

وزارة التعليم العالي والبحث العلمي

BADJI MOKHTAR- ANNABA UNIVERSITY
UNIVERSITE BADJI MOKHTAR ANNABA



جامعة باجي مختار - عنابة

Année : 2017

Faculté: Sciences de l'ingénierat
Département: Electronique

MEMOIRE

Présenté en vue de l'obtention du diplôme de : MASTER

Intitulé

Modélisation neuronal et neuronal hybride d'un processus chémostat

Domaine : Sciences et Technologie

Filière : Electronique

Spécialité: signaux et image en bio-ingénierie

Par : Benmerabet Imene

DEVANT Le JURY

Président : Zermi Narima M.C.B UBM Annaba

Directeur de mémoire : Chabbi Charef M.C.B UBM Annaba

Examineur : Hafs Toufik M.C.B UBM Annaba

dédicace

A mon Père, » abdenacer »

"L'épaule solide, l'œil attentif compréhensif et la personne la plus digne de mon estime et de mon respect. Aucune dédicace ne saurait mes sentiments, que Dieu te préserve et te procure santé et longue vie.

A ma Mère, »fatma zohra»

"Tu m'as donné la vie, la tendresse et le courage pour réussir.

"Tout ce que je peux t'offrir ne pourra exprimer l'amour et la reconnaissance que je te porte.

En témoignage je t'offre ce modeste travail pour te remercier pour tes sacrifices et pour l'affection dont tu m'as toujours entourée."

A mes frères amjed et adel qui me donne une envie de vivre.....

A mes sœurs houda . teissir

A mes amies emma amira bassma joujou nora

A mon ami idriss

A mon oncle mohammed

A mes tantes zakia et assia

....

REMERCIEMENT

Nous remercions d'abord le bon dieu, le tout puissant de nous Avoir donné la force, la puissance et la volonté, pour atteindre Notre but, symbolisé par ce modeste travail.

*Nous tenons à remercier d'une manière particulière notre Encadreur
Mr le professeur .**CHAREF CHABBI***

*Pour sa gentillesse, sa disponibilité, ses riches orientations, ces précieuses informations et les Efforts qu'il a déployés nous permettant
D'avoir bien mené cette recherche.*

Nous remercions aussi le membre du jury qui a bien voulu accepter De juger mon travail.

Je souhaiterais également remercier mes professeurs de la spécialité signaux et images en bio-ingénierie pour tout le savoir qu'ils nous ont donné.

Et je tenais à remercier le chef de département d'ELCTRONIQUE

'MR REDJATI' pour m'avoir accueillis les portes ouvertes

En fin à toutes celles et à tous ceux qui ont contribué de près ou de Loin à la réalisation de ce mémoire.

ABSTRACT

Neural and hybrid neural modeling of the chemostat fermentation of *saccharomyces cerevisiae* are described. In the neural part, we have used one network with one hidden layer of ten neurons plus the bias; and a network with two hidden layers of ten neurons plus the bias each; where we estimated and validated the concentrations of biomass, glucose, ethanol, dissolved oxygen and dissolved dioxide of carbone; the results of estimation and validation were better for the one with two hidden layers, at a price of bigger computing time. For the hybrid neural part, we have used the sensitivity approach to train the global system composed of the neural part and the balance equations part, the result was estimation of the specific growth rate, the specific glucose uptake rate and the specific ethanol reaction rate, knowing that these rates are difficult to measure, we can then estimate them using the hybrid neural technique. The optimization algorithm used is the Levenberg-Marquardt one. The training and validation data are generated using the mathematical model composed of six differential equations and twelve algebraic ones to give 201 samples, where we used 151 samples for training and 50 ones for validations.

The results obtained were satisfying, especially for the estimation of different rates that are not measurable.

In the future, we aim at using more performing algorithms that take less time and give more accurate results.

ملخص

يتم وصف النمذجة العصبية والهجين العصبي من تخمير ناظم كيميائي من ساكارومييز سيريفيسيبي. في الجزء العصبي، استخدمنا شبكة واحدة مع طبقة خفية واحدة من عشرة الخلايا العصبية بالإضافة إلى التحيز لكل منهما. حيث قمنا بتقدير والتحقق من صحة تركيزات الكتلة الحيوية والجلوكوز والإيثانول والأكسجين المذاب وثاني أكسيد الذائب من كاربون؛ كانت نتائج التقدير والتحقق من صحة أفضل لواحد مع اثنين من طبقات خفية، بسعر أكبر وقت الحوسبة. أما بالنسبة للجزء العصبي المختلط فقد استخدمنا نهج الحساسية لتدريب النظام العالمي المكون من الجزء العصبي ومعادلة التوازن جزء، وكانت النتيجة تقدير معدل النمو المحدد، ومعدل امتصاص الجلوكوز المحدد ومعدل تفاعل الإيثانول المحدد، مع العلم أن هذه المعدلات يصعب قياسها، يمكننا بعد ذلك تقديرها باستخدام تقنية العصبية الهجينة. خوارزمية التحسين المستخدمة هي ليفنبرغ-ماركاردت واحد. يتم إنشاء البيانات التدريب والتحقق من صحة باستخدام نموذج رياضي يتكون من ستة المعادلات التفاضلية و اثني عشر الجبرية منها لإعطاء 201 عينات، حيث استخدمنا 151 نماذج للتدريب و 50 منها للتحقق

وكانت النتائج التي تم الحصول عليها مرضية، وخاصة لتقدير معدلات مختلفة غير قابلة للقياس

في المستقبل، ونحن نهدف إلى استخدام خوارزميات أكثر أداء التي تأخذ وقتاً أقل وإعطاء نتائج أكثر دقة

Résumé

La modélisation neuronale et la modélisation neuronale hybride de la fermentation chemostat de la levure *saccharomyces cerevisiae* ont été décrites. Dans la partie neuronale, on a utilisé un réseau avec une seule couche cachée de 10 neurones plus le biais, et un réseau avec deux couches cachées de 10 neurones plus le biais chacune, où on a estimé et validé les concentrations de la biomasse, du glucose, d'éthanol, d'oxygène dissous et de gaz carbonique dissous ; Les résultats d'estimation et de validation étaient meilleurs pour le réseau avec deux couches cachées, payés par un temps de calcul plus long. Pour la partie neuronale hybride, nous avons utilisé l'approche de la sensibilité pour l'apprentissage du système global, composé de la partie neuronale et de la partie mathématique, le résultat était l'estimation du taux spécifique d'accroissement cellulaire, du taux spécifique de consommation du glucose et du taux spécifique de réaction d'éthanol, sachant que ces taux ne peuvent être mesurés, on les a estimés en utilisant la technique neuronale hybride. Pour l'optimisation, on a utilisé l'algorithme de Levenberg-Marquardt. Les données d'apprentissage et de validation sont générées par un modèle mathématique composé de 6 équations différentielles et de 12 équations algébriques pour nous donner 201 échantillons, où on a utilisé 151 échantillons pour l'apprentissage et 50 pour validation.

Les résultats obtenus étaient satisfaisants, spécialement dans l'estimation des différents taux qui ne peuvent être mesurés.

Dans le futur, on aimerait avoir des algorithmes plus performants qui consomment moins de temps et donnent des résultats plus précis.

LISTE DES FIGURES

Liste des figures

Figure 1 : graphe de la courbe exponentielle de croissance.....	1
Figure 2 : schéma du chémostat.....	3
Figure 3-1 :les courbes de X.S.Of.Cf.et du taux de dilution dil.....	10
Figure4-1 : organigramme de base de la modélisation.....	12
Figure 4-1 : Architecture du modèle à une seule couche cachée.....	13
Figure 4-2 : Organigramme de Levenberg- Marquardt.....	14
Figure 4-2 : Architecture du modèle à deux couches cachées.....	16
Fig.5-1 : Combinaison du réseau ANN et du modèle mathématique.....	18
Fig.5-2 : estimation du taux r_x et de la concentration X	19
Fig.5-3 : estimation du taux q_S et de la concentration S	21
Fig.5-4 : estimation du taux q_E et de la concentration E	22
Fig.5-1 : Courbes d'estimation de X , de MSE et d'estimation et validation de X	25
Fig.5-2 : Courbes d'estimation de S , de MSE et d'estimation et validation de S	26
Fig.5-3 : Courbes d'estimation de E , de MSE et d'estimation et validation de E	27
Fig.5-4 : Courbes d'estim. de O_F , de MSE, d'estim. et valid.de O_F et d'estim. de C_F	28
Fig.5-5 : Courbes de MSE et d'estimation et validation de C_F	29
Fig.5-6 : Courbes d'estimation de X , de MSE et d'estimation et validation de X	30
Fig.5-7 : Courbes d'estimation de S , de MSE et d'estimation et validation de S	31
Fig.5-8 : Courbes d'estimation de E , de MSE et d'estimation et validation de E	32
Fig.5-9 : Courbes d'estim. de O_F , de MSE, d'estim. et valid.de O_F et d'estim. de C_F	33
Fig.5-10 : Courbes de MSE et d'estimation et validation de C_F	34

LISTE DES FIGURES

Fig.5-11 : Courbes d'estimation de X , de MSE de X et d'estimation de r_x35

Fig.5-12 : Courbes d'estimation de S , de MSE de S et d'estimation de q_S36

Fig.5-13 : Courbes d'estimation de E , de MSE de E et d'estimation de q_E37

LISTE DES TABLEAUX

Liste des tableaux

	page
Tab1-Les coefficients de rendement	8
Tab2- les paramètres cinétiques.....	8

Sommaire

	page
Résumé	i
Abstract	ii
ملخص	iii
Chapitre 1 : Introduction générale	
Chapitre 2 : La fermentation chémostat	
II-1 introduction.....	1
II 2-le dispositif biologique.....	2
II-3 Principe de fonctionnement du chemostat.....	4
Chapitre III Modèle mathématique du processus	
III-1 Le modèle réactionnel.....	5
III-2 Le modèle biologique.....	7
III-3 Le modèle mathématique.....	8
Chapitre IV Modélisation neuronale du chémostat	
IV-1 Introduction.....	11
IV-2 Le modèle neuronal.....	12
IV-2-1 Le modèle neuronal avec une seule couche cachée	13
IV-2-2 Le modèle neuronal avec deux couches cachées	16
Chapitre V La modélisation neuronale hybride du processus	
V-1 Introduction.....	17

SOMMAIRE

V-2 Combinaison d'un modèle mathématique et d'un réseau ANN.....	18
V-2-1 Estimation du taux r_x et de la concentration X	19
V-2-2 Estimation du taux q_s et de la concentration S	21
V-2-3 Estimation du taux q_E et de la concentration E	22
Chapitre VI Simulations	
VI-1 Introduction.....	24
VI-2 Résultats du modèle neuronal avec une seule couche cachée	24
VI-2-1 Estimation et validation de la concentration X	25
VI-2-2 Estimation et validation de la concentration S	26
VI-2-3 Estimation et validation de la concentration E	27
VI-2-4 Estimation et validation de la concentration O_F	28
VI-2-5 Estimation et validation de la concentration C_F	29
VI-3 Résultats du modèle neuronal avec deux couches cachées.....	29
VI-3-1 Estimation et validation de la concentration X	30
VI-3-2 Estimation et validation de la concentration S	31
VI-3-3 Estimation et validation de la concentration E	32
VI-3-4 Estimation et validation de la concentration O_F	33
VI-3-5 Estimation et validation de la concentration C_F	34
VI-4 Résultats du modèle neuronal hybride.....	34
VI-4-1 Estimation du taux r_x et de la concentration X	35
4-2 Estimation du taux q_s et de la concentration S	36
VI-4-3 Estimation du taux q_E et de la concentration E	37
Conclusion générale.....	38

Chapitre I

Introduction générale

La fermentation chemostat est utilisée pour la fabrication de la levure du pain, des boissons, des antibiotiques, des produits laitiers, etc. ; Il est donc d'un grand intérêt de modéliser un tel processus, de le commander pour pouvoir maximiser, soit la production de la biomasse, soit la production de l'éthanol ; Dans le cas de la fermentation de la levure *saccharomyces cerevisiae*, c'est la concentration de la biomasse qu'on veut maximiser.

Certains paramètres tels que la concentration de la biomasse dans le réacteur, les taux spécifiques d'accroissement cellulaire, de consommation de glucose, de consommation et de production d'éthanol, sont non mesurables ou difficiles à mesurer vu l'absence de capteurs spécifiques ; une solution qu'on apporte à ce problème est l'utilisation d'un modèle neuronal hybride avec l'association de l'approche de la sensibilité ;

Comme les dynamiques de ce processus sont fortement non linéaires, pour l'estimation et la validation des variables telles que les différentes concentrations, on a utilisé le modèle neuronal tandis que pour l'estimation des différents taux, on a opté pour le modèle neuronal hybride.

Ce mémoire est organisé de la façon suivante :

Dans le chapitreI, on a donné l'introduction générale ;

Dans le chapitreII, on a procédé à l'étude de processus chémostat de fermentation de la levure *saccharomyces cerevisiae* ;

Dans le chapitreIII, on a extrait le modèle mathématique du processus et l'utiliser pour générer les données (par l'utilisation des paramètres de Sonnleitner et Käppeli) ;

Dans de chapitreIV, on a établi le modèle neuronal avec une seule couche cachée et le modèle neuronal avec deux couches cachées ;

Dans le chapitreV, le modèle neuronal hybride du processus est adressé ;

Les résultats de simulation des deux modèles neuronaux utilisés sont donnés au chapitreVI ;

Dans le chapitreVII, on a donné la conclusion générale.

Chapitre II

Le chémostat

II-1 Introduction

Une espèce bactérienne placée dans un milieu de culture équilibré contenant tous les nutriments indispensables dans des conditions de pH, et de température optimales se développe et croît suivant des lois précises. La courbe de croissance, obtenue par néphélométrie, exprime les différentes phases du phénomène

- 1-La phase stationnaire initiale ou phase de latence
- 2-La phase d'augmentation de la vitesse de croissance ;
- 3-La phase de croissance à vitesse constante maximale ou phase de croissance exponentielle
- 4-La phase de diminution de la vitesse de croissance
- 5-La phase stationnaire maximale
- 6-La phase de début de décroissance
- 7-La phase de décroissance




Figure2-1 la courbe exponentielle de croissance

La phase de ralentissement représente la limite de croissance qui dépend à la fois du type cellulaire et des conditions de culture ; Pendant cette phase certaines cellules continuent à croître lentement pendant que d'autres meurent par suite du manque de nutriments. Pendant la phase de décroissance, le taux de mortalité augmente, devient constant et la culture meurt.

Pour de nombreuses expériences de génétique ou de physiologie, il est souhaitable d'éviter cette période finale de l'évolution de la culture. Pour cela, il faut approvisionner la culture en nutriments de façon à éviter l'épuisement du milieu, tout en limitant l'importance de la population bactérienne. Le chémostat permet une telle culture ; Il est constitué d'un récipient dit de croissance équipé d'un siphon de trop plein et d'une tubulure permettant l'apport continu de milieu frais. On règle cet apport de manière à obtenir le taux de croissance désiré, car plus on ralentit l'approvisionnement en nutriments plus la multiplication cellulaire est lente. Chaque goutte qui arrive chasse par le trop plein une goutte de culture, de telle manière que le volume du liquide ne change pas. Dans ces conditions, le nombre total des cellules dans le récipient reste constant. Le chémostat permet donc de conserver, pendant une période de temps indéfinie, une population microbienne numériquement constante ayant un taux de croissance contrôlé. En réglant d'autre part le chémostat de façon que soient éliminées en un temps donné autant de cellules bactériennes qu'il s'en est formé, on peut maintenir la culture dans les conditions de la croissance exponentielle.

II-2 Le dispositif biologique

Un chémostat est un appareil de laboratoire (de type bioréacteur) dans lequel poussent de façon contrôlée, des organismes (bactéries, phytoplancton) ;

On peut schématiser un chémostat de la façon suivante:

On place dans la chambre du chemostat les organismes dont on veut étudier la Croissance ; Ces organismes sont "nourris" par l'entrée dans le système de nutriment, à un taux D et une concentration S

On peut schématiser un chemostat de la façon suivante [2], [7] :

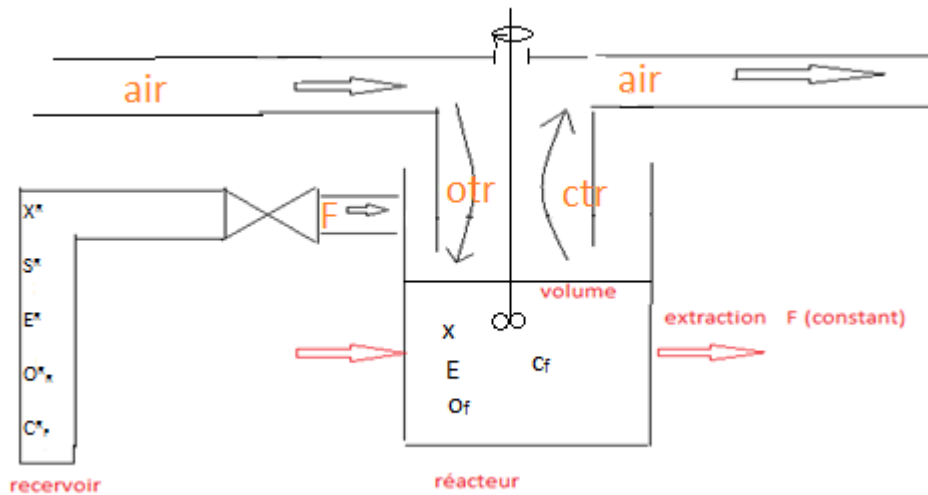


Figure2-2 schéma du chemostat

Il existe trois modes de fonctionnement:

- Mode "batch". Ici, l'entrée et la sortie sont nulles ; On assiste à une croissance exponentielle des organismes.
- Mode "fed batch". Seule la sortie est nulle. C'est le mode de fonctionnement préféré lorsque l'objectif est le contrôle de la population.
- Mode "continu". Le débit de la sortie est égal au débit de l'entrée. Le volume est donc constant dans le réacteur ;

Dans le cas du chemostat, c'est le troisième type de fonctionnement (en continu) qui est privilégié. Ainsi, le mélange est chassé du chemostat au même taux D que l'entrée. Le système maintient donc un volume constant et le taux de croissance du micro organisme est contrôlé par la manipulation de l'apport de milieu frais, tandis que la densité de la population est régulée en modifiant la concentration de l'élément nutritif limitant.

II-3 Principe de fonctionnement du chemostat

Introduction de milieu neuf stérile dans la chambre de culture à la même vitesse que le milieu contenant les microorganismes est éliminé (c'est le volume de milieu frais qui chasse par trop plein le volume de culture microbienne). Soumise à une bonne aération, à une vigoureuse agitation et les cellules ayant toujours à leur disposition les éléments nutritifs dont ils ont besoin, la multiplication exponentielle est maintenue à une vitesse spécifique de croissance rigoureusement contrôlée par l'apport de milieu neuf.

Avantages et inconvénients de la culture en continu

Les inconvénients sont la difficulté du contrôle du système de régulation et la possibilité de fabrication de produits libérés uniquement durant la phase de déclin ; Tandis que les avantages sont le maintien de la phase exponentielle, rendement Optimal, stérilisation facile du milieu de récupération des produits au fur et à mesure de leur production ;

Chapitre III

Modèle mathématique du processus

Pour l'analyse théorique du processus et le développement des stratégies de contrôle, Un modèle mathématique qui peut décrire toutes les phases de croissance importantes de la Levure a été construit, l'ensemble du modèle dynamique est constitué d'un modèle biologique et d'un modèle réactionnel. Ici, seulement les parties les plus importantes du modèle sont présentées.

III-1 Le modèle réactionnel

Le modèle réactionnel [2] est dérivé des équilibres des phases liquide et gazeuse des composants principaux dans le réacteur à cuve agitée en fonctionnement continu, qui est représenté sur la figure2-2 sous une forme simplifiée.

Les cellules de levure, représentées par la concentration globale de masse cellulaire X croissent dans la phase liquide: elles consomment ainsi le substrat de concentration S et l'oxygène dissous de concentration O_F et produisent du dioxyde de carbone de concentration C_F . L'éthanol E peut être un produit ou un substrat, tout dépend des concentrations de glucose et d'oxygène dissous.

Le modèle réactionnel est régi par les équations différentielles suivantes [4] :

$$\dot{X}(t) = (X^R(t) - X(t)) * D(t) + \mu(t) * X(t) \quad (3-1)$$

$$\dot{S}(t) = (S^R(t) - S(t)) * D(t) - q_S(t) * X(t) \quad (3-2)$$

$$\dot{E}(t) = (E^R(t) - E(t)) * D(t) + q_E(t) * X(t) \quad (3-3)$$

$$\dot{O}_F(t) = (O_F^R(t) - O_F(t)) * D(t) - q_O(t) * X(t) + OTR(t) \quad (3-4)$$

$$\dot{C}_F(t) = (C_F^R(t) - C_F(t)) * D(t) + q_C(t) * X(t) - CTR(t) \quad (3-5)$$

$$\dot{V}(t) = F = D * V \quad (3-6)$$

$$q_S = q_{Smax} \frac{S}{S+K_S} (1 - e^{-t/t_d}) \quad (3-7)$$

$$q_{Olim} = q_{Omax} \frac{O_f}{O_f+K_O} \frac{K_i}{E+K_i} \quad (3-8)$$

$$q_{Slim} = \frac{\mu_{cr}}{Y_{X/S}^O} \quad (3-9)$$

$$q_{SOX} = \min(q_S, q_{Slim}, q_{Olim}/Y_{O/S}) \quad (3-10)$$

$$q_{Sred} = q_S - q_{SOX} \quad (3-11)$$

$$q_{eup} = q_{emax} \frac{E}{E+K_e} \frac{K_i}{E+K_i} \quad (3-12)$$

$$q_{eOX} = \min(q_{eup}, (q_{Olim} - q_{SOX} Y_{O/S}) * Y_{e/O}) \quad (3-13)$$

$$q_{epr} = q_{Sred} Y_{e/S} \quad (3-14)$$

$$\mu = q_{SOX} Y_{X/S}^{OX} + q_{Sred} Y_{X/S}^{red} + q_{eOX} Y_{X/e} \quad (3-15)$$

$$q_c = q_{SOX} Y_{c/S}^{OX} + q_{Sred} Y_{c/S}^{red} + q_{eOX} Y_{c/e} \quad (3-16)$$

$$q_O = q_{SOX} Y_{O/S} + q_{eOX} Y_{O/e} \quad (3-17)$$

$$RQ = \frac{q_c}{q_O} \quad (3-18)$$

Où X, S, E, O_F et C_F sont les concentrations de la biomasse, du glucose, d'éthanol, d'oxygène dissous et du gaz carbonique dissous respectivement, tandis que X^R, S^R, E^R, O_F^R et C_F^R sont les concentrations dans le réservoir comme indiquées sur la figure 3-1 ; V est le volume liquide du réacteur ; F est le débit et D est le taux de dilution ;

Les taux μ, q_S, q_E, q_O et q_C sont le taux spécifique d'accroissement cellulaire, taux spécifique de consommation du glucose, taux spécifique de réaction d'éthanol, taux spécifique de consommation d'oxygène et taux spécifique de production du gaz carbonique respectivement ; Ces taux s'expriment en $[h^{-1}]$;

OTR et CTR sont les taux de transfert d'oxygène et de gaz carbonique respectivement et s'expriment en $[g/l/h]$;

III-2 Le modèle biologique

Le modèle biologique [2] de croissance de la levure permet de déterminer l'activité métabolique dans le principal chemin métabolique comme une fonction des concentrations du réacteur. Le but est de maximiser le taux spécifique μ d'accroissement cellulaire, qui est fonction de S, q_S, q_E et q_O

$$\mu(S, q_S, q_E, q_O) \rightarrow \text{maximum}$$

Les contraintes du problème d'optimisation sont les limitations des taux tels que :

- (i) Limitation d'éthanol $q_E < 1.1 * E$
- (ii) Limitation d'oxygène $q_O < 0.012 * O_F$
- (iii) Régulation du gluconéogénèses $q_S < q_{Smax}$
- (iv) Régulation de la respiration $q_O < q_{Omax}$
- (v) Limitation du glucose $q_S = q_{Smax} * \frac{S}{S+K_S}$

qui forment la cinétique multiple de Monod ;

III-3 Le modèle mathématique

La résolution des 6 équations différentielles de (3-1) à (3-6) en utilisant les paramètres (au nombre de 16) de (Sonnleitner et Käppli,1986) [1] et qui sont donnés dans les deux tableaux Tab1 et Tab2, donnés dans ce qui suit ;

Parmi les 16 paramètres, on compte les 9 premiers et qui sont des coefficients de rendements (les 's') dont les valeurs sont données dans le tableau Tab1 ; Par contre les 7 paramètres restants sont les paramètres cinétiques et sont donnés dans le tableau Tab2 ;

$Y_{X/S}^O$	0.49
$Y_{X/S}^r$	0.05
$Y_{X/E}^r$	0.10
$Y_{X/E}^{OE}$	0.72
$Y_{X/O}^O$	1.20
$Y_{X/O}^{OE}$	0.64
$Y_{X/C}^O$	0.81
$Y_{X/C}^r$	0.11
$Y_{X/C}^{OE}$	1.11

q_{Smax}	3.5 [h ⁻¹]
q_{Omax}	0.256[h ⁻¹]
μ_{Emax}	0.17 [h ⁻¹]
k_E	0.10 [g/l]
k_i	0.10 [g/l]
k_S	0.20 [g/l]
k_O	0.0001 [g/l]

Tab1-Les coefficients de rendement Tab2- les paramètres cinétiques

Les coefficients de rendements sont sans dimensions, car ils sont des facteurs de conversion exprimés en gramme biomasse par gramme de glucose, d'éthanol, d'oxygène ou de gaz carbonique ; par contre les paramètres cinétiques sont exprimés en [h⁻¹] ;

Les données utilisées dans notre travail de modélisation neuronale et modélisation neuronale hybride, sont générées par le modèle dynamique cité auparavant ; la durée du processus de fermentation de la levure *saccharomyces cerevisiae* est de 20 heures, avec une période d'échantillonnage de 0.1heure et un total de 201 valeurs générées exprimant le temps d'évolution des concentrations X, S, E, O_F et C_F sont collectées ; et les courbes de ces concentrations sont données dans la figure fig.3-1 :



Les 5 concentrations sont ici normalisées pour être utilisées dans les modélisations neuronales ; La normalisation d'une grandeur V est donnée par :

$$V_{nor} = \frac{V - \min(V)}{\max(V) - \min(V)} \tag{3-19}$$

On voit dans la figure3-1, que la concentration X croît jusqu'au temps $t = 15h$, qui n'est autre que le temps de changement du taux D de dilution, qui passe de $0.2h^{-1}$ à $0.25h^{-1}$;

Notons aussi que le changement du taux de dilution induit un changement dans les concentrations E , O_F et C_F qui augmentent très peu ; tandis que la concentration S reste inchangée car elle est déjà nulle ;

Dans les modélisations neuronales que nous allons discuter dans les chapitres 4 et 5, nous allons utiliser 151 échantillons pour faire l'apprentissage du réseau et les 50 échantillons restants pour la validation du modèle ;



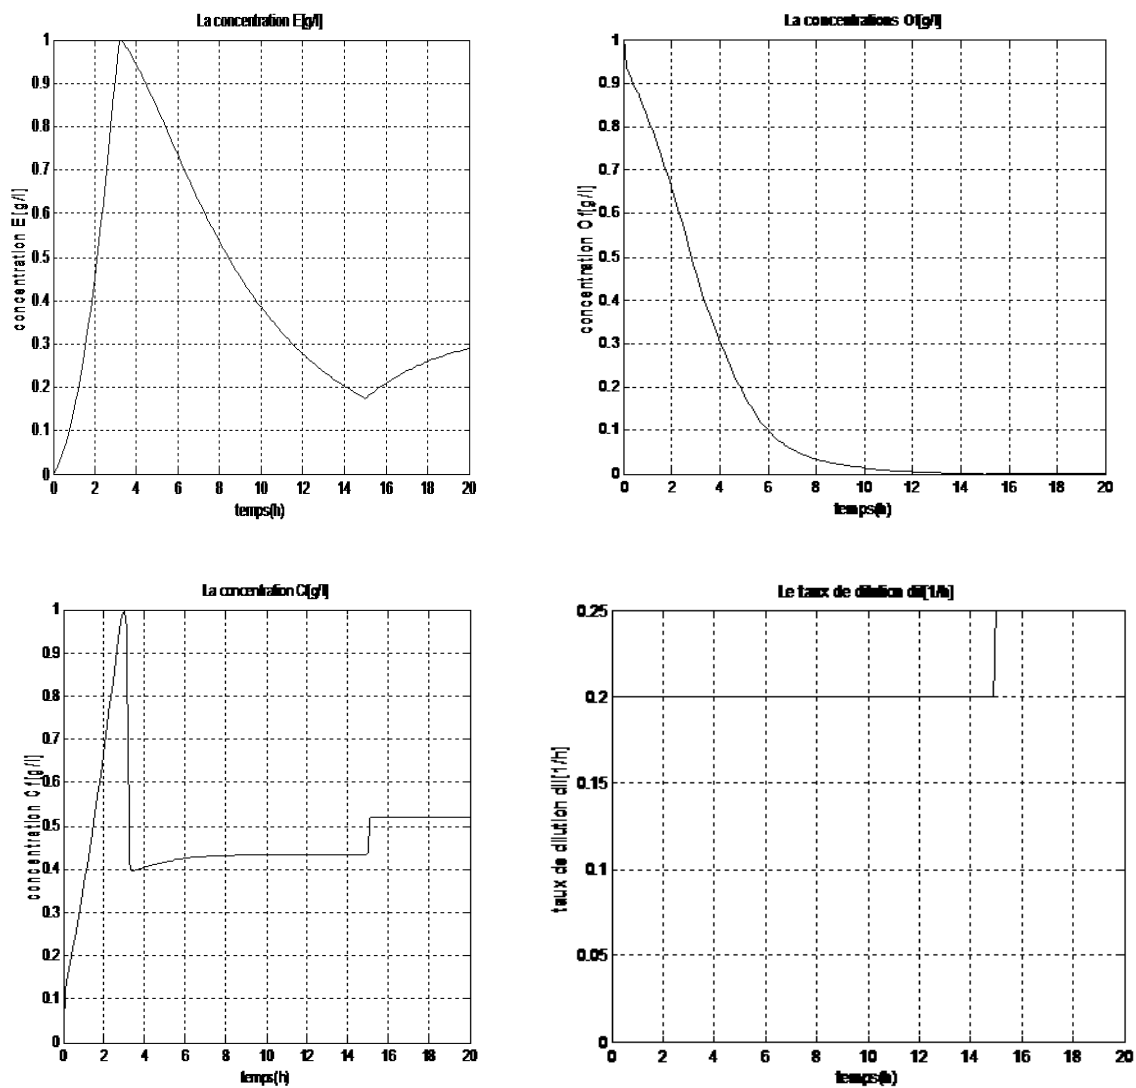


Fig.3-1 les courbes de X, S, E, O_F, C_F et du taux de dilution dil

Chapitre IV

Modélisation neuronale du chémostat

IV-1 Introduction

Plusieurs processus industriels de fermentation sont caractérisés par la non linéarité et le temps variant ; En plus, le milieu de culture contient des organismes vivants, l'application des techniques de commande échoue souvent à cause des effets tels que inhibition du substrat, inhibition du produit et effet crabtree. La commande réussie exige une bonne connaissance du processus à commander sous forme d'un modèle adéquat ;

Les méthodes d'intelligence artificielle ont offert de nouveaux outils effectifs dans la modélisation des systèmes ; Les méthodes basées sur les réseaux de neurones artificiels (ANN) sont imposées dans ce domaine durant cette dernière décade. Il a été montré que toute fonction continue peut être approximée d'une façon précise, par un réseau de neurones avec un nombre suffisant de neurones dans la couche cachée, (on utilise souvent une seule couche cachée, avec un nombre variable de neurones) ; et un nombre approprié de poids qu'on détermine en utilisant les données entrée /sortie; L'utilisation des modèles neuronaux boîte noire a réussi dans la modélisation des processus de fermentation.

IV-2 Le modèle neuronal

Pour modéliser notre processus, on a utilisé un modèle avec une seule couche cachée [3].[4] comportant 10 neurones et un biais, et dans un deuxième lieu un modèle avec deux couches cachées, comportant chacune 10 neurones et un biais ; Nous allons par la suite comparer les résultats d'apprentissage et de validation ; L'opération suivie est celle donnée par l'organigramme de base suivant :

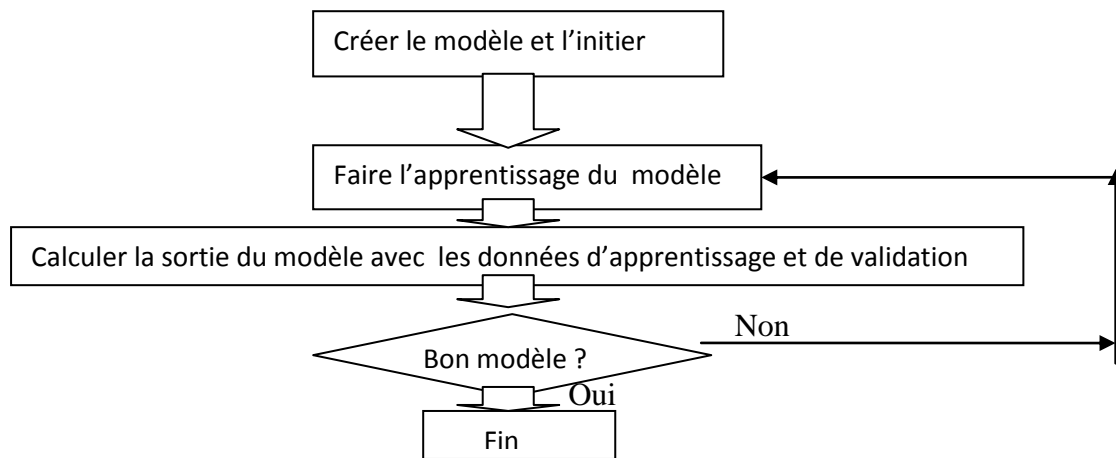


Figure4-1 organigramme de base de la modélisation

Le modèle doit donc répondre aux entrées qui sont en dehors du domaine d'apprentissage, c'est pourquoi on simule en appliquant les données d'apprentissage puis celle de validation et le modèle n'est acceptable que s'il vérifie aussi bien les données de validation avec une erreur satisfaisante que les données d'apprentissage ;

IV-2-1 Le modèle neuronal avec une seule couche cachée

L'architecture du modèle est donnée à la figure 4-1 [3] [4] :

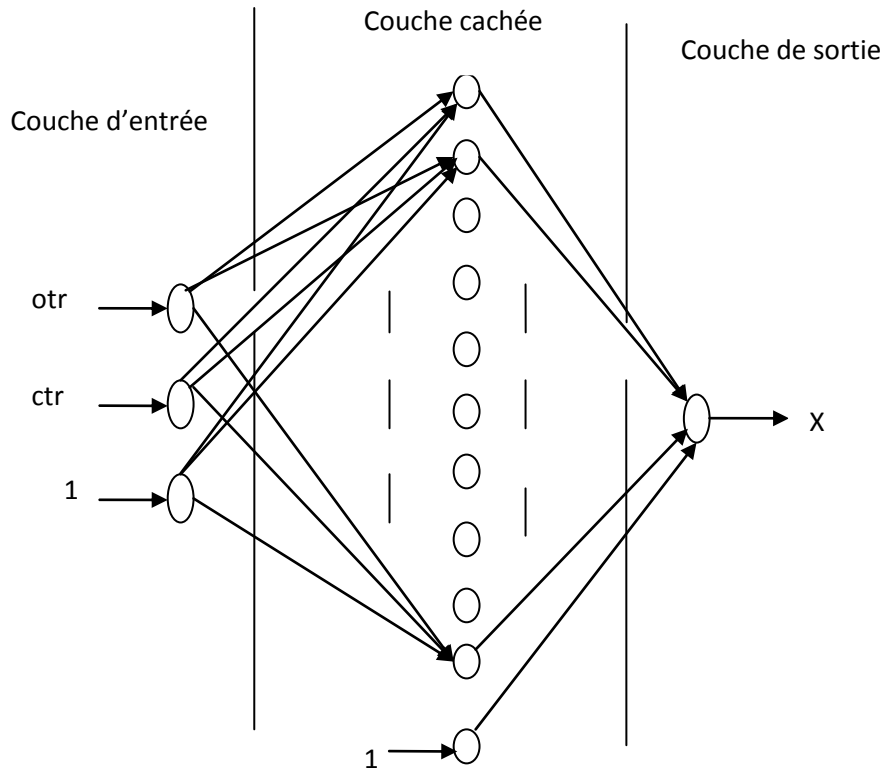


Figure 4-1 Architecture du modèle à une seule couche cachée

Le modèle neuronal de la figure 4-1, comporte une couche d'entrée composée de 3 neurones qui sont les neurones des entrées otr et ctr et le biais ; Une couche cachée composée de 10 neurones et un biais et enfin une couche de sortie qui comprend le neurone de sortie qui peut être X, S, E, O_F ou C_F ; Le nombre 10 de neurones de la couche cachée a été obtenu après essai et erreur, chaque neurone de la couche cachée reçoit 3 entrées et délivre une sortie ; la méthode utilisée est la minimisation de la somme des carrés des erreurs (SSE); on utilise le critère d'optimisation de levenberg-Marquardt [4] qui nous permet de déterminer un ensemble de poids (au nombre de 41 dans ces cas) minimisant SSE ; Les poids ici sont de deux types, il y a les poids de la couche d'entrée à la couche cachée et qui sont au nombre donné dans ce qui suit :

$$\text{nombre de poids entrée-cachée} = (\text{nombre d'entrées}+1)*h \quad (4-1)$$

résultant en 30 poids ; Où h est le nombre de neurones dans la couche cachée ; les poids de la couche cachée à la couche de sortie dont le nombre est donné par la formule suivante :

$$\text{nombre de poids cachée-sortie} = (h+1) \tag{4-2}$$

résultant en 11 poids ;

L'organigramme du critère de Levenberg-Marquardt est donné à la figure 4-2 ;

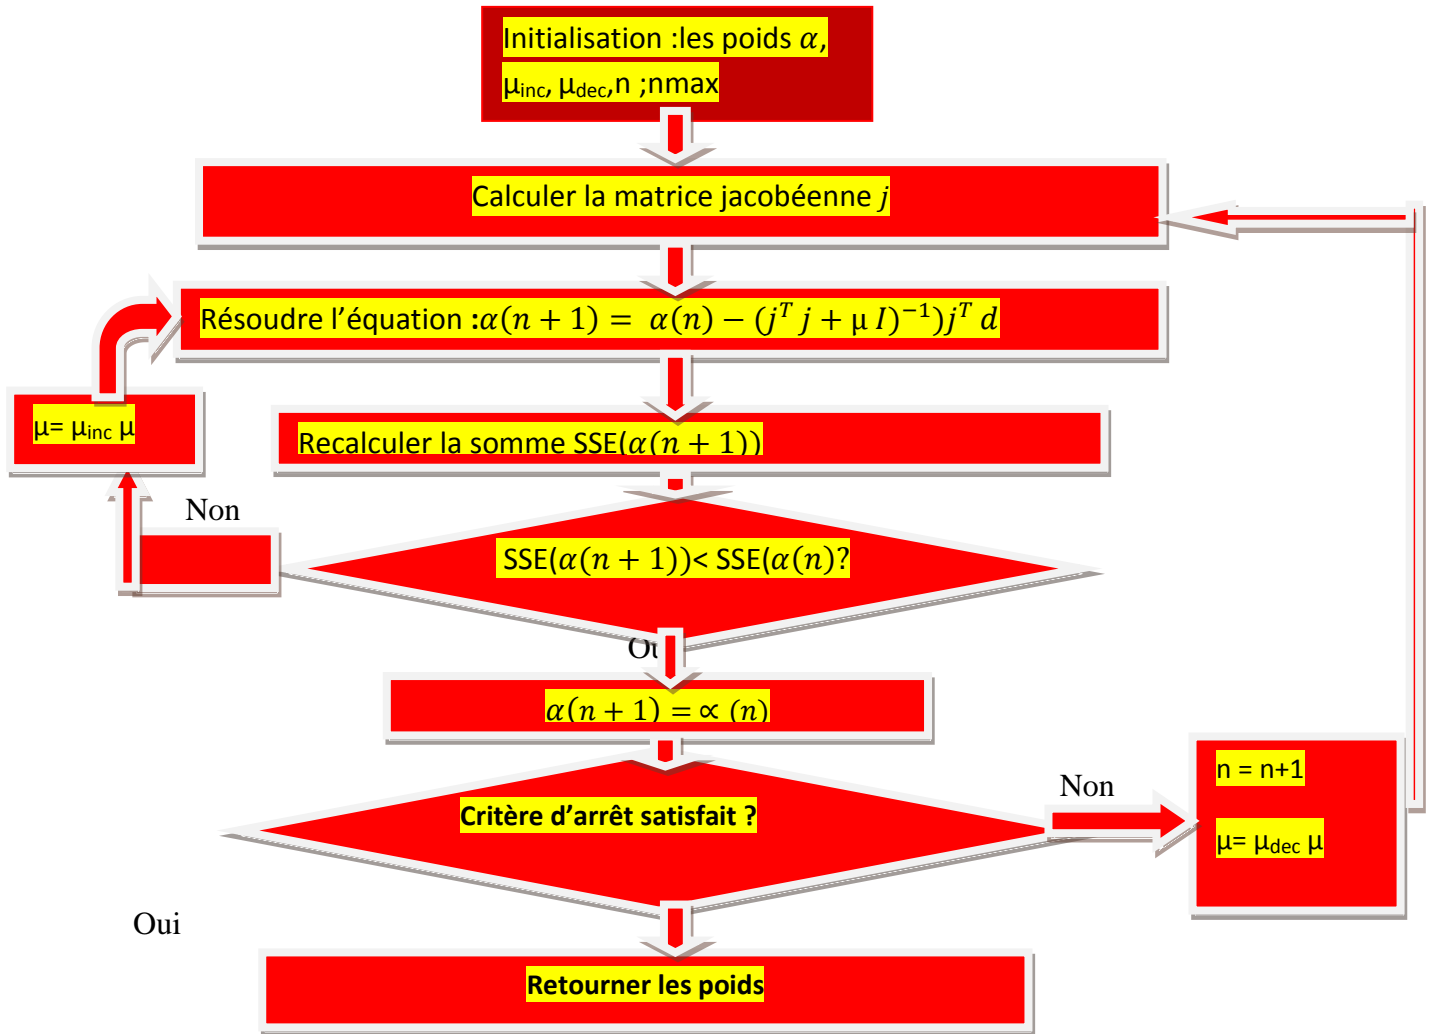


Figure 4-2 Organigramme de Levenberg- Marquardt

Dans l'organigramme de la figure 4-2, $\mu_{inc} = \frac{1}{\mu_{dec}}$;(exemple $\mu_{inc} = 10$; $\mu_{dec} = 0.1$; où $\mu_{inc} > 1$) ;

La procédure de l'algorithme est itérative et elle est conçue de la façon suivante :

- (i)- On part avec les poids initiaux, générés aléatoirement, qu'on utilise pour calculer la somme des carrés des erreurs (SSE) donnée par :

$$SSE = \frac{1}{2} \sum (\hat{y}(k) - y(k))^2 \quad (4-3)$$

Où \hat{y} et y sont les sorties estimée (du modèle) et mesurée respectivement ; Tandis que N est le nombre total d'échantillons d'apprentissage, qui est ici de 151 ;

L'algorithme *LM* trouve ce minimum en appliquant la routine :

$$\alpha(n + 1) = \alpha(n) - (J^T J + \mu I)^{-1} J^T d \quad (4-2)$$

de manière itérative, où :

J est la matrice jacobéenne, de dimension $(N, 41)$ donnée par :

$$J(w_i) = \begin{pmatrix} \frac{\partial \hat{y}(1)}{\partial w_1} & \dots & \frac{\partial \hat{y}(1)}{\partial w_{30}} & \dots & \frac{\partial \hat{y}(1)}{\partial w_{31}} & \dots & \frac{\partial \hat{y}(1)}{\partial w_{41}} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{\partial \hat{y}(151)}{\partial w_1} & \dots & \frac{\partial \hat{y}(151)}{\partial w_{30}} & \dots & \frac{\partial \hat{y}(151)}{\partial w_{31}} & \dots & \frac{\partial \hat{y}(151)}{\partial w_{41}} \end{pmatrix} \quad (4-3)$$

w_i sont les poids qui sont désignés par α dans l'organigramme de (4-2), tandis que d est le vecteur d'erreur donné par

$$d(k) = \hat{y}(k) - y(k) \quad (4-4)$$

(ii)- Calculer la matrice jacobéenne par l'équation (4-3) ;

(iii)- Résoudre l'équation (4-2) pour la mise-à-jour des paramètres α ;

(iv)- Avec ces nouveaux paramètres, recalculer la somme (SSE) par l'équation (4-1);

(v)- Si ($SSE (n+1) < SSE (n)$), prendre le nouveau vecteur de paramètres comme vecteur courant et diminuer le facteur μ ; Sinon, garder l'ancien vecteur de paramètres et augmenter le facteur μ et y rester jusqu'à ce que $SSE (n+1)$ devient encore plus petite que $SSE (n)$;

(vi)- Quand le critère d'arrêt est satisfait, retourner les poids α ; Le critère d'arrêt peut être obtenu quand le nombre d'itérations a atteint le nombre maximum et qui est fixé au debut des itérations (dans notre cas ,ce nombre est de $n_{max}=100$) ;

Les résultats de simulations en utilisant le modèle neuronal à une couche cachée sont donnés au chapitreV ;

IV-2-2 Le modèle neuronal avec deux couches cachées [3] [4] :

Le modèle neuronal de la figure 4-2, comporte une couche d'entrée composée de 3 neurones qui sont les neurones des entrées otr et ctr et le biais ; Une couche cachée composée de 10 neurones et un biais et une deuxième couche cachée qui comprend aussi 10 neurones et un biais, une couche de sortie qui comprend le neurone de sortie qui peut être X, S, E, O_F ou C_F ; Le nombre 10 des neurones de chacune des couches cachées a été obtenu après essai et erreur, chaque neurone de la 1^{ère} couche cachée reçoit 3 entrées et délivre 10 sorties ; Tandis que chaque neurone de la 2^{ème} couche cachée reçoit 10 entrées et délivre une sortie ;

La méthode utilisée est la minimisation de la somme des carrés des erreurs (SSE); on utilise le critère d'optimisation de levenberg-Marquardt [4] qui nous permet de déterminer un ensemble de poids (au nombre de 151 dans ces cas) en minimisant SSE ;

L'architecture du modèle est donnée à la figure 4-2 ;

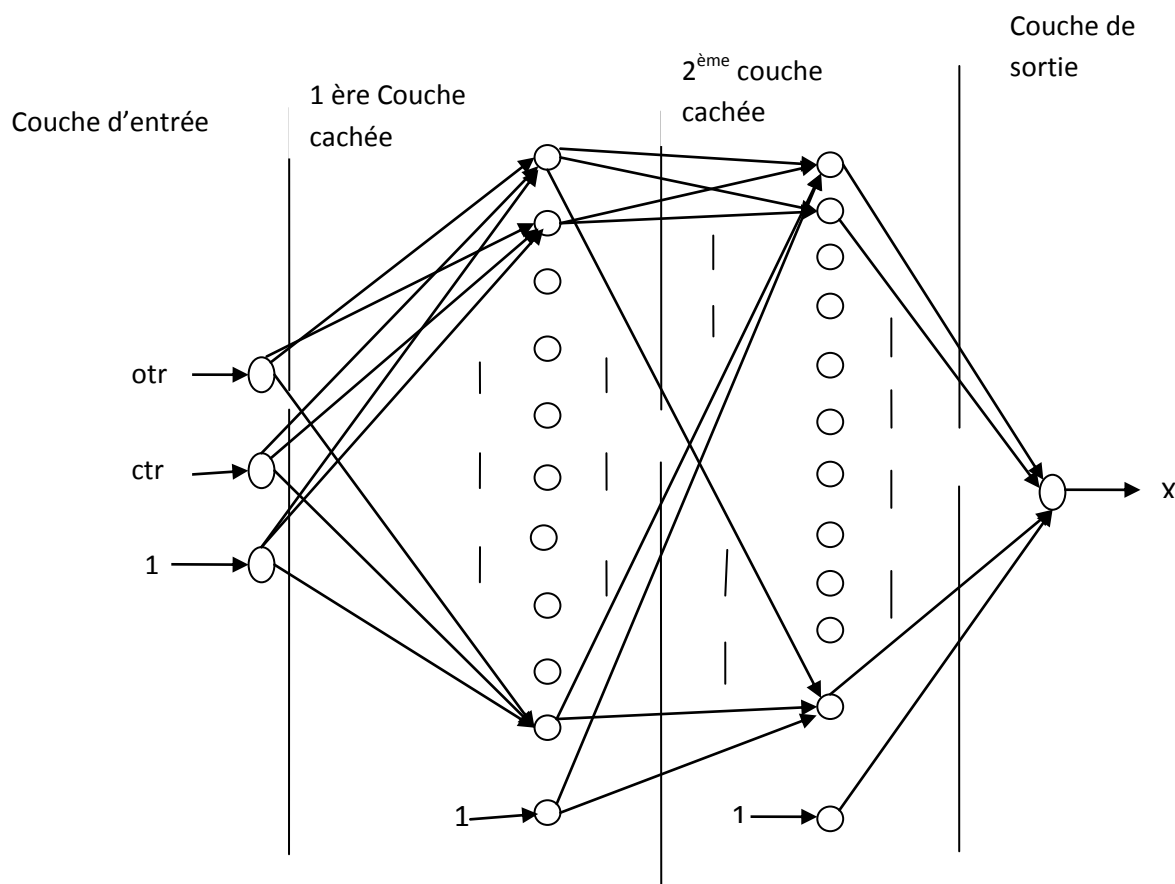


Figure 4-2 Architecture du modèle à deux couches cachées

Chapitre V**La modélisation neuronale hybride du processus****V-1 Introduction**

Les modèles des bioprocédés créent la base pour une supervision, optimisation et une commande avancées. Les modèles sont généralement vus comme des représentations qui peuvent être utilisées pour tester notre connaissance du processus considéré. Ils doivent être développés d'une façon itérative, par comparaison entre les données du processus réel et celles prédites par le modèle. L'ajustage des paramètres du modèle entre en jeu, dès que les déviations entre les sorties sont plus grandes qu'un certain seuil fixé auparavant. Uniquement, quand les prédictions et les données obtenues sous certaines conditions opératoires coïncident, que le modèle peut être regardé comme une représentation valide du processus. Une fois que le modèle est validé, il peut être utilisé pour améliorer la commande du procédé.

Pour l'utilisation des modèles mathématiques, des techniques numériques bien connues, peuvent être utilisées. Il y a plusieurs manières de représentations heuristiques d'un système. La représentation la plus populaire, durant ces dernières années, est basée sur la théorie floue développée par Zadeh (1973). Les données réelles peuvent être utilisées directement, pour l'apprentissage des réseaux de neurones. Les réseaux entraînés prouvent être des outils puissants pour la représentation des processus non linéaires.

Un défi dans la supervision et la commande avancées des procédés est l'utilisation simultanée de toutes les connaissances disponibles. On ne peut ignorer une partie de la connaissance.

Une première approche est de combiner un modèle mathématique dynamique, représenté par un ensemble d'équations différentielles ordinaires avec un réseau (ANN) de neurones artificiel [3], [4], [5] [6]. Le problème principal est que les procédures usuelles d'apprentissage ne peuvent fonctionner ; Alors de nouvelles méthodes d'apprentissage doivent être développées.

V-2 Combinaison d'un modèle mathématique et d'un réseau ANN

On considère le problème d'un système régi par une équation différentielle de la forme :

$$\frac{dy}{dt} = f(y(t), x(t), v) \quad (5-1)$$

Où f est un vecteur non linéaire, $y(t)$ est la sortie du système, $x(t)$ est les entrées du système, v est un ensemble de paramètres pouvant être déterminés à partir du réseau ANN ;

La combinaison est telle qu'elle est représentée par la figure fig.5-1 ; Pour entraîner le réseau ANN, des paires (x, y) de données d'entrée/sortie, mesurées au processus réel sont utilisées. L'apprentissage du réseau ANN exige que les poids w soient déterminés tels que la somme SSE des carrés des erreurs, entre la sortie \hat{y}_i prédite par le réseau et la sortie y_i du processus réel devient minimale, où SSE est donnée par l'équation (4-1) ; Le minimum de SSE est trouvé tel que les poids α sont reliés par l'équation (4-2), qui est expliquée dans le chapitre IV ;




Fig.5-1 Combinaison du réseau ANN et du modèle mathématique

La matrice jacobéenne J constituée des éléments $\frac{\partial y_i}{\partial w}$ ne peut être calculée, car dans le système combiné, la sortie \hat{y} est différente de la sortie v du réseau. Normalement, v n'est pas connue. Une alternative prometteuse est l'approche de la sensibilité, basée sur un concept développé dans l'engineering des systèmes. L'idée générale est de représenter le modèle entier, y compris le réseau ANN, par une seule équation différentielle donnée par :

$$\frac{dy}{dt} = f(y(t), x(t), w) \quad (5-3)$$

Où les paramètres caractérisant la partie réseau sont les poids w . Durant l'apprentissage du réseau, cette équation différentielle doit être résolue, pour un certain $x(t)$ fixé. Pour calculer $\frac{\partial y_i}{\partial w}$, on doit dériver l'équation différentielle (5-3) par rapport à w , pour obtenir :

$$\frac{d}{dt} \left(\frac{\partial y}{\partial w} \right) = \frac{\partial f}{\partial y} \frac{\partial y}{\partial w} + \frac{\partial f}{\partial w} \quad (5-4)$$

l'équation (5-4) est une équation différentielle, résolue pour déterminer $\frac{\partial y}{\partial w}$, la condition initiale pour sa résolution est $\frac{\partial y(t=0)}{\partial w} = 0$ [5] ;

V-2-1 Estimation du taux r_x et de la concentration X

Comme le taux spécifique d'accroissement cellulaire r_x , est non mesurable ; un moyen de l'estimer est l'utilisation du modèle hybride donné à la figure fig.5-1, comme dans ce cas, la sortie du réseau ANN est r_x , cette dernière est utilisée par le modèle mathématique pour estimer la concentration X de la biomasse, en utilisant l'équation différentielle (3-1), dans laquelle μ est remplacée par r_x ; Le schéma est donné par la figure fig.5-2 ;

L'équation (5-3) devient dans ce cas :

$$\frac{dX}{dt} = (r_x - D)X + X^R D \quad (5-5)$$

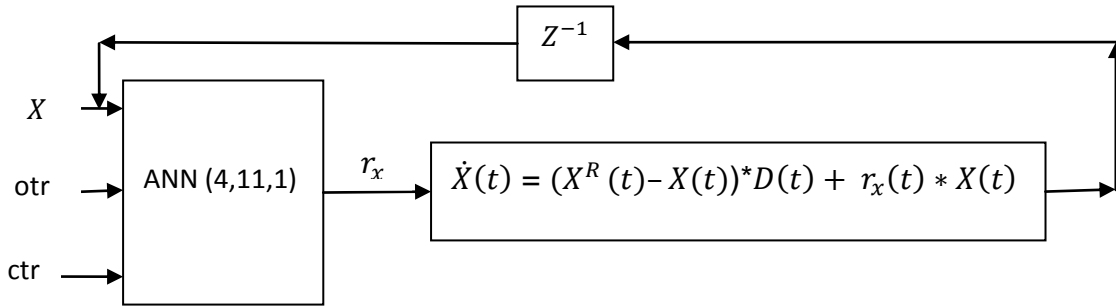


Fig.5-2 estimation du taux r_x et de la concentration X

Donc

$$f = (r_x - D)X + X^R D \quad (5-6)$$

$$\frac{\partial f}{\partial X} = (r_x - D) + X \frac{\partial r_x}{\partial X} \quad (5-7)$$

et
$$\frac{\partial f}{\partial w} = X \frac{\partial r_x}{\partial w} \quad (5-8)$$

Dans l'équation (5-4), il suffit de remplacer y par X , ainsi l'équation (5-4) devient :

$$\frac{d}{dt} \left(\frac{\partial X}{\partial w} \right) = \left(r_x - D + X \frac{\partial r_x}{\partial X} \right) \left(\frac{\partial X}{\partial w} \right) + X \frac{\partial r_x}{\partial w} \quad (5-9)$$

L'équation différentielle (5-9) où l'inconnue est $\frac{\partial X}{\partial w}$ est résolue en utilisant la condition initiale $\frac{\partial X(t=0)}{\partial w} = 0$; Dans sa résolution, on doit calculer $\frac{\partial r_x}{\partial X}$ et $\frac{\partial r_x}{\partial w}$; ces deux quantités sont calculées en utilisant la méthode de rétro propagation et avec toutes ces données, on utilise la méthode de Runge-Kutta d'ordre 4, pour résoudre l'équation (5-9) et obtenir $\frac{\partial X}{\partial w}$ nécessaire pour l'apprentissage du réseau, la formule de Runge-Kutta d'ordre 4 est donnée dans ce qui suit:

Considérons le problème :
$$y' = f(t, y) \quad (5-10)$$

Où
$$y(t_0) = w_0$$

Si h est le pas, tel que
$$t_i = t_0 + ih$$

Alors, la formule suivante :

$$k_1 = hf(t_i, w_i)$$

$$k_2 = hf\left(t_i + \frac{h}{2}, w_i + \frac{k_1}{2}\right)$$

$$k_3 = hf\left(t_i + \frac{h}{2}, w_i + \frac{k_2}{2}\right)$$

$$k_4 = hf\left(t_i + h, w_i + k_3\right)$$

$$w_{i+1} = w_i + (k_1 + 2k_2 + 2k_3 + k_4)/6$$

calcule une solution approximative, donnée par $w_i = y(t_i)$;

Les résultats d'estimation de r_x et X sont donnés dans le chapitre VI ;

V-2-2 Estimation du taux q_S et de la concentration S

On sait que le taux spécifique q_S de consommation du glucose ne peut être mesuré, pour l'estimer, on peut utiliser le modèle hybride qui est donné à la figure fig.5-3 ; La sortie du

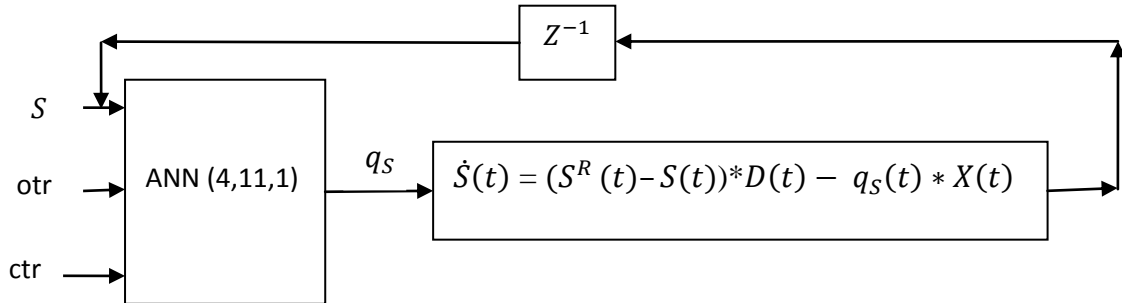


Fig.5-3 estimation du taux q_S et de la concentration S

réseau est q_S , que le modèle mathématique utilise pour estimer la concentration S du glucose ; L'équation (5-3) devient dans ce cas :

$$\frac{dS}{dt} = -SD - q_S X + S^R D \quad (5-11)$$

La fonction f est donc donnée par :

$$f = -SD - q_S X + S^R D \quad (5-12)$$

$$\frac{\partial f}{\partial S} = -D - X \frac{\partial q_S}{\partial S} \quad (5-13)$$

et
$$\frac{\partial f}{\partial w} = -X \frac{\partial q_S}{\partial w} \quad (5-15)$$

L'équation finale est donnée par :

$$\frac{d}{dt} \left(\frac{\partial S}{\partial w} \right) = \left(-D - X \frac{\partial q_S}{\partial S} \right) \left(\frac{\partial S}{\partial w} \right) - X \frac{\partial q_S}{\partial w} \quad (5-16)$$

Dans cette équation, l'inconnue est $\frac{\partial S}{\partial w}$ et elle est résolue en utilisant la condition initiale $\frac{\partial S(t=0)}{\partial w} = 0$; La dérivée de la valeur initiale de la concentration S par rapport à w est nulle ; On utilise la méthode de rétro propagation pour calculer $\frac{\partial q_S}{\partial S}$ et $\frac{\partial q_S}{\partial w}$ qui sont nécessaires pour la résolution d'une telle équation ; $\frac{\partial S}{\partial w}$ est utilisée dans l'apprentissage du réseau et elle est calculée par l'intermédiaire de la formule de Runge-Kutta d'ordre 4 ;

V-2-3 Estimation du taux q_E et de la concentration E

Comme on ne peut mesurer le taux spécifique de réaction q_E d'éthanol, on a utilisé le modèle hybride pour l'estimer ; Le taux q_E est donné par :

$$q_E = q_{Epr} - q_{Ec} \tag{5-17}$$

Où q_{Epr} et q_{Ec} sont les taux spécifiques de production et de consommation d'éthanol respectivement, car dans la fermentation de la levure, l'éthanol peut être un substrat ou un produit ; le modèle utilisé est donné à la figure fig.5-4

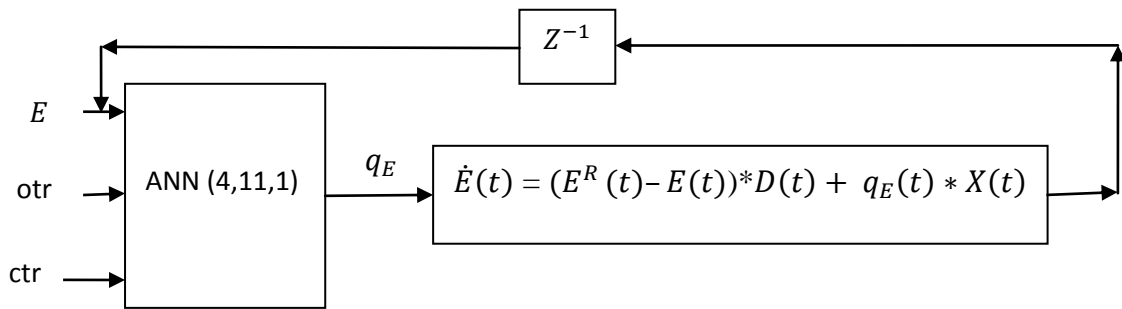


Fig.5-4 estimation du taux q_E et de la concentration E

Pour estimer la concentration E d'éthanol, le modèle mathématique utilise q_E qui est à son tour, estimé par le réseau ANN, l'équation (5-3) devient dans ce cas

$$\frac{dE}{dt} = -ED + q_E X + E^R D \tag{5-18}$$

$$f \text{ est donnée par : } f = -ED + q_E X + E^R D \tag{5-19}$$

$$\frac{\partial f}{\partial E} = -D + X \frac{\partial q_E}{\partial E} \tag{5-20}$$

et
$$\frac{\partial f}{\partial w} = X \frac{\partial q_E}{\partial w} \tag{5-21}$$

Finalement, l'équation est donnée par :

$$\frac{d}{dt} \left(\frac{\partial E}{\partial w} \right) = \left(-D + X \frac{\partial q_E}{\partial E} \right) \left(\frac{\partial E}{\partial w} \right) + X \frac{\partial q_E}{\partial w} \tag{5-22}$$

Cette équation dont l'inconnue est $\frac{\partial E}{\partial w}$ est résolue en utilisant la condition initiale

$\frac{\partial E(t=0)}{\partial w} = 0$, qui signifie que la dérivée de la concentration initiale de E par rapport à w est nulle ; Les quantités $\frac{\partial q_E}{\partial E}$ et $\frac{\partial q_E}{\partial w}$ qui sont nécessaires pour la résolution de l'équation (5-22), sont calculées en utilisant la méthode de la rétro propagation ; La solution de cette équation différentielle et qui est $\frac{\partial E}{\partial w}$ est utilisée dans l'apprentissage du réseau ANN. On utilise toujours la formule de Runge-Kutta d'ordre 4 pour résoudre cette équation.

Chapitre VI

Simulations

VI-1 Introduction

Les réseaux de neurones artificiels (ANN), ont été toujours utilisés pour approximer des fonctions aussi compliquées qu'elles soient ; le grand avantage des réseaux (ANN), est qu'ils peuvent être synthétisés sans une connaissance détaillée du processus à étudier. Uniquement, après la présentation des données entrée/sortie, la question qui se pose est est-ce que les sorties du réseau sont conformes aux spécifications du processus. La restriction est très sévère quand le réseau opère sur des données qui sont à l'extérieur du domaine d'apprentissage ; à ce moment, les prédictions peuvent être très différentes des sorties réelles ; Un moyen est que durant la simulation, il faut faire l'apprentissage et la validation et le modèle n'est accepté que s'il vérifie les deux ; Aussi, dans la modélisation des procédés de fermentation , certains facteurs tels que le taux spécifiques d'accroissement cellulaire, le taux spécifique de consommation du glucose, le taux spécifique de production d'éthanol ne peuvent être mesurés et un moyen de les estimer est d'utiliser le modèle hybride qu'on a détaillé dans le chapitre V.

VI-2 Résultats du modèle neuronal avec une seule couche cachée

Les données d'apprentissage du modèle sont celles générées par le modèle mathématique où les paramètres sont ceux de Sonnleitner et Käppeli, la durée de la fermentation est de 20h ; L'intervalle d'échantillonnage est de 0.1h ; on obtient ainsi 201 échantillons, où on utilise 151 pour apprentissage et 50 pour validation ; on procède à l'estimation et la validation des cinq composantes ;

VI-2-1 Estimation et validation de la concentration X

En utilisant le modèle neuronal avec une seule couche cachée de 10 neurones plus le biais, et avec les entrées otr et ctr, qui sont les taux de transfert d'oxygène et de gaz carbonique respectivement, les courbes d'estimation de la concentration X , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de X sont données dans fig.5-1 ; L'erreur (MSE) d'estimation est de $1.3e-5$, tandis que l'erreur (MSE) de

validation est de 0.0194, l'erreur (MSE) d'estimation est beaucoup plus petite que l'erreur(MSE) de validation est du au fait que les données de validation sont en dehors du domaine d'apprentissage, mais une telle erreur de validation est satisfaisante pour que le modèle peut être accepté de représenter le processus pour supervision, optimisation et commande ;

VI-2-2 Estimation et validation de la concentration S

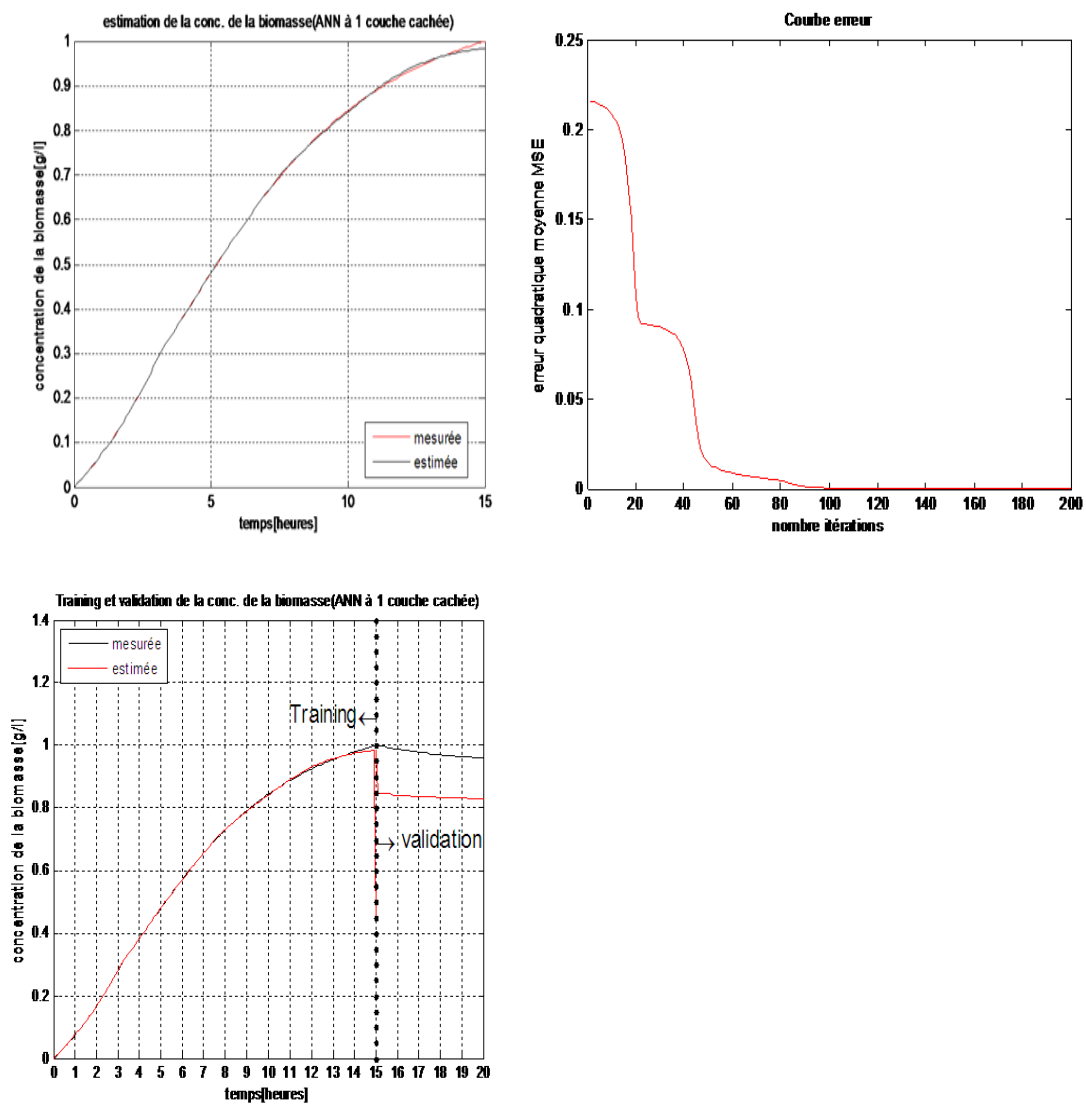


Fig.5-1 Courbes d'estimation de X , de MSE et d'estimation et validation de X

En utilisant le modèle neuronal avec une seule couche cachée de 10 neurones plus le biais, et avec les entrées otr et ctr, les courbes d'estimation de la concentration S , de l'erreur quadratique moyenne d'estimation (MSE) et de validation de S sont données dans fig.5-2 ; L'erreur (MSE) d'estimation est de $5.44e-8$, tandis que l'erreur (MSE) de validation est de $4.72e-8$, une telle erreur de validation est satisfaisante mais elle est plus petite que l'erreur d'estimation à cause, tout simplement, que le domaine de validation est très proche de zéro ;

VI-2-3 Estimation et validation de la concentration E

En utilisant le modèle neuronal avec une seule couche cachée de 10 neurones plus le biais, et avec les entrées otr et ctr, les courbes d'estimation de la concentration E , de l'erreur quadratique moyenne d'estimation (MSE) et de validation de E sont données dans fig.5-3 ; L'erreur (MSE) d'estimation est de $2.83e-5$, tandis que l'erreur (MSE) de validation est de 0.17, une telle erreur de validation est satisfaisante mais elle est beaucoup plus grande que l'erreur d'estimation à cause, tout simplement, que le domaine de validation est très différent du domaine d'apprentissage ;

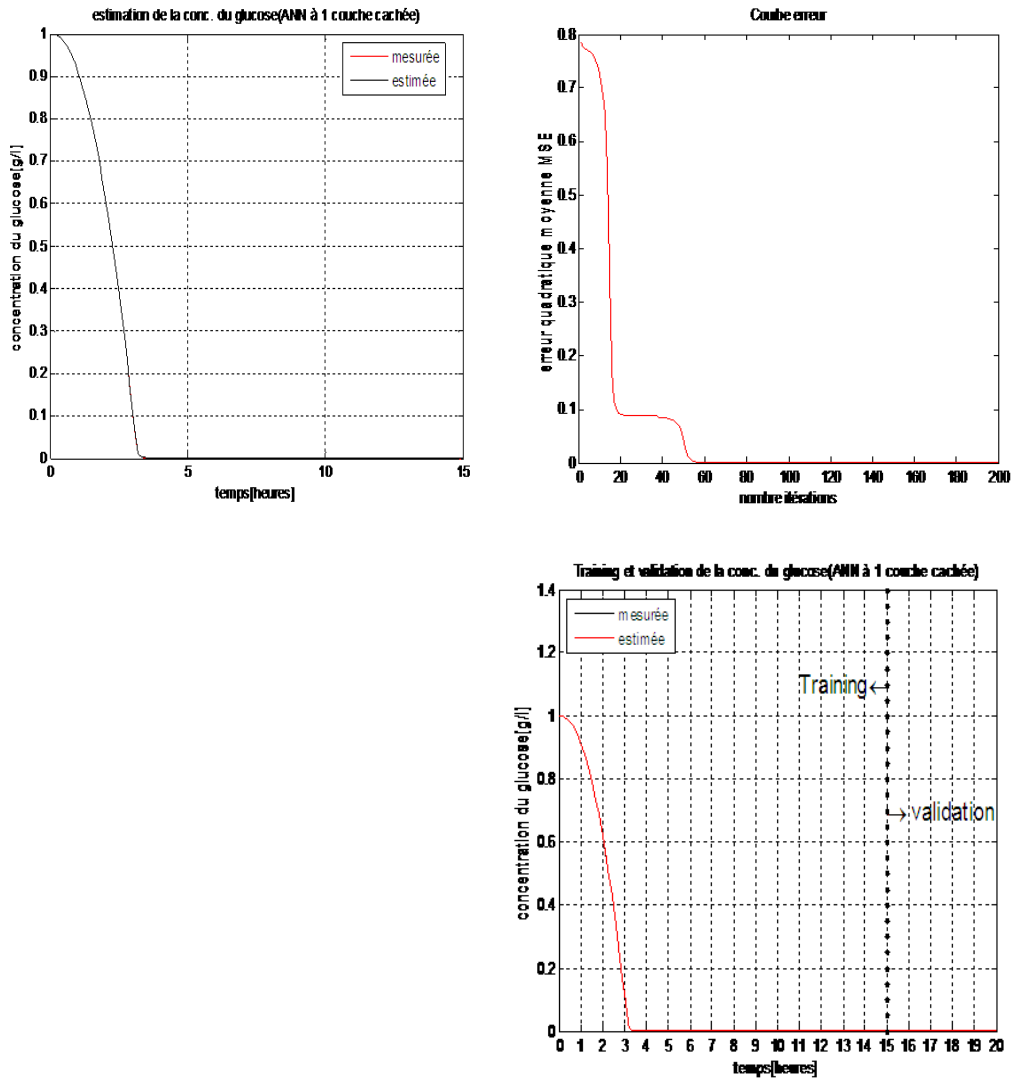


Fig.5-2 Courbes d'estimation de S , de MSE et d'estimation et validation de S

VI-2-4 Estimation et validation de la concentration O_F

En utilisant le modèle neuronal avec une seule couche cachée de 10 neurones plus le biais, et avec les entrées otr et ctr, les courbes d'estimation de la concentration O_F , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de O_F sont données dans fig.5-4 ; L'erreur (MSE) d'estimation est de 1.26×10^{-5} , tandis que l'erreur (MSE) de validation est de 1.87×10^{-4} , une telle erreur de validation est satisfaisante ;

VI-2-5 Estimation et validation de la concentration C_F

En utilisant le modèle neuronal avec une seule couche cachée de 10 neurones plus le

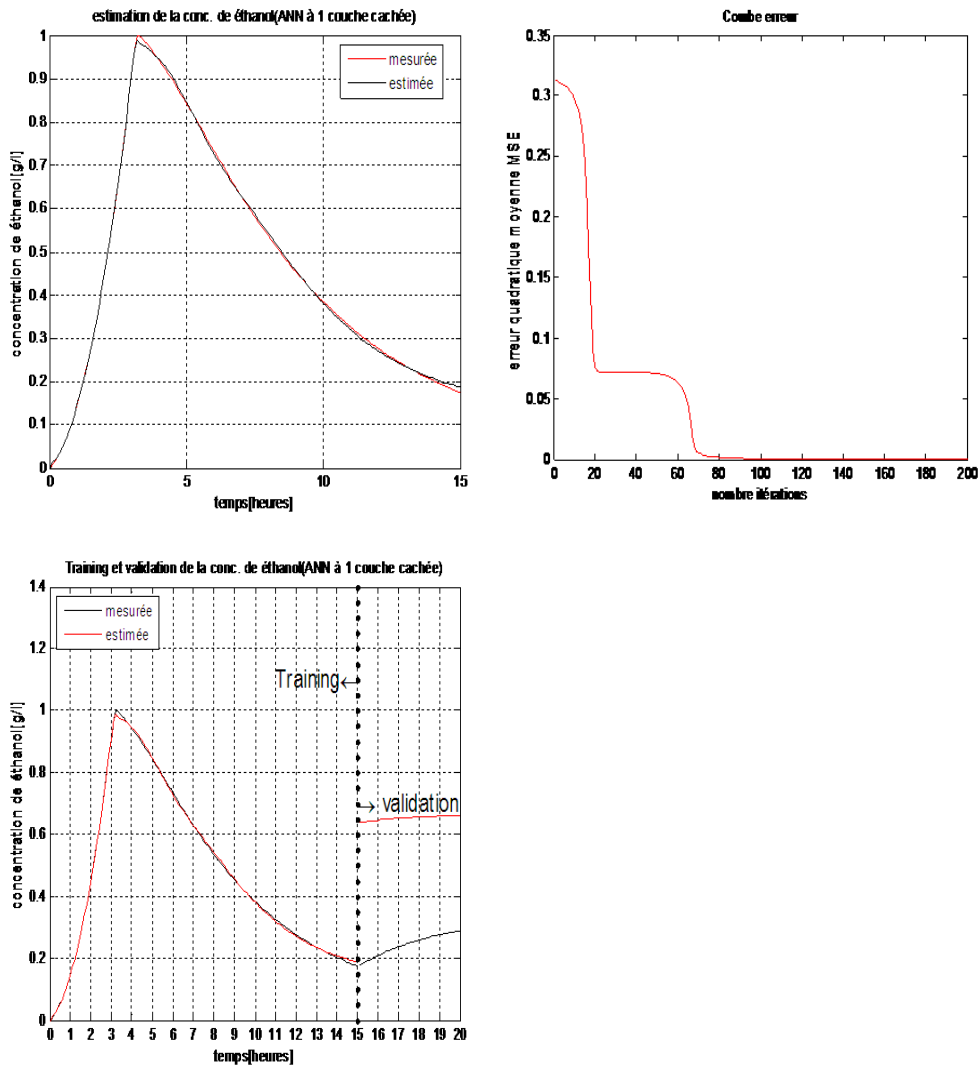


Fig.5-3 Courbes d'estimation de E , de MSE et d'estimation et validation de E

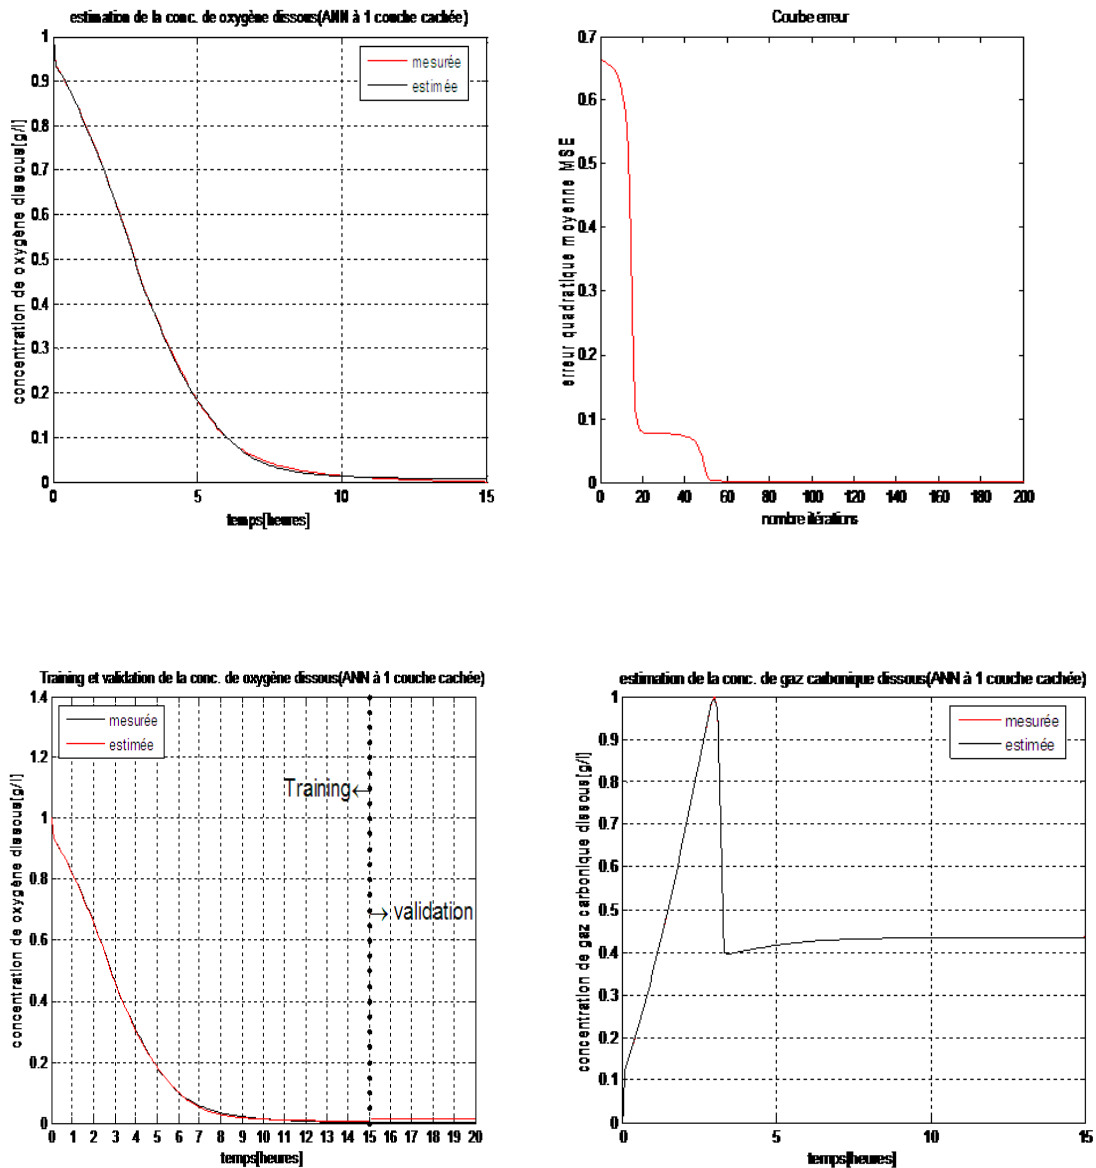


Fig.5-4 Courbes d'estim. de O_F , de MSE, d'estim. et valid.de O_F et d'estim. de C_F

biais, et avec les entrées otr et ctr, la courbes d'estimation de la concentration C_F est donnée à la figure fig.5-4,les courbes l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de C_F sont données dans fig.5-5 ; L'erreur (MSE) d'estimation est de $3.02e-7$, tandis que l'erreur (MSE) de validation est de $3.48e-6$, une telle erreur de validation est satisfaisante ;

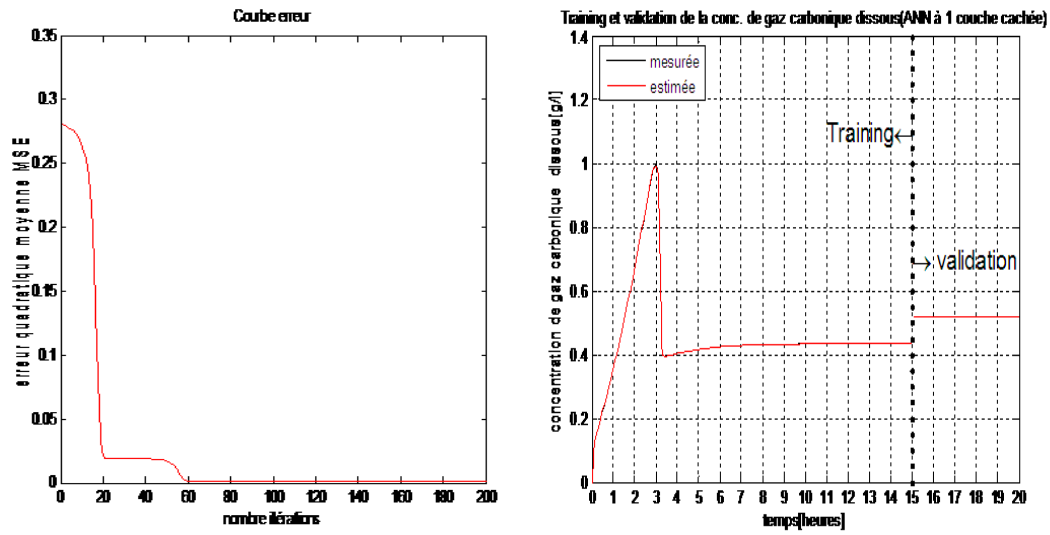


Fig.5-5 Courbes de MSE et d'estimation et validation de C_F

VI-3 Résultats du modèle neuronal avec deux couches cachées

Les données d'apprentissage du modèle sont toujours celles générées par le modèle mathématique où les paramètres sont ceux de Sonnleitner et Käppeli, la durée de la fermentation est de 20h ; L'intervalle d'échantillonnage est de 0.1h ; on obtient ainsi 201 échantillons, où on utilise 151 pour apprentissage et 50 pour validation ; on procède à l'estimation et la validation des cinq composantes ;

VI-3-1 Estimation et validation de la concentration X

En utilisant le modèle neuronal avec deux couches cachée de 10 neurones plus le biais chacune, et avec les entrées otr et ctr, qui sont les taux de transfert d'oxygène et de gaz carbonique respectivement, les courbes d'estimation de la concentration X , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de X sont données dans fig.5-6 ; L'erreur (MSE) d'estimation est de $1.83e-6$, tandis que l'erreur (MSE) de validation est de 0.0257, l'erreur (MSE) d'estimation est beaucoup plus petite que l'erreur (MSE) de validation est du au fait que les données de validation sont en dehors du domaine d'apprentissage, mais une telle erreur de validation est satisfaisante pour que le modèle peut être accepté de représenter le processus pour supervision, optimisation et commande ;

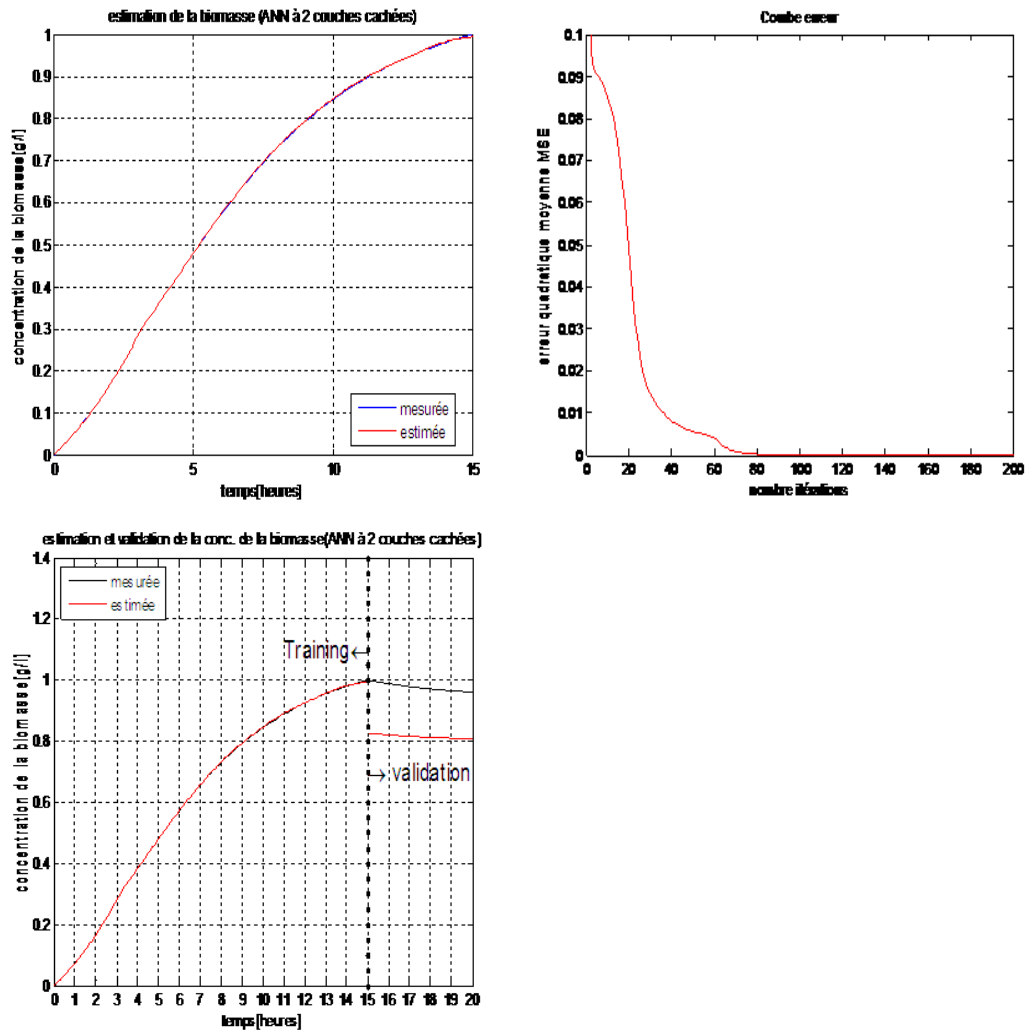


Fig.5-6 Courbes d'estimation de X , de MSE et d'estimation et validation de X

VI-3-2 Estimation et validation de la concentration S

En utilisant le modèle neuronal avec deux couches cachée de 10 neurones plus le biais chacune, et avec les entrées otr et ctr, qui sont les taux de transfert d'oxygène et de gaz carbonique respectivement, les courbes d'estimation de la concentration S , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de S sont données dans fig.5-7; L'erreur (MSE) d'estimation est de $6.64e-8$, tandis que l'erreur (MSE) de validation est de $2.87e-9$, une telle erreur de validation est satisfaisante mais elle est plus petite que l'erreur d'estimation à cause, tout simplement, que le domaine de validation est très proche de zéro ;

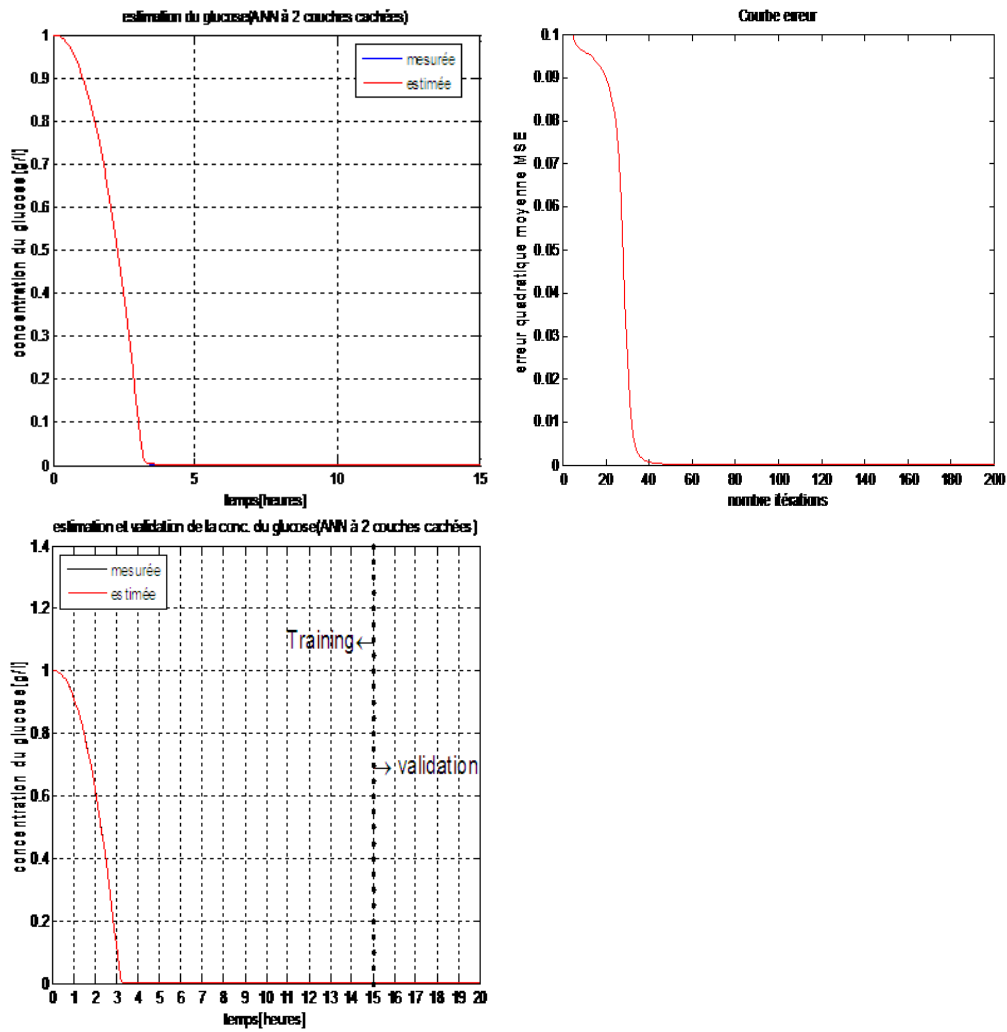


Fig.5-7 Courbes d'estimation de S , de MSE et d'estimation et validation de S

VI-3-3 Estimation et validation de la concentration E

En utilisant le modèle neuronal avec deux couches cachée de 10 neurones plus le biais chacune, et avec les entrées otr et ctr, qui sont les taux de transfert d'oxygène et de gaz carbonique respectivement, les courbes d'estimation de la concentration E , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de E sont données dans fig.5-8 ; L'erreur (MSE) d'estimation est de $2.16e-6$, tandis que l'erreur (MSE) de validation est de 0.12, une telle erreur de validation est satisfaisante mais elle est plus grande que l'erreur d'estimation car le domaine de validation est très différent de celui d'apprentissage.

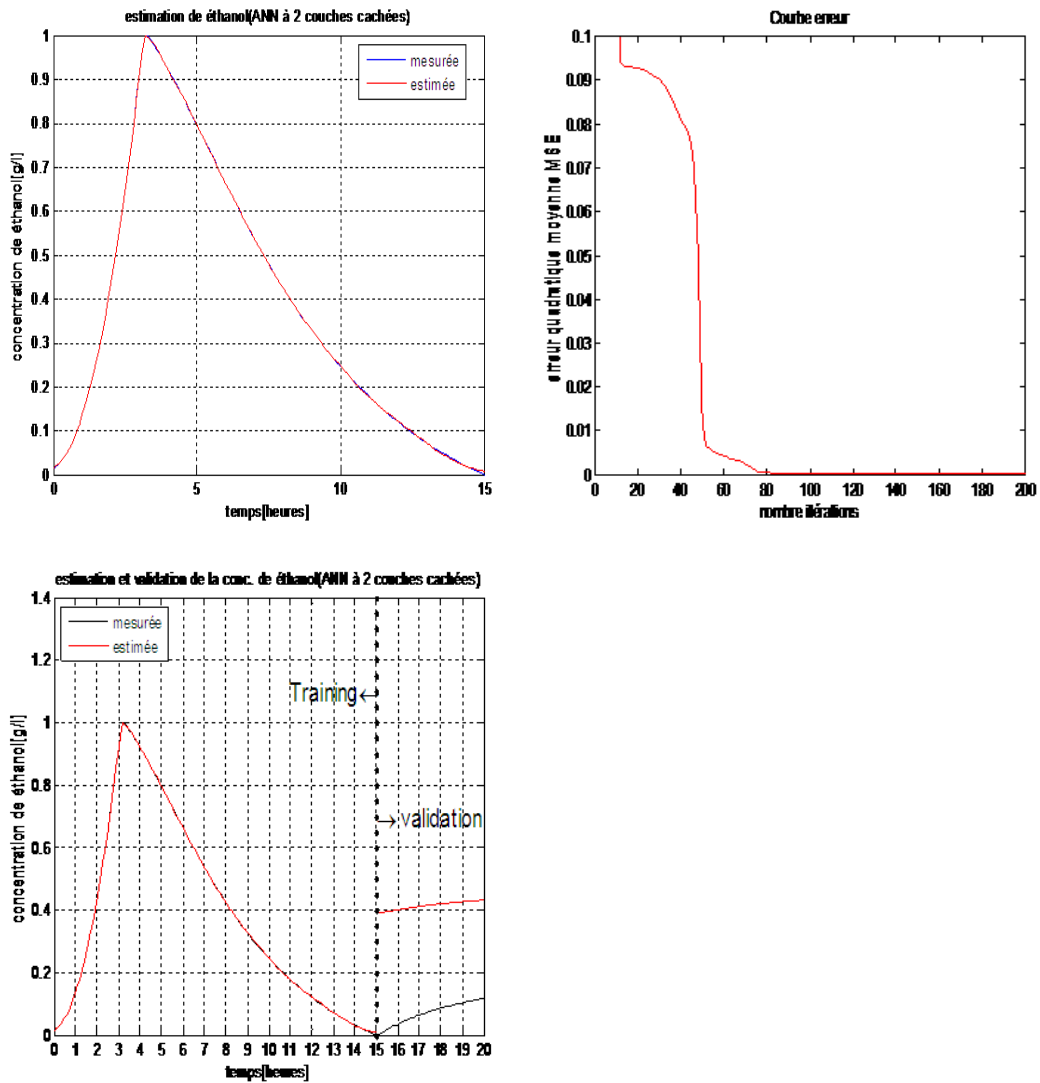


Fig.5-8 Courbes d'estimation de E , de MSE et d'estimation et validation de E

VI-3-4 Estimation et validation de la concentration O_F

En utilisant le modèle neuronal avec deux couches cachées de 10 neurones plus le biais chacune, et avec les entrées otr et ctr, les courbes d'estimation de la concentration O_F , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de O_F sont données dans fig.5-9 ; L'erreur (MSE) d'estimation est de $1.85e-7$, tandis que l'erreur (MSE) de validation est de $4.5e-5$, une telle erreur de validation est satisfaisante ;

VI-3-5 Estimation et validation de la concentration C_F

En utilisant le modèle neuronal avec deux couches cachées de 10 neurones plus le biais

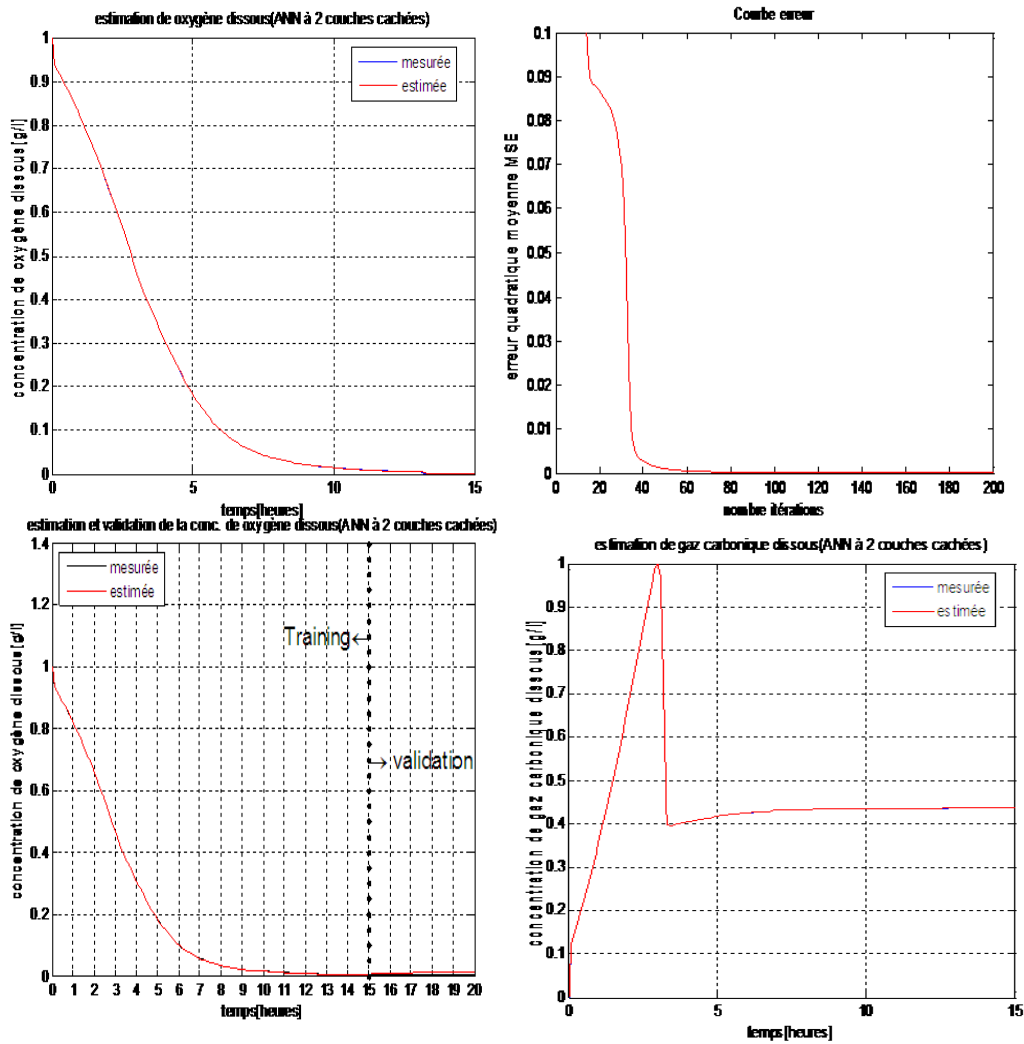


Fig.5-9 Courbes d'estim. de O_F , de MSE, d'estim. et valid.de O_F et d'estim. de C_F

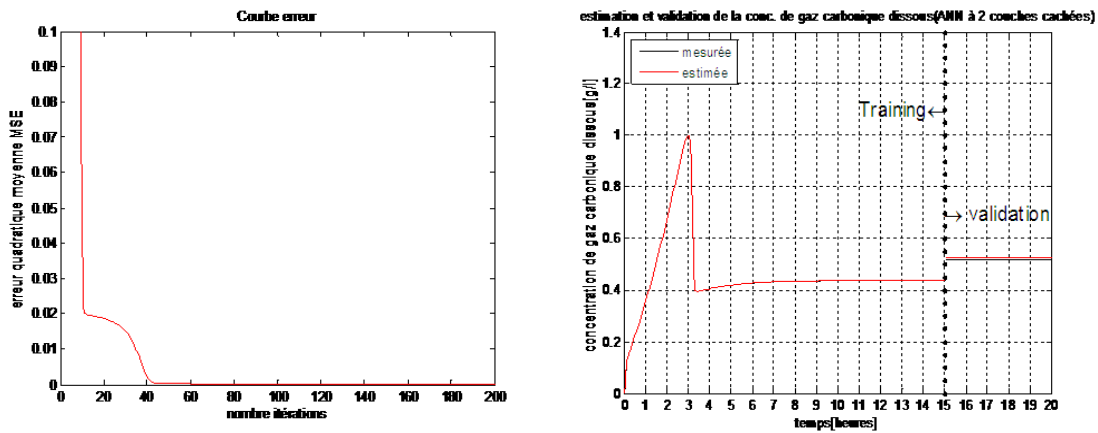


Fig.5-10 Courbes de MSE et d'estimation et validation de C_F

chacune, et avec les entrées otr et ctr, les courbes d'estimation de la concentration C_F , de l'erreur quadratique moyenne d'estimation (MSE) et d'estimation et de validation de C_F sont données dans fig.5-9 ; L'erreur (MSE) d'estimation est de $6.45e-9$, tandis que l'erreur (MSE) de validation est de $3.49e-5$, une telle erreur de validation est satisfaisante ;

VI-4 Résultats du modèle neuronal hybride

Avec le modèle neuronal hybride de la figure fig.5-1, les données d'entrée/sortie sont toujours générées par le modèle mathématique, le réseau (ANN) est ici utilisé pour estimer les taux spécifiques (taux spécifique r_x d'accroissement cellulaire, taux spécifique q_S de consommation du glucose et taux spécifique q_E de réaction d'éthanol), qui ne peuvent être mesurés, leur estimation par ce moyen est très satisfaisante ;

VI-4-1 Estimation du taux r_x et de la concentration X

On estime en premier lieu, le taux spécifique r_x normalisé qu'on utilise pour calculer la jacobéenne $\frac{\partial X}{\partial w}$ qu'on exprime en utilisant l'approche de la sensibilité, par l'équation (5-9), puis on utilise la formule de Runge-Kutta pour déterminer $\frac{\partial X}{\partial w}$, qui entre dans détermination des poids w_i pour l'apprentissage du réseau ANN ; Les courbes d'estimation de la concentration X , de l'erreur quadratique moyenne (MSE) et d'estimation du taux r_x sont données à la figure fig.5-11 ; L'erreur (MSE) d'estimation de X est de $1.44e-6$ et l'erreur (MSE) d'estimation de r_x est de $1.76e-4$; Ces erreurs sont satisfaisantes.

VI-4-2 Estimation du taux q_S et de la concentration S

On commence par estimer le taux spécifique q_S normalisé, ce dernier est utilisé dans la détermination de la jacobéenne $\frac{\partial S}{\partial w}$, qui est exprimée en utilisant l'approche de la sensibilité et on fait appel après cela à la formule de Runge-Kutta pour calculer $\frac{\partial S}{\partial w}$, la jacobéenne est utilisée dans Levenberg-marquardt pour déterminer les poids w_i qui entrent dans l'apprentissage du réseau ANN ; Les courbes d'estimation de la concentration S , de l'erreur quadratique moyenne (MSE) et d'estimation du taux q_S sont données à la figure fig.5-12 ; L'erreur (MSE) d'estimation de S est de $1.44e-6$ et l'erreur (MSE) d'estimation de q_S est de $1.76e-4$; Ces erreurs sont satisfaisantes.

VI-4-3 Estimation du taux q_E et de la concentration E

Le premier paramètre à estimer est le taux spécifique q_E de réaction d'éthanol, le calcul de la matrice jacobéenne $\frac{\partial E}{\partial w}$ fait appel à l'application de l'approche de la sensibilité pour la mettre comme une inconnue dans une équation différentielle où la valeur initiale de $\frac{\partial E}{\partial w}$ à $t=0$ est égale à zéro ; Pour la mise-à jour des poids w_i , on utilise cette jacobéenne dans le critère de Levenberg-Marquardt par l'équation (4-2) ; Les courbes d'estimation de la concentration E , de l'erreur quadratique moyenne (MSE) et d'estimation du taux q_{Ea} sont données à la figure fig.5-13 ; L'erreur (MSE) d'estimation de E est de $5.47e-5$ et l'erreur (MSE) d'estimation de q_E est de $1.02e-4$; Ces erreurs sont satisfaisantes

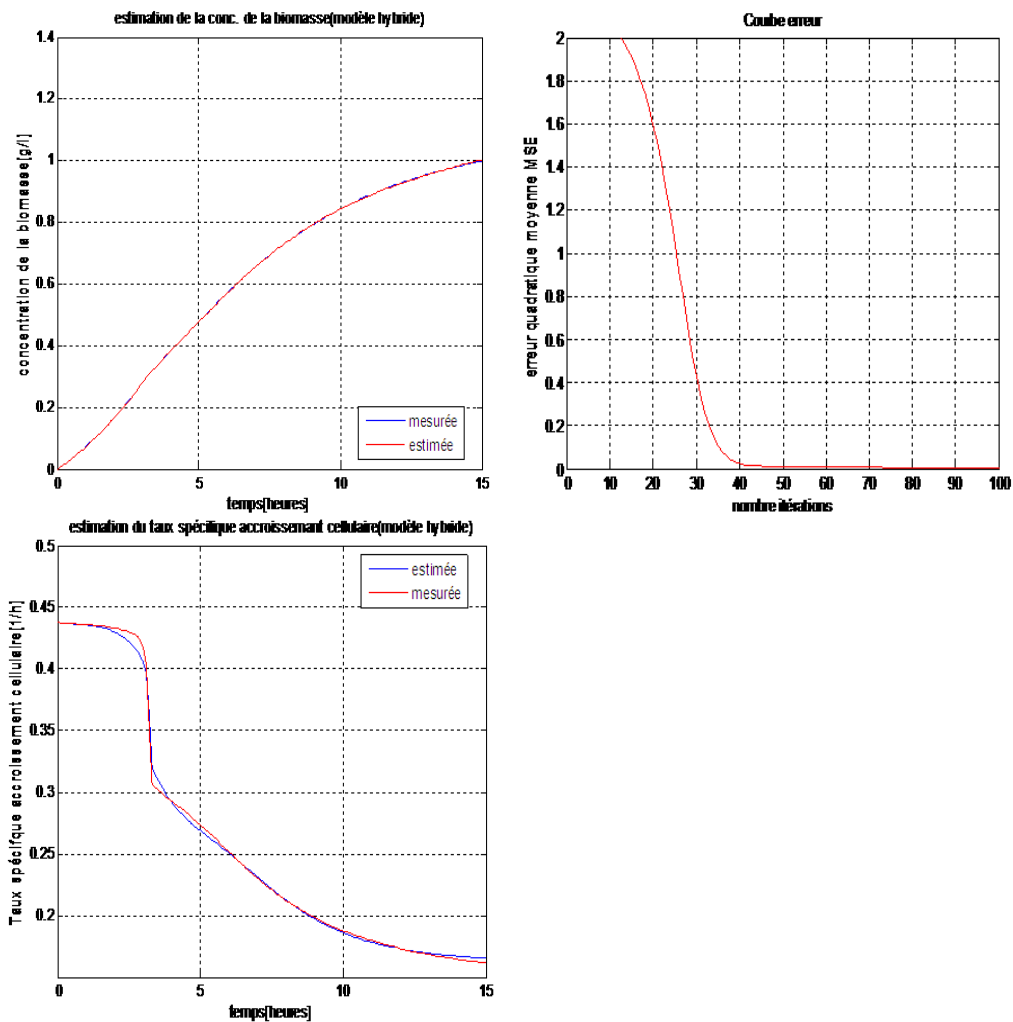


Fig.5-11 Courbes d'estimation de X , de MSE de X et d'estimation de τ_x

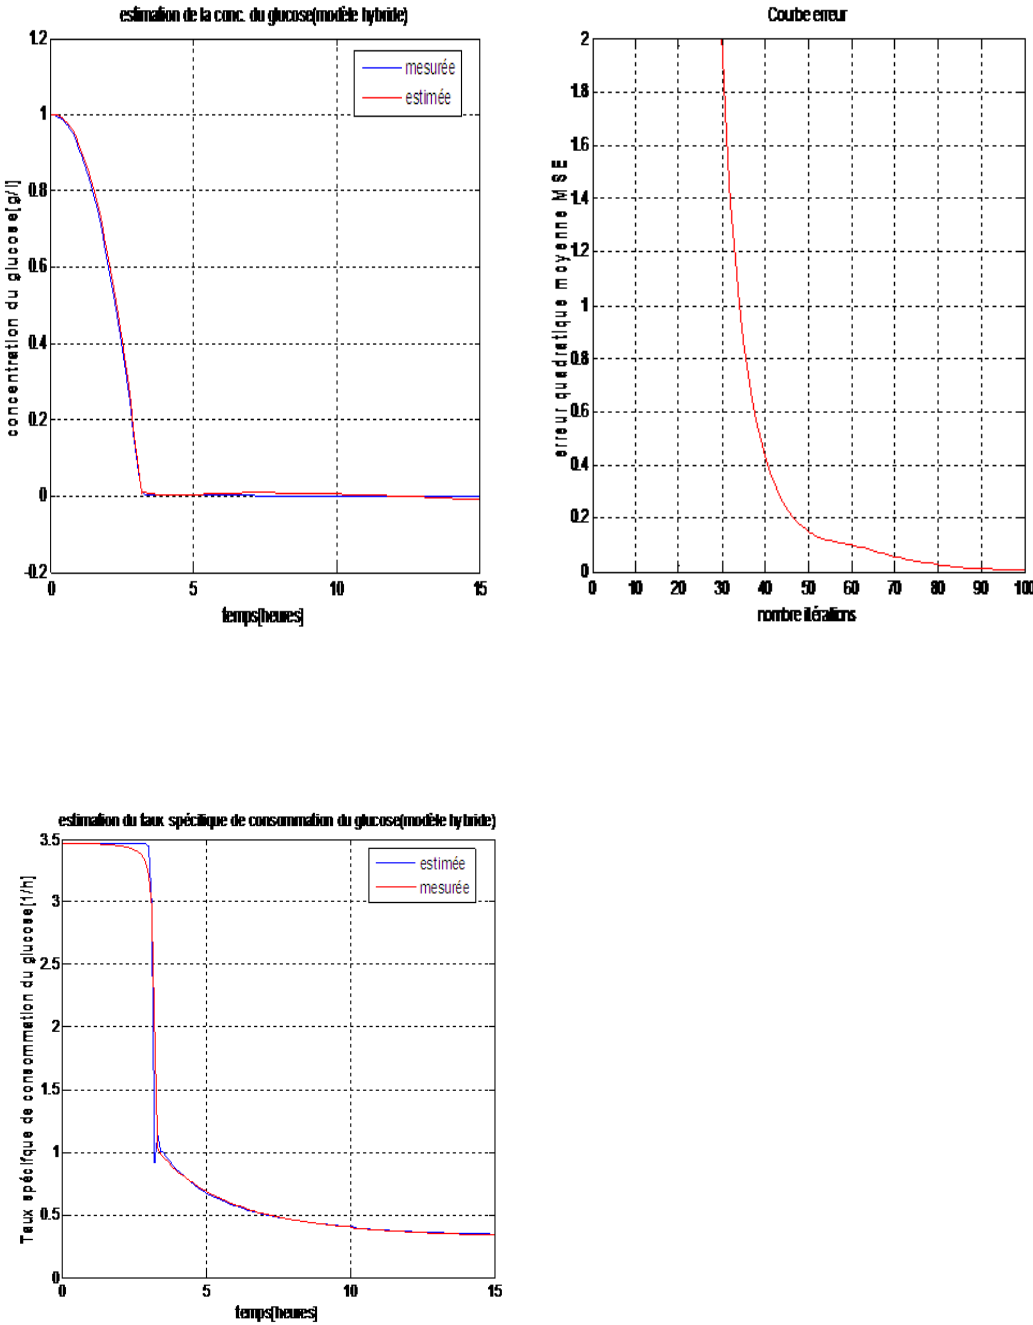


Fig.5-12 Courbes d'estimation de S , de MSE de S et d'estimation de q_S

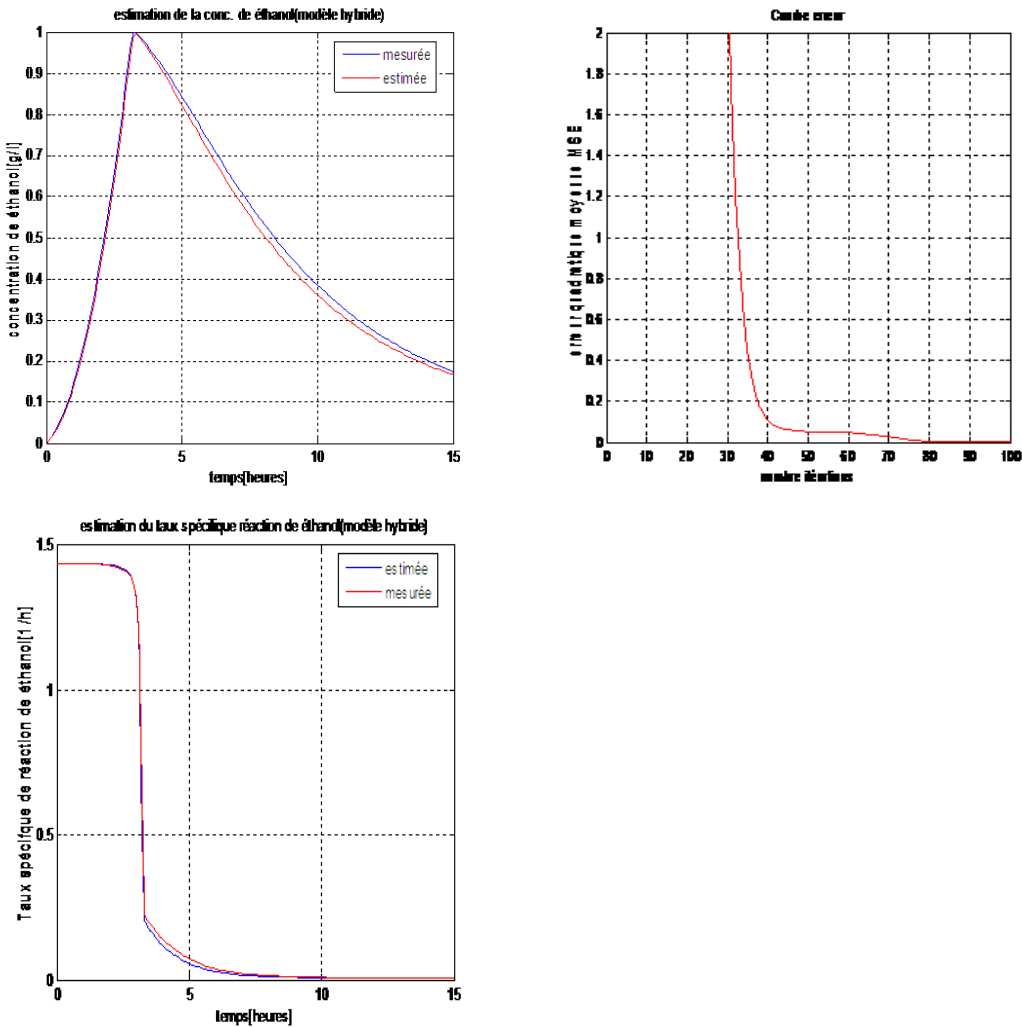


Fig.5-13 Courbes d'estimation de E , de MSE de E et d'estimation de q_E

Conclusion générale

Pour l'estimation des concentrations de notre processus de fermentation chemostat, on a utilisé otr (taux de transfert d'oxygène) et ctr (taux de transfert de gaz carbonique) comme entrées de notre (RNA), et on a mis au point en premier lieu un réseau avec une seule couche cachée de 10 neurones plus le biais, ce nombre de neurones a été fixé par suite d'essai et erreur, puis on a utilisé un réseau avec deux couches cachées avec 10 neurones plus le biais chacune, par comparaison des résultats obtenus le réseau avec deux couches cachées donne les meilleurs résultats, malgré un temps de calcul plus grand ; Et comme les taux spécifiques d'accroissement cellulaire, de consommation du glucose, de réaction d'éthanol sont nécessaires dans l'implémentation d'un modèle, on a établi un modèle hybride en combinant un réseau RNA et un modèle mathématique pour utiliser l'approche de la sensibilité pour l'apprentissage du réseau combiné pour estimer les trois taux spécifiques.

Les résultats d'estimation obtenus étaient très satisfaisants, surtout l'estimation des trois taux qui, pour les mesurer, il faut utiliser des capteurs spécifiques ;

Dans le futur, on continue pour incorporer d'autres entrées et même établir un modèle hybride et plus complexe pour une estimation plus précise.

Bibliographie

- [1] B.sonnleitner and O.käppelli, “Growth of *saccharomyces cerevisiae* is controlled by its respiratory capacity, formulation and verification of a hypothesis”, journal of biotechnology and bioengineering, Vol.28, pp.927-937, 1986
- [2] K.H.Belgardt and al ., ‘Application of an extended kalman filter for state estimation of a yeast fermentation ‘control theory and application ,IEE proceeding ,vol .5,pp,226-234,1986
- [3] M.N.karim and S.L.Rivera, “ Artificial Neural Networks in bioprocess state Estimation” Advanced Biochem Eng Biotechnol. vol.46, pp.1-33, 1992.
- [4] M.L.Thompson and M.A.Kramer, “Modeling chemical processes using prior knowledge and neural networks”, Process systems engineering, AIChE journal, Vol.40, pp.1328-1340, 1994
- [5] J.Schubert and al., “Bioprocess optimization and control: Application of hybrid modeling”, Elsevier, journal of biotechnology,vol.35, pp.51-68, 1994.
- [6] A.Andrasik and al., “On line tuning of a neural PID controller based on plant hybrid modeling”, Elsevier, computers and chemical engineering, Vol.28, pp.1499-1509, 2004.
- [7] S.C.Hernandez and al., “State estimation by artificial neural networks in a continuous bio reactor”, 12th IFAC Symposium on Computer Applications in Biotechnology, pp.221-226, 2013.
- [8] N.F.Abunde, ”Mathematical modeling and optimal control: Maximizing yield in submerged alcoholic fermentation”, Master thesis, Ghana, pp.1-114, 2016.