch et Pitts, en 1943, avec le neurone biologique. Ce fut la première modélisation mathématique d'un neurone. Il s'agit d'un corps cellulaire qui exécute une somme pondérée des signaux d'entrée qui lui parviennent (figure 2.2). Si cette somme dépasse un certain seuil, le neurone est activé, ou au niveau haut. Autrement le neurone est dit désactivé, ou au niveau bas.

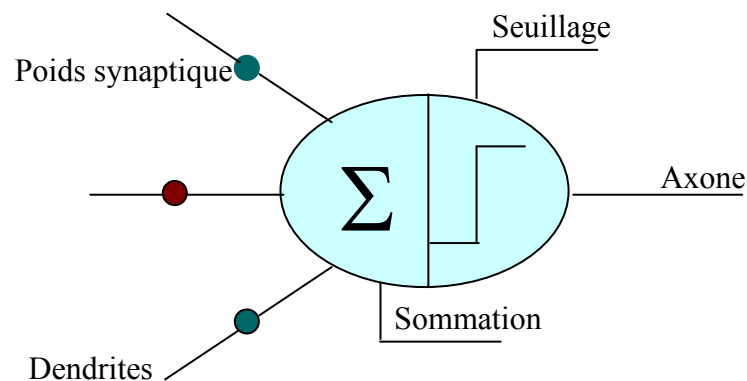


Figure 2.2 : Neurone formel

La (figure 2.3) montre la correspondance entre le neurone biologique et le neurone artificiel.




Figure 2.3 : Mise en correspondance neurone biologique/ neurone artificiel

Le neurone formel est modélisé par deux opérateurs comme le montre la (figure 2.4).




Figure 2.4 : Modèle formel d'un neurone

Les paramètres sont attachés aux entrées du neurone : La sortie du neurone est une fonction nonlinéaire d'une combinaison des entrées $\{x_i\}$ pondérées par les paramètres $\{w_i\}$, qui sont souvent désignés sous le nom de poids ou, en raison de l'inspiration biologique des réseaux de neurones poids synaptiques, conformément à l'usage (également inspiré par la biologie), cette combinaison linéaire sera appelé potentiel. Le potentiel p le plus fréquemment utilisé est la somme pondérée, à laquelle s'ajoute un terme constant ou biais.

$$p = \sum_{i=1}^k w_i x_i + w_0 \quad (2.1)$$

Avec :

p : Potentiel somatique

w_0 : Biais

x_i : Entrée du neurone i

w_i : Poids synaptiques (Les connexions entre neurones ont des poids variables, ce qui rend les neurones plus ou moins influents sur d'autres neurones).


2.3.1.a Fonction de seuil (ou d'activation)

C'est un opérateur qui calcule la sortie y du neurone en fonction de son potentiel p .

$$y = f(p) \quad (2.2)$$

La fonction d'activation f doit être en générale saturable pour éviter des valeurs en sortie trop élevées qui peuvent déstabiliser le réseau. D'autre part, la fonction d'activation est en général nonlinéaire, ce qui rend les réseaux de neurones capables de simuler des fonctions complexes.


Les figures suivantes présentent des fonctions d'activation utilisées :



Fonction identité


Dans ce cas la sortie du neurone est égale au produit scalaire du vecteur d'entrée par le vecteur de poids.

$$S = f(p) = p$$




Fonction à seuil

Ici la fonction f est booléenne, si le produit scalaire p dépasse un certain seuil β le neurone répond par 1, mais si p est inférieur ou égal à β , le neurone répond par 0.


**Fonction signe**

Comme dans le cas précédent la fonction f est une fonction binaire, si p est supérieur à β la sortie est +1, autrement, si p est inférieur ou égal à β la sortie est -1.

**Fonction log-sigmoïde**

Dans ce cas f est une fonction sigmoïde prenant ses valeurs sur l'intervalle $[0, 1]$.

$$f(p) = \frac{1}{1 + \exp(-p)}$$

**Fonction tan-sigmoïde**

Il s'agit d'une fonction sigmoïde (tangente hyperbolique) prenant ses valeurs sur l'intervalle $[-1, 1]$ suivant l'expression :

$$f(p) = \frac{\exp(p) - \exp(-p)}{\exp(p) + \exp(-p)}$$

2.4 Réseaux de neurones et approximateurs universels

Cybenko et Hornik (1989) considèrent les réseaux de neurones comme une classe d'approximateurs universels. On a ainsi démontré qu'un perceptron multicouches avec une seule couche cachée pourvue d'un nombre suffisant de neurones, peut approximer n'importe quelle fonction avec la précision souhaitée. Cette propriété ne permet pas, Néanmoins de choisir, pour un type de fonction donné, le nombre de neurones optimal dans la couche cachée.

2.5 L'apprentissage des réseaux de neurones

On appelle apprentissage des réseaux de neurones la procédure qui consiste à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse au mieux la tâche qui leur est affectée.

L'apprentissage est la phase qui permet de déterminer les poids et le seuil de chaque neurone dans un RNA. Une fois l'apprentissage terminé, le réseau est prêt à remplir sa fonction. Cette fonction peut être la mémorisation, la classification, ou l'optimisation.

Dans le cadre de cette définition, on peut distinguer deux types d'apprentissage : l'apprentissage supervisé et l'apprentissage non supervisé.

2.5.1 Apprentissage supervisé

Le processus d'apprentissage supervisé est réalisé à l'aide d'un expert qui fournit une sortie que le réseau doit approcher au mieux en réponse aux stimuli provenant de son environnement (figure 2.5). Pour ce faire, les deux réponses sont comparées pour définir un critère d'erreur. Les méthodes classiques d'optimisation sont utilisées pour minimiser ce critère et atteindre la précision désirée. Parmi les algorithmes qui utilisent ce type d'apprentissage, on trouve la règle de Widrow- Hoff et la rétropropagation du gradient.

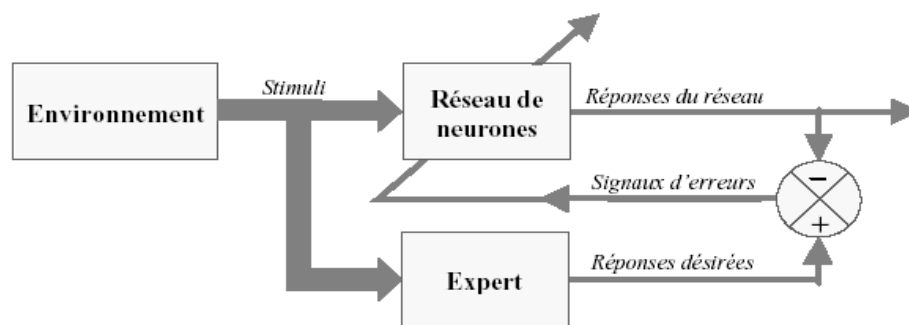


Figure 2.5 : Schéma d'un apprentissage supervisé.

2.5.2 Apprentissage non supervisé

L'apprentissage non supervisé se fait en l'absence d'expert. C'est le réseau lui-même qui détermine une classification en s'auto-organisant par association des réponses aux stimuli (figure 2.6). La qualité de représentation de la connaissance au sein du réseau est exprimée

par un critère d'erreur mesuré dépendant uniquement des réponses. Le modèle de Kohonen, entre autres, utilise ce type d'apprentissage.




Figure 2.6: Schéma de l'apprentissage non supervisé.

L'apprentissage non supervisé est un outil à objectifs multiples :

- Dans le cas de l'optimisation il détermine les paramètres donnant la solution optimale au problème.

- Dans le cas de la classification il divise l'espace de représentation en régions de décisions dont les limites sont définies par les règles de décisions adoptées dans le RNA et les représentants de chaque classe seront codés par leurs poids (modèle de Kohonen).

2.5.3 Surapprentissage [HAM93]

Les travaux expérimentaux menés sur les réseaux de neurones ont montré que, si on dépasse un certain nombre d'exemples d'entraînement, le réseau peut perdre sa capacité de généralisation, et donner ainsi des sorties non satisfaisantes pour des nouvelles entrées en gardant des réponses correctes pour les entrées déjà apprises, c'est ce que l'on appelle le surapprentissage.

Pour éviter ce phénomène, on effectue un test de généralisation chaque fois que le réseau aura appris un certain nombre d'exemples. Si le test s'avère être négatif, on arrête l'introduction de nouveaux exemples, pour éviter le surapprentissage. Cette explication est résumée en figure 2.7.




Figure 2.7 : Phénomène de sur-apprentissage

2.6 Architecture des réseaux de neurones artificiels

Le neurone lui-même, en tant qu'unité autonome élémentaire n'a aucun pouvoir. La force et l'efficacité du cerveau résident en effet, dans le regroupement de ces neurones et le partage des tâches entre eux. La connexion de plusieurs neurones entre eux, constitue ce qu'on appelle un champ de neurones, ces derniers forment à leur tour un réseau de neurones, où les unités intérieures travaillent ensemble pour accomplir une tâche bien déterminée. Il existe des réseaux de neurones qui sont organisés en couches: une couche d'entrée, des couches cachées, et une couche de sortie ; c'est ce que l'on appelle des réseaux multi-couches. Un autre type de réseaux sont les réseaux récurrents.

Aux cours des dernières années, différents modèles ont été créés et étudiés. Ces modèles diffèrent dans l'organisation de leurs neurones, les connexions entre ces derniers, et le type d'apprentissage. En se basant sur ces paramètres nous pouvons faire la classification pour les architectures existantes :

2.6.1 RNA à Propagation Directe

Dans ce cas les neurones sont organisés en couches (couche d'entrée, couches cachées et couche de sortie). Chaque couche ne communique sa sortie qu'à la couche suivante (figure 2.8). En effet, les neurones d'une couche ne sont connectés qu'aux neurones de la couche suivante à travers les poids de connexions et l'information se propage de l'entrée vers la sortie du RNA. D'où l'appellation propagation directe « feedforward ».

Les neurones sont reliés entre eux par des connexions pondérées. Ce sont les poids de ces connexions qui gouvernent le fonctionnement du réseau. .

Durant l'apprentissage la propagation de l'information se fait dans les deux sens. Le signal d'entrée se propage vers la sortie, et le signal d'erreur se propage de la sortie vers l'entrée, ce qu'on appelle la rétropropagation de l'erreur qui provoque la modification des poids de connexion. Une fois l'apprentissage terminé, l'information reprend un sens unique de l'entrée vers la sortie.

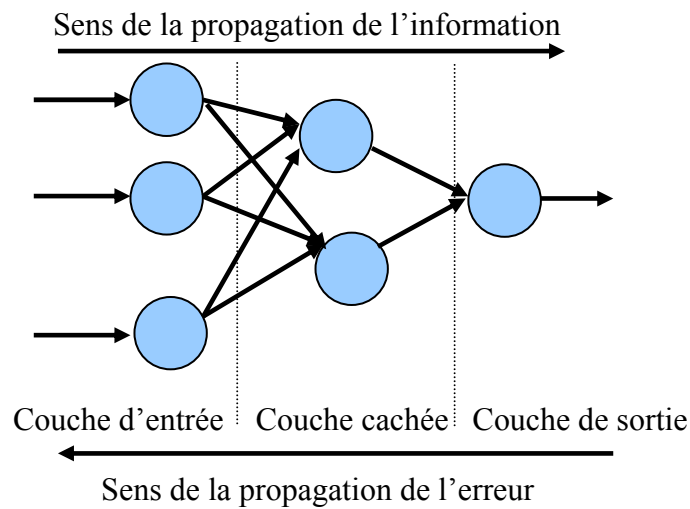


Figure 2.8 : RNA à propagation directe

2.6.2 Les réseaux de neurones bouclés (ou récurrents)

L'information dans ce cas là se propage dans plusieurs sens. Les neurones possèdent une dynamique récurrente. En effet, le RNA est bouclé sur lui-même, d'où son nom de RNA récursif. Lorsque on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de « cycle »). Ainsi, à chaque connexion d'un réseau de neurones bouclé (ou à chaque arête de son graphe) est attaché, outre un poids comme pour les réseaux non bouclés, un retard.

La (figure 2.9) représente un exemple de réseau de neurones bouclé. Les chiffres dans les carrés indiquent le retard attaché à chaque connexion, exprimé en multiple de l'unité de temps (ou période d'échantillonnage). Ce réseau contient un cycle, qui part du neurone 3 et revient à celui-ci en passant par le neurone 4. La connexion de 4 vers 3 ayant un retard de 1 unité de temps.

A l'instant kT , le neurone 3 reçoit en entrée les quantités $u_1(kT)$, $u_2(k-1)T$ et $y_4(k-1)T$ (où k est un entier positif et $y_4(kT)$ est la sortie du neurone 4 à l'instant kT), et calcule sa sortie $y_3(kT)$. Le neurone 4 reçoit $u_2(kT)$ et $y_3(kT)$, et calcule sa sortie $y_4(kT)$. Le neurone 5 reçoit $y_3(kT)$, $u_1(kT)$ et $y_4(k-1)T$, et calcule sa sortie, qui est la sortie du réseau de neurones $g(kT)$.




Figure 2.9 : Un réseau de neurones bouclé à deux entrées

2.7 Algorithmes d'apprentissage

La phase d'apprentissage est une étape déterminante dans la conception du réseau de neurones. Pour cela, des algorithmes appropriés ont été élaborés et développés au fil des années, chaque algorithme est développé pour un type spécifique de réseau. Ces méthodes sont basées sur des techniques mathématiques connues qui ont prouvée leurs efficacités.

Nous présentons ici l'algorithme de rétropropagation valable pour les réseaux à propagation directe. Cette algorithme de rétropropagation du gradient proposé par Werbos [WER92], dans sa thèse de doctorat, et développé par Rumelhart, Hinton et Williams en 1986. C'est grâce à lui que l'on doit le renouveau d'intérêt pour les RNA au début des années 80. Il s'agit d'une méthode d'apprentissage supervisée.

2.7.1 Algorithme de rétropropagation (Back-Propagation BP)

Cet algorithme offre une procédure d'apprentissage commode. Il est basé sur une méthode numérique dite de relaxation qui effectue une descente de gradient sur la surface d'erreur quadratique moyenne. Il utilise donc les techniques de dérivées partielles (on peut représenter la descente de gradient comme une bille que l'on poserait sur la surface (figure 2.12), et qui descendrait le long de la pente), le gradient représente la pente instantanée en un point donné de la surface. La rétropropagation de l'erreur est essentiellement une généralisation de la règle de Windrow et Hopf à des fonctions d'activation dérivables (Sigmoides).

Le principe de la méthode est résumé dans la (figure 2.10). Il s'agit de présenter au réseau un vecteur d'entrée et un vecteur de sortie désirée. Le réseau va calculer sa propre sortie par une propagation avant (forward). Une fois la sortie calculée, celle-ci est comparée à la valeur désirée (erreur). Cette erreur est utilisée pour l'adaptation des pondérations en faisant une propagation arrière (backward), de la couche de sortie vers la couche d'entrée, dans le but de minimiser l'erreur.




Figure 2.10: Principe de la rétropropagation

2.7.2 Résumé de l'algorithme BP

Soit le réseau de la (figure 2.11) à n_0 neurones en entrées, n_1 neurones dans la couche cachées, n_2 neurones en sortie, η s'appelle le pas du gradient, le taux d'apprentissage ou bien le gain de l'algorithme $0 \leq \eta \leq 1$.

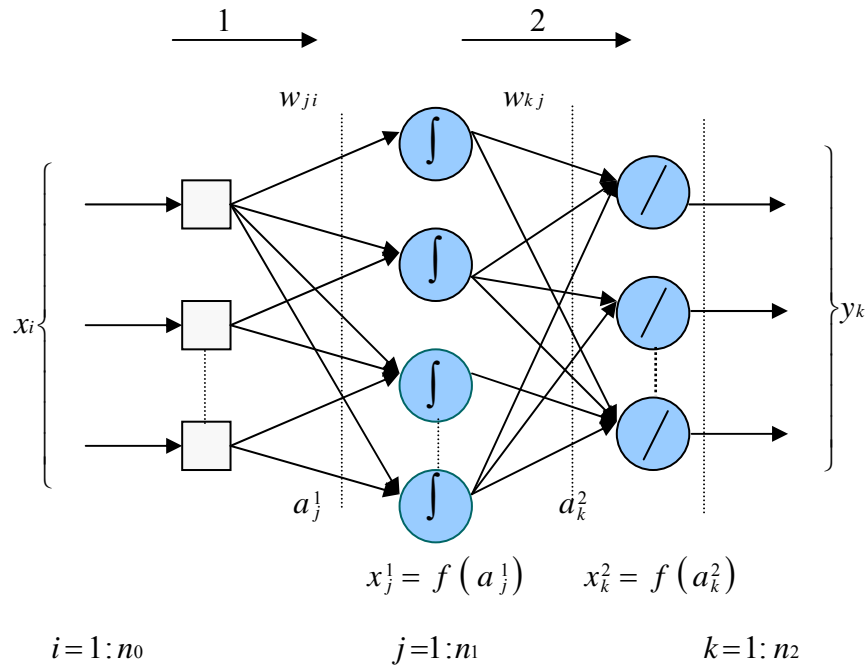


Figure 2.11 : Réseau multi-couches

1-Propagation

On calcule les sorties du réseau en propageant les valeurs de x , de la couche d'entrée vers la couche de sortie. a représente l'entrée de chaque couche de neurone.

$$a_j^1 = \sum_{i=1}^{n_0} w_{ji} x_i + b_j^1 \quad (2.3)$$

$$x_j^1 = f(a_j^1) \quad (2.4)$$

$$a_k^2 = \sum_{j=1}^{n_1} w_{kj} x_j^1 + b_k^2 \quad (2.5)$$

$$y_k = g(a_k^2) = a_k^2 \quad (2.6)$$

2-Calcul de l'erreur

-On présente un exemple avec un vecteur d'entrée $x = [x_1 \dots x_{n_0}]$

- le vecteur de sortie désirée (y^{des}) sera $y^{des} = [y^{des}_1 \dots y^{des}_{n_2}]$

-On calcule la sortie correspondante $y = [y_1 \dots y_{n_2}]$, l'erreur est : $e_k = y^{des}_k - y_k$

-Le coût associé à l'exemple est : $J(exemple) = \frac{1}{2} \sum_{k=1}^{n_2} e_k^2$ (Somme des erreurs quadratiques observées).

3- Calcul du gradient

La correction des poids de neurones de w_{ji} et w_{kj} sont calculés par :

$$\Delta w = -\eta \frac{\partial J}{\partial w} ; \quad (2.7)$$

$$\text{Et la correction des biais } b \text{ sont calculés par : } \Delta b = -\eta \frac{\partial J}{\partial b} \quad (2.8)$$

3. a- Couche de sortie

Calcul de $\frac{\partial J}{\partial w_{kj}}$ pour un exemple fixé

$$\frac{\partial J}{\partial w_{kj}} = \frac{\partial J}{\partial y_k} \frac{\partial y_k}{\partial a_k^2} \frac{\partial a_k^2}{\partial w_{kj}}$$

$$J = \frac{1}{2} \sum_{k=1}^{n_2} (y^{des}_k - y_k)^2 \Rightarrow \frac{\partial J}{\partial y_k} = -(y^{des}_k - y_k) : \text{La forme choisie pour } J \text{ est l'erreur}$$

quadratique de la sortie y par rapport à la sortie désirée y_d .

$$y_k = g(a_k^2) \Rightarrow \frac{\partial y_k}{\partial a_k^2} = g'(a_k^2) = 1$$

$$a_k^2 = \sum_{j=1}^{n_1} w_{kj} x_j^1 + b_k^2 \Rightarrow \frac{\partial a_k^2}{\partial w_{kj}} = x_j^1 ; \quad \frac{\partial a_k^2}{\partial b_k^2} = 1 \quad (2.9)$$

$$\text{Posons : } S_k^2 = \frac{\partial J}{\partial a_k^2} = -(y_k^{des} - y_k) g'(a_k^2) \quad (2.10)$$

$$\Rightarrow \frac{\partial J}{\partial w_{kj}} = S_k^2 x_j^1 \quad \text{et} \quad \frac{\partial J}{\partial b_k^2} = S_k^2 \quad (2.11)$$

3. b- Couche cachée

Calcul de $\frac{\partial J}{\partial w_{ji}}$ pour un exemple fixé

$$\frac{\partial J}{\partial w_{ji}} = \frac{\partial J}{\partial x_j^1} \frac{\partial x_j^1}{\partial a_j^1} \frac{\partial a_j^1}{\partial w_{ji}} \quad (2.12)$$

$$\frac{\partial J}{\partial x_j^1} = \sum_{k=1}^{n_2} \frac{\partial J}{\partial a_k^2} \frac{\partial a_k^2}{\partial x_j^1} = \sum_{k=1}^{n_2} S^2_k w_{kj} \quad (2.13)$$

$$x_j^1 = f(a_j^1) \Rightarrow \frac{\partial x_j^1}{\partial a_j^1} = f'(a_j^1) \quad (2.14)$$

$$a_j^1 = \sum_{i=0}^{n_0} w_{ji} x_i + b_j^1 \Rightarrow \frac{\partial a_j^1}{\partial w_{ji}} = x_i \quad (2.15)$$

Posons : $S_j^1 = \frac{\partial J}{\partial a_j^1}$

$$S_j^1 = \left(\sum_{k=1}^{n_2} S^2_k w_{kj} \right) f'(a_j^1) \quad (2.16)$$

$$\frac{\partial J}{\partial w_{ji}} = S_j^1 x_i \quad \text{et} \quad \frac{\partial J}{\partial b_j^1} = S_j^1 \quad (2.17)$$

Remarque 1 [MAR04] : Pour corriger l'erreur observée, il s'agit de modifier les poids w dans le sens opposés au gradient $\frac{\partial J}{\partial w}$ de l'erreur. Cette dérivée partielle représente également la fonction de sensibilité (figure 2.12).




Figure 2.12 : Gradient de l'erreur totale

Remarque 2

- L'initialisation des poids synaptiques w est aléatoire.
- L'expérience a montré qu'il est généralement, préférable d'initialiser les poids à des valeurs comprises entre 0 et 1 pour éviter de déstabiliser le réseau dès le départ [FRE92], [SHU90].
- Le pas du gradient η est choisi entre 0 et 1, et on le diminuera au fur et à mesure pour atteindre une valeur fixe.
- Le choix des exemples d'apprentissage est très important, un choix judicieux de ces derniers pourra faciliter la généralisation sur des exemples non appris. Ceci a poussé les chercheurs à faire l'étude statistique des données d'entraînement pour trier celles qui sont le plus représentatives du phénomène qu'on souhaite avoir [HAM93].
- L'algorithme de rétropropagation du gradient a pu être étendu à certaines classes de réseaux récurrents c'est ce que l'on appelle la rétropropagation dynamique.

2.7.3 Difficultés et limites de l'algorithme

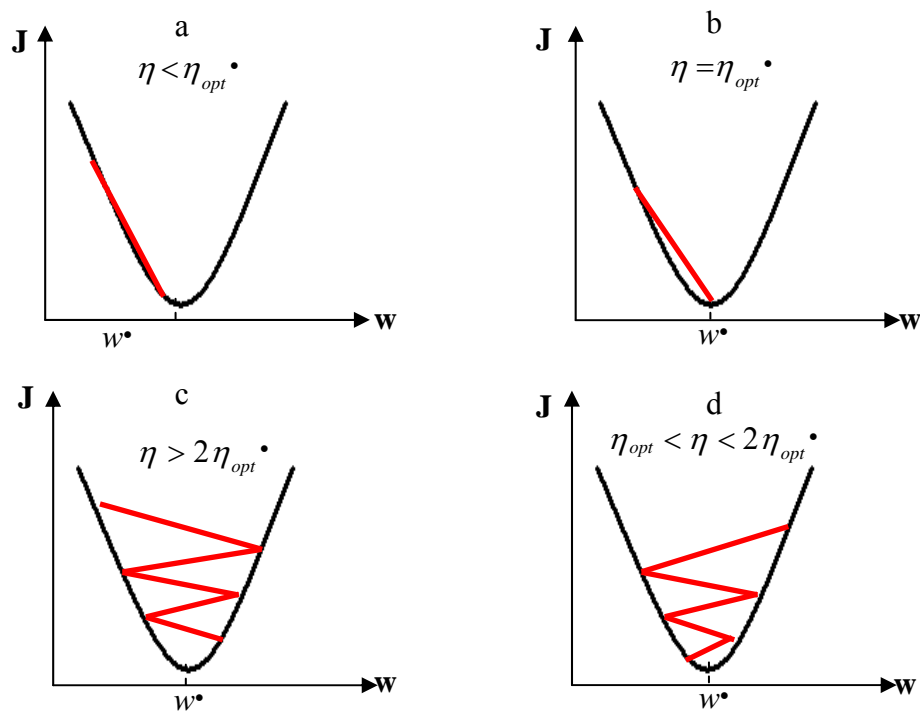
De nombreuses questions restent posées quant à l'utilisation de cet algorithme :

-la première étant le nombre de couches, et le nombre de neurones par couches ?

-les réponses ne sont données que par l'expérience, et il n'existe aucune règle théorique précise qui puisse fixer le nombre de neurones ou de couches dans le réseau.

-le problème de minimisation n'est pas facile à résoudre. En effet, la surface d'erreur peut présenter des caractéristiques peu satisfaisantes, telles que des minima locaux qui empêchent la convergence vers le minimum global, ainsi que des plateaux où les pentes sont très faibles.

-Le pas du gradient (figure 2.13) peut être difficile à choisir. S'il est faible, la convergence peut être très lente. S'il est élevé, l'erreur risque d'osciller sans pour autant converger.



a- Convergence lente b- Convergence rapide c- Divergence
d- Convergence oscillatoire

Figure 2.13 : Convergence et choix de η

2.7.4 Algorithme de Back- propagation avec Momentum

Comme nous l'avons mentionné précédemment, le pas du gradient peut être difficile à choisir. S'il est faible, la convergence peut être très lente. S'il est élevé, l'erreur risque de diverger.

Une solution proposée par D.E.Rumelhart, consiste à introduire un terme supplémentaire pour la réadaptation des poids.

L'équation d'adaptation devient alors :

$$\Delta w_{ji}(t) = -\eta S_j^l(t) x_i(t) + \alpha \Delta w_{ji}(t-1) \quad (2.18)$$

Le terme ajouté est appelé momentum (élan, quantité de mouvement), en analogie avec la mécanique classique, ou un objet en mouvement garde l'élan acquis grâce à la quantité de mouvement qui lui a été communiquée précédemment.

Le paramètre α est utilisé pour pondérer l'effet de ce terme. Sa valeur est généralement prise entre 0.8 et 0.9. Des recherches plus poussées ont montré que l'adaptation de sa valeur, comme c'est le cas pour le taux d'apprentissage η , donne des résultats très intéressants.

L'utilisation de cette méthode permet de faire sortir les poids des minimums locaux, (figure 2.14) afin de chercher d'autres optimums. Ce qui donne beaucoup de chance d'aboutir à un minimum global.

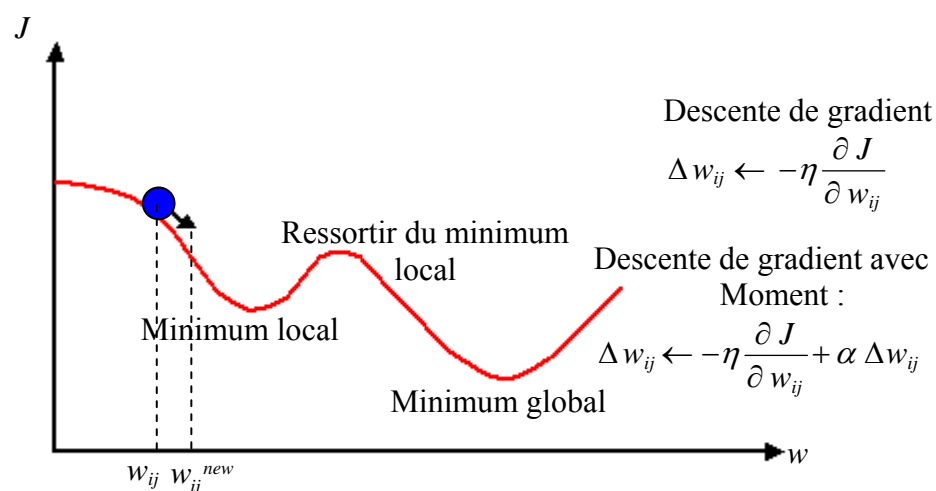


Figure 2.14 : Effet de momentum pour échapper d'un minimum local

2.7.5 Application de l'algorithme (BP) [FRE92]

Malgré les difficultés citées, l'algorithme de rétropropagation s'est révélé très performant dans la résolution de plusieurs problèmes, tels que :

- La reconnaissance des formes géométrique.
- Le traitement et l'analyse des signaux.
- La commande des processus.
- La classification
- Le filtrage de bruit
- Le diagnostic médical.

2.7.6 Méthode d'optimisation du second ordre

Les méthodes d'optimisation du second ordre sont des méthodes itératives de descente du gradient qui consistent à remplacer la fonction de coût par son approximation quadratique au voisinage de point courant (quadratique osculatrice ou fonction elliptique) [HAG96]. On considère le critère suivant :

$$Q(h_k) = V(w_k) + g(w_k)^T h_k + \frac{1}{2} h_k^T G(w_k) h_k \approx V(w_k + h_k) \quad (2.19)$$

On peut approximer $V(w_k + h_k)$ par $Q(h_k)$

Avec :

$$V = \sum_{i=0}^N e_i^2(w_k) = \sum_{i=0}^N (y_d - \hat{y}(w_k))^2 : \text{fonction de coût} \quad (2.20)$$

$$N = q \times SM :$$

→ q : nombre d'exemple

→ SM : nombre de sortie

Remarque : w désigne un vecteur de dimension n de l'ensemble des poids des couches du réseau et la variable k désigne la $k^{\text{ème}}$ itération.

On peut montrer que :

$$g(w_k) = \nabla_k V = J^T(w_k) e(w_k) : \text{Gradient.} \quad (2.21)$$

$$G(w_k) = \nabla_k^2 V = J^T(w_k) J(w_k) + S(w_k) : \text{Hessien.} \quad (2.22)$$

Où $J(w)$ est la matrice Jacobienne telle que :

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix} \quad (2.23)$$

et

$$S(w) = \sum_{i=1}^N e_i(w) \nabla^2 e_i(w). \quad (2.24)$$

$$\text{car : } \frac{\partial^2 e_i^2}{\partial w_k \partial w_l} = \frac{\partial e_i}{\partial w_k} \frac{\partial e_i}{\partial w_l} + e_i \frac{\partial^2 e_i}{\partial w_k \partial w_l} \quad (2.25)$$

Si on suppose que :

$$e_i \frac{\partial^2 e_i}{\partial w_k \partial w_l} \ll \frac{\partial e_i}{\partial w_j} \frac{\partial e_i}{\partial w_k}$$

On obtient :

$$\nabla_k^2 V = J^T(w_k) J(w_k) \quad (2.26)$$

2.7.7 Algorithme de Newton

La méthode de Newton consiste à calculer w_{k+1} de manière à minimiser $Q(h_k)$ de l'équation (2.16). On déduit la formule itérative,

$$w_{k+1} = w_k - [G(w_k)]^{-1} g(w_k) \quad (2.27)$$

Le minimum existe si le Hessien $G(w_k)$ est défini positif. La méthode de Newton nécessite le calcul du vecteur gradient et de l'inverse du Hessien de la fonction de coût.

Pour une fonction non linéaire quelconque, cette méthode ne converge pas nécessairement vers un minimum global. De plus, si le poids de départ w_0 est initié trop loin du minimum, la méthode ne converge pas [BAT92].

2.7.8 Méthode de Gauss-Newton

A partir de l'approximation du gradient par la matrice Jacobienne J et en supposant que $S(w_k)$ très petit devant $J^T(w_k)J(w_k)$, ($S(w_k) \approx 0$), la correction des poids sera donnée comme suit :

$$w_{k+1} = w_k - [J^T(w_k)J(w_k)]^{-1} J^T(w_k)e(w_k) \quad (2.28)$$

2.7.9 Algorithme de Levenberg-Marquardt

Parmi les algorithmes de la famille quasi-Newton, la méthode de Levenberg-Marquardt [MAR04] est un standard pour l'optimisation de l'erreur quadratique due à ses propriétés de convergence rapide et de robustesse ; Elle s'appuie sur les techniques de l'algorithme de Gauss-Newton [HAG94] et consiste à approximer $S(w_k)$ de la manière suivante :

$$S(w_k) \approx \mu_k I_n \quad (2.29)$$

Où : I_n est la matrice identité et on aura donc :

$$w_{k+1} = w_k - [J^T(w_k)J(w_k) + \mu_k I_n]^{-1} J^T(w_k)e(w_k) \quad (2.30)$$

La variable μ_k est contrôlée par le ratio

$$R_k = \frac{\Delta V_k}{\Delta Q_k} \quad (2.31)$$

avec

$$\Delta V_k = V(w_k) - V(w_k + h_k) \quad \text{dénomme « actual reduction »}$$

$$\Delta Q_k = Q(0) - Q(h_k) \quad \text{dénomme « predicted reduction »}$$

L'apprentissage s'arrête lorsqu'un minimum est atteint, soit en fonction d'un critère d'arrêt sur la fonction de coût, soit sur la valeur minimale de la norme du gradient.

2.7.9.1 Résumé de l'algorithme de Levenberg-Marquardt

Initialisation des poids w_0 par une distribution uniforme et $\mu_0 > 0$

La solution est donnée par l'algorithme suivant la $k^{\text{ème}}$ itération :

- 1- Evaluer la matrice Jacobienne $J(w)$
- 2- Donner w_k et μ_k , calculer $g(w_k)$ et $G(w_k)$ suivant les équations (2.21) (2.22) et (2.23),
- 3- calculer : $h_k = [J^T(w_k)J(w_k) + \mu_k I_n]^{-1} \times g(w_k)$,
- 4- calculer : $V(w_k + h_k)$ et R_k ,

Calcul du paramètre μ_k

- 5- Si $R_k \leq 0.25$ alors $\mu_{k+1} = 4\mu_k$,
- 6- Si $R_k \geq 0.75$ alors $\mu_{k+1} = \frac{\mu_k}{2}$ si non $\mu_{k+1} = \mu_k$,

Calcul de la correction des poids w_k

- 7- Si $R_k \leq 0$ alors $w_{k+1} = w_k$ si non $w_{k+1} = w_k + h_k$

Les constantes pour les valeurs seuils de R_k sont empiriques.

2.8 Conclusion

Dans ce chapitre, nous avons introduit différentes notions théoriques concernant les réseaux de neurones tel que l'architecture, l'activation et l'apprentissage. Chaque réseau est caractérisé par un certain nombre de paramètres (fonction d'activation, connexions des différents neurones du réseau,...etc.), en tenant compte de cela, nous aboutissons au réseau de neurones multicouches.

De manière générale les réseaux de neurones présentent un moyen efficace pour résoudre des problèmes pour lesquels, les méthodes classiques ont montré leurs limites, que cela soit en identification ou en commande, et les résultats obtenus sont appréciables.

Chapitre 3

Identification par Réseaux de Neurones de la colonne d'absorption

3.1 Introduction

La commande des processus chimique n'est pas une tâche aisée car leur complexité les rend souvent difficile à modéliser et à commander, ce qui justifie l'identification du processus. Les réseaux de neurones, jouent actuellement un très grand rôle en identification et commande de systèmes non linéaires. Leur intérêt réside dans leurs capacités d'apprentissage, de généralisation et d'approximation universelle de fonctions.

Si on dispose d'un réseau de neurones, d'un échantillon de données du processus pour entraîner le réseau et d'un algorithme d'apprentissage approprié. La question posée est quelle doit être la taille du réseau pour obtenir la meilleure généralisation possible?. L'approximation de fonctions complexes nécessite un réseau de grande taille avec de nombreuses couches cachées, cependant, outre l'inconvénient qu'il présente : temps de calcul élevé, un réseau surdimensionné risque de conduire à une mauvaise généralisation.

L'amélioration des capacités de généralisation est essentiellement expérimentale. Aucune méthode ne permet de déterminer précisément la structure du réseau en fonction des exemples à prendre pour fournir une généralisation optimale. Les travaux présentés par le mathématicien Vapnik [VAP82] offrent un cadre théorique sur l'application de la minimisation structurelle aux réseaux neuronaux. Même si ces travaux ne sont pas encore validés pratiquement, ils constituent une avancée remarquable sur le plan théorique. [BHA90].

Dans ce chapitre, nous présentons les étapes de modélisation neuronale, par l'acquisition de données expérimentales, le choix de la période d'échantillonnage et la généralisation du modèle d'identification neuronale.

3.2 Les étapes de Modélisation Neuronale

Il y a trois étapes dans la procédure de modélisation qui contribuent à la validité du modèle neuronal résultant :

- L'acquisition des données (constitution du fichier de données entrée/sortie).
- Le choix de la période d'échantillonnage T_e .
- La validation du modèle.

3.2.1 Acquisition des données

La première étape d'identification par réseaux de neurones consiste en la génération des données d'apprentissage. Un signal généralement utilisé est le RAS (Random Amplitude Signal) qui consiste en une succession de créneaux d'amplitude aléatoire et uniformément distribuée sur tout le domaine de fonctionnement de la colonne d'absorption.

3.2.2 Période d'échantillonnage

L'étude de la réponse du processus à un échelon de perturbation de débit de gaz en entrée, donnée un temps de réponse de 1.5 seconde. Cela nous suggère de choisir une période d'échantillonnage de 0.5 seconde.

3.2.3 Validation du Modèle Neuronale

Après apprentissage du réseau de neurones sur les données expérimentales, un test de validation du réseau est réalisé sur des données différentes de celles utilisées en apprentissage. Un programme sur MATLAB 7.5, nommé **colonneverif**, compare la sortie prédite \hat{y} est la sortie du processus y .

L'apprentissage du réseau de neurones est réalisé par le programme MATLAB 7.5, nommé **identificationneuronale**.

3.2.4 Modélisation Neuronale

Pour des raisons de simplicité, nous utiliserons un réseau de neurones à propagation directe. La détermination du modèle neuronal, comporte les éléments ci-dessous :

- définir le nombre d'entrée du réseau modélisateur
- fixer le nombre de couche
- définir les fonctions d'activation des neurones

3.3 Identification Neuronale de la colonne d'absorption

Nous supposons que le système à identifier est de la forme générale :

$$y(k) = f(y(k-1), y(k-2), \dots, y(k-n), u(k-1), u(k-2), \dots, u(k-m))$$

où $f(\cdot)$ est une fonction nonlinéaire, nous choisissons dans notre travail une fonction d'activation pour le réseau de neurones, la fonction sigmoïde. Nous prendrons également pour simplifier une seule couche cachée.

Par identification d'un processus nous entendons l'entraînement d'un réseau, pour reproduire une fonction donnant les sorties ou l'état du processus à partir des entrées.

Le principe général consiste à placer en parallèle le réseau et le processus à identifier, comme indiqué sur la (figure 3.1). Dans cette identification série-parallèle du système physique, on présente en entrée du réseau de neurones les entrées et sorties retardées du processus ($u(k-1), u(k-2), \dots, u(k-m)$) et ($y(k-1), y(k-2), \dots, y(k-n)$). La sortie ainsi obtenue du réseau de neurones est notée \hat{y} .

Durant la phase d'apprentissage on recueille $l+1$ échantillons des entrées et sorties retardées du système physique et les $\hat{y}(t), \hat{y}(t+1), \dots, \hat{y}(t+l)$ correspondant. On cherche alors à minimiser le critère d'erreur suivant :

$$J_1 = \sum_{i=0}^{i=l} ((y(t+i) - \hat{y}(t+i))^2) \quad (3.1)$$

Cette minimisation sera faite de manière itérative en utilisant en générale l'algorithme de rétropropagation du gradient ou la méthode de Levenberg-Marquardt.

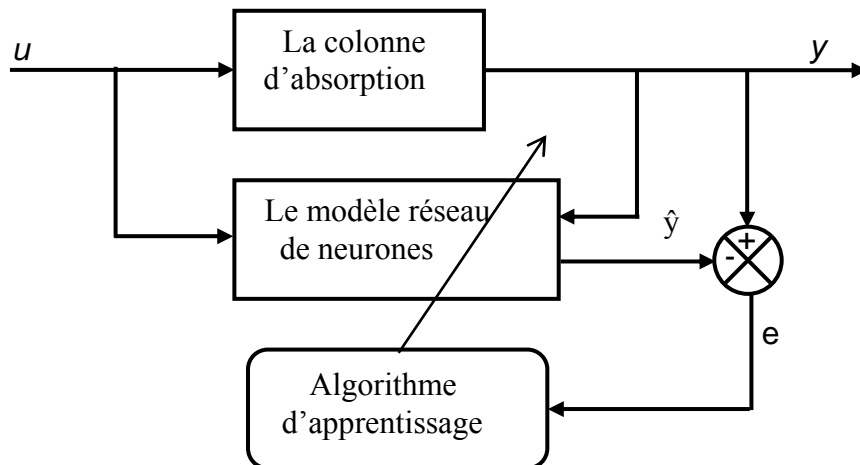


Figure 3.1. Schéma de modélisation neuronale

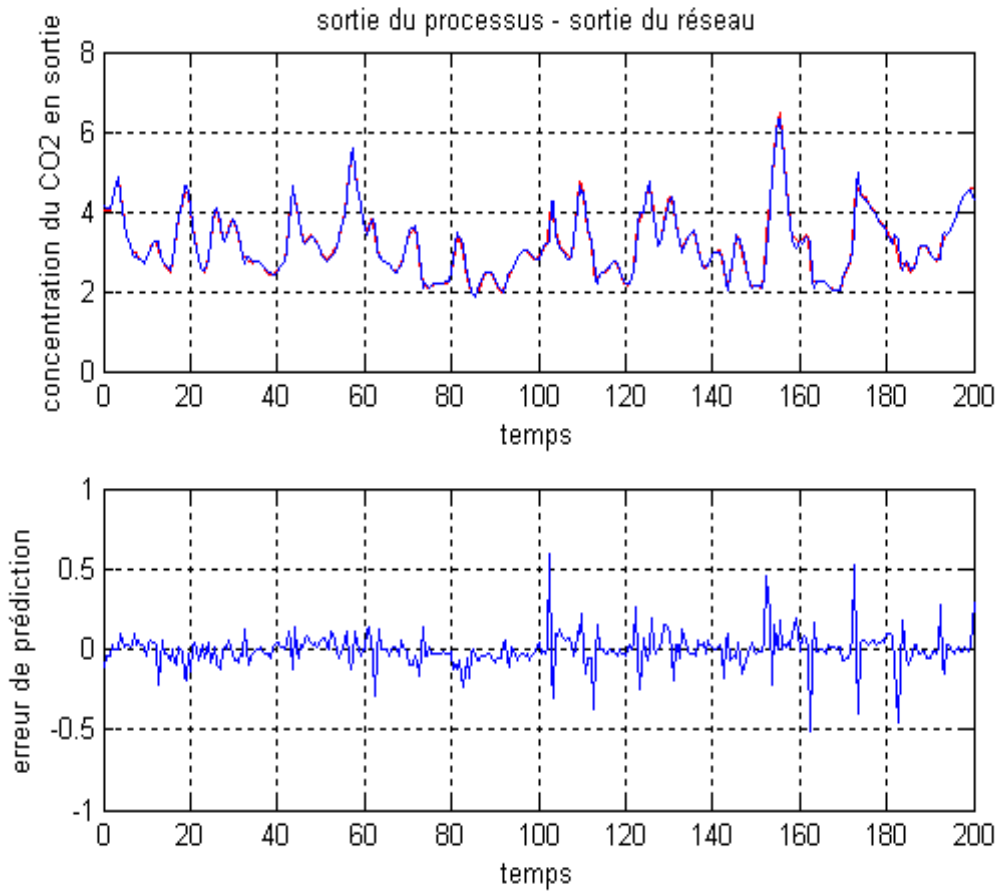

3.4 Résultats de Modélisation de la colonne d'absorption



Après plusieurs simulations sur un modèle à deux entrées et sorties retardées $((u(k), u(k-1), y(k), y(k-1)))$, nous avons retenu une couche cachée à 15 neurones. On effet, ce nombre est assez restreint pour simplifier les calculs tout en assurant une bonne identification.



Quatre modèles à plusieurs entrées et sorties retardées ont été élaborés :



- **modèle 1** : on considère comme entrées $u(k), u(k-1), y(k)$ et $y(k-1)$
- **modèle 2** : on considère comme entrées $u(k), y(k)$ et $y(k-1)$
- **modèle 3** : on considère comme entrées $u(k), u(k-1)$ et $y(k)$
- **modèle 4** : on considère comme entrées $u(k), u(k-1), u(k-2), y(k), y(k-1)$ et $y(k-2)$

L'entraînement préalable a été fait en prenant 400 échantillons ; afin d'apprendre au réseau à prendre en compte les perturbations en sortie. Un test de validation du réseau de neurones est fait sur un autre ensemble d'échantillons.

Modèle1 :**Apprentissage****Test validation**

Modèle2 :**Apprentissage****Test validation**

Modèle3 :**Apprentissage****Test validation**

Modèle4 :**Apprentissage****Test validation**

3.5 Critère de performance

Les deux critères suivant sont des indices de performances classiques. Nous utiliserons le critère I_1 qui met en relief les performances.

- **Intégral absolu erreur IAE**: ce critère détermine la déviation maximale entre la solution désirée et la sortie prédite. Ce critère est utilisé dans notre analyse des performances.

$$I_1 = \int |e(t)|$$

- **Intégral square erreur ISE** : ce critère permet d'évaluer l'erreur globale sur la solution et pénalise tous les écarts importants.

$$I_3 = \int (e(t))^2 dt$$

On considère pour une raison de normalisation la grandeur F tel que :

- **F : Somme absolu de sortie \hat{y}** :

$$F = \int |\hat{y}(t)|$$

Tableau comparatif des performances

Pour le choix du modèle adéquat et la conduite de notre analyse, nous nous sommes appuyés sur les indices de performances. Les résultats sont donnés au tableau 3.1.

Evaluation du Critère de performance	Modèle1	Modèle2	Modèle3	Modèle4
I_1	7,9421	9,4046	13,1817	14,0079
F	1271,4	1271,4	1271,8	1278,6
Rapport I_1 / F	0,00624	0,00739	0,01090	0,01095

Tableau 3.1: indices de performance

Finalement, nous choisissons le modèle1, car il présente les meilleures performances.

3.6 Conclusion

La colonne d'absorption est un système fortement non linéaire. Les réseaux de neurones sont des approximateurs non linéaire universels, d'où leur intérêt pratique. Leur application à l'identification de nombreux systèmes dynamiques a été couronnée de succès. Dans le cadre de ce travail, l'identification de la colonne d'absorption s'est faite avec un réseau possédant une seule couche cachée avec 15 neurones et a donné des résultats satisfaisants.

Les algorithmes du second ordre utilisés pour faire l'apprentissage des réseaux multicouches, comme l'algorithme de Levenberg-Marquardt assure en général une convergence plus rapide que celle du premier ordre. Nous constatons que l'écart entre la valeur désirée et la valeur prédite est faible, cela justifie donc l'emploi de réseau de neurones comme prédicteurs universels.

L'identification de la colonne d'absorption constitue une étape primordiale dans la synthèse de la commande, c'est le réseau de neurones estimateur qui sera à la base de l'élaboration d'une loi de commande qui nous donnera les performances désirées. Le contrôleur neuronal utilisé en commande sera l'objet du chapitre suivant.

Chapitre 4

Stratégies de Commande Neuronale de la colonne d'absorption

4.1 Introduction

La commande des processus faiblement non linéaires pouvant être approchées par des systèmes linéaires, est aujourd'hui un domaine bien maîtrisé par les Automaticiens. On peut obtenir pour ces systèmes des contrôleurs possédant de bonnes propriétés en stabilité, temps de réponse et amortissement. Cependant dans le monde réel, un grand nombre de processus sont caractérisés par un comportement dynamique non linéaire complexe, et cela rend difficile l'utilisation des outils classiques de l'Automatique. Il en est de même pour les systèmes pour lesquels les modèles mathématiques connus sont incomplets ou défaillants. Il n'existe pas aujourd'hui de théorie systématique applicable à la commande de tels processus. Pour résoudre ce problème une des solutions proposées consiste à avoir recours à un apprentissage pour reconnaître le modèle du processus ou du contrôleur.

Le terme apprentissage désigne ici la modification de structure et /ou des paramètres du système, de manière à améliorer ses performances futures, en se basant sur des observations expérimentales passées [BAK92].

Les RNA [HAN95] permettent d'approcher n'importe quelle fonction nonlinéaire car ce sont des approximateurs universels de fonctions. C'est cette propriété qui motive leur utilisation pour la réalisation de systèmes de commande non linéaire par apprentissage.

L'objectif de ce chapitre est de présenter l'application et l'adaptation d'algorithmes connus à la régulation de la colonne d'absorption. La première partie du chapitre présente l'application de la commande par équivalence certaine neuronale à la colonne d'absorption. La deuxième partie présente l'application des algorithmes de commande prédictive neuronale (Nnpc), qui permettent d'améliorer la rapidité du processus et de tenir compte efficacement des perturbations. La troisième partie, traite la commande neuronale à moyenne glissante Narma. Finalement, la dernière partie de ce chapitre présente une étude comparative des différentes stratégies de commandes appliquées à la colonne d'absorption.

4.2 Commande par équivalence certaine

Cette approche consiste à construire un modèle neuronal direct du processus. En supposant que le modèle coïncide parfaitement avec le processus réel (principe d'équivalence certaine), une stratégie de commande est établie en s'appuyant sur le réseau estimateur [RAN95].

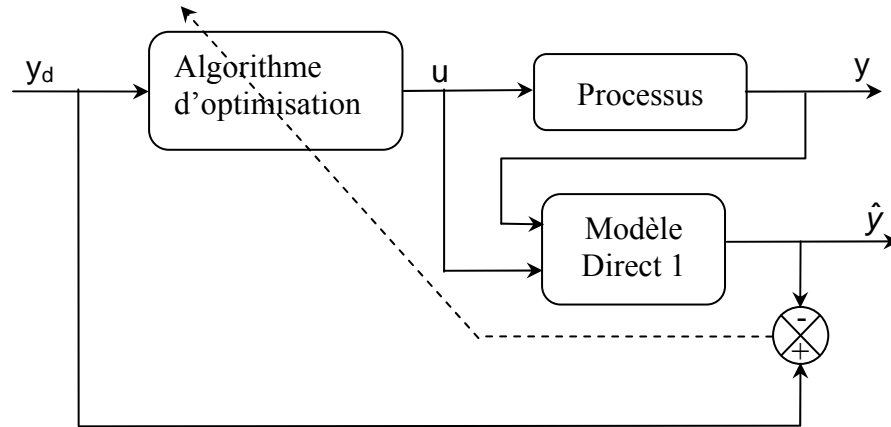


Figure 4.1 . Commande neuronale par identification du modèle neuronal direct

La stratégie de commande se base souvent sur des méthodes d'optimisation d'un critère portant sur les sorties prédites afin qu'elles soient le plus proche possible d'un comportement de référence et éventuellement sur les variables de commande afin d'assurer une conduite sans à-coups.

4.2.1 Description de la commande par équivalence certaine

L'objectif est de minimiser l'erreur entre la consigne et la sortie prédite par le réseau de neurones dont le comportement est supposé identique à celui du processus. Le critère choisi est :

$$J(k) = \frac{1}{2} (y_d(k+1) - \hat{y}(k+1))^2 \quad (4.1)$$

où $\hat{y}(k)$ représente la sortie prédite du processus (sortie du réseau de neurones) et $y_d(k)$ est la sortie désirée.

L'algorithme d'optimisation utilisé est une descente de gradient. La commande à appliquer à l'instant (k) est calculée à l'instant k tel que :

$$u(k) = u(k-1) + \Delta u(k) \quad (4.2)$$

Avec

$$\Delta u(k) = -\eta \frac{dJ}{du} = -\eta \frac{dJ}{d\hat{y}} \frac{d\hat{y}}{du} \quad (4.3)$$

$$\Delta u = \eta (y_d(k+1) - \hat{y}(k+1)) \frac{d\hat{y}(k+1)}{du(k)} \quad (4.4)$$

$u(k)$ n'étant pas disponible à l'instant k , on approxime par :

$$(y_d(k+1) - \hat{y}(k+1)) \frac{d\hat{y}(k+1)}{du(k)} \approx (y_d(k) - \hat{y}(k)) \frac{d\hat{y}(k)}{du(k-1)} \quad (4.5)$$

où η est le pas de descente de gradient

Pour simplifier, on prend un réseau de neurones avec une seule couche cachée. Par tâtonnement le nombre de neurones optimal est pris égale à 15. On considère un réseau de neurones à 4 entrées.

La fonction d'activation des neurones de la couche cachée est donné par :

$$A_i = \sum_{j=1}^4 w_{eij} p_j + b_{ei} \quad (4.6)$$

Où les p_j sont les composantes du vecteur d'entrée P défini par :

$$P = \begin{bmatrix} u(k) \\ u(k-1) \\ y(k) \\ y(k-1) \end{bmatrix} \quad (4.7)$$

La sortie du réseau de neurones est donnée par :

$$\hat{y} = \sum_{i=1}^{15} w_{si} f(A_i) + b_s \quad (4.8)$$

Avec :

w_{eij} sont les éléments de la matrice $W_e(15 \times 4)$ des poids de la couche d'entrée.

w_{si} sont les éléments du vecteur $W_s(15 \times 1)$ des poids de la couche de sortie.

b_{ei} sont les éléments du vecteur $B_e(15 \times 1)$ des biais des neurones de la couche cachée.

b_s scalaire est le biais du neurone de la couche de sortie.

Alors

$$\frac{d\hat{y}}{du} = \sum_{i=0}^{15} w_{si} \frac{df(A_i)}{du} \quad (4.9)$$

La fonction d'activation utilisée pour la couche cachée est la tangente hyperbolique (sigmoïde) :

$$f(A_i) = \frac{\exp(A_i) - \exp(-A_i)}{\exp(A_i) + \exp(-A_i)} \quad (4.10)$$

En utilisant 4.7. on obtient :

$$\frac{df(A_i)}{du} = \frac{4w_{ei1}}{(\exp(A_i) + \exp(-A_i))^2} \quad (4.11)$$

4.2.2 Application à la commande de la colonne d'absorption

Le schéma de principe du système de commande est représenté par la figure 4.2

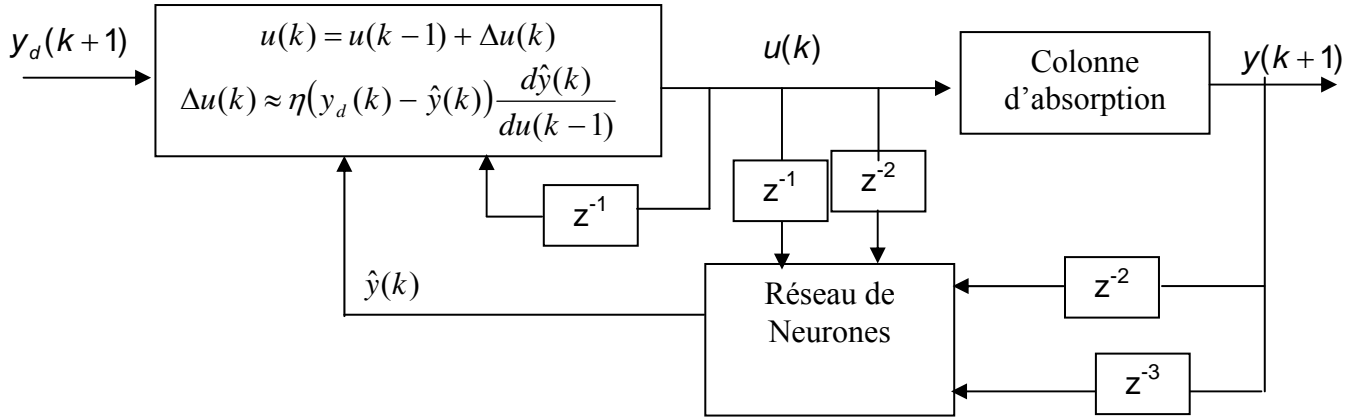


Figure 4.2 . Schéma de principe du système de commande

Remarque :

On a :

$$u(k) = u(k-1) + \Delta u(k) \quad (4.12)$$

$$\Delta u(k) \approx \eta(y_d(k) - \hat{y}(k)) \frac{d\hat{y}(k)}{du(k-1)} \quad (4.13)$$

Avec cette formule, on garantit la convergence de $\hat{y}(k+1)$ vers y_d , mais comme $\hat{y}(k+1)$ diffère de $y(k+1)$ à cause des erreurs d'identification, on observera un biais en régime permanent.

Pour supprimer ce biais on remplace dans la formule $y_d(k+1) - \hat{y}(k+1)$ par $y_d(k+1) - y(k+1)$ dans le programme.

Nous présentons donc les résultats de notre simulation pour différentes perturbations sur la concentration de gaz en entrée et sur le débit de gaz en entrée :

4.2.3 Résultat de simulation

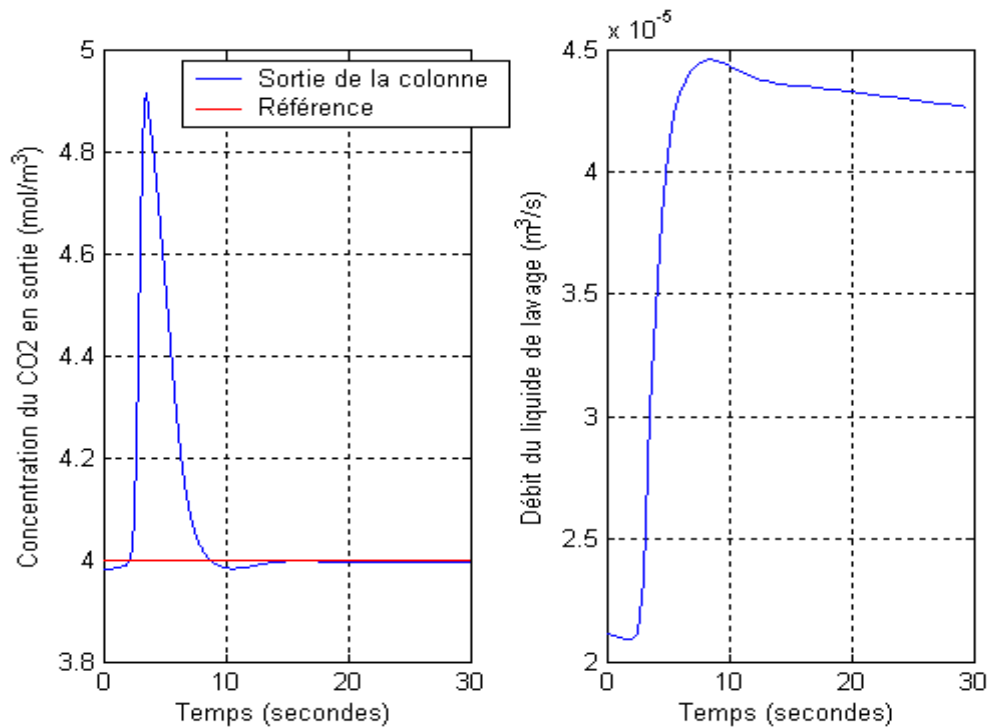


Figure 4.3. Concentration du CO₂ en sortie pour un échelon de perturbation de +20% sur la concentration de gaz en entrée de la colonne




Figure 4.4. Concentration du CO₂ en sortie pour un échelon de perturbation de -20% sur la concentration de gaz en entrée de la colonne




Figure 4.5. Echelon de perturbation de + 10% sur le débit de gaz en entrée de la colonne




Figure 4.6. Echelon de perturbation de - 10% sur le débit de gaz en entrée




Figure 4.7. Echelon de perturbation de + 20% sur le débit de gaz en entrée




Figure 4.8. Echelon de perturbation de - 20% sur le débit de gaz en entrée




Figure 4.9. Concentration en sortie du CO₂ et débit du liquide de lavage pour une variation de consigne de 3.996 à 4.5 mole/m³




Figure 4.10. Concentration en sortie du CO₂ et débit du liquide de lavage pour une variation de consigne de 3.996 à 3.0 mole/m³




Figure 4.11 Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de +15% sur la concentration de CO₂ en entrée de la colonne et de +10% sur le débit de gaz en entrée




Figure 4.12 Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de -15% sur la concentration de CO₂ en entrée de la colonne et de -10% sur le débit de gaz en entrée

4.3 Commande prédictive neuronale de la colonne d'absorption (Nnpc)

Des travaux antérieurs ont porté sur l'application de la commande prédictive généralisée linéaire à la colonne d'absorption [BOU01], mais il est intéressant d'utiliser une méthode non linéaire, car la relation entre débit de MEA et l'absorption du CO_2 est fortement non linéaire. La commande neuro-prédictive nous a paru prometteuse car tout en gardant les caractéristiques de la commande prédictive, elle permet d'utiliser les capacités d'apprentissage et de généralisation des réseaux de neurones, ce qui est fort pratique quand on a affaire à des processus dont la dynamique est fortement non linéaire.

4.3.1 Principe de la commande prédictive neuronale

Le principe de base de cet algorithme est d'utiliser un modèle pour bâtir une prédiction du comportement futur du procédé. Cette prédiction est comparée au comportement désiré, ce qui permet de déterminer les modifications de la commande à effectuer sur un horizon donné pour atteindre la référence. Comme dans la commande prédictive généralisée linéaire, à chaque itération, seule la première action de commande calculée est appliquée au procédé. La figure 4.13 résume les éléments principaux de cette stratégie.

Le prédicteur emploie un modèle basé sur un réseau de neurones pour prédire le comportement futur du système. Le contrôleur calcule alors la commande qui optimise les performances du système sur un horizon de temps spécifié. La première étape dans le processus de conception de la commande prédictive neuronale est donc de déterminer le réseau de neurones qui assure une identification valide du système. Ce réseau de neurones est ensuite utilisé par le contrôleur pour prédire les futures actions de commande.

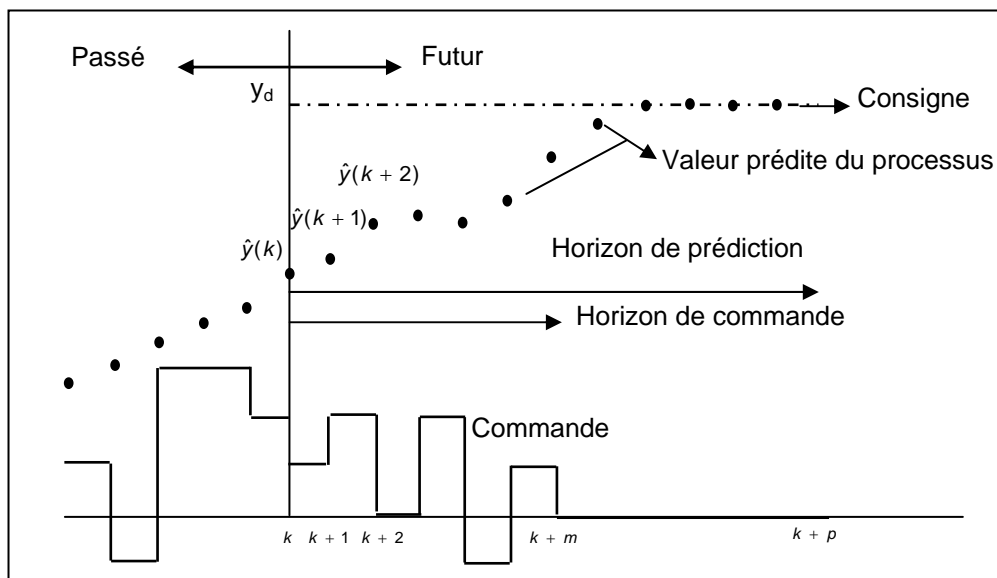


Figure 4.13. Principe de la commande prédictive

4.3.2 Algorithme pour la commande prédictive neuronale

Les stratégies de commande prédictive sont basées sur la technique d'horizon de prédiction [SOL96]. Le réseau de neurones prédit la réponse du système sur un intervalle de temps spécifié. La prédiction est utilisée par le programme d'optimisation pour déterminer le signal de commande qui minimise le critère de performance ci-dessous sur l'horizon de prédiction considéré.

$$J = \sum_{j=N_1}^{N_2} (y_d(t+j) - \hat{y}(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (4.14)$$

Où $U'(t)$ est le vecteur de commandes tests :

$$U'(t) = [u'(t) \dots \dots \dots u'(t + N_u - 1)]^T \quad (4.15)$$

$$u'(t+j) = u'(t + N_u - 1) \quad \text{pour } j \geq N_u \quad (4.16)$$

N_1 et N_2 définissent l'horizon sur lequel l'erreur est évaluée, N_u définit l'horizon sur lequel le signal commande est évalué. La variable y_d est la réponse désirée et \hat{y} est la sortie du modèle de réseau de neurones. La valeur de ρ détermine la contribution des commandes tests dans le critère de performance. Le critère J est minimisé en utilisant un algorithme d'optimisation itératif. Il en existe plusieurs, le principal est l'algorithme BFGS qui est une méthode quasi Newton avec recherche sur une ligne [DEN83].

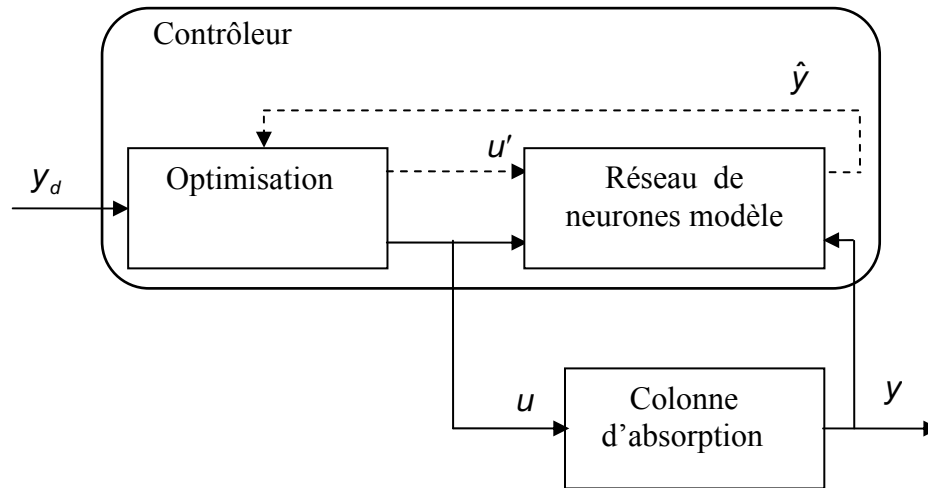


Figure 4.14 Schéma de la commande prédictive neuronale

Le diagramme de la figure ci-dessus illustre la stratégie de commande prédictive neuronale. Le contrôleur est composé d'un réseau de neurones modèle et d'un bloc d'optimisation. Le bloc d'optimisation applique sur le modèle neuronal le vecteur de commande test $U'(t)$. Le critère J est d'abord évalué sur le modèle neuronal et ensuite optimisé de manière itérative, en fonction de U' jusqu'à obtention de résultat satisfaisant. Le vecteur de commande test $U'(t)$ devient alors le vecteur de commande $u(t)$ qui est appliqué au système physique.

Les aspects importants de l'algorithme de la commande Nnpc sont :

- quand on minimise la fonction de coût (4. 12), on considère $N_u \leq N_2$. Si les variations des futurs points de réglage sont inconnus, on se contente de maintenir l'action de commande au delà de N_u .
- Le contrôleur a quatre paramètres à régler N_1 , N_2 , N_u et ρ . N_1 devrait être choisi équivalent au temps mort t_d [SOL96],[DRA96]. Puisque $u'(t)$ n'a aucun effet sur les sorties $\hat{y}(t + j)$ avec $j < t_d$. Ainsi les paramètres principaux à régler sont N_2 , N_u et ρ .

Nous présentons maintenant les résultats de simulation obtenus avec N_1 est fixé à 1, N_2 à 4, N_u à 4 et ρ à 4×10^9 , et ce pour une entrée de perturbation sur la concentration du gaz en entrée de la colonne d'absorption.

4.3.3 Simulation pour un échelon de perturbation sur la concentration de gaz en entrée




Figure 4.15. Concentration du CO₂ en sortie pour un échelon de perturbation de +20% sur la concentration de gaz en entrée de la colonne




Figure 4.16. Concentration du CO₂ en sortie pour un échelon de perturbation de -20% sur la concentration de gaz en entrée de la colonne

On constate une erreur en régime permanent due aux erreurs de modélisation. Pour remédier à ce problème, dès que l'erreur approche un voisinage de la référence, on switche sur un régulateur PI dit de régime permanent (la largeur de la zone est fixée à 4% de la référence).

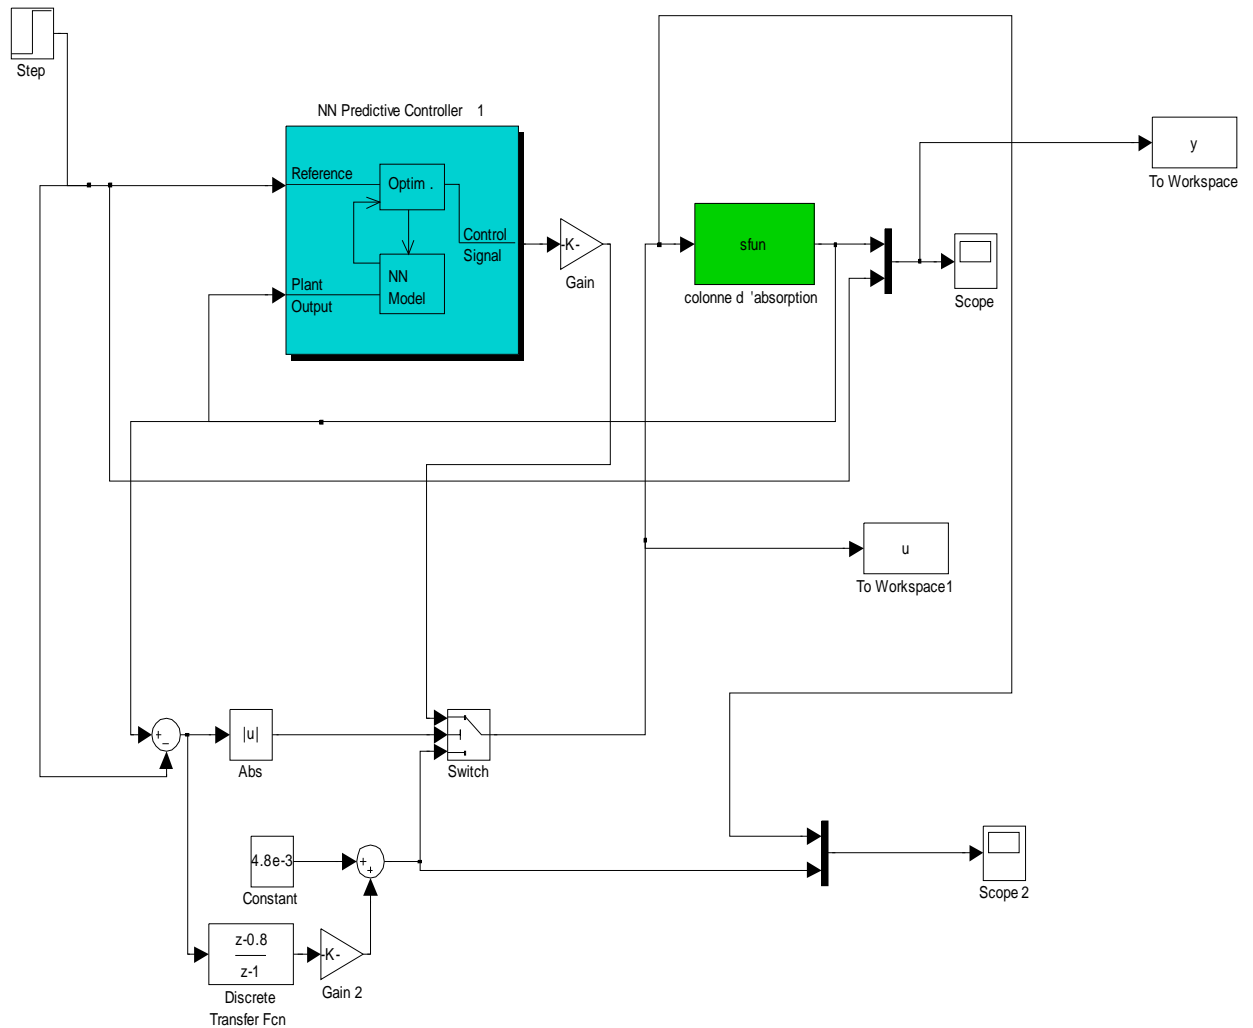


Figure 4.17. Commande neuronale Nnpc avec régulateur PI

Nous présentons les résultats de simulations de la colonne d'absorption avec le régulateur PI de régime permanent.

4.3.4 Simulation avec régulateur PI




Figure 4.18. Concentration du CO₂ en sortie pour un échelon de perturbation de +20% sur la concentration de gaz en entrée de la colonne




Figure 4.19. Concentration du CO₂ en sortie pour un échelon de perturbation de -20% sur la concentration de gaz en entrée de la colonne




Figure 4.20 Concentration du CO₂ en sortie pour un échelon de perturbation de +10% sur la concentration de gaz en entrée de la colonne




Figure 4.21 Concentration du CO₂ en sortie pour un échelon de perturbation de -10% sur la concentration de gaz en entrée de la colonne




Figure 4.22. Echelon de perturbation de + 10% sur le débit de gaz en entrée




Figure 4.23. Echelon de perturbation de - 10% sur le débit de gaz en entrée




Figure 4.24. Echelon de perturbation de + 20% sur le débit de gaz en entrée




Figure 4.25. Echelon de perturbation de - 20% sur le débit de gaz en entrée




Figure 4.26. Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de +15% sur la concentration de CO₂ en entrée de la colonne et de +10% sur le débit de gaz en entrée




Figure 4.27. Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de -15% sur la concentration de CO₂ en entrée de la colonne et de -10% sur le débit de gaz en entrée

4.4 La commande neuronale NARMA

La commande NARMA (Non linear Autoregressive Moving Average) permet la linéarisation d'un système non-linéaire [Matlab 7.5] particulier. Le contrôleur neuronal est ici simplement un réarrangement d'un modèle neuronal du processus, qui est entraîné hors ligne en batch. Le seul calcul effectué en ligne est un passage direct à travers le contrôleur neuronal, ce qui permet un calcul rapide. L'inconvénient de cette méthode est que le système doit être affine en la commande ou être correctement approché par un système affine en la commande.

$$x(k+1) = f[x(k), \dots, x(k-n+1), u(k-1), \dots, u(k-n+1)] + g[x(k), \dots, x(k-n+1), u(k-1), \dots, u(k-n+1)] \times u(k) \quad (4.17)$$

4.4.1 Principe de la commande NARMA

Comme dans la méthode de la commande neuro-prédictive, la première étape consiste en l'identification du réseau de neurones. Une structure de représentation particulière est choisie afin de faciliter le calcul de la commande nécessaire. On approxime ainsi la sortie $y(k+d)$ par :

$$\hat{y}(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)] + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)] \times u(k) \quad (4.18)$$

où : $u(k)$ est l'entrée du système et $y(k)$ est la sortie.

Dans cette représentation, on remarque que $u(k)$ n'est pas contenu dans la non-linéarité, ainsi si l'on veut suivre une trajectoire de référence $\hat{y}(k+d)=y_r(k+d)$, on doit choisir $u(k)$ tel que :

$$u(k) = \frac{y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]}{g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]} \quad (4.19)$$

$u(k)$ est ainsi obtenu aisément. Mais on suppose ici que $y(k)$ est connu à l'instant k ce qui peut poser des problèmes de réalisation, si l'acquisition des sorties $y(k)$ est lente. Pour éviter ce problème, Matlab considère la représentation pour pour $d \geq 2$:

$$y(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k), \dots, u(k-n+1)] + g[y(k), y(k-1), \dots, y(k-n+1), u(k), \dots, u(k-n+1)] \times u(k+1) \quad (4.20)$$

Une dernière remarque est que $g[y(k), y(k-1), \dots, u(k-1), \dots, u(k-n+1)]$ doit garder le même signe pour que la commande ne diverge pas.

Contrôleur neuronal NARMA

$$u(k) = \frac{y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]}{g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]} \quad (4.21)$$

4.4.2 Application de la commande neuronale NARMA à la colonne d'absorption

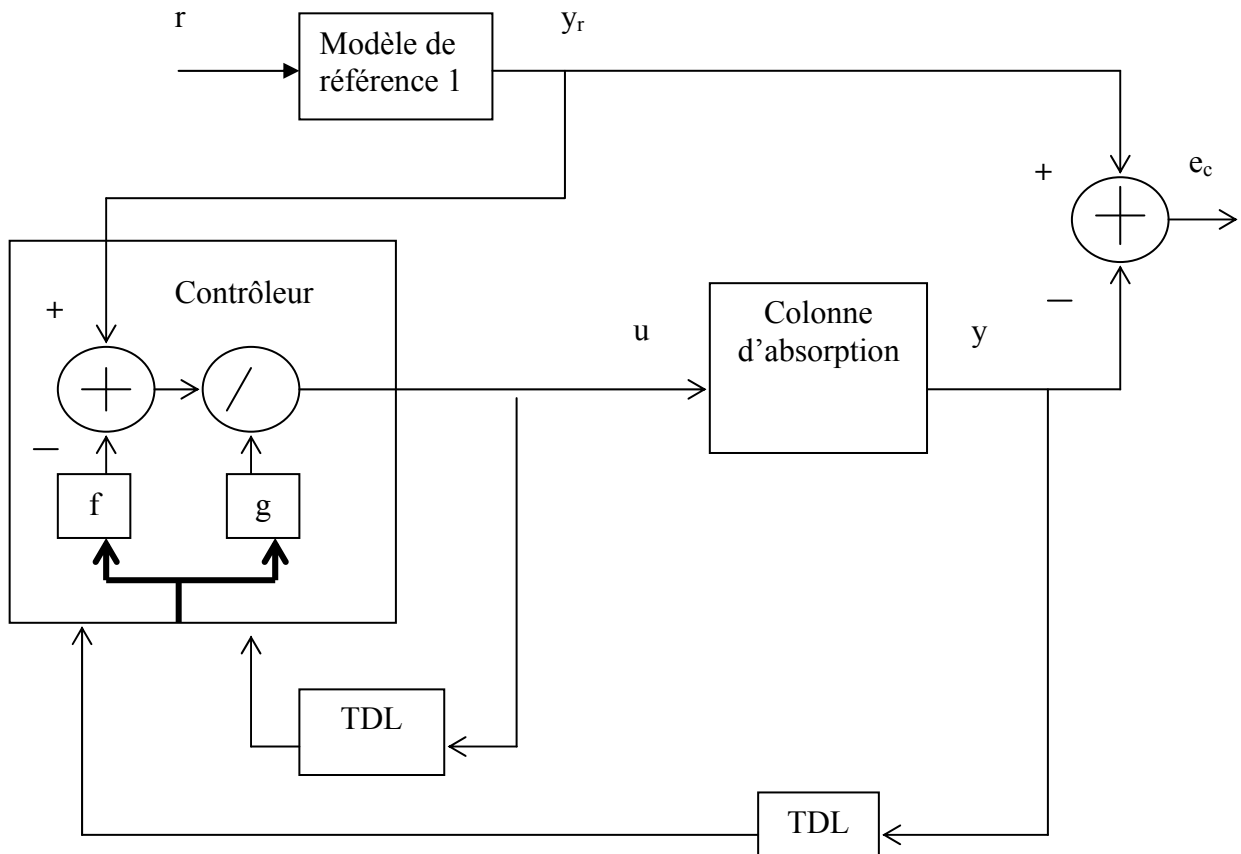


Figure 4.28. Commande NARMA de la colonne d'absorption

Les fonctions f et g constituent un réseau de neurones à entraîner par apprentissage en offline. Le schéma descriptif est donné comme suit :

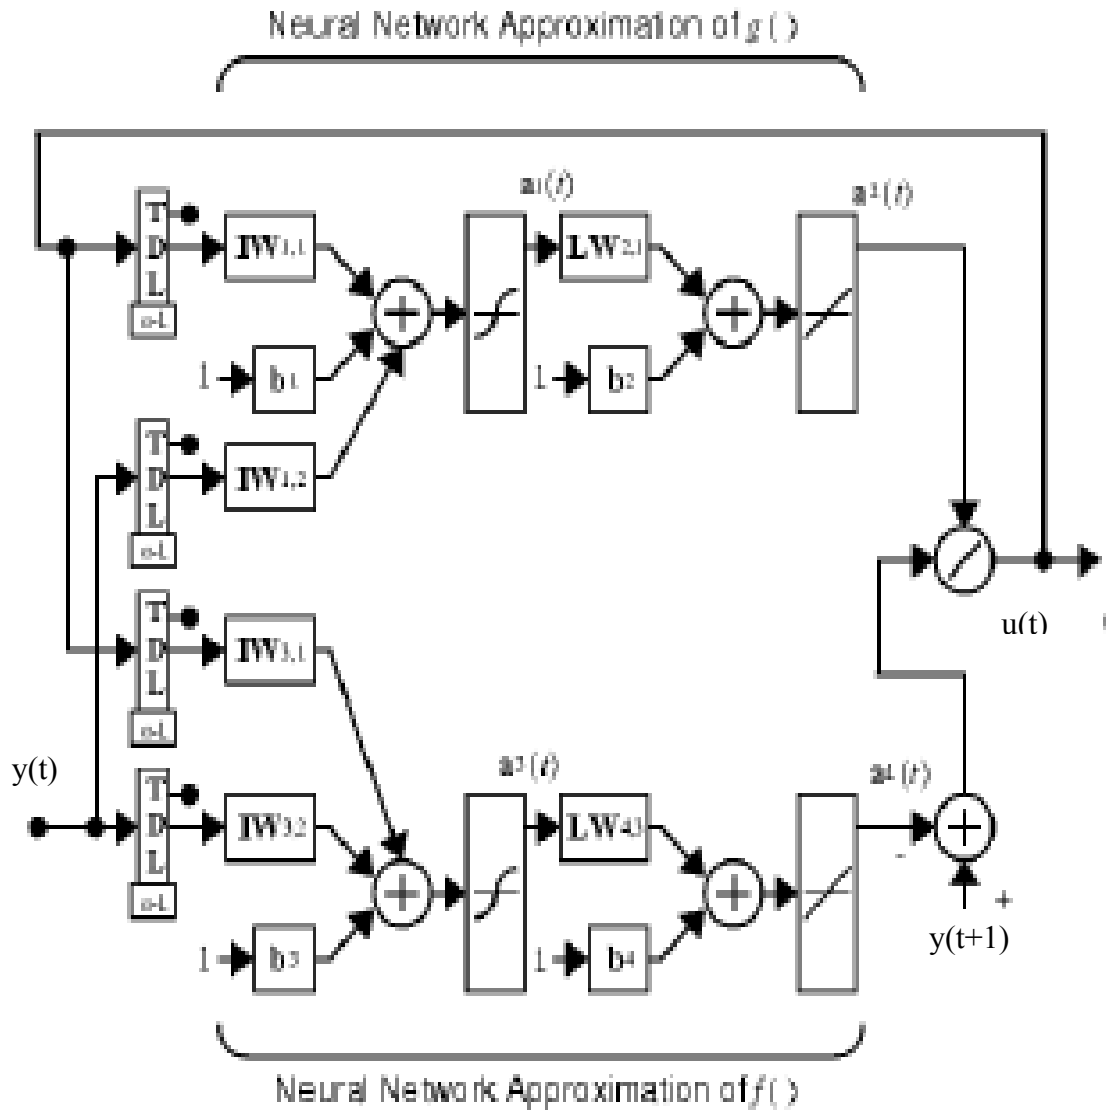


Figure 4.29. Implémentation du contrôleur NARMA

Nous simulons à présent la régulation de la colonne d'absorption pour une entrée de perturbation de concentration gaz en entrée :

4.4.3 Simulation pour un échelon de perturbation sur la concentration de gaz en entrée




Figure 4.30. Concentration du CO₂ en sortie pour un échelon de perturbation de +20% sur la concentration de gaz en entrée de la colonne




Figure 4.31. Concentration du CO₂ en sortie pour un échelon de perturbation de -20% sur la concentration de gaz en entrée de la colonne

On constate une erreur en régime permanent dûe :

- aux erreurs de modélisation
- à l'erreur d'approximation sur \hat{g} qui entraîne une oscillation de part et d'autre de la valeur moyenne en régime permanent

Pour remédier à ce problème, dès que l'erreur approche un voisinage de la référence, on switche sur un régulateur PI dit de régime permanent (la largeur de la zone est fixée à 5% de la référence).

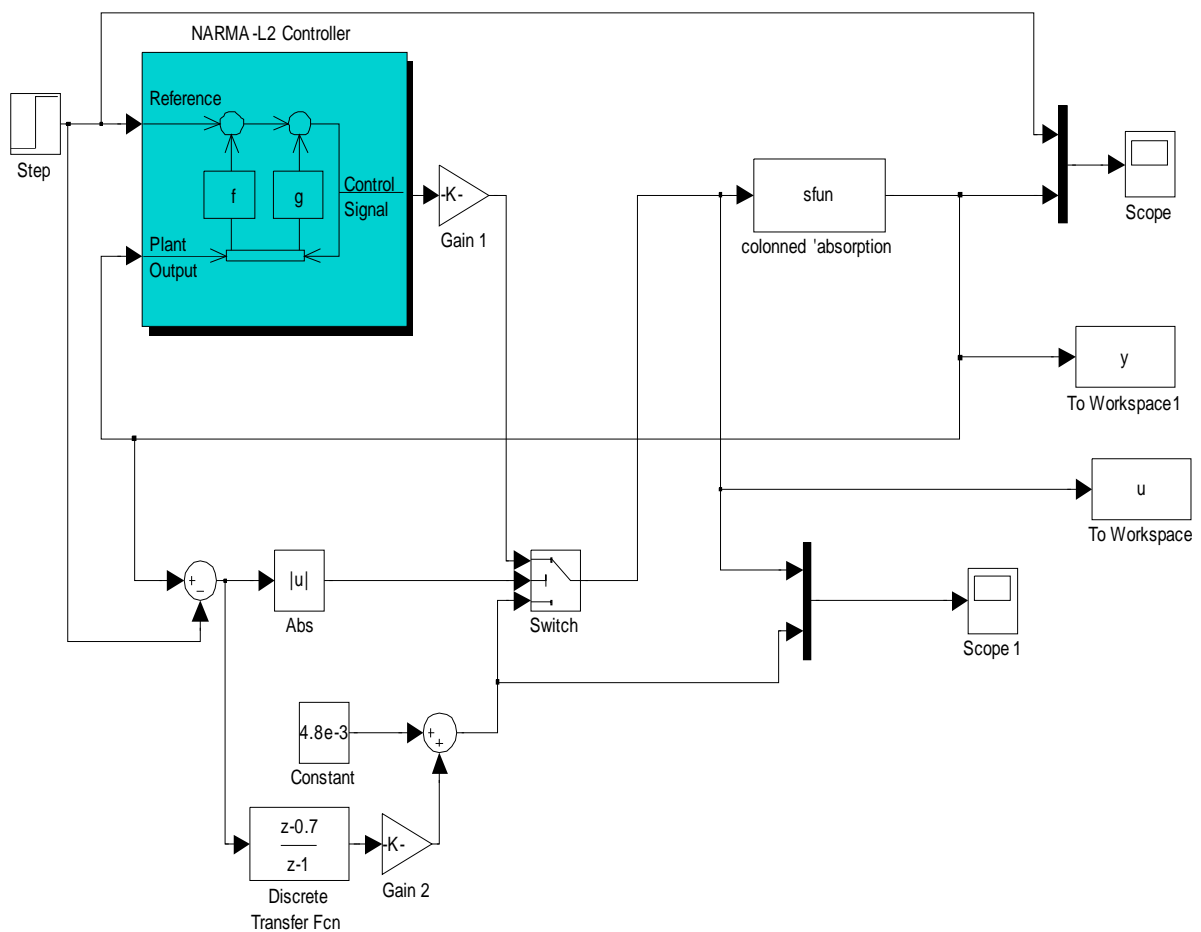


Figure 4.32 . Commande neuronale NARMA avec régulateur PI

Nous simulons la régulation de la colonne d'absorption selon le schéma ci-dessus avec un régulateur PI pour différentes entrées de perturbations de gaz en entrée:

4.4.4 Simulation avec régulateur PI

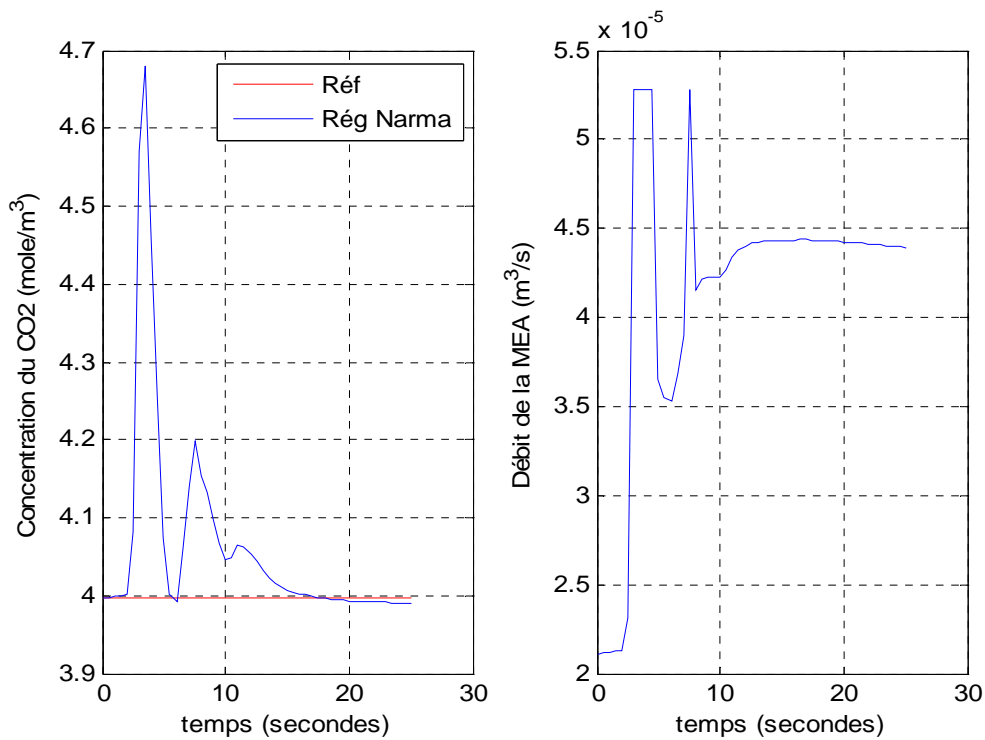


Figure 4.33. Concentration du CO₂ en sortie pour un échelon de perturbation de +20% sur la concentration de gaz en entrée de la colonne




Figure 4.34. Concentration du CO₂ en sortie pour un échelon de perturbation de -20% sur la concentration de gaz en entrée de la colonne




Figure 4.35. Concentration du CO₂ en sortie pour un échelon de perturbation de +10% sur la concentration de gaz en entrée de la colonne




Figure 4.36. Concentration du CO₂ en sortie pour un échelon de perturbation de -10% sur la concentration de gaz en entrée de la colonne




Figure 4.37. Echelon de perturbation de + 10% sur le débit de gaz en entrée




Figure 4.38. Echelon de perturbation de - 10% sur le débit de gaz en entrée




Figure 4.39. Echelon de perturbation de + 20% sur le débit de gaz en entrée




Figure 4.40. Echelon de perturbation de - 20% sur le débit de gaz en entrée




Figure 4.41. Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de +15% sur la concentration de CO₂ en entrée de la colonne et de +10% sur le débit de gaz en entrée




Figure 4.42. Concentration en sortie du CO₂ et débit du liquide de lavage pour des perturbations de -15% sur la concentration de CO₂ en entrée de la colonne et de -10% sur le débit de gaz en entrée

4.5. Interprétation

Commande par équivalence certaine

Les figures (fig 4.3) à (fig 4.10) représentent l'évolution de la concentration de CO₂ en haut de la colonne en fonction des perturbations intervenant sur la concentration de CO₂ en entrée de la colonne ainsi que sur le débit de gaz, nous avons également étudié le cas du changement de consigne (fig 4.9) et (fig 4.10).

Ces figures, montrent la robustesse de la commande par équivalence certaine pour différentes perturbations. Pour un changement de consigne, notre sortie converge rapidement vers la consigne. La consigne est atteinte au bout de 10 secondes. La régulation synthétisée est ainsi robuste par rapport aux perturbations.

Les résultats obtenus en simulation sont satisfaisants. Cette stratégie a une bonne aptitude à conduire le système vers la valeur de consigne. On remarque également que les temps de réponse sont plus courts et moins sensibles au signe des perturbations que pour le régulateur PI.

Commande neuro-prédictive

Les figures (fig 4.15) et (fig 16) représentent l'évolution de la concentration de CO₂ en haut de la colonne en fonction des perturbations intervenant sur la concentration de CO₂ en entrée. On remarque une erreur en régime permanent due aux erreurs de modélisation par réseaux de neurones. Cela justifie l'utilisation d'un régulateur de régime permanent (fig 4.18) à (fig 4.27).

Le régulateur assure la stabilité du système et donne de bons résultats du point de vue de la convergence vers la consigne. A cause de l'algorithme d'optimisation de la commande appliquée au processus, le calcul de la commande est plus lent, la réponse est par contre non oscillatoire. La régulation assure ainsi la robustesse par rapport aux perturbations.

On remarque également que les temps de réponse sont plus courts et moins sensibles au signe des perturbations que pour la régulation PI.

Commande neuronale NARMA

Les figures (fig 4.30) et (fig 31) représentent l'évolution de la concentration de CO₂ en haut de la colonne en fonction des perturbations intervenant sur la concentration de CO₂ en entrée. On remarque une erreur en régime permanent due aux erreurs de modélisation ainsi que l'erreur d'approximation sur \hat{g} , ce qui entraîne une oscillation de part et d'autre de la valeur moyenne en régime permanent. Cela justifie l'utilisation d'un régulateur de régime permanent (fig 4.33) à (fig 4.42).

Le régulateur assure la stabilité du système et donne de bons résultats du point de vue de la rapidité de la convergence vers la consigne, ainsi que pour la robustesse par rapport aux perturbations.

On remarque également que la régulation Narma assure des temps de réponse très courts et moins sensibles au signe des perturbations que pour la régulation PI et la régulation neuro-prédictive.

4.6. Comparaison entre les différentes techniques de commande

Les résultats obtenus sont satisfaisants, les réponses du système aux commandes par équivalence certaine et commande Narma, pour les perturbations sur la concentration de CO₂ en entrée sont rapides, et la sortie converge vers la consigne grâce au régulateur intégrateur de régime permanent. Pour ce qui est des perturbations sur le débit de gaz en entrée, les performances obtenues sont bien meilleures que pour la régulation PI déjà développées et cela aussi bien du point de vue temps de réponse que de la stabilité par élimination des oscillations.

La commande par équivalence certaine est relativement simple à calculer et à implémenter et assure de bonnes performances dynamiques.

La commande neuronale Narma présente une réponse rapide par rapport aux deux autres techniques de commande neuronale.

La commande neuronale prédictive a une dynamique plus lente à cause de l'optimisation d'un critère de coût sur un horizon élargi. Elle assure par contre de bonne performance et une erreur faible en régime permanent en l'absence de régulateur de régime permanent. On remarque qu'il n'y a pas d'oscillation de la concentration de CO₂ autour de la valeur de consigne.

On peut noter que pour les deux dernières commandes neuro-prédictive et Narma, on est obligé d'insérer un régulateur PI de régime permanent pour assurer la convergence de la sortie vers la consigne et ce pour supprimer le biais dû aux erreurs de modélisation.

Conclusion Générale

Conclusion Générale

Les travaux présentés dans ce mémoire ont pour objectif d'appliquer des techniques de commande neuronale afin de répondre aux objectifs de robustesse et d'assurer la régulation de la colonne d'absorption pilote à garnissage.

La commande des processus chimique n'est pas une tâche aisée car leur complexité les rend souvent difficiles à modéliser et à commander, ce qui justifie une identification du processus. L'approche classique basée sur la théorie des systèmes linéaires a obtenu un très grand succès dans les milieux industriels. Cependant, la nécessité d'atteindre de hautes performances a imposé la prise en compte de la dynamique globale non linéaire des processus dans la synthèse de la commande.

Les réseaux de neurones, nous paraissent idéals car ils ont des capacités d'apprentissage, de généralisation et d'approximation universelle de fonctions. Ce qui fait qu'il jouent actuellement un très grand rôle en identification et en commande des processus.

Dans le premier chapitre, nous avons développé un modèle mathématique dynamique décrivant le processus d'absorption de CO_2 dans une colonne à garnissage opérant à contre courant en se basant sur les principes fondamentaux du transfert de matière et les équations du bilan de matière. Le modèle obtenu est non linéaire aux dérivées partielles et prend en compte une réaction du deuxième ordre. Les relations décrivant le système ont pu être établies en considérant que $C_{BL}(x)$ n'était pas constante dans le sens transversal ni le long de la colonne. Puis, nous avons utilisé la fonction pdepe afin de pouvoir simuler le comportement dynamique de notre colonne.

Les simulations numériques de la réponse à un échelon de perturbation pour différentes amplitudes que ce soit sur les concentrations ou bien sur les débits, nous ont permis d'étudier les différents aspects structurels de notre système ainsi que les propriétés de ce modèle, à savoir : stabilité en boucle ouverte, nature fortement non linéaire du système, et présence d'un temps mort sur les perturbations en concentration dû à la propagation du gaz le long de la colonne d'absorption. Les simulations mettent également en évidence la dynamique très lente de la concentration de la MEA et sa faible influence sur la concentration de CO_2 .

Nous avons ensuite appliqué une régulation PI à notre système, et ce dans le but de comparer les résultats donnés par une approche classique de commande avec ceux donnés par des approches avancées telle que les réseaux de neurones. Les résultats obtenus en simulation sont satisfaisants, le régulateur PI prend en charge les perturbations sur les concentrations et le débit. Mais nous constatons que le système présente en régulation PI un très net comportement asymétrique dû à la forte non linéarité de la sortie par rapport à la commande choisie qui est le débit du liquide de lavage.

Dans le troisième chapitre, nous avons commencé par présenter l'aspect identification, qui est une étape primordiale dans la synthèse de la commande. Cela, nous a permis de déterminer la structure optimale d'identification par réseaux de neurones.

Dans le dernier chapitre, nous avons appliqué trois techniques de commande basées sur les réseaux de neurones : la commande par équivalence certaine, la commande neuro-prédictive (Nnpc) et la commande neuronale Narma. Nous avons présenté les résultats de simulation obtenus par l'application de ces stratégies de commande neuronale pour le points de fonctionnement considéré de la colonne d'absorption pilote et ce pour différentes perturbations intervenant sur la concentration de CO_2 , le débit de gaz en entrée ainsi qu'une variation imposée de consigne.

Afin d'annuler les erreurs sur l'identification et la modélisation, nous avons inséré en fin de course un régulateur intégrateur pour les commandes neuro-prédictive(Nnpc) et Narma. Les résultats de simulation montrent bien l'efficacité de la loi de commande pour la régulation.

Les simulations montrent que malgré la complexité de notre système non linéaire et à paramètres répartis, nous obtenons avec les stratégies de commande neuronales des performances très satisfaisantes et une grande robustesse par rapport aux perturbations sur la concentration de CO₂ à l'entrée de la colonne et sur le débit de gaz en entrée. Les commandes par équivalence certaine et Narma, donnent des dynamiques rapides et la commande neuro-prédictive, bien qu'exigeante en calcul, nous donne une réponse sans oscillation et une erreur faible en régime permanent en l'absence de régulateur de fin de course.

On constate également que la régulation neuronale améliore nettement les résultats obtenus avec une simple régulation PI non seulement du point de vue du temps de réponse mais également par l'homogénéité des réponses aux perturbations aussi bien positives que négatives.

A l'issue de ces travaux, cette thèse ouvre de nouvelles perspectives de recherche parmi lesquelles nous citons:

- L'extension de la modélisation à des colonnes d'absorption industrielles et le test des commandes développées à des systèmes réels.
- L'application d'autres stratégies de commande telle que la commande par mode de glissement.

Bibliographie

- [**ABE02**] Aberkane.S, BABAAMMI.D «Commande neuro floue appliquée à une colonne d'absorption», PFE, ENP, Alger, 2002.
- [**ALL07**] Allad.M, «technique de commande moderne appliqué aux bioréacteurs». Thèse de Magister, ENP, Alger, 2007.
- [**BAT92**] Battiti,R.«First and second order methods for learning :Between steepest descent and Newton's method».Neural Computation,vol.4,N°.2,pp. 141-166, (1992)
- [**BOU01**] Boulrouah.M.A, «Commande prédictive généralisée appliquée à une colonne d'absorption», PFE, ENP, Alger, 2001.
- [**BEZ07**] Bezzaoucha.S, «Commandes Floues d'une Colonne d'absorption». Thèse de Magister, ENP, Alger, 2007.
- [**BAK92**] Baker. W. L and Farrell. J. A., «An introduction to connectionist learning control systems». In D. A. White and D. A. Sofge, editors, Handbook of intelligent Control, pp.35-64. Van Nostrand Reinhold, (1992).
- [**BER68**] Berger, J.A. et Lapidus, L. «An introduction to the stability of distributed systems via a Lyapunov functional». ACHE Journal N° 14, pp.558-568. (1968)
- [**BAT92**] Battiti, R. «First- and second order methods for learning: Between steepest descent and Newton's method». Neural Computation, vol. 4, N°. 2, pp. 141-166, (1992).
- [**BHA90**] Bhat, N.V. and Mcavoy, T.J. « Use of neural nets for dynamic modelling and control of chemical process systems », Computers Chem. Engng., Vol. 14, N°. 4/5, pp.573-583, (1990)
- [**BOH98**] Böhm, M., Demetriou, M.A. Eich, S. et Osen, I.G. « Model reference adaptive control of distributed parameter systems », SIAM Journal of Control and Optimisation, Vol. 36, N° 1, pp.33-81. (1998).
- [**BAU89**] Baum. E.B, and Haussier.D, «What Size Net Gives Valid Generalization, Neural Computation», Vol.1, pp151-160, (1989).
- [**CRO76**] Crosby, J.E. et Durbin.L.D, «Design and application of state variable feedback controller for a packed trickle bed column with carbon dioxide absorption», Joint Automatic Control Conference, West Lafayette, IN (1976).
- [**CHK97**] Chkravarti, S. et Ray, H. « Boundary identification and control of distributed parameter systems using singular functions », In: American Control Conference.Albuquerque. pp.2223-2227, (1997).
- [**CHR98a**] Christofides, P.D. et Daoutidis, P. « Nonlinear feedback control of parabolic pde Systems », NATO ASI Serie E Applied Science, N° 353, pp. 371-401. (1998).
- [**CHR98b**] Christofides, P.D. « Robust control of parabolic pde systems », Chemical Engineering Science, Vol. 53, N°16, pp.2949-2965. (1998).
- [**CUR82**] Curtain, R.F. « Finite-dimensional compensator design for parabolic distributed systems with point sensors and boundary input », IEEE Transactions on Automatic Control, Vol. 27, N° 1, pp.98-104, (1982).
- [**CYB89**] Cybenko, G., « Approximation by Superpositions of a Sigmoidal Function »,Math. Cont. Sign. Syst. N° 2, pp. 303-314, (1989).
- [**DAR80**] Darwish, M. et Fantin.J, «Stabilization and control of absorber tower chemical Process». Third IFAC/IFIP/IFORS Conference on System Approach for Development, Rabat (1980).
- [**DOU06**] Doukhan J.C, Cours Polytech'Lille Sciences des Matériaux «Défauts Cristallins» , Première année, 2006.
- [**DEN83**] Dennis, J.E., and Schnabel R. B., « Numerical Methods for Unconstrained Optimization and Nonlinear Equations », Englewood Cliffs, NJ: Prentice-Hall, 1983.
- [**DOC94**] Dochain, D. « Contribution to the analysis and control of distributed parameter systems with application to (bio)chemical processes and robotics ». Thèse d'agrégation. Université catholique de Louvain, 1994.

- [DRA96] Draeger. A., Engel. S. et Ranke. H., « Model predictive Control Using Neural Network », IEEE Control System Magazine, N°10, pp.61-66, (1996)
- [DRA97a] Drakunov, S. et Barbieri, E. « Manifold control of a class of distributed parameter systems using modal expansion », In: Conference on Decision and Control. San Diego, pp. 1082-1087, (1997).
- [DRA97b] Drakunov, S. et Barbieri, E. « Sliding surfaes design for distributed parameter Systems », In: American Control Conference. pp.3023-3027, (1997).
- [ELJ90] El.Jai.El, A. et Amouroux, M. « Automatique des systèmes distribués », Hermès. Paris, 1990.
- [ERI84] Eriksson, K and Thomée, V. « Galerkin methods for singular boundary value problems in one space dimension ». Math. Comp., N° 42, pp.345-367. (1984)
- [EVA94] Evans, J.T. « Investigation of a multi-layer perceptron network to model and control a non-linear system ». Ph.D. Thesis, Liverpool John Moores University, UK. 1994
- [FAR93] Farlow, S.J. « Partial Differential Equations for Scientists and Engineers ». 2^{ed}. Dover publications. New York. (1993).
- [FRE92] Freeman, «Neural Networks», Ed Addison-Wesley, 1992.
- [GAR89] Garcia, C.E., Prett, D.M. and Morari, M. « Model predictive control: Theory and practice, asurvey » . Automatica, Vol. 25, pp.335-348, (1989)
- [GLO96] Glowinski, R. et He, J.W. « On control problems for some convection-reaction-diffusion Systems ». In: Conference on Decision and Control (IEEE, Ed.). Kobe,Japan. pp.3717-3722. (1996)
- [GUS80] Gustafson, K.E. « Introduction to Partial Differential equations and Hilbert Space Methods ». John Wiew and Sons. New York, (1980).
- [HAD06] Haddouche.R, «Simulation et Contrôle d'une Colonne d'absorption». Thèse de Magister, ENP, Alger, 2006.
- [HAM93] Hammerstrom.D, «Working With Neural Networks» , IEEE Spectrum, Vol.30, N°.7, pp.46-53, (1993).
- [HAG96] Hagan, M.T., Demuth, H.B, and Beale, M.H. « Neural Network Design ». Boston, MA :PWS Publishing, (1996).
- [HAG94] Hagan, M.T, and Menhaj, M. « Training feedforward networks with the Marquardt algorithm ». IEEE Transactions on Neural Networks, Vol. 5, N° 6, pp. 989-993, (1994).
- [HAN95] Hanczyc, E.M. et Palazoglu, A. « Nonlinear control of a distributed parameter process: The case of multiple characteristics. », Industrial Engineering and Chemical Research N° 34, pp.4406-4412, (1995).
- [HAY94] Haykin.S, «Neural Networks, A comprehensive Foundation», Macmillan College Publisher Corp, (1994).
- [HEC89] Hecht-Nielsen, R., « Theory of the Backpropagation for Neural Network », in "Proc. Int. Joint Conf. on Neural Networks", Washington D.C, pp.18-22, June 1989, (1989)
- [HEN98] Henson, M.A. « Nonlinear model predictive control: current status and future Directions ». Computers Chem. Engng., Vol. 23, N°. 2, pp.187-202, (1998)
- [HER94] Herault.J, Jutien.C, «Réseaux de neurones et traitement du signal», Edition Hermès, 1994.
- [HON94] Hong, K.S. et Bentsman, J. « Direct adaptive control of parabolic systems: Algorithm synthesis and convergence and stability analysis ». IEEE Transaction on Automatic Control, Vol. 39, N°10, pp.2018-2033, (1994)
- [ILL02] Illoul, R., Selatnia, A. et Boulrouah, A. « Commande prédictive généralisée d'une colonne d'absorption ». 4^{eme} Journées Francophones sur les réacteurs Gaz-Liquide, Liège (2002).
- [ILL04] Illoul R, Selatnia.A, Aberkane.S et Baba.Ammi.D, «simulation de la commande par logique floue et neuro-floue d'une colonne d'absorption reactive», 9^{eme} Congrès SFGP Saint-Nazaire, France, (2004).

- [IDE06] Idem.R, Wilson.M, Tontiwachwuthikul.P, Chakma.A, «Pilot Plant Studies of the CO₂ Capture Performances of Aqueous MEA and Mixed MEA/MDEA Solvents at the University of Regina CO₂ Capture Technology Development Plant and the Boundary Dam CO₂ Capture Demonstration Plant», Ind. Eng. Chem. Res, vol 45, pp: 2414-2420, (2006).
- [IFP03] Conférence de presse de l'Institut Français du Pétrole, «Réduction des émissions de CO₂ : les solutions», IFP, France, (2003).
- [ISI89] Isidori.A, «Nonlinear Control Systems». Springer Verlag, New York, 1989.
- [JOD94] Jodouin.J.F, «Les Réseaux de Neurones, Principes et Définitions», Ed Hermes, 1994.
- [KIS79] Kishinevskii, M.K., «Theory and fundamentals of chemical engineering». Vol n°4, p 641 (1979).
- [KRE78] Kreyszig, E. « Introductory Functional Analysis with Applications ». John Wiley & Sons. New York. (1978).
- [KUO98] Kuo, E. « Automatic Control ». John Wiley et Sons. New York. (1998)
- [LEV92] Levin A.U., «Neural Networks in Dynamical Systems», Thèse de Doctorat, Yale University, Etats Unis, 1992.
- [LIU06] Liu.G.B, Yu.K.T, Yuan.X.G and Liu.C.L, «New Model for Turbulent Mass Transfer and Its Application to the Simulations of a Pilot-Scale Randomly Packed Column for CO₂-NaOH Chemical Absorption» , Ind. Eng. Chem. Res, vol 45, pp: 3220-3229, (2006).
- [MAR95] Marino R. and Tomei P., «Nonlinear Control Design», NJ: PrenticeHall, Englewood Cliffs, Etats Unis, 1995.
- [MAR04] Marc.P, «Le perceptron Multicouche et Son Algorithme de Rétropropagation des Erreurs», Université de Laval, (2004).
- [MAT7.5] Matlab Version 7.5, Release 14, (2007).
- [NAJ95] Najim, K., et Ruiz, V. « Long range predictive control of an absorption packed column ». Applied Mathematical Journal, Vol. 19, N°1, pp.39-45 (1995).
- [NAJ91] Najim, K., «Modelling and self-ajusting control of an absorption column», International Journal of AdaptiveControl and Signal Processing , vol 5, pp. 335-345, (1991).
- [NAR90] Narendra, K. S. and Parthasarathy.K., « Identification and Control of Dynamical Systems using Neural Networks », IEEE Trans. Neural Networks, Vol.1, N°.1, pp 4-27, (1990).
- [OLA04] Olafadehan.O.A, Susu.A.A, «Modeling and Simulation of liquid- Phase Ternary Adsorption in Activated Carbon Column», Ind. Eng. Chem. Res, vol 43, n°25, (2004).
- [PAR95] Park, S.K.. « Application of Petrov-Galerkin finite element method to nonlinear transient diffusion-convection-reaction system ». Chemical Engineering Communication, N°139, pp.159-200, (1995)
- [PET80] Petrovski, D. « A design scheme for multivariable output constrained PI regulators with applications to absorption column », Automatic Control Theory Applications, N°8, pp.61-69. (1980)
- [PIN84] Pinglot, D.P. « Commande optimale et sous optimale d'un système hyperbolique non linéaire : Colonne d'absorption ». Doctorat d'Etat en Automatique, Toulouse 1984
- [PIN93] Pintola T., Tontiwachwuthikul.P, et Melsen.P, «Simulation of pilot plant and industrial CO₂-MEA absorbers Gas separation and purification». Vol.7, n°1, pp. 47-52, (1993).
- [POT97] Pottmann, M. and Seborg, D.E. « A nonlinear predictive control strategy based on radial basis function models ». Computers Chem. Engng, vol. 21, pp. 965-980. (1997)
- [RAY81] Ray, W.H. «Advanced Process Control», McGraw-Hill Chemical Engineering Series, Vol. 376, McGraw-Hill. Montréal, (1981).
- [RAP01] Rapin.P, Lachat.J.C, «Equations aux dérivées partielles», Techniques de l'ingénieur, 2001.
- [RAN95] Randers.J.M, « Algorithmes génétiques et réseaux de neurones », édition HERMES, 1995.

- [RAW94] Rawlings, J.B., Meadows, E.S. and Muske, K.R. « Nonlinear model predictive control: a tutorial and survey ». Proc. Advanced Control of Chemical Processes, pp. 185-197. (1994)
- [RAY81] Ray, W.H. « Advanced Process Control », Vol. 376 of McGraw-Hill Chemical Engineering Series. McGraw-Hill. Montréal, (1981).
- [RAY78] Ray, W.H. et Lainiotis, D.G. « Distributed Parameter systems ». Dekker. New York. (1978)
- [ROF76] Roffel, B., «Control of processes with a state variable inequality constraint», Journal A, Vol 17, pp. 19-28, (1976).
- [RIC78] Richalet, J., Rault, A, Testud, J.L and Papon, J. « Model predictive heuristic control: application to industrial processes ». Automatica , Vol. 14, N° 5, pp.413-428. (1978)
- [RUM86] Rumelhart, D.E., Hinton, G.E., and Williams, R.J. « Learning representations by backpropagations errors ». Nature, Vol. 323, pp. 533-536, (1986).
- [RUS75] Russell, R.D and Shampine, L.F. «Numerical methods for singular boundary value problems ». SIAM J.Numer. Anal., N° 12, pp.13-36, (1975).
- [SHA00] Shang, H., Forbes, F. et Guay, M. « Feedback control of hyperbolic pde systems ».In: ADCHEM. Pisa, Italy. (2000)
- [SHU90] Shun-Ichi, A Mathematical Foundations of Neurocomputing, Proc of the IEEE, Vol. 78, n° 9, p 1443-1463, (1990).
- [SAA96] Saari H., «Commande répétitive de procédés échantillonnés à déphasage non minimal», Thèse de Doctorat, Université de Savoie, France, 1996.
- [SAN95] Sandail. O.C et Hanna, O.T. « Computational Methods in Chemical Engineering ». Prentice Hall. Upper Saddle River, NY. (1995).
- [SED04] Seddari S., «Simulation d'une colonne à garnissage d'absorption du CO₂ par une solution aqueuse de monoéthanolamine à 25°C et 40 °C». Thèse de Magister, ENP, Alger, 2004.
- [SEL02] Selatnia.A, «Communication au congrès sur les réacteurs polyphasiques», Louvain, (2002).
- [SKE90] Skeel, R.D and Berzins, M. «A method for the spatial discretization of parabolic equations in one space variable ». SIAM Journal Science. Statistical. Comput. Vol.11, N°1, pp.1-32 January 1990, (1990).
- [SLO91] Slotine.J.E and W. Li, «Applied nonlinear control», Prentice Hall, Englewood Cliffs, NJ, Etats Unis, (1991).
- [SOL96] Soloway, D. and Haley, P.J. « Neural Generalized Predictive Control ». Proceedings of the 1996 IEEE International Symposium on Intelligent Control, pp. 277-281. (1996).
- [TOM87] Tomizuka M., «Zero Phase Error Tracking Algorithm for Digital Control», ASME Journal of Dynamic Systems, Measurement and Control, Vol. 109, pp. 65-68, (1987).
- [TON92] Tontiwathukul,P., Melsen.P et Linn.A «CO₂ Absorption by NaOH, MEA and AMP solutions to paced columns», Chemical Engineering Science, Vol. 47, n°2, pp. 381-390, (1992).
- [TRA84] Trambouze P., Landegheim. H.V et Wauquier. J.P,« Les réacteurs chimiques, conception/ calcul/mise en œuvre», Ed. Technip, (1984).
- [VAN97] Vandoren, V.J.« Multivariable controllers enter the mainstream ». Control Engineering, Vol. 44, N° 4, pp. 107-112. (1997).
- [VAP82] Vapnik.V.N, Estimation of Dependences Based on Empirical Data. Springer Series in Statistics, Springer-Verlag, (1982).
- [VAN76] Van Der Weg, R. « Sur la modélisation et l'optimisation d'une colonne d'absorption ». Thèse de Doctorat d'Etat. Toulouse 1976.
- [VEN02] Venkat.A..N, Gudi.R.D, «Fuzzy Segregation Based Identification and Control of Nonlinear Dynamic Systems», Ind. Eng. Chem. Res, vol 41, pp: 538-552, (2002).
- [VIL78] Villadsen, J. et Michelsen, M.L. «Solution of differential equations modes by polynomial approximation». Prentice-Hall International series in the physical and chemical engineering sciences, Prentice Hall, Toronto, Canada, (1978).

-
- [WEC04]** 19th World Energy Congress, Sydney, Australia, September 5-9, (2004).
- [WER92]** Werbos, P. J., McAvoy, T. et Su, T. « Neural Networks, System Identification and Control in the Chemical Process Industries », in D. A. White and D. A. Sofge, Eds., "Handbook of Intelligent Control", Van Nostrand Reinhold, New York, NY (1992)
- [ZHA99]** Zhang.Y, Wen.C et Chai Soh.Y «Robust Adaptive Control of Uncertain Discrete-Time Systems». Automatica, Vol. 35, pp 321-329, (1999).
- [ZIE95]** Ziegler, J.G. et Nichols, N.B. « Optimum settings for automatic controllers ».Trans. ASME, Vol. 64, N° 11, pp. 759-768. (1942).

ملخص

يهدف هذا العمل الى استعمال الجمل الغامضة في التحكم في أسطوانة الإمتصاص المستعملة لاستخراج غاز CO₂ من مزيج غازي (هواء+ CO₂) بالامتصاص بواسطة سائل الغسل MEA. التمثيل النموذجي لهذا النظام بإستعمال ميزانية المادة تمكن من الحصول على معالة لا خطية ذات وسائط موزعة. لتحسين النتائج المتحصل عليها بالتحكم الكلاسيكي PI طبقنا على أسطوانة الإمتصاص ثلاث طرق لتحكم تعتمد على الجمل الغامضة: التحكم العصبوني التتبعي المؤكد, التحكم العصبوني التنبأ, التحكم العصبوني NARMA قدمنا بعض نتائج المحاماة العددية لكل طريقة لإبراز كفاءة أدائها.

الكلمات المفتاحية :

أسطوانة الإمتصاص، معالة ذات مشتقات جزئية، نموذج ذات وسائط موزعة، التحكم PI، التحكم و التبين العصبوني ، الشبكة العصبونية .

Abstract:

This work deals with the application of neuronal control to an absorption packed column destined to remove CO₂ from a gas mixture (air+CO₂) using an aqueous solution of MonoEthanolAmine (MEA). The model is obtained using mass balance considerations and is non linear with distributed parameters.

In order to improve the results obtained with a classic PI regulator, we applied to our system three control techniques based on neural network: the neural control using the certainty equivalence principle, neural network predictive control (Nnpc), and finally NARMA neural control(Non linear Autoregressive Moving Average). For each scheme, simulation results are given to highlight performances of each one.

Keywords:

Absorption packed column, distributed parameters model, PI regulation, neuronal identification and control, neural networks.

Résumé :

L'objectif de ce travail porte sur l'application de différentes stratégies de commande neuronale à une colonne d'absorption pilote à garnissage utilisée pour retirer le CO₂ d'un mélange gazeux (air+CO₂) par absorption grâce à un liquide de lavage (Eau+MonoEthanolAmine). La modélisation de notre système à l'aide d'un bilan de matière permet d'obtenir un système non linéaire aux paramètres répartis.

Afin d'améliorer les résultats obtenus avec une régulation PI classique, nous avons appliqué à notre système trois techniques de commande se basant sur les réseaux de neurones, qui sont : la commande par équivalence certaine, la commande prédictive neuronale (Nnpc) et en fin la commande neuronale NARMA(Non linear Autoregressive Moving Average).

Pour chaque structure de commande, des résultats de simulation sont présentés pour montrer ses performances.

Mots clés :

Colonne d'absorption à garnissage, modèle à paramètres répartis, régulation PI, commande et identification par réseaux de neurones, réseaux de neurones.