

Université M'HAMED BOUGARA



Faculté des Hydrocarbures et de la Chimie
BOUMERDES



Département : *Automatisation des Procédés Industriels et Électrification*
Laboratoire : *Automatique appliquée. Axe : Diagnostic et commande des systèmes.*

Mémoire de Magister

Spécialité : *Cénie électrique. Option : Automatique appliquée et traitement du signal.*

Présenté par :

Abdelmalek KOUADRI

THEME

MODELISATION ET COMMANDE D'UN SYSTEME BOILER-TURBINE PAR LES RESEAUX DE NEURONES ET LES ALGORITHMES GENETIQUES.

Soutenu publiquement le : 05/10/2003

devant le jury composé de :

Mr. F. LAAOUAD	(M.C, Université de Boumerdès)	Président
Mr. A. BENHALLA	(C.C, Université de Boumerdès)	Examineur
Mr. M. DIAF	(M.C, Université de Tizi Ouzou)	Examineur
Mr. S. AISSANI	(M.C, Université de Boumerdès)	Examineur
Mr. M. ZELMAT	(M.C, Université de Boumerdès)	Rapporteur

Boumerdès 2003

منذ ظهور الإنسان على وجه هذه البسيطة وهو في صراع مع الطبيعة، وارتداء موهبته الفكرية، استطاع أن يتخطى عن سبل اختياره، يحضر من عوامل محيطه، مستنلا بذلك على كائنات صنعت لنفسها كل المتطلبات التي تساعدها على العيش في بيئتها، حتى الطيور أحشاشها، وكيف هي النظم و الأنماط الحياتية في ممالك الدحل والنمل؟ إلى غير ذلك، استخلص و استخدم الإنسان من الطبيعة بعض ما أو الهبات التي أظهرت قدرتها على تخطي بعض من الصعاب إن لم نقل جهلها، فياكتشفه لإمكانات العقل وقدرته على التحكم استطاع أن يتخطى عن تلك الأساسيات عقلا اصطناعيا، ولم يتوقف به الحال إلى هذا الحد، بل راح يفكر في طرق تجعل الرقابة للأتمى والأصابع لعمل على أتمى هذا، حتى الهبات المستهدفة على شكل جينات (صبغيات) في الكروموزوم يورثها جيلا إلى جيل إلى أن يصل إلى نتجية كل ما هو غير مناسب حسب ما يحتاجه الجيل التالي.

ففي هذا السياق ينصب عملنا المتواضع، حيث قمنا بالتحديد والتخصيص و التحكم في نظام المسمى بـ *Boiler-Turbine* وهذا باستخدام تقنيات التجهيز بين الشبكة العصبية والخوارزمية الوراثية. يعد نظام *Boiler-Turbine* الذي كان وما زال هدفنا، تلك الدائرية التي استطاعنا حلها بحكمة وقادرة على تشخيصه وكذا التحكم في ديناميكياته بطريقة جيدة، نظاما معقدا وصعبا بتراكيبه و بثلاثته الوظيفية، ويتوزع الترميز في مستوى الماء في المخزن العلوي للمواد البخاري خاصة مميزة، حيث يسبب مشكلا حقيقيا في تعديله، وهذا راجع إلى التوزيع الغير المتجانس في جميع قنوات المواد البخاري وكذلك عند أي تغيير في الطلب البخار فيبذل على مستوى الماء بطريقة مباشرة مسببا له و الهدات لكل الخوارزميات.

بناءا على التمثيل الرياضي لـ *BELL et ASTRÖM* الذي يمثل أهم الديناميكيات لـ *Boiler-Turbine* قمنا بتشخيص هذا النظام الممثل بجملة المعادلات التفاضلية، وهذا باستخدام الشبكة العصبية التي تعتبر أبرز المقويات العامة. أدت الخوارزمية التي تم في ميكانيكيات التاقين الشبكة العصبية، حيث قامت بتعديل عواملها وكذا بنيتها وفقا لمعيار يحدد معدل الفرق بين النظام الحقيقي ونظام الترميز والشبكة العصبية. استخدمت في هذه الخوارزمية مجموعة من الأفراد ذات أطوال مختلفة حيث يمثل فيها كل فرد بنية خاصة وأحما جينات. تلك الدالة المستخدمة في الشبكة العصبية. ومن أجل التحكم أحسن وأفضل استعملنا نفس الخوارزمية وهذا يعد أن أدت نظام تحكم التاقين مع نظام الترميز مع نظام الترميز على أساس التقنية الخلوية الكلاسيكية *LQG* وهذا انقريبه من البنية المقننة.

باستخدام نتائج المرحلة التمهيدية، وضعنا استراتيجية عامة للتحكم في نظام *Boiler-Turbine* التي توطد نظام التحكم العنفي على الشبكة العصبية عدلت الخوارزمية الوراثية العوامل والبنية وفقا للمعيار الذي يعطى الفرق بين مدار بين اثنين المتحكمين، بل التكامل المحدود في الزمان وهذا باستخدام المصفوفتين Q و R اللتين وجدنا في تقنيات التحكم الخطي الكلاسيكي *LQG*.

Abstract:

The Boiler-Turbine system is the crucial part of the most power plants. It's considered as a complex system where many modeling and controlling efforts have been made. In the regard to the complexity and the strong non linearities of the boiler-turbine dynamics, and in the attempt to find a simple model structure which can capture in some appropriate sense the key of the dynamical properties of the physical plant, we investigate in this work the existence and the use of radial basis function neural network (RBFNN) with hybrid genetic algorithm in the identification and control of the Boiler-Turbine dynamics.

It's stated that about 30% of the emergency shutdowns in the power plants are caused by poor level control of the steam water level. One reason is that the control problem is difficult because of the complicated shrink and swell dynamics. This creates a nonminimum phase behavior that changes significantly with the operating conditions.

The Boiler-Turbine dynamic model developed by *Aström* and *Bell* describes well the dynamic behavior, but is of a little interest for control design. The RBFNN is applied to solve identification problems for the system by using hybrid genetic algorithm optimizer. The main is to apply the genetic algorithm that incorporates the gradient descent optimizer for fast convergence, to optimize the neural network structure and parameters.

In addition, the problem of control design is considered in this work for the Boiler-Turbine system. In the first, the design procedure proposed in the preliminary phase is to find an auxiliary controller based on radial basis function neural network placed in parallel with an other obtained by the application LQG/LTR methods in which the modeling algorithm is considered.

Finally, a direct way to compute the controller is presented. We suggest to apply a general strategy based on RBFNN controller design in which it's calculates its parameters and optimal structure by using hybrid genetic algorithm, where such that the cost function is minimized. The cost function to be minimized is the difference between the quadratic performance indexes where the positive definite and symmetric matrices obtained from LQG/LTR classical techniques are used.

Sommaire

Introduction générale	1
Chapitre I : description du système à base d'un Boiler-Turbine	3
I.1. Introduction	3
I.2. Description du principe de fonctionnement du système à base d'un Boiler-Turbine	3
I.3. Modélisation de la dynamique du Boiler-Turbine	5
I.4. commande du système Boiler-Turbine	8
I.4.1. commande de pression	10
I.4.2. commande d'alimentation	10
I.4.3. commande de la température	11
I.4.4. commande du niveau-gonflement	11
I.5. conclusion	13
Chapitre II : les réseaux de neurones	14
II.1. introduction	14
II.2. caractéristique d'un neurone formel	14
II.3. fonctions d'activation usuelles	15
II.4. architecture de connexion	17
II.5. propriété fondamentale des réseaux de neurones	17
II.6. apprentissage des réseaux de neurones	18
II.7. algorithmes d'apprentissage	19
II.8. accélération de l'apprentissage	19
II.8.1. le gain d'adaptation	19
II.8.2. initialisation des poids	20
II.9. augmentation du pouvoir de généralisation	20
II.10. réseaux de neurones à fonction de base radiale	21
II.11. mise en œuvre des réseaux de neurones	24
II.12. principales applications des réseaux de neurones	25
II.12.1. identification du processus	25
II.12.2. Commande du processus	26
II.13. conclusion	28
Chapitre III : les algorithmes génétiques	29
III.1. introduction	29
III.2. méthodes traditionnelles de recherche et d'optimisation	29
III.3. différence avec les algorithmes génétiques	29
III.4. algorithme génétique standard	30
III.5. amélioration de l'algorithme génétique standard	31

III.5.1. autres mécanismes de sélection	31
III.5.2. sélection par rangement	32
III.6. le codage non-binaire et les opérations génétiques	32
III.6.1. croisement dans les algorithmes génétiques codés-réels	33
III.6.2. mutation dans les algorithmes génétiques codés-réels	33
III.7. critères d'arrêt	33
III.8. conclusion	35
Chapitre IV : les stratégies appliquées à la modélisation et la commande du système Boiler-Turbine	36
IV.1. stratégie de modélisation du système Boiler-Turbine par un réseau de neurones.....	36
IV.1.1. introduction	36
IV.1.2. modélisation de la dynamique de Boiler-Turbine	38
IV.1.3. description de la stratégie appliquée à l'identification du système Boiler-Turbine	41
IV.1.4. simulation et comparaison	46
IV.2. stratégie de commande neuronale pour le système Boiler-Turbine	50
IV.2.1. introduction	50
IV.2.2. contrôleur auxiliaire	50
IV.2.3. stratégie générale de commande de système Boiler-Turbine	53
IV.2.4. simulation et comparaison	54
IV.3. conclusion	66
Annexe	67
Bibliographie	69

Introduction générale :

Depuis quelques années, la vision des scientifiques prend, dans certains domaines technologiques particuliers, une tournure particulièrement intéressante, dans le sens de développer la théorie de commande et de ses applications. Il est donc naturel de rechercher dans la science de la vie, un mécanisme (un système vivant) susceptible de faire apparaître les caractéristiques intelligentes, ceci face à des variations intensives dans un environnement plus complexe.

Il est rare que les grandes conquêtes technologiques s'inspirent de vivant. La nature n'est pourtant pas avare de réalisations qui nous étonnent ou tiennent en échec notre curiosité. Parmi elles, le cerveau occupe évidemment une place de choix. Cette « machine » surprenante est en effet composée de plus de dix milliards d'unités élémentaires, les neurones, reliés entre eux par une multitude de connexions qui travaillent de façon concertée à l'élaboration des tâches les plus complexes. L'idée de s'inspirer du cerveau pour construire une machine intelligente, douée de propriétés cognitives et capable d'apprentissage, est un vieux et ambitieux projet humain. Ce projet, s'il n'est pas encore en passe de se réaliser, s'est en tout cas précisé au cours des cinquante dernières années, grâce au progrès de nos connaissances en neurosciences et à l'apport de théories mathématiques et physiques. Nous ne cherchons pas à copier aveuglement une réalité encore confuse ou mal comprise, au contraire, par l'introduction de ce concept de « cybernétique » qui signifie littéralement « science de la commande », nous tentons simplement d'améliorer certaines techniques traditionnelles qui se trouvent incapables de s'adapter à des environnements complexes, incertains ou variants dans le temps.

C'est dans ce contexte que l'on propose dans ce travail d'examiner et d'illustrer l'aptitude de l'application des réseaux de neurones et des algorithmes génétiques d'une part à la caractérisation et la représentation des systèmes complexes, et d'autre part à la synthèse de stratégies de commande appropriées pour ce type de systèmes, en prenant l'exemple d'un processus à base d'une turbine accouplée à un générateur de vapeur que nous convenons de le designer dans ce travail par « Boiler-Turbine ».

Plusieurs travaux se sont axés sur le problème de son modélisation, dont la plupart ont présenté des modèles rigoureux, avec une structure mathématique très complexe limitant, par conséquent, la possibilité de leur exploitation directe par les méthodes de commande conventionnelles. En effet, ces modèles sont établis dans des conditions de fonctionnement nominales. En dépit de leurs simplicité, quoique, ils ne tiennent pas compte de la distribution de la vapeur et de l'eau dans les différents faisceaux tubulaires, de la vitesse de circulation et des risques de stratifications dans les parcours horizontaux ou peu inclinés, Ce qui rend difficile le contrôle de la variation du niveau d'eau dans le ballon supérieur du Boiler, dans la mesure où 30% des arrêts d'urgence enregistrés dans les centrales électriques à base d'un Boiler-Turbine sont dus principalement à la désadaptation du contrôleur de niveau aux variations paramétriques. Cependant, le maintien du niveau d'eau, entre deux limites admissibles, joue un rôle important de fonctionnement normal du Boiler. Suivant la précision exigible, on fait appel à des systèmes de commande assez robustes, capable de s'adapter à un certain degré de satisfaction aux éventuelles variations des paramètres du processus et des conditions de son fonctionnement. En fait, il semble plus que nécessaire d'avoir des connaissances suffisamment précises et complètes du processus à commander pour remplir les exigences de robustesse et de performance (entre autre, une connaissance a priori de la structure du processus). Les réseaux de neurones et les algorithmes génétiques sont caractérisés, par leur faculté de se « reconfigurer » -souvent par les principes d'auto-organisation- face à un environnement inconnu de façon incrémental et robuste.

Ces systèmes biologiques semblent nécessiter moins d'hypothèses restrictives et d'information a priori sur le processus ou, tout au moins, des besoins différents. Ils constituent donc une approche prometteuse pour la commande de processus.

Quant à l'idée d'hybridation des techniques, elle consiste en la combinaison des réseaux des neurones et les algorithmes génétiques, entre elles ou avec d'autres techniques plus traditionnelles,

afin d'en marier les avantages respectifs et d'augmenter ainsi l'efficacité des méthodes développées.

C'est dans ce cadre-là où s'inscrit notre contribution. Nous proposons d'étudier dans le présent travail l'application des réseaux de neurones et des algorithmes génétiques à la modélisation et la commande du système à base d'un Boiler-Turbine.

Nous débutons ce mémoire par une description du principe de fonctionnement de ce type de procédé. Nous traitons par la suite le problème lié à la modélisation du Boiler-Turbine en présentant les étapes d'une représentation mathématiques déjà établie dans la littérature. Enfin nous détaillons les particularités destinées à réaliser une commande appropriée.

Dans le chapitre II, nous illustrons une présentation relativement brève sur le principe de calcul neuronal. Cette présentation est suivie les propriétés fondamentales et quelques indications générales sur la méthodologie de développement d'un réseau de neurones ; ceci nous permet d'introduire les notions de base dont nous nous servirons par la suite. Ensuite, nous présentons les réseaux de neurones à base radiale que nous utilisons dans notre application. Nous exposons par ailleurs les principales applications.

Nous présentons dans le chapitre III, les algorithmes qui nous semblent les plus appropriées compte tenu de notre application et ses contraintes, il s'agit des algorithmes génétiques, l'efficacité de cet algorithme est justifié par la comparaison avec les autres techniques d'optimisation. Après avoir aborder en revue les différentes opérations génétiques utilisées dans les algorithmes génétiques standard, nous illustrons d'autres variantes qui s'avèrent plus pratiques dans leur emploi.

Nous entamons enfin dans le chapitre IV le problème de la modélisation et la commande du Boiler-Turbine. Nous avons subdivisé ce chapitre en deux parties : une partie consacrée à la modélisation, et l'autre partie consacrée à la commande, dans laquelle sont mis en œuvre les concepts et les techniques introduits dans la première partie.

A partir du modèle mathématique décrit dans le chapitre I, nous avons développé une stratégie d'identification par réseau de neurones à fonction de base radiale. Mentionnons une combinaison intéressante entre les algorithmes génétiques et le réseau neuronal pour l'apprentissage de cette stratégie. Nous montrons les avantages significatifs apportés par cette hybridation.

Pour obtenir une grande robustesse du système Boiler-Turbine, nous avons cherché au premier temps, dans la deuxième partie, une loi de commande neuronale auxiliaire. Par l'illustration de la même tâche utilisée dans la première partie, nous développerons une stratégie générale de la commande basée sur celle de l'approche LQG/LTR classique qui s'avère très efficace pour le problème de contrôle du niveau d'eau. Ce chapitre se termine par une évaluation des performances apportées par l'application de cette stratégie à la commande de Boiler-Turbine en comparaison avec d'autres résultats obtenus par l'utilisation de la technique LQG/LTR de commande robuste classique.

I.1. Introduction :

La construction des centrales électriques, couramment utilisées à la production d'électricité, requiert un choix judicieux des paramètres techniques tels que :

- La puissance qui dépend de la demande du réseau;
- Le type de centrale : à cycle vapeur, de turbine à gaz, à cycle combiné;
- Le rendement qui conditionne la hauteur de l'investissement et les frais d'approvisionnement en combustible.

Le Boiler représente la partie cruciale de la plupart des centrales électriques dans la génération de la vapeur à haute pression. Ce dernier se transforme en une force motrice entraînant la turbines. L'utilisation de cette technique a affiné les notions de la thermodynamique et l'amélioration du rendement des cycles énergétiques.

Ces développements ont contribué à la simplification de la conception du Boiler. D'un point de vue très schématique, un Boiler à combustible fossile peut se ramener à :

- un foyer servant à convertir l'énergie potentielle du combustible (pouvoir calorifique) en gaz chauds et en rayonnement;
- des échangeurs utilisés principalement pour transférer, l'énergie contenue dans ces gaz à un fluide dans un cycle thermodynamique de production d'électricité.

Les pertes de vapeur dans les réseaux tubulaires, imposent généralement l'adjonction d'échangeurs préparateurs de la vapeur de chauffage à moyenne et basse pression, de façon à ce que le Boiler haute pression, la turbine et le poste d'eau, marchent en circuit fermé à l'abri des pollutions en provenance du réseau.

Le bilan énergétique (la puissance du combustible, les débits de chaleur cédés aux faisceaux tubulaires, la répartition des énergies rayonnées, la circulation des fluides le long du parcours) caractérise la dynamique du Boiler ainsi que la dynamique de la turbine. Il permet de bien déterminer le choix d'un mode de réglage selon la demande du réseau.

I.2. Description du principe de fonctionnement du système à base de Boiler-Turbine :

Le Boiler représente une part prépondérante dans l'investissement d'une centrale thermique, sa conception est toujours adaptée au combustible à brûler, en vue du meilleur choix technico-économique. La diversité des combustibles à brûler, les politiques énergétiques très dépendantes du contexte politique et économique de chaque pays rendent difficile la standardisation du Boiler. Toutefois, en fonction de l'expérience acquise, on peut mentionner trois types de Boiler correspondants aux trois catégories courantes de combustibles : fuel, charbon gras et lignite.

Pour réaliser la transformation de l'enthalpie de formation, contenue dans un combustible en vapeur sous pression à haute température dans une installation Boiler à haute pression, associée à une turbine à contre pression entraînant un alternateur (voir Fig. I.1.), La combustion s'effectue dans le foyer des brûleurs, après avoir convenablement préparé le combustible, en introduisant la quantité nécessaire d'oxygène prise de l'air extérieur, pulsé vers le foyer à l'aide de ventilateur de soufflage [ALE 97a]. Le passage de cet air à travers le réchauffeur, permet le refroidissement des fumées à la sortie du Boiler et assure le séchage du combustible, améliorant ainsi le rendement de la combustion.

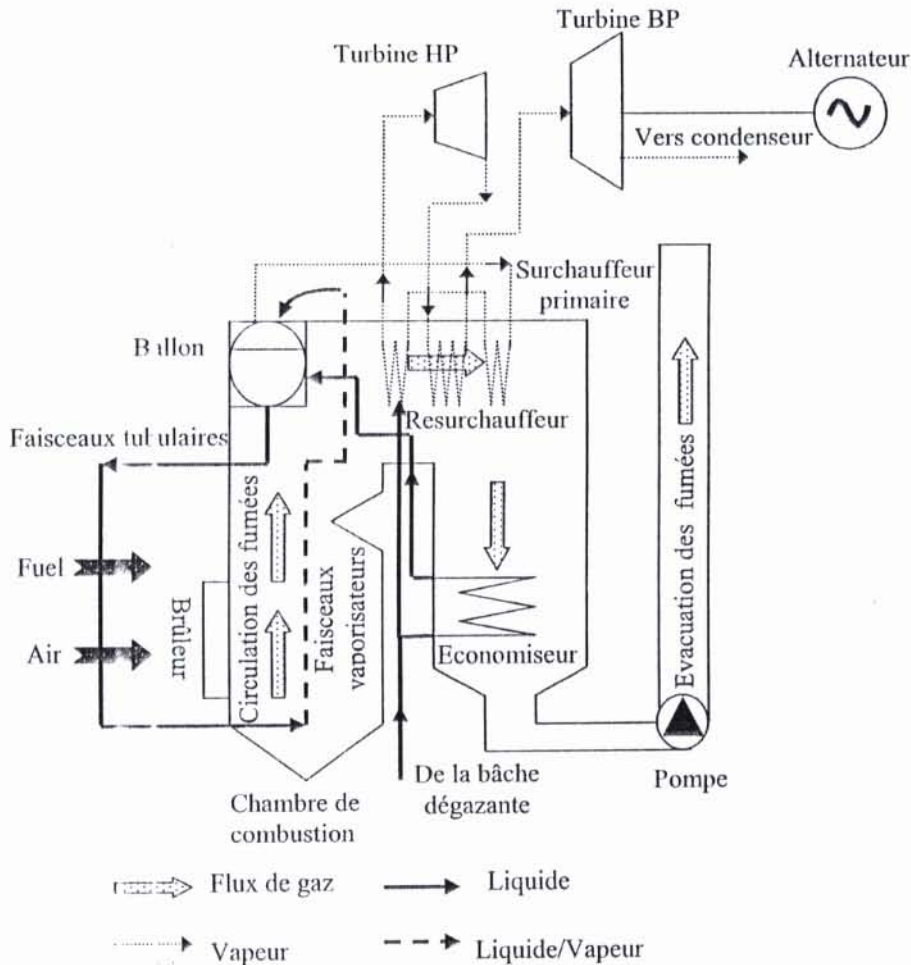


Fig. I.1 : Schéma du Boiler-Turbine.

Avant de refouler les fumées à haute température de la combustion, vers les cheminées, elles passent à travers une chaîne d'échangeurs et aussi à travers des faisceaux vaporisateurs, dans le but de transférer leur chaleur. La température de la vapeur augmente progressivement dans le surchauffeur pour atteindre la température de saturation dans le resurchauffeur. Les fumées passent en dernière étape, dans l'économiseur puis le réchauffeur d'air.

L'eau provenant d'une bâche alimentaire dégazante, est progressivement réchauffée dans l'économiseur pour aboutir à une température peu inférieure à celle de la saturation. Une partie de l'eau est dérivée avant l'entrée de l'économiseur, et pulvérisée dans la vapeur surchauffée, pour créer une zone froide où se concentrent les gaz incondensables. Elle sert ainsi au réglage de la température de la vapeur à la sortie du dernier surchauffeur.

Les bulles de vapeur sont générées en quantité de plus en plus grande, dans le ballon supérieur du Boiler. Le mélange d'eau et vapeur appelé émulsion, tourne dans un circuit fermé. La vapeur saturée produite, est séparée de l'émulsion dans un séparateur et se trouve remplacée dans le circuit vaporisant par l'eau en provenance de l'économiseur. Cette vapeur saturée sort de l'extrémité de ce circuit, pour passer ensuite dans le surchauffeur, dans lequel elle s'échauffe progressivement, et est acheminée directement vers l'arbre HP de la turbine.

Le resurchauffeur permet d'élever la température de la vapeur à moyenne pression, envoyée depuis la turbine jusqu'à une valeur en général égale ou supérieure à celle de la sortie de la vapeur surchauffée. Le resurchauffeur s'effectue par passage dans des échangeurs disposés séparément dans le circuit des fumées, elle est assurée par une rampe injectant la vapeur soutirée de la turbine dans la

masse d'eau. Le désurchauffeur assure la protection des échangeurs et de la turbine contre les dépassements intempestifs de la température.

L'énergie cinétique de la vapeur resurchauffée est transformée en énergie mécanique, tournant ainsi l'arbre BP de la turbine accouplé à un alternateur où est généré l'énergie électrique à la sortie de ce dernier.

I.3. Modélisation de la dynamique de Boiler-Turbine :

Le rôle d'un Boiler est essentiellement de transmettre l'énergie sous forme de chaleur à de l'eau sous pression pour obtenir, de l'eau surchauffée sous pression, de la vapeur ou un fluide à l'état supercritique devenant de la vapeur par détente. De plus, le Boiler-Turbine de grande puissance sont en général associés à un alternateur produire de l'énergie électrique.

L'étude du comportement d'un Boiler-Turbine en régime transitoire, est apparue récemment, indispensable pour la détermination du type de commande le mieux adapté et l'optimisation de ces paramètres. Et ce devant, la complexité du processus qui présente une dynamique difficile à modéliser.

Plusieurs travaux se sont axés sur le problème de modélisation d'un Boiler, muni d'une turbine entraînant une génératrice d'électricité. Citons à titre d'exemple [AST 00, FLY 99] dont la plupart ont présenté des modèles rigoureux, avec une structure mathématique très complexe limitant, par conséquent, la possibilité de leur exploitation directe par les méthodes de commande conventionnelles.

La modélisation de la dynamique du système est basée fondamentalement, sur les principes de conservation de masse et d'énergie. On peut considérer quatre catégories de données nécessaires pour déterminer un Boiler, qui obligent à faire une conception sur mesure :

- Les conditions de fonctionnement;
- Les caractéristiques de l'eau et de la vapeur;
- Les caractéristiques du ou des combustibles et leurs conditions optimales de combustion, ainsi que celles de l'environnement;
- Les performances attendues et les conditions normales ou extrêmes d'utilisation du matériel.

A partir de ces données, le calcul d'un Boiler fait appel à plusieurs phénomènes physico-chimiques, appliqués à une succession d'éléments, le plus souvent assimilés à des échangeurs. Il est important de prendre en compte les interactions de ces échangeurs entre eux. C'est l'une des raisons de la complexité de calcul, qui vient s'y ajouté la nature complexe du combustible, rare le cas où on a à faire à un combustible bien défini.

La figure (I.2) représente un Boiler limité à un tube de vaporisation, le modèle de transfert de chaleur est défini à partir de la chaleur prédominante dans le foyer, qui est le rayonnement à l'intérieur d'un volume. La quantité Q de chaleur échangée par rayonnement en une seconde, à l'intérieur d'un volume bien déterminé, s'exprime par :

$$Q = \varepsilon_g r S (T_g^4 - T_p^4) \quad (W) \quad (I.1)$$

avec

ε_g : coefficient d'émissivité du gaz à la température T_g pour le trajet moyen $L=3.4\frac{V}{S}$, avec $V(m^3)$

volume de la zone rayonnante et $S(m^2)$ surface enveloppe de cette zone,

r : coefficient d'absorptivité de la paroi,

T_g : température thermodynamique du gaz,

T_p : température thermodynamique de la paroi.

Cette chaleur est transmise à une rangée de tubes, provoquant la formation de la vapeur. Pour assurer le refroidissement correct des tubes situés dans les zones les plus chaudes et répondre aux besoins de la génération de la vapeur saturée, c'est-à-dire, le passage du fluide chauffé, de l'état liquide à l'état émulsion et vapeur, une quantité d'eau condensée q_f est injectée dans le ballon supérieur du générateur de vapeur.




Fig .I.2 : Schéma du boiler

La différence de masse volumique entre l'eau et la vapeur, fait détacher les bulles de vapeur contenues dans l'émulsion, qui devient de plus en plus un volume important au-dessus du plan d'eau. Un débit de vapeur saturée q_s est pris à la sortie du Boiler pour être ensuite admis à la turbine.

Le bilan matière du Boiler s'écrit :

$$\frac{d}{dt} [\rho_s V_{st} + \rho_w V_{wt}] = q_f - q_s \tag{I.2}$$

Et celui énergétique est décrit par l'équation :

$$\frac{d}{dt} [\rho_s h_s V_{st} + \rho_w h_w V_{wt} + m_t C_p t_m] = Q + q_f h_f - q_s h_s \tag{I.3}$$

en tenant compte de l'énergie interne :

$$u = h - M\rho \tag{I.4}$$

le principe de la conservation de l'énergie devient :

$$\frac{d}{dt} [\rho_s h_s V_{st} + \rho_w h_w V_{wt} - pV_t + m_t C_p t_m] = Q + q_f h_f - q_s h_s \tag{I.5}$$

où le volume total dans le Boiler s'exprime par :

$$V_t = V_{st} + V_{wt} \tag{I.6}$$

Dans une paroi tubulaire soumise extérieurement à un flux calorifique Φ , et parcourue intérieurement par de l'eau à la température de saturation T_s . La température de la paroi interne du tube est donnée par la formule suivante :

$$T_s = t_f + \Phi/\alpha_i \quad (I.7)$$

Les valeurs du coefficient d'échange paroi/fluide α_i , ont fait l'objet de nombreuses recherches pour le régime biphasique. La détermination du coefficient d'échange interne α_i n'est pas simple pour des pressions élevées, ayant le flux calorifique et la pression il faut alors contrôler la vitesse de l'émulsion, qu'elle soit suffisante pour assurer le refroidissement du tube.

En régime monophasique (eau ou vapeur) et pour les tubes lisses on a :

$$N_u = 0.023Re^{0.8}Pr^{1/3} \quad (I.8)$$

tel que :

$$Re = \frac{Vd}{\nu}, \quad Pr = \frac{\mu C_p}{\lambda} \quad \text{et} \quad Nu = \frac{\alpha_i d}{\lambda}$$

On constate que le coefficient d'échange α_i , en écoulement monophasique est fonction de la vitesse à la puissance 0.8.

La température du métal peut être exprimée en fonction de la pression de vapeur. En combinant les équations (I.2), (I.3) et (I.6) on obtient un système d'équations différentielles exprimé par :

$$\begin{cases} e_{11} \frac{dV_{wt}}{dt} + e_{12} \frac{dp}{dt} = q_f - q_s \\ e_{21} \frac{dV_{wt}}{dt} + e_{22} \frac{dp}{dt} = Q + q_f h_f - q_s h_s \end{cases} \quad (I.9)$$

où :

$$\begin{cases} e_{11} = \rho_w - \rho_s \\ e_{12} = V_{st} \frac{\partial \rho_s}{\partial p} + V_{wt} \frac{\partial \rho_w}{\partial p} \\ e_{21} = \rho_w h_w - \rho_s h_s \\ e_{22} = V_{st} \left(h_s \frac{\partial \rho_s}{\partial p} + \rho_s \frac{\partial h_s}{\partial p} \right) + V_{wt} \left(h_w \frac{\partial \rho_w}{\partial p} + \rho_w \frac{\partial h_w}{\partial p} \right) - V_t + m_t C_p \frac{\partial T_s}{\partial p} \end{cases} \quad (I.10)$$

En utilisant la table de vapeur saturée, on obtient les valeurs des différents paramètres intervenant dans le calcul des coefficients e_{ij} . Pour le cas du P16-G16, les valeurs numériques de ces paramètres et les autres grandeurs figurant dans ces équations seront décrites en annexe [A-1] et [A-2] respectivement. Le modèle développé par Aström et Bell dans [AST 00], décrit le comportement dynamique de la pression de la vapeur dans le ballon supérieur et le volume total d'eau dans le système. Il admet comme variables d'entrée, la quantité de chaleur cédée aux faisceaux tubulaires Q et le débit massique d'eau q_f , et comme variable de sortie le débit massique de vapeur saturée q_s .

Ce modèle est obtenu dans des conditions de fonctionnement nominales. En dépit de sa simplicité, quoique, il ne tient pas compte de la distribution de la vapeur et de l'eau dans les différents faisceaux tubulaires, de la vitesse de circulation pour avoir un coefficient d'échange

correct et des risques de stratification dans les parcours horizontaux ou peu inclinés. Ce qui rend difficile le contrôle de la variation du niveau d'eau dans le ballon.

Pour pouvoir exploiter ce modèle, lors de la synthèse du système de commande, il est nécessaire d'analyser la variation du niveau d'eau, en tenant compte de la modélisation de la distribution et de la circulation, de la vapeur et de l'eau dans les circuits de Boiler. Par la considération de toutes ces spécifications, et par l'application du principe de conservation d'énergie et de masse, ainsi que leurs répartitions dans le ballon et les faisceaux tubulaires, on obtient :

$$\begin{cases} A \frac{\partial \rho}{\partial t} + \frac{\partial q}{qz} = 0 \\ \frac{\partial p_h}{\partial t} + \frac{1}{A} \frac{\partial q_h}{\partial z} = \frac{Q}{V} \end{cases} \quad (I.11)$$

Le modèle développé par Bell et Aström [AST 00] semble en première vue le plus simple et le plus rationnel. Il consiste à mesurer d'une part la quantité d'énergie introduite au Boiler et, d'autre part, l'énergie apportée au fluide eau/vapeur, pendant un laps de temps et une direction déterminée dans l'espace. Ce modèle nécessite de connaître avec une bonne précision, le débit du combustible, le débit de vapeur, le débit d'eau d'alimentation et d'évaluer correctement les apports de chaleur extérieure. Lorsque les conditions de précision sont relativement réalisées, ce modèle est utilisé pour synthétiser une loi de commande convenable.

Pour remédier à l'imprécision des paramètres du modèle, et devant la complexité du système, on a appliqué les réseaux de neurones, vu leur précision et leur utilité, pour la synthèse du système de commande qui fera l'objet du chapitre IV.

Dans cette étude, on a pris un modèle plus complexe du Boiler-Turbine de type P16-G16 à 160MW, développé par Bell et Aström dans [BEL 87]. Ce modèle est fortement non linéaire, il décrit simultanément les variations de la pression P dans le ballon supérieur, le facteur de qualité de la vapeur α_s dans les conduites, le débit de vapeur q_s dans le système, la puissance électrique W et le niveau d'eau l dans le ballon. La commande de ces variables se fait par action, sur la soupape d'injection du fuel u_1 , la vanne d'admission placée en amont de l'arbre HP de la turbine u_2 , et le système d'alimentation du ballon en eau condensée u_3 . La relation entre ces grandeurs est décrite par le système d'équations suivant :

$$\begin{cases} \frac{dp}{dt} = -0.0018u_2 \sqrt[8]{p^9} + 0.9u_1 - 0.15u_3 \\ \frac{dW}{dt} = (0.073u_2 - 0.016) \sqrt[8]{p^9} - 0.1W \\ \frac{d\rho}{dt} = \frac{1}{85} (141u_3 - 1.1u_2 p - 0.19p) \\ l(t) = 0.05(0.13073\rho + 100\alpha_s + q_s/9 - 67.975) \end{cases} \quad (I.12)$$

où :

$$\begin{cases} \alpha_s = \frac{(1 - 0.001583\rho)(0.8p - 25.6)}{\rho(1.0394 - 0.0012304p)} \\ q_s = (0.854u_2 - 0.147)p + 45.59u_1 - 2.514u_3 - 2.096 \end{cases} \quad (I.13)$$

I.4. Commande du système Boiler-Turbine :

Le système de commande du Boiler-Turbine, est destiné à réaliser une commande appropriée par rapport à la variation paramétrique du procédé. la commande qui traduit toujours la même idée,

à savoir l'insensibilité ou à défaut la quasi-insensibilité [ALE 97a, OUS 94] doit se manifester par la réalisation de l'ensemble des objectifs de synthèse suivants, et ce bien évidemment, dans les limites physiques du procédé :

- Maintenir le débit et les caractéristiques de vapeur (facteur de qualité de vapeur) constantes.
- Fournir le complément d'énergie thermique pour les besoins industriels par soutirage ou contrepression de la vapeur à la sortie de la turbine.
- Maintenir la fréquence, donc la vitesse de l'alternateur, constante, en commandant le débit de vapeur à l'admission de la turbine.
- Répondre avec le minimum de pertes à une demande brusque de puissance électrique.
- Compenser l'effet des perturbations (fluctuations de la puissance électrique, gradients thermiques, dérégulation des vannes de commande) sur les équipements.
- Réaliser une adaptation rapide aux nouvelles conditions de fonctionnement.

Les contrôleurs du système Boiler-Turbine actuellement en service, peuvent réaliser les objectifs cités ci-dessus, mais dans des limites bien spécifiques, vu de leur méthode de synthèse qui n'est plus basée sur des techniques systématiques de commande multivariable [KWO 89].

La plupart des installations à la base de Boiler-Turbine font appel à des configurations de commande classiques employant des régulateurs (PID) installés pour la régulation de plusieurs boucles, dont les principales sont : la boucle de régulation du débit du fuel et la boucle de régulation du niveau d'eau. Cette dernière fait appel à deux actions (PID) et une action proportionnelle (P). Le débit de vapeur est contrôlé en commandant le débit du combustible fossile au Boiler, alors que la puissance électrique est réglée, en commandant le débit de vapeur à l'admission de la turbine. La figure (I.3) illustre la configuration du système de commande classique, installé pour la filière Boiler-Turbine de type P16-G16 à 160 MW.

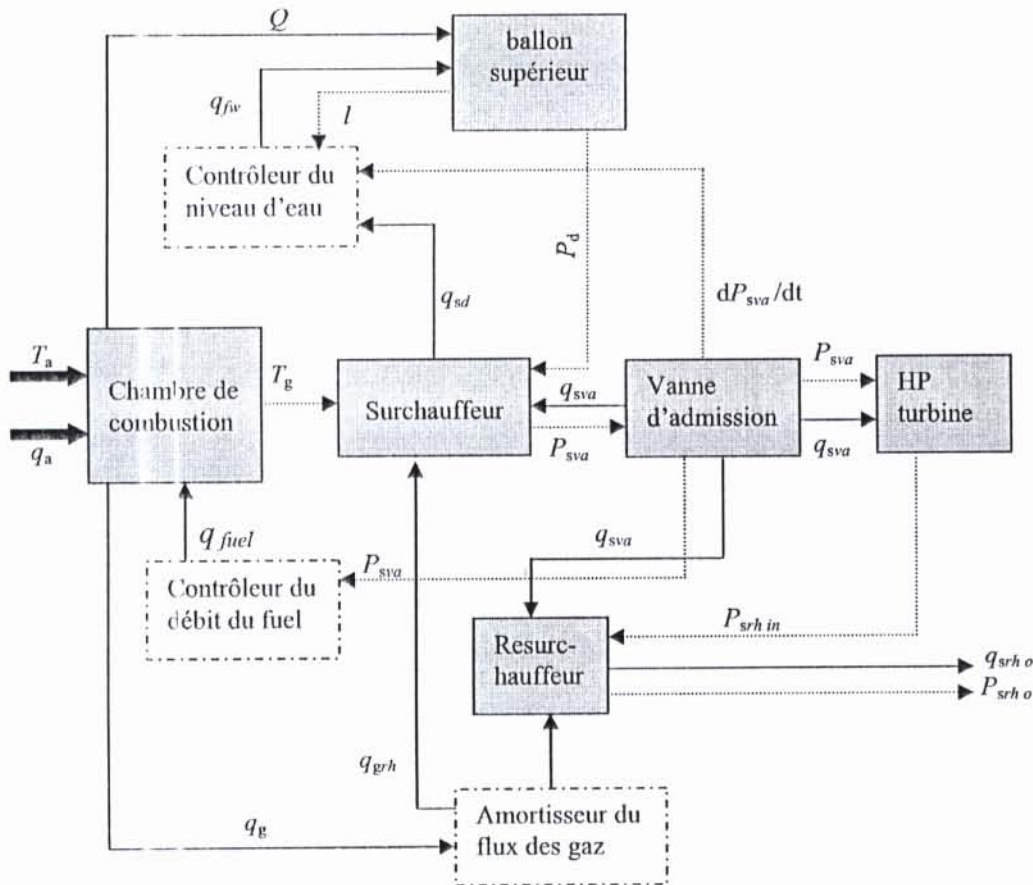


Fig. I.3 : Configuration de principale commande classique du système Boiler-Turbine.

I.4.1. Commande de pression

Le débit de chaleur est commandé par la pression de vapeur indépendamment du débit de vapeur, car dans un Boiler munis d'un surchauffeur, la mesure du débit de vapeur est inutile, de plus, elle peut être nuisible. En effet, on constate le plus souvent, que le débit de vapeur dépend de la pression et par conséquent du débit de chaleur fourni, donc une augmentation de celle-ci provoque une augmentation du débit de vapeur, et cela risque d'augmenter le débit du combustible.

Souvent l'apport de chaleur, est fait par un nombre de brûleurs variable. Il en résulte que le gain du système est lui-même variable. Il conviendrait donc de rendre le gain du régulateur variable en sens inverse. Pour éviter cette complication, on emploie la technique de l'asservissement par le débit de chaleur fourni.

Lorsque le pouvoir calorifique du combustible est suffisamment constant, et lorsque son débit est mesurable, c'est la mesure de ce dernier qui est utilisée pour représenter le débit de chaleur. Au contraire, lorsque le pouvoir calorifique du combustible est variable ou bien lorsque son débit n'est pas mesurable, on remplace le débit de chaleur entrant dans le Boiler par le débit de chaleur sortant c'est-à-dire le débit de vapeur.

I.4.3. Commande d'alimentation

La commande d'alimentation du Boiler est liée de plus en plus au problème du gonflement qu'il convient de le préciser. Une des branches de tube d'un Boiler représentée sur la figure (I.2) reçoit le flux thermique Q , tandis que l'autre branche sert au retour de l'eau. La masse volumique de l'émulsion eau-vapeur située dans la colonne I, étant inférieure à celle de l'eau qui se trouve dans la colonne II, est à l'origine d'un courant de circulation. Au fur et à mesure que la charge thermique augmente, le taux de la vapeur contenue dans toute la zone de vaporisation s'accroît, c'est-à-dire que le volume total de vapeur situé dans cette zone prend une importance de plus en plus considérable.

Dans ces conditions, le volume de la vapeur contenue dans toute la masse d'eau qui s'y trouve est proportionnel au débit de la vapeur. Lorsque pour une raison ou pour une autre, le débit de vapeur chute rapidement, le volume total de vapeur contenu dans la masse en circulation, s'abaisse. Il en résulte un tassement du niveau.

Ce phénomène est d'ailleurs très rapide et ne prend que quelques secondes pour s'établir. Il en résulte que toute variation de demande de vapeur, provoque quasi immédiatement une variation du plan d'eau, par conséquent, une demande brusque de vapeur fait monter le plan d'eau et une diminution brusque le fait baisser.

Enfin, il convient de mentionner que le niveau d'un Boiler ne réagit pas immédiatement dans toute son amplitude vis-à-vis des variations du débit d'eau d'alimentation : il existe une inertie que nous appellerons effet de trempe, distincte de l'effet de gonflement qui, lui, est lié aux variations du débit de vapeur.

L'effet de trempe provient du fait que l'eau d'alimentation est plus froide que celle du ballon du Boiler, et son arrivée dans les tubes de vaporisation retarde plus au moins la formation des bulles de vapeur. Cet effet peut justifier l'emploi d'une action proportionnelle et dérivée (PD) dans le régulateur de niveau.

L'addition d'une action dérivée permet d'améliorer l'effet d'inertie, mais au détriment de variations plus importantes du débit d'eau, qui se répercutent sur l'installation de pompage et le poste d'eau. A cet effet, l'ajout de la mesure du débit de vapeur dans cette commande est indispensable.

Il est également possible de compenser l'effet de gonflement, au lieu de chercher à l'annuler par l'addition d'une action intégrale au correcteur du niveau. On variant le point de consigne du niveau avec la charge. Le niveau dans le ballon est maintenu systématiquement à un niveau bas à faible charge et à un niveau haut à forte charge. On a ainsi une caractéristique hyperstatique.

I.4.4. Commande de la température de surchauffe :

Dans le Boiler à surchauffe élevée ($>450^{\circ}\text{C}$), il est nécessaire d'introduire une commande de température de vapeur, vu les contraintes thermiques sur les aciers utilisés. Cette commande est probablement celle qui présente le plus de difficultés pour les deux raisons suivantes :

- la masse métallique du surchauffeur est toujours importante puisqu'on cherche à obtenir une température élevée de vapeur; il en résulte une constante de temps élevée de cet appareil, qui répond lentement aux actions de commande qu'on peut exercer sur lui;
- la commande de température de vapeur est toujours une commande de répartition du flux thermique; il s'agit à chaque instant de corriger, par un moyen de réglage approprié, la mauvaise répartition des flux thermiques entre le circuit de vaporisation, d'une part et le circuit de surchauffe d'autre part. Il y a donc une corrélation étroite entre la commande de température de vapeur et la commande de pression, puisque toutes les deux interviennent sur le flux thermique.

Donc, dans la plupart du temps, on est obligé de faire appel à des systèmes de commandes complexes dans lesquels, il est nécessaire de faire intervenir des actions de découplage entre les chaînes de régulation de pression et celles de température. Cependant, comme la température de vapeur est caractérisée par une dynamique lente, le découplage en question est le plus souvent exercé uniquement dans le sens d'une information venant de la chaîne de pression vers celle de température.

La dynamique des surchauffeurs est caractérisée par une constante de temps élevée, conduisant le plus souvent à l'insertion d'une action dérivée première (PD) et même seconde (PDD) dans la commande. Malgré l'emploi de ces actions dérivées, il est nécessaire de tenir compte, des variations de gain statique et de constante de temps apparente du surchauffeur en fonction de la charge. En effet, l'analyse de la transmittance d'un surchauffeur à plusieurs charges, indique la variation de son gain et sa constante de temps. Il faut donc, concevoir un système de commande qui tient compte de cette variation paramétrique.

I.4.5. Commande du niveau – gonflements :

La qualité de la commande du niveau d'eau, entre deux limites admissibles de niveau haut et bas, joue un rôle important dans le fonctionnement normal du Boiler. Suivant la précision exigible, on fait appel à des systèmes de commande qui sont le niveau, le débit de vapeur et le débit d'eau. S'il y a peu de variation en puissance, la commande pilotée par le niveau est suffisante, mais elle est erronée par le phénomène de gonflement. Une demande progressive de vapeur entraîne instantanément un retard de l'apport thermique du combustible par rapport au prélèvement thermique de la vapeur, et par suite, une légère chute de pression. Celle-ci entraîne une auto-vaporisation instantanée d'une partie de l'eau dans tout le Boiler, qui augmentera instantanément le taux de vapeur de l'émulsion et son volume massique. Il en résulte une élévation transitoire, mais très sensible, du niveau d'eau dans le réservoir correspondant au gonflement de l'émulsion.

C'est ainsi qu'une commande pilotée par le niveau d'eau, commence à réduire l'alimentation en cas d'augmentation du débit de vapeur, alors que l'inverse serait nécessaire, c'est bien qu'une fois les débits, d'eau et de vapeur stabilisés et le gonflement disparu, le niveau en Boiler peut se trouver trop bas, et avoir tendance à descendre encore plus bas, dans ce cas, l'eau froide est apportée massivement dans le ballon, pour rattraper la valeur de consigne. En effet, cette eau condense une partie de vapeur de l'émulsion, ce qui tend à diminuer son volume massique, donc à

faire baisser le niveau, par conséquent, à exagérer la demande d'alimentation. Le phénomène est rigoureusement inverse lors d'une réduction importante du débit de vapeur, entraînant un tassement transitoire du niveau, qui fait appel à l'augmentation du débit d'eau, alors qu'il s'agissait d'une diminution du débit demandé.

I.5. Conclusion

Ce chapitre a traité la difficulté rencontrée lors de la recherche d'une représentation mathématique beaucoup plus précise et utile à la commande du Boiler-Turbine. Le modèle décrit n'est qu'une modélisation dans des conditions de fonctionnement normal. Dans ce cas, il y a nécessité de définir une température de référence, la qualité du combustible de l'eau et de la vapeur générée, pour évaluer correctement le bilan énergétique et massique du système, quoique la moindre couche de dépôt interne ou externe ajoute une résistance au transfert de chaleur.

Ce processus industriel qui est d'autant plus complexe par sa structure physique comme par sa conduite, fait l'objet de recherches intensives traitant des problèmes divers liés principalement à sa modélisation et sa commande. Nous avons donné une description du système de commande, chargé de contrôler les différentes variables physiques devant la complexité du processus, qui présente une dynamique difficilement modélisable. La source de complication de la commande du Boiler-Turbine est liée principalement au maintien du niveau d'eau dans le réservoir. C'est un problème de commande majeur qui a suscité de nombreuses recherches par la plupart des industriels. Le comportement à non minimum de phase de la dynamique du niveau d'eau se traduit physiquement par l'effet de gonflement, ce qui nécessite la mise en œuvre d'un système de contrôle assez robuste.

II.1. Introduction :

Ce que l'on désigne habituellement par « réseau de neurones », ou réseau neuromimétique est un réseau de neurones artificiels basés sur un modèle simplifié de neurone biologique. Ce modèle permet certaine fonction du cerveau, comme la mémorisation associative, l'apprentissage par l'exemple, le travail en parallèle, etc. cependant le neurone formel ne possède pas toutes les capacités des neurones biologiques, comme le partage de synapses, l'activité membranaire ou la structuration prénatale des neurones, par conséquent les réseaux de neurones sont loin d'avoir les possibilités du cerveau.

Les réseaux de neurones artificiels sont nés il y a cinquantaine d'années, des efforts combinés de scientifiques issus d'horizons divers et aux motivations variées. Leur histoire est jalonnée d'un certain nombre de publications clés, livres ou articles d'intérêt essentiellement historique, associées aux étapes décisives de leur développement.

Tout commence en 1943, lorsque deux bio-physiciens Mc.Culloch et Pitts, s'inspirant des récentes découvertes en neurobiologie, conçoit le premier modèle du neurone biologique, baptisé neurone formel ou automate à seuil. Un peu plus tard, un neurophysiologiste, Donald Hebb, propose en 1949 une formulation du mécanisme d'apprentissage, sous la forme d'une règle de modification des connexions synaptiques. Finalement, c'est en 1958 que Rosenblatt, combinant les idées de ses prédécesseurs, conçoit le perceptron, un réseau de neurones artificiels inspiré du système visuel, possédant une couche de neurones perceptive et une autre décisionnelle.

Les travaux de Rosenblatt suscitent au début des années 60 un vif enthousiasme chez les scientifiques alors fortement impliqués dans la recherche sur l'intelligence artificielle. Cet enthousiasme se voit pourtant brusquement refroidi en 1969 lorsque, Minsky et Papert, publient un livre qui, au terme d'une analyse mathématique approfondie, met à jour les limites intrinsèques du perceptron, en particulier son incapacité à résoudre les problèmes non linéairement séparables, tels que le célèbre problème du XOR. Ces conclusions plongent alors la recherche sur les réseaux de neurones dans une disgrâce qui ne prendra fin que 15 plus tard.

Il faut attendre le début des années 80 pour voir un regain d'intérêt pour les réseaux de neurones artificiels. Un changement de perspective intervient en 1982, quand plusieurs physiciens et en particulier le professeur John Hopfield suggèrent d'étudier le cerveau comme un système complexe pouvant relever des méthodes de la physique statistique. Ce nouveau et puissant moyen, démontre sur le plan théorique, que les réseaux de neurones seraient à même de réaliser des tâches que des moyens plus conventionnels n'effectueraient que difficilement.

En 1986, Rumelhart a publié un article qui est semble-t-il l'une des références les plus prises dans les publications de physique des particules. S'y trouve décrit l'algorithme d'apprentissage dit de « rétropropagation de l'erreur » qui a fourni le moyen d'entraîner les réseaux de neurones à un nombre quelconque de couches cachées. C'est cet algorithme qui a relancé l'intérêt pour les réseaux de neurones multicouches.

II.2. Caractéristiques d'un neurone formel :

Chaque neurone artificiel transforme l'ensemble des signaux qu'il reçoit en un signal de sortie, qui est communiqué à un certain autre neurone [FUK 92]. La transformation s'effectue en deux étapes :

Tout d'abord le neurone artificiel i multiplie chaque signal x_j provenant d'un neurone artificiel (cette valeur est aussi la sortie du j -ième neurone) par un coefficient synaptique de la connexion correspondante w_{ij} (poids synaptique ou poids tout court, elle représente le poids de connexion

entre neurone émetteur j et le neurone cible i), et il ajoute toutes ces entrées pondérées afin d'obtenir une stimulation totale :

$$p_i = \sum_j w_{ij} x_j \quad (\text{II.1})$$

où l'indice j représente toutes les connexions des neurones émetteurs avec le neurone cible i , dont ces connexions peuvent être excitatrices comme inhibitrices et elles sont quantifiées par le signe de leurs poids (la connexion excitatrice prend un poids positif et celle inhibitrice prend un poids négatif).

La stimulation totale obtenue est transférée à l'aide d'une fonction de transfert f_i dite «fonction d'activation» du neurone pour donner la sortie de ce dernier, communiquée par la suite aux neurones suivants, elle est exprimée par :

$$y_i = f_i(p_i) \quad (\text{II.2})$$

En général, la fonction d'activation est une fonction non linéaire, monotone croissante. Sa monotonie implique que les neurones sont semi- linéaires. Son choix donne une bonne estimation des fonctions complexes ainsi que l'atténuation des bruits, mais les calculs et l'analyse risquent d'être complexes. (Voir Fig. II.1)




Fig. II.1 : Le neurone formel.

II.3. Fonctions d'activation usuelles

La fonction d'activation $f_i(\cdot)$ transforme le signal d'entrée p_i non borné à l'instant t en un signal de sortie y_i borné. Elle prend différentes formes selon l'utilisation et selon la nature continue ou discrète. On va maintenant citer quelques fonctions d'activation usuelles dont la sigmoïde est la plus utilisée.

La fonction sigmoïde est une fonction bornée, monotone croissante ayant la propriété suivante : Si on définit $Of_\varepsilon(x) = f\left(\frac{x}{\varepsilon}\right)$, $\forall \varepsilon > 0$ alors la dérivée $f'_\varepsilon(x) = \frac{1}{\varepsilon} f'\left(\frac{x}{\varepsilon}\right)$ converge dans le sens de la fonction généralisée vers la fonction δ quand $\varepsilon \rightarrow 0$.

Ainsi, si $f(\infty) - f(-\infty) = 1$, alors pour toute fonction $g(\cdot)$ infiniment dérivable, on aura :

$$\lim_{\varepsilon \rightarrow 0} \int_{-\infty}^{+\infty} f_{\varepsilon}'(x) g(x) dx = g(0)$$

Cette fonction dont la forme générale est celle d'une tangente hyperbolique a des valeurs comprises entre -1 et +1 ou des valeurs comprises entre 0 et +1.

Une autre fonction d'activation est la *fonction linéaire seuillée* définie par :

$$f_i(p_i) = \begin{cases} 1 & \text{Si } c.p_i \geq 1 \\ 0 & \text{Si } c.p_i < 0 \\ c.p_i & \text{ailleurs} \end{cases}$$

qui peut être mise sous forme

$$f_i(p_i) = \min(1, \max(0, c.p_i))$$

où c représente la pente de la partie linéaire

Pour une nécessité à une sortie binaire [AMA 90, BER 90], on a besoin d'une fonction d'activation de la forme *signe(i)* avec les valeurs -1 et +1 ou bien les valeurs 0 et +1 :

$$f_i = \text{sgn}(p_i)$$

ou

$$f_i(p_i) = U(p_i)$$

L'exponentielle *seuillée* est une autre fonction qu'on peut utiliser, elle est définie par :

$$f_i(p_i) = \min(1, \exp(cp_i))$$

où c est un constant positif.

La *distribution exponentielle* est une autre fonction d'activation de la famille des fonctions exponentielles seuillées :

$$f_i(p_i) = \max(0, 1 - \exp(-cp_i))$$

La fonction est monotone croissante. De plus, il est à constater qu'elle est strictement convexe.

La dernière fonction d'activation est une *fonction rationnelle* :

$$f_i(p_i) = \max\left(0, 1 - \frac{c}{c + p_i^n}\right) \quad \text{pour } n \geq 2$$

Où c est un constant positif.

II.4. Architecture de connexion :

Un réseau de neurones complexe peut être fonctionnellement partagé en plusieurs couches, dont on peut définir un sens préférentiel du transfert de l'information dans cette succession de couches. On définit comme le montre la figure (II.5), les connexions directes par le transfert des entrées de la première couche vers la couche qui suit dans une seule direction (les flèches indiquent le sens du transfert), et les connexions récurrentes caractérisées par un retour vers la couche elle-même ou vers les couches précédentes.




Fig. II.5 : Connexion directe (a) et récurrentes (b)

Par ailleurs, à l'intérieur d'une même couche ou entre deux couches, les connexions peuvent être partielles ou totales (Fig. II.6). Les connexions partielles sont à distribution spatiales ou locales.




Fig. II.6 : Connexions partielles (a) et totales (b)

II.5. Propriété fondamentale des réseaux de neurones :

Etant donné un ensemble de données, on peut lui ajuster un réseau de neurones en calculant ses paramètres. Une fois que l'ajustement des paramètres a été effectué, le réseau de neurones peut interpoler entre ces données, prévoir les résultats qui n'ont pas encore été réalisés, expliquer les résultats obtenus dans le passé, ...etc. Un réseau de neurones de paramètres ajustés constitue un modèle statistique non linéaire de données. Il en découle leur propriété remarquable comme approximateurs universels d'où son intérêt pratique dans divers domaines.

Dans notre cas, le réseau de neurones est utilisé pour réaliser une fonction particulière, il s'agit d'effectuer des tâches de modélisation et de commande de la dynamique d'un Boiler-Turbine.

Plusieurs approches théoriques ont montré que les réseaux de neurones à trois couches sont capables d'effectuer l'approximation de fonctions continues [CYB 89, FUN 89, GIR 90]. Ces approches sont fondées sur deux théorèmes mathématiques, le théorème de Stone-Weierstrass et le théorème de Kolmogorov qui ne fournissent que des théorèmes d'existence d'un réseau multicouche. Le théorème de Kolmogorov précise le nombre de neurones dans chaque couche, mais ne prédit pas la nature de neurones, c'est-à-dire les fonctions d'activations qui permettent cette

approximation. Par contre, celui de Stone-Weierstrass montre qu'un réseau ayant suffisamment d'unités peut approximer n'importe quelle fonction en utilisant une fonction non linéaire saturante [FUN 89, HOR 89,].

L'emploi du réseau de neurones plutôt que les techniques classiques à l'approximation des fonctions peut se justifier par les arguments suivants :

- Simplicité de mise en œuvre ;
- Capacité d'approximation universelle prouvée ;
- Robustesse par rapport à des défaillances interne du réseau ;
- Capacité d'adaptation ;
- Réalisation matérielle parallèle inhérente.

Lorsque l'approximation est une combinaison de fonctions non linéaires à paramètres ajustables, on ajuste à la fois les coefficients de la combinaison et la forme que l'on combine [SON 98]. On conçoit facilement que cette souplesse supplémentaire, conférée par le fait que l'on ajuste la forme des fonctions que l'on superpose, permet d'utiliser des fonctions élémentaires, donc un plus petit nombre de paramètres ajustables. La capacité d'un réseau à réaliser une fonction peut être estimée à partir de deux paramètres : L'erreur d'approximation et l'erreur de généralisation.

L'erreur d'approximation exprime la différence entre la fonction réalisée par le réseau et la fonction désirée et est donnée par :

$$J = \frac{1}{2t} \sum_{i=1}^t \|y_i - \hat{y}_i\|_P^2 \quad (\text{II.3})$$

où y_i exprime la valeur de la sortie de la fonction réelle à l'instant i , la valeur de la fonction approchée par réseau de neurones est donnée par \hat{y}_i , t représente le nombre de pas dans la période d'approximation et P est une matrice carrée définie positivement et elle est considérée généralement comme la matrice d'identité.

Cette erreur résulte du caractère fini de la taille du réseau, ceci a pour conséquence de limiter la capacité du réseau pour mémoriser une fonction désirée ou encore définir avec précision l'espace correspondant à une classe de données.

L'erreur de généralisation est mise en évidence lorsque les performances sur la base de test sont sensiblement inférieures à celles obtenues sur la base d'apprentissage. Ce phénomène se produit lorsque le réseau a appris par cœur les exemples de la base d'apprentissages. Ce problème provient du nombre fini de données dans la base d'apprentissage.

Lorsqu'une architecture neuronale est constituée d'un nombre insuffisant de neurones et de connexions, l'erreur d'approximation est importante. Par contre, pour une architecture à nombre de neurones trop important, il se produit une mauvaise généralisation. C'est l'un des problèmes fondamentaux de l'emploi des réseaux neuronaux pour l'approximation de fonctions.

II.6. Apprentissage des réseaux de neurones :

L'apprentissage d'un réseau de neurones est un mécanisme permettant d'améliorer les performances futures sur la base d'une connaissance acquise au fur et à mesure des expériences passées. L'information est codée par les poids liés aux connexions; l'apprentissage est réalisé par les algorithmes de calcul dont le but est d'adapter ces poids en fonction des stimuli présentés à l'entrée du réseau. Une fois l'apprentissage fini, les poids ne sont plus modifiés.

Les procédures d'apprentissage peuvent être classées en deux catégories : supervisé et non supervisé. L'apprentissage supervisé consiste à calculer les poids de manière que les sorties du réseau de neurones soient aussi proches que possibles des sorties désirées, pour les exemples utilisés lors de l'apprentissage [BER 90, NGU 90]. Ces sorties peuvent être la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie du processus à commander.

Dans le cas de la présence des données possédant une certaine redondance pour des réseaux de neurones autonomes, appelés généralement «auto organisateurs» ou à apprentissage compétitif, l'apprentissage est alors qualifié de non-supervisé [BEH 98, EIK 99, KOI 94].

L'objectif de notre étude étant d'effectuer la modélisation et la commande de la dynamique de Boiler-Turbine par un réseau de neurones, nous utilisons dans ce cas seulement l'apprentissage de type supervisé.

II.7. Algorithmes d'apprentissage :

La plupart des algorithmes d'apprentissage des réseaux de neurones sont des algorithmes d'optimisation, ils cherchent à minimiser par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées.

Fondamentalement, les modifications des poids des connexions peuvent se faire suivant deux mécanismes de rétroaction : par gradient et sans gradient.

Par le gradient : le mécanisme nécessite alors la connaissance de la quantité du gradient de la fonction de coût, essentiellement sous forme approchée, qui fournit une information de direction et d'amplitude du changement à effectuer sur les poids pour améliorer les performances [BER 90, NAR 91].

Sans gradient : lorsque l'information du gradient n'est pas disponible, il faut recourir à des mécanismes d'apprentissage par renforcement, qui fonctionnent sur la base d'une exploration judicieusement organisée de toutes les actions de commande possibles et en déduisant les variations correspondantes aux variations des poids.

Le gradient est estimé par une méthode spécifique aux réseaux de neurones dite méthode de rétropropagation du gradient total [BER 90, ROB 89]. Dans la plupart des cas, le principe consiste à apporter quelques modifications au gradient afin de résoudre certains problèmes tels que ceux de la lenteur de convergence, de l'arrêt prématuré de l'apprentissage, ou de « sur-apprentissage ».

Dans notre étude, nous nous sommes limités aux algorithmes basés sur celui de rétropropagation du gradient, hybridée avec les algorithmes génétiques, car leurs mise en œuvre augmente le pouvoir de généralisation et la rapidité de l'apprentissage.

II.8. Accélération de l'apprentissage :

Il existe deux manières d'optimiser un apprentissage, en utilisant au mieux l'algorithme tel qu'il est ou modifié. Ici, nous évoquerons ces deux possibilités à travers de différentes caractéristiques liées à l'apprentissage : le gain d'adaptation et le choix du poids initiaux lors du lancement de l'apprentissage.

II.8.1. Le gain d'adaptation :

Le choix des paramètres d'un algorithme d'apprentissage influe beaucoup sur la rapidité de calcul. Le principe de descente de gradient consiste à effectuer, d'une manière itérative, pas à pas

une modification des poids selon une direction afin d'obtenir un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et de la validation disjointe du précédent.

Dans le cas où le gain d'adaptation est défini trop petit, le nombre d'itérations nécessaire peut s'avérer relativement important et contribue donc à ralentir de manière non négligeable l'apprentissage. Notons qu'il est même possible que l'algorithme rencontrant un minimum local, ne peut plus en sortir. Si le pas est trop important, l'algorithme peut devenir instable.

L'amélioration la plus couramment utilisée consiste à modifier l'algorithme pour ajouter à ce gain un terme de filtrage appelé «momentum». Il est proportionnel à la modification de poids effectué au cycle précédent, revient à faire varier le pas en fonction de la progression du gradient.

II.8.2. Initialisation des poids :

Les valeurs initiales des poids doivent être différentes de zéro pour que l'algorithme de rétropropagation puisse fonctionner. D'autre part, l'utilisation de valeurs élevées peut provoquer un phénomène de saturation prématuré qui contribue à diminuer la vitesse de convergence de l'apprentissage. Ce phénomène est en fonction de l'amplitude des poids, de la pente de la fonction d'activation et du nombre de neurones dans chaque couche.

Afin de se situer dans la zone linéaire de la fonction d'activation (zone définie pour une entrée proche de zéro), une méthode consiste à effectuer une initialisation des poids selon une distribution uniforme dans l'intervalle $[-M, M]$ avec M défini par l'équation suivante [HER 94] :

$$M = \frac{0.87}{K\sqrt{n}\sqrt{E(x_j^2)}} \quad (\text{II.4})$$

Avec k représente la pente de la fonction d'activation dans la zone linéaire, n le nombre d'entrées du neurone et $E[x^2]$ la variance des données de la base d'apprentissage.

Une telle limitation des poids garantit qu'il n'y aura pas de saturation prématurée, mais absolument rien quand à la suite de l'apprentissage [ZEL 01a].

II.9. Augmentation du pouvoir de généralisation :

Le problème de sur-apprentissage, qui est provoqué par la capacité du réseau de neurones où le nombre d'unités est plus que nécessaire, par conséquent, le réseau a appris parfaitement les exemples de la base d'apprentissage. Typiquement, l'évolution de l'erreur quadratique moyenne pour l'apprentissage et le test en fonction des itérations d'apprentissage, suit respectivement les courbes A et B illustrées par la figure (II.7).

Afin d'arrêter l'apprentissage juste avant qu'il ne se produise ce phénomène de sur-apprentissage, plusieurs méthodes ont été proposées [ALE 97a, ALE 97b] :

La plus simple consiste à disposer de trois bases de données distinctes : une base d'apprentissage, une base de test est une base dite «validation croisée». Cette dernière est utilisée pendant l'apprentissage afin d'examiner le comportement du réseau pour les données qui lui sont inconnues. Ainsi, l'apprentissage est arrêté lorsque l'erreur sur cette courbe B (base de validation croisée) atteint un minimum.

Notons que cette technique nécessite d'avoir suffisamment de données pour constituer trois bases à la fois représentatives et distinctes.

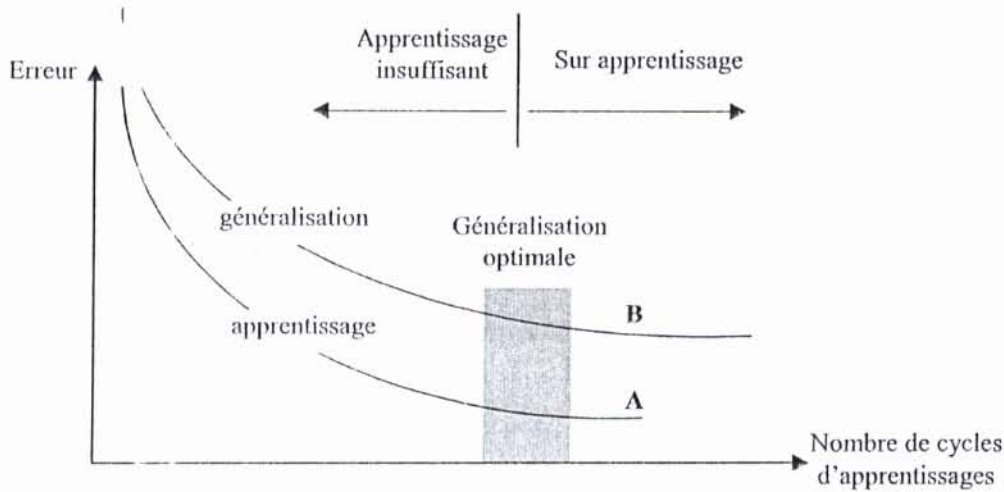


Fig. II.7 : Evolution de l'erreur d'apprentissage et de généralisation.

II.10. Réseaux de neurones à fonction de base radiale :

La plupart des applications courantes utilisent une architecture du « réseau perceptron à couche multiples » dont la fonction d'activation à chaque nœud est de type sigmoïde [FAN 99, LEV 93, LUO 00, ZEL 01a].

Il existe un certain nombre de théorème garantissant les capacités d'approximation universelle dans certaines conditions (continuité de la fonction à approcher, nombre suffisant d'unités dans les couches cachées), même si le réseau ne comporte qu'une seule couche cachée. Cependant, ces théorèmes ne fournissent pas des méthodes systématiques constructives guidant le choix de la topologie adapter pour une application particulière. En outre, ce type d'architecture entraîne des difficultés d'apprentissage dont les plus importantes sont :

- la présence de minima locaux dans la fonction de coût s'explique, par le fait que, les paramètres (poids des connexions) apparaissent non linéairement dans l'expression de la sortie du réseau. La permutation indifféremment des nœuds ainsi que leurs poids correspondants dans les couches cachées tout en gardant le même comportement de sortie augmente le nombre d'optima. Les méthodes d'ajustement de type « gradient » peuvent donc conduire à un apprentissage sous optimal, tandis que les méthodes à caractères stochastiques s'avèrent plus fiables mais plus pesantes ;
- la possibilité de paralysie durant l'apprentissage à cause de la saturation introduite par les sigmoïde (voir initialisation des poids);
- la possibilité de désapprentissage dû au caractère « non local », introduit par la combinaison des sigmoïdes.
- La difficulté d'introduire l'information a priori, ce qui est dû au caractère distribué et non local de la représentation.

On peut, dès lors, songer à adapter un autre type d'architecture pour éviter au mieux ces problèmes.

Les réseaux de neurones à fonction de base radiale surmontent toutes les difficultés d'apprentissage dans une architecture neuronale de type sigmoïde [GIR 90]. Cette variante de réseaux doit satisfaire les contraintes suivantes :

- Capacité d'approximation universelle;

- Couverture mathématiquement exprimée, par le fait que, pour chaque sortie y_i associée à un vecteur d'entrée \mathbf{u} il existe au moins un paramètre w_j tel que la valeur $\left| \frac{\partial y_i(\mathbf{u}, \mathbf{w})}{\partial w_j} \right|$ soit suffisamment grande au voisinage de \mathbf{u} ;

- Généralisation locale : si la valeur $\left| \frac{\partial y_i(\mathbf{u}, \mathbf{w})}{\partial w_j} \right|$ est grande au voisinage de \mathbf{u} , elle doit être relativement proche de zéro une fois que l'on s'éloigne de ce voisinage.

la structure du réseau est constituée d'une couche d'entrée, une autre de sortie et une couche cachée de n unités qui sont caractérisées par une fonction d'activation de type gaussien (Fig. II.8)

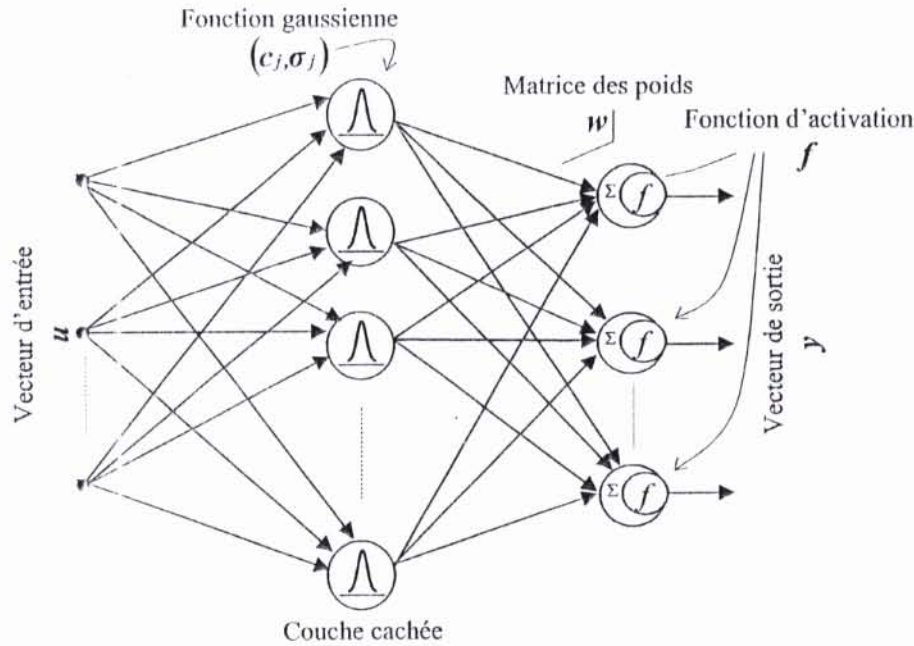


Fig. II.8 : Réseau de neurones à fonction de base radiale

La valeur à la sortie est donnée par :

$$y_i = \frac{\sum_{j=1}^{n_n} w_{ij} \rho_j(\mathbf{u})}{\sum_{j=1}^{n_n} \rho_j(\mathbf{u})} \quad \left(\sum_{j=1}^{n_n} \rho_j(\mathbf{u}) \text{ est le terme de normalisation} \right) \quad (II.5)$$

tel que:

$$\rho_j = \exp\left(-\frac{1}{2}(\mathbf{u} - \mathbf{c}_j)^T \mathbf{Q}_j^{-1}(\mathbf{u} - \mathbf{c}_j)\right) \quad (II.6)$$

où \mathbf{c}_j représente le vecteur du centre du nœud j , \mathbf{Q}_j est la matrice des rayons gaussiennes, exprimée par l'équation suivante :

$$\mathbf{Q}_j = \left(\text{diag}[\sigma_{1,j}, \sigma_{2,j}, \sigma_{3,j}, \dots, \sigma_{n,j}] \right)^2 \quad (II.7)$$

et \mathbf{u} est le vecteur d'entrée.

Les réseaux normalisés possèdent la propriété où le neurone requiert uniquement des données locales pour le calcul de son activation.

Les centres sont choisis pour représenter les zones de grande concentration des données ou de les disposer en treillis réguliers pour couvrir uniformément la partie utile de l'espace d'entrée et respecter ainsi les contraintes de couverture et de généralisation localisée. La matrice de « rayons » est choisie le plus souvent diagonale. Dans le cas où les centres seraient disposés en treillis réguliers, c'est-à-dire la distance entre deux centres voisins est constante et les valeurs de rayons sont fixes, dans le but d'assurer un certain degré de recouvrement entre les différentes gaussiennes exprimé par :

$$\tau = \exp\left(-\frac{1}{2} \frac{\left(\frac{\delta}{2}\right)^2}{\sigma^2}\right) \quad (\text{II.8})$$

Le degré de recouvrement illustré par la figure (II.9) résulte d'un compromis entre les propriétés de localité et de généralisation, l'étendu de la généralisation est donc contrôlable.




Fig. II.9 : Taux de recouvrement pour un treillis régulier unidimensionnel.

La plupart des applications utilisant les fonctions à base radiale disposent de centres et de rayons fixés une fois pour toutes. Dans ce cas la sortie du réseau est linéaire en ces paramètres, il est tout à fait concevable d'utiliser les techniques d'optimisation linéaire classique pour obtenir un apprentissage rapide et précis. En outre, la disposition des centres a priori s'avère quelques fois impraticable. En effet, le nombre de centre requis est parfois trop élevé [BAN92, KOU 02, PAR 95, SUN 00].

Le recours aux réseaux à base radiale modifiés appelés aussi réseaux à base radiale généralisés s'avère nécessaire. Ils permettent non seulement l'apprentissage des poids mais aussi celui des centres et des rayons.

Par conséquent, la sortie n'est plus linéaire en les paramètres, cette caractéristique rend l'utilisation des algorithmes d'optimisation linéaire inutiles. L'ajustement effectué par une descente de gradient sur les poids, les positions des centres ainsi que les valeurs des rayons associés, risque de tomber dans des minima locaux. L'introduction des connaissances a priori sur la distribution initiale des centres, rayons et des poids permet de disposer des valeurs trop éloignées de celles optimales.

En utilisant un réseau à base radiale normalisé et en se référant aux équations (II.3), (II.5) et (II.6), les valeurs des gradients s'expriment par les équations suivantes :

$$\frac{\partial J}{\partial w_{ij}} = (y_i - \hat{y}_i) \frac{\rho_j(\mathbf{u})}{R(\mathbf{u})} \quad (II.9)$$

$$\frac{\partial J}{\partial c_{j,k}} = \frac{\partial J}{\partial \rho_j} \frac{\partial \rho_j}{\partial c_{j,k}} \quad (II.10)$$

$$\frac{\partial J}{\partial \sigma_{j,k}} = \frac{\partial J}{\partial \rho_j} \frac{\partial \rho_j}{\partial \sigma_{j,k}}$$

$$\frac{\partial J}{\partial \rho_j} = (y_i - y_{id}) \left[\frac{w_{ij} R(\mathbf{u}) - \sum_{i=1}^n w_i \rho_i(\mathbf{u})}{R(\mathbf{u})^2} \right] \quad (II.11)$$

$$\frac{\partial \rho_j}{\partial c_{j,k}} = \rho_j \frac{u_k - c_{j,k}}{\sigma_{j,k}^2} \quad (II.12)$$

$$\frac{\partial \rho_j}{\partial \sigma_{j,k}} = \rho_j \frac{(u_k - c_{j,k})^2}{\sigma_{j,k}^3} \quad (II.13)$$

Les corrections s'obtiennent par :

$$\Delta w_{ij} = -\eta_w \frac{\partial J}{\partial w_{ij}} \quad (II.14)$$

$$\Delta c_{j,k} = -\eta_c \frac{\partial J}{\partial c_{j,k}} \quad (II.15)$$

$$\Delta \sigma_{j,k} = -\eta_\sigma \frac{\partial J}{\partial \sigma_{j,k}} \quad (II.16)$$

On constate qu'il y a une augmentation des nombres de paramètres à ajuster à l'ordre $(1 + 2n_e)n_{cc}$ au lieu de n_{cc} valeurs dans le cas précédent (où n_e est le nombre d'entrée et n_{cc} représente le nombre de neurones dans la couche cachée).

II.11. Mise en œuvre des réseaux de neurones :

Pour réaliser, l'application de la fonction de régression cherchée à l'aide d'un réseau de neurones, il est nécessaire de disposer de deux bases de données : une base pour effectuer l'apprentissage et une autre pour tester le réseau obtenu et déterminer ses performances. Afin de contrôler la phase d'apprentissage, il est souvent préférable de posséder une troisième base de données appelée «base de validation croisée».

Quatre étapes successives sont nécessaires :

- Il faut choisir l'architecture du réseau qui peut dépendre :

- de la tâche à effectuer (contrôle de processus, classification, association, ...),
- de la nature des données (les données stationnaires et non-stationnaires),
- d'éventuelles contraintes d'utilisation temps réel,
- du nombre de paramètres ajustables (l'un des facteurs fondamentaux de nécessité d'une application).

Le problème de la détermination de l'architecture optimale est un problème majeur dans l'utilisation des réseaux de neurones. Dans notre étude, nous avons mis en jeu un algorithme qui nous permet de déterminer cette architecture.

- Il faut calculer les poids du réseau, ce calcul des coefficients constitue l'apprentissage pour tous les modèles du réseau de neurones. Plusieurs types d'apprentissage peuvent être adaptés à un même type de réseau de neurones. Les critères du choix sont souvent la rapidité de la convergence et les performances de généralisation.

- Le critère d'arrêt de l'apprentissage est souvent calculé à partir d'une fonction de coût, caractérisant l'écart entre les valeurs de sortie obtenues et les valeurs de référence. La technique de validation croisée, permet un arrêt adéquat de l'apprentissage afin d'obtenir de bonnes performances de généralisation.

Il est nécessaire de tester le réseau de neurones après apprentissage sur une base de données différentes de celles utilisées pour l'apprentissage ou de la validation croisée. Ce test permet à la fois d'apprécier les performances du système neuronal et de détecter le type de données qui pose le problème.

II.11. Principales applications des réseaux de neurones :

II.11.1. Identification de processus :

L'identification d'un système consiste à trouver une fonction qui décrit le comportement dynamique du processus d'une façon satisfaisante. Les réseaux de neurones, comme nous l'avons vu ci-dessus, offrent des avantages intéressants pour l'approximation de fonctions sur la base d'exemples. Il est, dès lors, naturel de penser à appliquer ces techniques à l'identification du processus, surtout pour les phénomènes non linéaires complexes. La nécessité de l'emploi de réseaux neuronaux à l'identification de processus a un intérêt évident de commande [HYL 95, SUY 95, SON 98].

C'est souvent sur la base d'un modèle, qu'il est possible de recevoir une stratégie de conduite, ne se justifie que dans le cas où le modèle est difficile, voire impossible d'avoir «classiquement» un système approché (avec des propriétés fixes), basé sur la connaissance disponible a priori. Ces difficultés découlent généralement de la complexité du système dynamique.

Le processus d'apprentissage du réseau pour la tâche de l'identification est illustré par la figure (II.10). Comme nous avons indiqué dans la section (II.7), que l'apprentissage pour le réseau de neurones consiste à calculer les coefficients de telle sorte que l'erreur comprise entre les sorties du réseau et les sorties réelles soit minimale suivant les méthodes décrites aux équations (II.3), (II.5), (II.6) et (II.7). La non linéarité des processus, la complexité, le dimensionnement élevé, les erreurs de modélisation, le bruit de mesure, les perturbations...etc.; requièrent l'utilisation des réseaux de neurones, en particulier ceux à base radiale [SUN 94].




Fig. II.10 : Schéma de principe de l'identification de système par réseau de neurones

II.11.2. Commande de processus :

Commander un système revient à lui imposer un comportement préalablement défini en fonction des signaux de commande.

L'application des réseaux de neurones à la commande de processus offre les avantages suivants :

- Le traitement parallèle et distribué des informations servant à la commande ;
- Des facultés simples d'adaptation et d'apprentissage ;
- L'absence presque totale des restrictions sur la non linéarité du processus ;
- La possibilité de débiter la conduite avec un minimum d'information a priori sur le processus ;
- La robustesse par rapport au bruit et aux défaillances internes.

Dans un système connexionniste comme il est illustré par la figure (II.11), la conception d'un régulateur neuronal basée sur les critères de performance peut être plus simple que dans un système de commande classique. Malgré les avantages apportés par le réseau de neurones lors de l'application à la commande des processus, il y a toujours un manque d'outils théoriques permettant d'atteindre et de garantir certaines performances.

Une méthodologie expérimentale semble nécessaire pour développer des applications pour la commande de systèmes non linéaires complexes, avant qu'une théorie solide ne soit établie.

Dans le cas où on prend des hypothèses assez restrictives sur le processus c'est-à-dire supposé (linéaire, permanent, minimum de phase, ordre et temps mort connus), on obtient effectivement des garanties de stabilité. Par contre, devant un processus dynamique tout à fait général (non linéaire et inconnu), on est obligé d'adopter des systèmes de commande à structure complexe, qui sont difficiles à analyser et même à concevoir, par conséquent, l'adaptation et la stabilité ne peuvent être garanties. La preuve de stabilité se base sur la théorie dite d'«hyperstabilité» montrée dans [SLO 91].

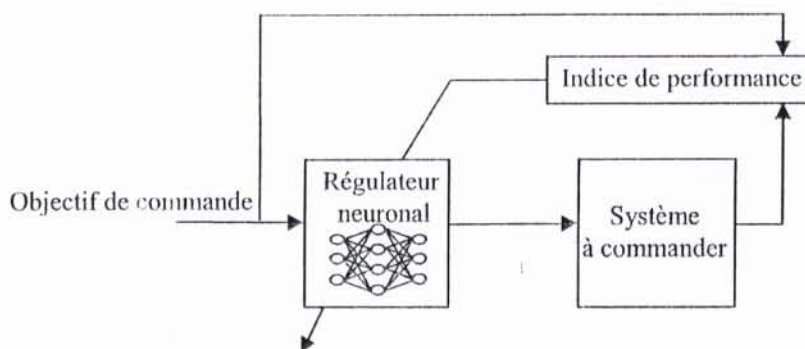


Fig. II.11 : Schéma de principe de commande par réseau neuronal

Les procédures d'apprentissage utilisent les lois d'optimisation basées sur le gradient d'une fonction ou d'un indice de performance.

Il existe différentes architectures qui peuvent être envisagées pour la commande de processus par un réseau neuronal à retropropagation [AHM 98, AOY 96,]. L'ensemble commande et processus peut donc être considéré comme un système qui génère une fonction que l'on peut approcher par un réseau de neurones.

II.13. Conclusion :

Nous avons exposé dans ce chapitre les éléments essentiels qui permettent de comprendre, pourquoi et dans quel cas il est avantageux de mettre en œuvre des réseaux de neurones. Nous avons montré, de manière concrète, ce qu'on peut attendre de cette technique applicable dans des domaines très variés, si elle est bien comprise et convenablement utilisée. L'intérêt pratique crucial des réseaux de neurones réside dans leur propriété remarquable qui est l'approximation universelle parcimonieuse.

La spécificité de cet approximateur universel réside précisément dans le fait qu'il nécessite moins de paramètres ajustables que les approximateurs universels couramment utilisés. En présence d'un nombre d'éléments suffisants, constituant une base représentative de données susceptibles de réaliser une fonction, l'utilisation du système neuronal, nous permet un meilleur usage de ces mesures que les méthodes de régression non linéaires conventionnelles. La fonction désirée est obtenue après avoir ajusté les paramètres du réseau de neurones au cours d'une phase dite l'apprentissage.

L'apprentissage est réalisé par des algorithmes d'optimisation dont le but est de minimiser la fonction de coût qui définit l'écart entre les sorties du réseau et les sorties réelles, en modifiant les poids synaptiques d'une manière itérative.

Les réseaux de neurones à base radiale sont de bons candidats pour la modélisation et la commande des systèmes caractérisés par : une dynamique complexe, la non linéarité, des erreurs de modélisation, des bruits de mesure, des perturbations,...etc.

Sur le plan théorique, nous avons présenté l'application des réseaux de neurones à la modélisation et la commande du processus dans un cadre aussi général que possible. Une étude consacrée à la conduite d'un Boiler-Turbine où sont appliqués les concepts et les techniques introduits dans cette partie, fera l'objet du chapitre IV.

III.1. Introduction :

La recherche de solution dans un espace complexe implique souvent un compromis entre deux objectifs apparemment contradictoires : l'exploitation des meilleures solutions disponibles à un moment donné et l'exploration robuste de l'espace de solutions possibles. Les méthodes de type grimpeur représentent une extrémité possible de compromis, en se basant uniquement sur l'exploitation et en souffrant par conséquent de la non globalité de l'optimum trouvé, sauf dans des cas bien particuliers. Les méthodes de type recherche aléatoire représente l'autre extrémité mais sont souvent inacceptables en pratique à cause de leur lenteur excessive et de leur ignorance aveugle. Les algorithmes génétiques sont une classe de stratégies de recherche réalisant un compromis équilibré et raisonnable entre l'exploration et l'exploitation.

Leur fonctionnement repose sur une heuristique très simple, les meilleures solutions seront trouvées dans des régions de l'espace de recherche contenant des proportions relativement élevées de bonnes solutions.

Les algorithmes génétiques sont des techniques probabilistes de recherche, inspirées des mécanismes de l'évolution darwinienne et de la génétique moderne, ils sont utilisés comme outils d'optimisation et de la recherche combinatoire.

Ces techniques font évoluer une population de créatures artificielles (individus), interagissant très simplement grâce aux mécanismes de la sélection naturelle, et qui concurrencent dans une lutte au cours de la vie où les plus convenables survivent (au sens d'un critère) et sont laissés se reproduire.

III.2. Méthodes traditionnelles de recherche et d'optimisation :

On peut distinguer au moins deux stratégies fondamentales, suivant leurs façon d'exploiter et d'explorer le domaine de la fonction à optimiser. La première telle que la méthode Quasi-Newton explore l'espace de recherche en utilisant un point unique et exploite toutes les informations locales pour progresser vers un meilleur point.

La méthode Quasi-Newton est basée sur la méthode de Newton qui consiste en la minimisation, à chaque itération, d'une approximation quadratique de la fonction de coût. Elle exige que cette fonction soit deux fois différentiable et que le gradient et la matrice des dérivées secondes (matrice Hessienne) soient calculables en chaque point. La méthode Quasi-Newton, quant à elle ne nécessite pas le calcul de la matrice Hessienne, mais l'approche itérativement, par conséquent, seules les dérivées premières de la fonction à optimiser sont nécessaires [SAB 00].

La deuxième stratégie possible, utilise une famille de points pour explorer le domaine et exploiter l'ordre relatif des diverses solutions candidates pour guider la recherche dans une meilleure direction. Les deux stratégies sont habituellement qualifiées de grimpeur, parce qu'elles emploient uniquement des informations locales pour trouver une meilleure solution. Quoique leur convergences vers un point stationnaire, n'est généralement d'aucune garantie que ce soit effectivement l'optimum global.

Le critère de terminaison dépend généralement de l'amplitude de la différence entre itérations successives, la recherche est arrêtée dès que cette différence est inférieure à un certain seuil prédéfini.

III.3. Différence avec les algorithmes génétiques :

Dans les algorithmes génétiques, il existe quatre traits distinctifs de nombreuses méthodes traditionnelles :

1. Parallélisme :

Les algorithmes génétiques travaillent en parallèle sur un certain nombre de points candidats, et non pas sur un candidat unique, le parallélisme est essentiel pour le mécanisme de recombinaison (croisement).

2. Manipulation d'entité arbitraire :

Les algorithmes génétiques manipulent des entités qui ne sont pas forcément numériques, en fait, un algorithme génétique peut travailler sur n'importe quel espace de recherche, à condition que les points de cet même espace soient toujours constitués d'un ensemble d'entités élémentaires sur lesquelles il est possible de définir des opérations de mutation et de croisement.

3. Utilisation minimale des informations à priori :

Les algorithmes génétiques ne requièrent de l'environnement qu'une mesure de la qualité de l'individu, il ne repose sur aucune autre information, telle que la continuité et la différentiabilité de la fonction à optimiser.

4. Balance exploration/exploitation :

Les phases de croisement et de reproduction sont exécutées en utilisant des règles probabilistes plutôt que des règles déterministes, l'introduction du hasard a en outre d'autres buts, celui de maintenir les propriétés d'exploration lors de la recherche.

III.4. Algorithme génétique standard :

Les opérations de l'algorithme génétique standard sont très simples. Il maintient une population $C_{1..N} = [C_1, C_2, \dots, C_N]$ de N individus. Les individus sont des solutions candidates à une certaine fonction objective F , distribués dans l'entièreté de l'espace de recherche. Les individus sont représentés sous forme de chromosomes qui sont une chaîne constituée d'un alphabet qui codent leurs propriétés.

Plus formellement, le chromosome $C = [c_1, c_2, \dots, c_l]$ de longueur l membre de l'ensemble $S=A^l$, est constitué d'un ensemble d'éléments appelés gènes, pouvant prendre plusieurs valeurs allèles, utilisant un alphabet A non nécessairement numérique. Le codage chromosomique d'une solution s'appelle le génotype et les caractéristiques codées s'appellent phénotype de l'individu. Dans l'algorithme de base, les allèles sont 0 et 1, et le chromosome est donc une chaîne binaire [CHU 00, ZHA 00]. Le but est donc de chercher la combinaison optimale de ces éléments qui donne lieu au maximum d'adéquation.

Les algorithmes génétiques utilisent trois opérations :

1) Sélection :

La sélection est le processus d'évaluation de la fonction d'adéquation (fonction objective) des membres de la population, et de créer une nouvelle population avec des individus mieux adaptés à l'environnement tel qu'il est représenté par la fonction d'adéquation. En nature, la fonction d'adéquation est déterminée par les capacités d'une créature à surmonter les dangers qui pourraient empêcher celle-ci pour atteindre l'âge adulte et pour se reproduire. Dans l'environnement artificiel, nous avons besoin d'une fonction d'adéquation pour évaluer la qualité des individus dans la population. Cette fonction prend le génotype de l'individu comme argument, le décode dans un phénotype, et de juger sa qualité.

Supposons, sans perdre de généralité, que la fonction objective F mentionnée ci-dessus est positive et devrait être optimisée. La fonction d'adéquation f peut être simplement rendue égale à F , et nous désignons par $f(C_i)$ la fonction de qualité de l'individu C_i . A chaque itération t , appelée génération, la fonction f de chaque individu est évaluée, les individus les plus convenables sont alors choisis

selon, bien sûr, un critère d'optimisation et les laisser se reproduire en utilisant le croisement et la mutation afin de créer la prochaine génération [WEL 00].

2) Croisement :

L'algorithme génétique combine les individus sélectionnés au moyen d'opérateurs génétiques tels que la mutation et le croisement. Le croisement comme le montre la figure (III.1), échange certains gènes d'un parent avec ceux de l'autre avec une probabilité P_c , plus précisément, on choisira au hasard deux parents dans la population et un site de croisement, soit k l'indice du site, on obtiendra alors deux enfants en prenant d'une part les k premiers gènes de premier parent et les $l-k$ derniers gènes du second parent, et pour l'autre enfant les k premier gènes du second parent et les $l-k$ derniers gènes du premier parent [SIII 94].




Fig. III.1. : Croisement de l'algorithme génétique standard.

Cette méthode est la plus simple, et est connue comme croisement en un seul point, il existe aussi des croisements multipoints et le croisement uniforme.

Le croisement étant le conducteur principal de recherche des algorithmes génétiques, habituellement appliqué avec une probabilité plus grande de 0.5.

La figure (III.1) représente un exemple de croisement en un seul point dans les algorithmes génétiques de base.

3) Mutation :

Ce mécanisme sert à changer localement les solutions représentées par les parents, la mutation illustrée dans la figure (III.2), agit en modifiant aléatoirement un ou plusieurs gènes d'un chromosome. Lorsqu'une population peut subir une mutation avec une probabilité P_m , la valeur du gène muté est remplacée par une autre appartenant au même alphabet.




Fig. III.2 : Mutation de l'algorithme génétique standard.

III.5. Amélioration de l'algorithme génétique standard :

III.5.1. Autres mécanismes de sélection :

Si nous employons le mécanisme standard de croisement de l'algorithme génétique de base, il y a toujours une possibilité que les bons individus dans la population sont remplacés par les membres moins adaptés lors du passage d'une génération à la suivante. Pour empêcher ceci de se produire, nous pouvons utiliser la stratégie élitiste dont le meilleur individu ou les $m\%$ meilleurs de

la population survient toujours à la prochaine génération [ZEL 01b]. Cette stratégie, simple mais efficace a été adoptée dans toutes les applications que nous traiterons dans le chapitre suivant.

III.5.2. Sélection par rangement :

Le mécanisme de sélection proportionnelle a ses avantages mais aussi ces inconvénients [WEL 00], en particulier, si un individu est très supérieur à la moyenne, il constituera presque exclusivement la population suivante et on aura perdu toute diversité (risque de convergence prématurée), de même, s'il y a très peu de différence entre les qualités d'adéquation des différents individus la recherche stagnera et se comportera plutôt comme une promenade aléatoire.

Il faut donc trouver une solution de compromis pour éviter ce genre d'excès. Une solution possible procède par un changement d'échelle de la fonction d'adéquation; on s'arrange pour que la fonction d'adéquation minimum et la fonction d'adéquation maximum aient des valeurs données en adoptant un changement d'échelle statique ou dynamique, linéaire ou exponentiel; évidemment, le changement d'échelle est indispensable quand les valeurs de la fonction d'adéquation sont négatives.

Au lieu de la sélection forme proportionnelle, nous pouvons également baser notre mécanisme de sélection sur le rang. Les individus sont tout d'abord rangés par ordre décroissant de leur fonction d'adéquation (dans le cas de maximisation), on attribue, par la suite, à l'individu de rang i un nombre moyen d'enfant exprimé par :

$$k_i = k_N + \frac{(k_1 - k_N)(N - i)}{(N - 1)} \quad \text{pour } 1 < i < N \quad (\text{III.1})$$

L'individu le plus convenable possède un nombre d'enfant moyen égal à k_1 et le moins convenable possède un nombre k_N pour une population de taille N telle que :

$$k_1 + k_N = 2 \quad (\text{III.2})$$

où k_N est la pression de sélection, i le rang de l'individu et N le nombre des individus dans la population [ZEL 01b].

Cette stratégie de sélection évite les inconvénients de sélection proportionnelle.

III.6. Le codage non-binaire et les opérations génétiques :

De nombreuses versions modifiées des algorithmes génétiques originaux ne se basent plus sur un codage binaire des paramètres à optimiser, mais travaillent directement sur les paramètres eux-mêmes.

Ces versions que nous appellerons algorithmes génétiques codés-réels, offrent généralement l'avantage d'être mieux adaptés aux problèmes d'optimisation numériques continus, d'accélérer la recherche et de rendre plus aisé le développement de méthodes hybrides avec des méthodes classiques.

Ces versions sont plus proches des besoins et des habitudes des praticiens industriels pour la résolution des problèmes réels.

Cependant, les algorithmes génétiques codés-réels nécessite le développement d'opérateurs spéciaux (mutation, croisement,...etc.), qui sont fait en tenant compte des spécification propre à chaque application. Pratiquement, tout se passe comme dans l'algorithme de base si ce n'est que les chromosomes forment une chaîne de nombres réels, plutôt qu'une chaîne de 0 et 1, les mécanisme d'évaluation et de sélection restent les mêmes, seule change la définition des opérateurs de mutation et de croisement.

III.6.1. Croisement dans les algorithmes génétiques codés-réels :

Le croisement en un point, le croisement en deux points, et celui uniforme peuvent être aussi utilisés dans le cas où les gènes posséderaient des valeurs réelles.

Nous définirons deux types de croisements, le premier, appelé croisement discret appliqué avec une probabilité P_{cd} . Ce type de croisement est identique à celui appliqué dans les algorithmes génétiques standards. (Voir Fig. III.1)

L'autre type décrit clairement par la figure (III.3), est appliqué avec une probabilité P_{cc} , et effectue une opération de type arithmétique sur les valeurs des gènes u et v des deux parents choisis au hasard, les allèles u' et v' des deux enfants sont donnés par [KOU 02]:

$$\begin{cases} u' = \alpha u + (1-\alpha)v \\ v' = (1-\alpha)u + \alpha v \end{cases} \quad (III.3)$$

avec : $\alpha \in [0,1]$, si $\alpha=0.5$, le croisement est dit de type moyen.




Fig. III.3. : Croisement continu de l’algorithme génétique codé-réel.

Il existe d’autres types de croisements, qui ont pour rôle d’accélérer la recherche et d’exploiter l’espace de recherche convenablement.

III.6.2. Mutation dans les algorithmes génétiques codés-réels :

Soit $C = [c_1, c_2, \dots, c_l]$ l’individu soumis à l’opérateur de mutation. Chacun des gènes représente un paramètre à optimiser et doit subir une modification selon l’équation suivante :

$$\begin{cases} c'_k = c_k + (c_{max} - c_k) \left(1 - r^{\left(\frac{1-t}{T} \right)^s} \right) & \text{si } p = +1 \\ c'_k = c_k - (c_k - c_{min}) \left(1 - r^{\left(\frac{1-t}{T} \right)^s} \right) & \text{si } p = -1 \end{cases} \quad (III.4)$$

tels que c_{max} et c_{min} désignent respectivement les bornes inférieure et supérieure de la valeur du gène c_k ; r est un nombre aléatoire appartenant à l’intervalle $[0,1]$, t est la génération courante, T est le nombre de génération et p est un nombre pris au hasard et vaut un changement négatif ou un changement positif avec une probabilité égale [KOU 02].

III.7. Critères d’arrêt :

On peut utiliser trois critères possibles d’arrêt pour l’algorithme génétique :

- i. Une solution satisfaisante a été atteinte;

- ii. Un nombre prédéfini de génération a été atteint ;
- iii. La population a convergé à un certain niveau de variation génétique.

Dans le premier critère, on peut stopper la procédure lorsque tous les individus sont presque identiques ou quand la population s'est regroupée à l'intérieur d'une hyper-sphère de rayon donné. Le deuxième critère consiste à tester l'amélioration de la fonction d'adéquation du meilleur individu au cours des générations successives.

Dans cette étude, nous avons procédé à l'arrêt de la recherche après un nombre fixe de générations.

III.8. Conclusion :

Nous avons exposé, dans la première partie de ce chapitre, des définitions permettant de se familiariser avec les méthodes d'optimisation, ainsi que leurs limitations lors d'une application à la résolution d'un problème d'optimisation. Rappelons qu'un algorithme génétique est un algorithme itératif de recherche globale dont le but est d'optimiser une fonction définie par l'utilisateur, en utilisant une population de points candidats dispersés dans l'espace de recherche et identifier rapidement les sous-domaines susceptibles de contenir l'optimum global.

Sur la base des caractéristiques de chaque méthode, nous nous attendons tout naturellement à ce que les méthodes classiques fassent preuve de bonne qualité d'exploitation et à ce que les algorithmes génétiques montrent de bonne propriété d'exploration. Après avoir exposé les différents mécanismes génétiques utilisés dans les algorithmes génétiques standards, sur lesquels une grande partie de la théorie a été établie, on a cité d'autres variantes, qui s'avèrent plus pratiques dans leur emploi, plus rapides, plus précises, et elles nous ont permis encore l'hybridation avec d'autres méthodes de type grimpeur dans le but de réduire leurs inconvénients et de marier leurs avantages, c'est ces caractéristiques qui rendent les algorithmes génétiques codés-réels souhaitables en optimisation et seront mises en évidence dans le chapitre suivant.

IV.1. Stratégie de modélisation du système Boiler-Turbine par un réseau de neurones :

IV.1.1. Introduction :

En présence d'un processus à contrôler, le premier souci de l'automaticien est d'en obtenir une description convenable. On cherche souvent à donner un modèle mathématique des phénomènes, c'est-à-dire à trouver un système d'équations dont la résolution fournit un résultat ou des prévisions conformes à l'observation. Les systèmes de commande pourront alors être élaborés sur la base de ces modèles mathématiques.

Pour obtenir ces équations, les lois de la physique seront souvent d'une certaine utilité, à condition que les phénomènes restent relativement simples, mais il est souvent hors de question de mettre en équations tous les phénomènes régissant un processus complexe. Dans ce cas, plutôt que de tenter l'impossible, et souvent inexploitable la mise en équations du processus à contrôler, la démarche habituelle consistera à l'identifier.

Le modèle obtenu dans ce contexte pourra suffire pour élaborer un dispositif de commande. Dans le cadre d'un modèle global pour un processus complexe, il faut introduire un critère plus réaliste pour traduire la qualité d'une identification.

Bien que l'identification puisse être parfois, une opération élémentaire, certaines difficultés se font jour lorsque des bruits et perturbations diverses apparaissent et empêchent de mesurer avec précision les caractéristiques des signaux enregistrés. De plus, il n'est pas toujours possible d'exciter le processus à identifier par des signaux d'entrée simple.

Lorsque toutes ces difficultés s'accumulent, l'identification n'est plus un problème élémentaire et nécessite de faire appel à des théories et techniques assez élaborées.

Dans la littérature, on peut trouver beaucoup de travaux sur les techniques d'identification, cependant, les modèles utilisés sont linéaires, par conséquent ils ne sont pas appropriés à la modélisation d'un système non linéaire et complexe.

Dans le domaine de la commande, l'objectif est de déterminer le dispositif de commande qui assure au procédé réglé les performances fixées par le concepteur, conformément à un compromis entre ces exigences et les limites physiques du procédé. La mesure de performance est habituellement liée à l'erreur entre un comportement de référence et la sortie réelle du processus, éventuellement élevée au carré et intégrée sur un certain intervalle de temps, cet indice de l'erreur peut même être moyenné sur différentes conditions initiales, différents points de fonctionnement et différents types de perturbations. On peut aussi envisager de lier la mesure de performance moyenne au temps écoulé avant que le système ne sorte d'un certain domaine de viabilité, quand l'objectif de la commande n'est pas précis.

Lorsque l'environnement avec lequel le système interagit est complexe (environnement incertain et bruité, les interactions, ...etc.), la synthèse d'une stratégie de commande performante s'avère par fois difficile et inexploitable.

D'une manière générale, cette absence de robustesse vis-à-vis des paramètres du procédé ne permet pas de garantir les spécifications sur les performances de la commande sachant que l'état paramétrique nominal du procédé, pour lequel est calculé le correcteur, ne correspond que très rarement au véritable état paramétrique.

C'est dans cette veine générale où s'inscrit le problème de la commande du système Boiler-Turbine que nous aborderons dans ce chapitre. Le système de commande est composé de deux parties, d'une part, la partie identification qui a pour but de traiter et d'analyser l'information provenant du processus suivant le cas, pour tenter d'établir un modèle de processus. D'autre part, la partie commande qui élabore des stratégies de commande appropriées.

Les usures, le vieillissement, les dépôts internes ou externes, les qualités d'eau et de combustible, sont des raisons pour lesquelles le modèle mathématique reste imprécis. Et font l'objet de recherches intensives traitant des problèmes divers liés principalement à la modélisation et la commande de la dynamique du Boiler-Turbine.

A l'ensemble de ces causes citées ci-dessus, vient s'ajouter la qualité de contrôle du niveau d'eau dans le ballon supérieur du générateur de vapeur, qui joue un rôle important pour le fonctionnement normal du Boiler. Ce phénomène complexe est dû essentiellement au retard de l'apport thermique du combustible lors d'un accroissement de la demande de vapeur. Celle-ci influe considérablement sur le taux de vapeur de l'émulsion et son volume massique. Il convient de souligner que 30% des arrêts d'urgence enregistrés dans les centrales thermiques à vapeur sont dus principalement au mauvais contrôle du niveau d'eau. Ce dernier crée un comportement dynamique à non minimum de phase dit : phénomène de gonflement.

Pour remédier à ces problèmes, il faut concevoir des dispositifs de commande qui se chargent de contrôler la pression de vapeur, le niveau d'eau et la puissance électrique recueillie à la sortie de l'alternateur d'une manière très robuste par rapport à l'état paramétrique du procédé.

Quelques travaux sont récemment apparus dans la littérature qui suggèrent l'utilisation des réseaux de neurones pour résoudre adéquatement les problèmes de commande des systèmes complexes, s'ils sont bien compris et convenablement utilisés.

C'est dans cette optique où s'inscrit notre contribution. A partir d'un modèle mathématique complexe développé par Bell et Aström décrivant, les différentes variables physiques du système de Boiler-Turbine P16-G16, employé dans une installation de cogénération à 160 MW, nous proposerons au cours de ce chapitre l'application des réseaux de neurones à la modélisation et à la commande du Boiler-Turbine avec une version plus ou moins modifiée. En ajoutant quelques améliorations susceptibles d'en améliorer les performances par la combinaison de réseaux de neurones avec les algorithmes génétiques; la stratégie proposée se trouve apte à reproduire le modèle complexe et à éviter, par conséquent, la désadaptation du système de commande au procédé. Il vaut la peine de noter que le but principal de cette stratégie est de reproduire au mieux les caractéristiques dynamiques du modèle complexe, par la réalisation de l'ensemble des objectifs de synthèse requis.

IV.1.2. Modélisation de la dynamique du Boiler-Turbine :

Reprenons le système différentiel (1.12) du chapitre I qui a été développé par Bell et Aström dans [BEL 87] :

$$\begin{cases} \frac{dp}{dt} = -0.0018u_2 \sqrt[8]{p^9} + 0.9u_1 - 0.15u_3 \\ \frac{dW}{dt} = (0.073u_2 - 0.016) \sqrt[8]{p^9} - 0.11W \\ \frac{d\rho}{dt} = \frac{1}{85} (141u_3 - 1.1u_2 p - 0.19p) \\ l(t) = 0.05(0.13073\rho + 100\alpha_s + q_s/9 - 67.975) \end{cases} \quad (IV.1)$$

où :

$$\begin{cases} \alpha_s = \frac{(1 - 0.001583\rho)(0.8p - 25.6)}{\rho(1.0394 - 0.0012304p)} \\ q_s = (0.854u_2 - 0.147)p + 45.59u_1 - 2.514u_3 - 2.096 \end{cases} \quad (IV.2)$$

En pratique, la structure et les différents paramètres du modèle complexe (IV.1) sont établis sous plusieurs hypothèses simplificatrices.

Les dynamiques négligées liées à un certain nombre de sous-systèmes constituent souvent une source d'erreur significative provoquant de larges variations paramétriques dans le processus global. C'est ainsi que, pour une raison ou une autre, il s'avère fort utile de faire appel à des techniques bien spécifiques pour une meilleure caractérisation de la complexité du système qui pourrait se traduire par une faible sensibilité aux erreurs de modèle.

En effet, on distingue deux types d'incertitudes sur le système :

- Incertitudes structurelles : il s'agit principalement des dynamiques liées aux échangeurs intervenant dans le système, supposées être proportionnelles à la charge. Cette prétention peut s'avérer très simple. D'autres approximations structurelles sont inhérentes à l'utilisation des tables de la vapeur et aux diverses fonctions de transformation.
- Incertitudes paramétriques : les constantes thermodynamiques et les paramètres géométriques sont généralement incertains et peuvent changer lors du fonctionnement du procédé (diamètre des tubes, capacités thermiques des divers métaux utilisés, etc.).

Pour satisfaire les exigences technologiques, le niveau d'eau doit être maintenu à 50% du volume total du ballon supérieur de Boiler quant à la pression elle est de 108 kg/cm² pour une puissance électrique nominale de 66.65 MW. Ces valeurs représentent le point de fonctionnement nominal, quant à celle associées aux différentes marges de variations sont indiquées dans le tableau ci-dessous :

Points de fonctionnement	1 (80%)	2 (90%)	3 (110%)	4 (120%)
P^0	86.40	97.20	118.8	129.6
W^0	36.65	50.52	85.063	105.8
ρ^0	342.4	385.2	470.8	513.6
u_1^0	0.2090	0.2706	0.4182	0.5046
u_2^0	0.5520	0.6210	0.7590	0.8280
u_3^0	0.2556	0.3400	0.5434	0.6625

Pour simplifier la représentation fonctionnelle du modèle (IV.1), il convient de l'exprimer sous la forme suivante :

$$\begin{cases} \dot{x}_i = f(x_i, u_i, \theta) \\ y_i = g(x_i, u_i, \theta) \end{cases} \quad (IV.3)$$

avec θ est un vecteur regroupant l'ensemble des paramètres incertains et les dynamiques négligées lors de la linéarisation du système, et $x_i = [P \ W \ \rho]^T$ et $y_i = [P \ W \ l_i]^T$ désignent respectivement les valeurs d'état et de sortie du système Boiler-Turbine.

Pour analyser et évaluer l'erreur de modélisation, nous procédons à la linéarisation du modèle non linéaire (IV.1) au voisinage du point de fonctionnement nominal, il en résulte un modèle linéaire admettant la réalisation d'état suivante :

$$\begin{cases} \delta \dot{x}(t) = A \delta x(t) + B \delta u(t) \\ \delta y(t) = C \delta x(t) + D \delta u(t) \end{cases} \quad (IV.4)$$

où : $\delta x = x - x^0$, $\delta u = u - u^0$, $\delta y = y - y^0$,

et $x^0 = [108 \ 66.65 \ 428]^T$, $u^0 = [0.34 \ 0.69 \ 0.436]^T$, $y^0 = [108 \ 66.65 \ 0]^T$ sont les coordonnées du point d'équilibre. Les matrices A , B , C et D évaluées en ce point sont données par :

$$A = \begin{bmatrix} -2.509E-3 & 0 & 0 \\ 6.940E-2 & -0.1 & 0 \\ -6.690E-3 & 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} 0.9 & -0.349 & -0.15 \\ 0 & 14.155 & 0 \\ 0 & -1.398 & 1.659 \end{bmatrix}$$

$$C = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 6.34E-3 & 0 & 4.71E-3 \end{bmatrix}, \quad D = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0.253 & 0.512 & 0.014 \end{bmatrix}$$

A partir de ce modèle linéaire, On fait l'analyse et l'évaluation de l'erreur de modèle du Boiler-Turbine, qui est due à la variation de son point de fonctionnement dans une marge allant de 80% à 120% de son état paramétrique nominal.

La dynamique du système Boiler-Turbine au voisinage d'un point de fonctionnement donné est décrite par un modèle linéaire représenté par les matrices (A_i, B_i, C_i, D_i) , dont la matrice de fonction de transfert correspondante est désignée par $G_i(s)$, $(i = 1, 2, 3, 4)$, et celle correspondant au modèle nominal est notée $G_0(s)$. L'erreur de modèle multiplicative $L_i(s)$ s'exprime alors par :

$$L_i(s) = \delta G_i(s) \cdot G_0^{-1}(s) \tag{IV.5}$$

où

$$\delta G_i(s) = G_i(s) - G_0(s) \tag{IV.6}$$

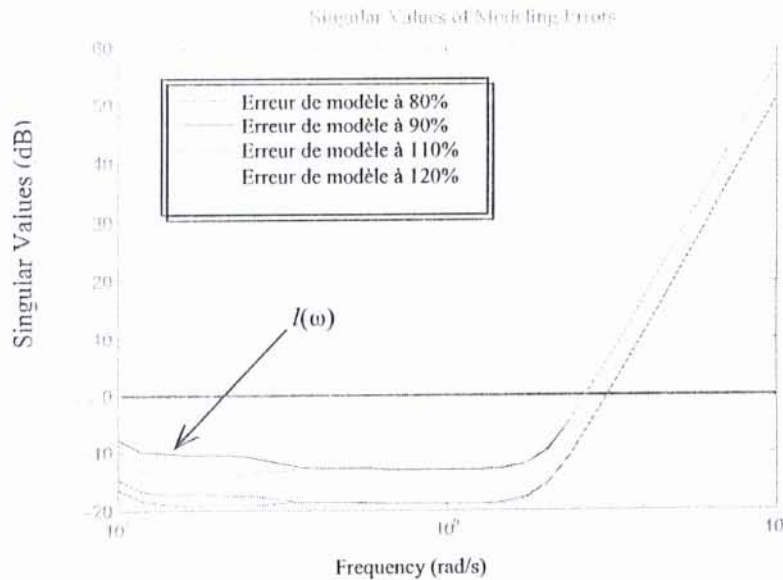


Fig. IV.1 : Caractéristiques des erreurs de modèle.

Pour pouvoir évaluer la caractéristique de l'erreur de modèle, on procède à la décomposition en valeurs singulières de $L_i(s)$, $(i = 1, 2, 3, 4)$. La figure (IV.1) montre les caractéristiques fréquentielles des erreurs de modèle évaluées par rapport au point de fonctionnement nominal. Il apparaît clairement, d'après cette figure, qu'une variation de 80% du point de fonctionnement nominal entraîne une erreur de modèle assez prononcée en comparaison avec les autres caractéristiques. Cette dernière peut être exprimée par la relation suivante :

$$I(\omega) = \max_i \bar{\sigma}((G_i - G_0)G^{-1}(j\omega)) \quad \forall \omega \tag{IV.7}$$

De plus, il convient de constater que toutes les erreurs de modèle deviennent significatives pour les fréquences supérieures à 20 rad/sec. Ce sont les dynamiques négligées qui provoquent généralement cette allure dans les hautes fréquences.

Pour une condition initiale donnée, on définit la fonction de coût suivante :

$$J = \frac{1}{2t} \sum_{i=1}^t \|y_i - \hat{y}_i\|_P^2 \tag{IV.8}$$

où y_i représente le vecteur de sortie du processus réel à chaque instant d'incrément i , \hat{y}_i est le vecteur de sortie du système approché, la période du temps prise pour l'évolution du système est définie par t pas et P est une matrice appropriée définie positive.

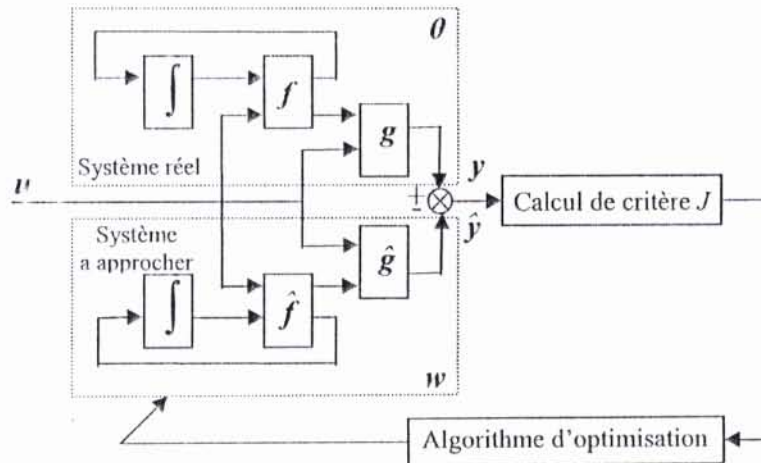


Fig. IV.2 : Schéma structurel de principe de l'identification.

Le problème d'identification du processus décrit par le modèle (IV.3) devient alors un problème d'optimisation paramétrique. La figure (IV.2) représente un schéma fonctionnel du principe d'identification dont la dynamique du système approché est donnée par :

$$\begin{cases} \dot{\hat{x}}_i = \hat{f}(\hat{x}_i, u_i, w) \\ \hat{y}_i = \hat{g}(\hat{x}_i, u_i, w) \end{cases} \quad (IV.9)$$

Les réseaux de neurones, comme nous l'avons vu dans le chapitre II, offrent un avantage intéressant, lorsque nous les utilisons pour l'approximation de fonctions sur la base d'exemples. Il est dès lors évident de penser à appliquer ces techniques à l'identification du procédé Boiler-Turbine.

IV.1.3. Description de la stratégie appliquée à l'identification du système Boiler-Turbine :

Il vaut la peine de noter que :

- Les non-linéarités, les interactions entre les différentes variables dans le système et la variation du point de fonctionnement provoquent des variations paramétriques non négligeables dans la dynamique du système, par conséquent, il est impossible d'appliquer les techniques classiques, tels que, le filtre de Kalman ou la méthode des moindres carrés ;
- La présence des dynamiques non modélisables, les non-linéarités non différentiables et par la considération d'un modèle simple, en négligeant certaines dynamiques, rendent difficile l'emploi des techniques basées sur une certaine méthode de linéarisation comme le filtre de Kalman étendu ou d'autres algorithmes basés sur le calcul des gradients des fonctions de coût.

Dans cette optique, il est intéressant d'appliquer les réseaux de neurones en commande devant les limitations pleinement reconnus des méthodes classiques. Néanmoins, cette technique, appliquée seule, se limite principalement aux points suivants :

- i. Les algorithmes d'apprentissage consistent le plus souvent en une descente de gradient, et sont donc sujet aux pièges des minima locaux, à moins que les poids initiaux ne soient pas trop éloignés de leurs valeurs optimales.

- ii. Le manque de moyens systématiques pour établir la topologie optimale.
- iii. Un début d'apprentissage n'est pas toujours maîtrisé, pouvant même entraîner des dommages néfastes.

En examinant les deux premières limitations énoncées ci-dessus, on se rend aisément compte que les algorithmes génétiques pourraient naturellement fournir une solution à ces problèmes, grâce à leur capacité de recherche globale et à leur habilité à faire évoluer favorablement des structures.

Pour ces raisons, l'application des deux techniques à l'identification du système Boiler-Turbine est donc à priori une approche prometteuse, et dans le but comme d'en combiner les propriétés avantageuses tout en évitant leurs inconvénients lorsqu'elles sont employées seules.

Avant de décrire la stratégie plus en détail, nous soulignons que le couplage des réseaux de neurones et les algorithmes génétiques, est utilisé pour la recherche d'une topologie optimale, dont l'individu des algorithmes génétiques est une description architecturale du réseau spécifiant le nombre de neurones dans la couche cachée; les algorithmes génétiques sont alors employés pour faire évoluer favorablement une population de topologie.

Le système approché, que nous énumérons individu, consiste en un réseau de neurones à base radiale caractérisé par un nombre de centres l_1 et de rayons vectoriels l_2 avec l_1 égal à l_2 . Les poids du réseau qui ont un nombre l_3 font aussi partie du gynotype.

Les centres c_i et les rayons σ_i des fonctions à base radiales de l'individu i sont fixés initialement. La disposition des centres et des rayons définit en quelque sorte un dallage de l'espace d'entrée. Dans ce cas, cette procédure représente une phase préliminaire pour un réseau de neurone dit neutre dont l'algorithme d'apprentissage devra ajuster seulement les poids.

L'individu manipulé par les algorithmes génétiques est un ensemble de centres c_i , de rayons σ_i et de poids associés w_i , tous représentés en valeurs réelles (algorithmes génétiques codés-réels). Le nombre $l_1 + l_2 + l_3$ représente la longueur de l'individu. Elle est différente d'un individu à un autre à la première génération, et elle détermine en quelque sorte la complexité du réseau.

La population est composée de N individus, chaque individu représente une architecture bien déterminée, et nous procéderons les opérations génétiques par une complexité croissante de la topologie mais contrôlée.

L'entrée du réseau est formée par le vecteur $u = [u_1 \ u_2 \ u_3]^T$ dont chaque composante est constituée de t éléments. A partir du modèle (IV.1) et des entrées prises dans l'intervalle $[0,200]$, on forme le vecteur $y = [y_1 \ y_2 \ y_3]^T$ de sortie du système.

Nous avons considéré dans la partie identification du système Boiler-Turbine un réseau à treillis régulier dont les centres sont uniformément disposés dans les domaines d'approximation. Le nombre n des centres et le nombre n_e des entrées du système définissent un individu neutre unique dont l'architecture est de n^{n_e} neurones.

La figure (IV.3) illustre le taux de recouvrement τ d'un réseau de neurones à base radiale à treillis régulier unidimensionnel qui est donné par :

$$\tau = \exp\left(-\frac{1}{2} \left(\frac{\delta}{\sigma}\right)^2\right) \quad (IV.10)$$

avec δ est la distance entre deux centres adjacents.

Pour les différents cas de simulation envisagés dans cette étude, nous avons disposé cinq centres. Les fonction à base radiale associées à ces différents centres disposé uniformément sont représentées à la figure (IV.3). Cette partition constitue une bonne couverture (locale et globale) sur une plage de variation allant de 80% à 120% du point de fonctionnement nominal.




Fig. IV.3 : Une gaussienne à treillis régulier unidimensionnel

Il s'agit donc d'approcher la dynamique du système Boiler-Turbine sur l'intervalle $[0,200]s$, on dispose pour cela de t échantillons pris uniformément dans ce même intervalle.

Définissons au préalable l'indice de performance donné par l'équation (IV.8) où \hat{y}_i représente la sortie du réseau et est donnée par l'équation suivante :

$$\hat{y}_i = \frac{1}{R_i} w p_i \quad (IV.11)$$

avec $R_i = \sum_{j=1}^{n_n} \rho_{j,i}$ est le terme de normalisation. (IV.12)

où $\rho_{j,i} = \exp\left(-\frac{1}{2}(u_i - c_j)^T Q_j^{-1}(u_i - c_j)\right)$ (IV.13)

le vecteur de centres c_j a la même dimension que le vecteur d'entrée du système u_i et Q_j est une matrice carrée qui représente les rayons de la gaussienne, donnée par :

$$Q_j^{-1} = \left(\text{diag} \left[\frac{1}{\sigma_{1,j}} \quad \frac{1}{\sigma_{2,j}} \quad \frac{1}{\sigma_{3,j}} \quad \dots \quad \frac{1}{\sigma_{n_e,j}} \right] \right)^2 \quad (IV.14)$$

Par conséquent, l'individu a la forme d'un vecteur de $l_1+l_2+l_3$ composantes réelles. Au cours de sa vie l'individu est capable d'apprendre à identifier le processus en changeant graduellement ces poids au moyen d'une méthode d'optimisation du genre « descente de gradient ». Dans l'intervalle

régulier de temps de t pas, les individus sont sélectionnés et combinés suivant le principe de base des algorithmes génétiques, pour former une nouvelle génération.

Comme le fonctionnement des algorithmes génétiques utilisés dans cette partie est assez différent du fonctionnement classique, il est de rigueur de procéder à la révision de toutes les phases de ce nouvel algorithme génétique :

Sélection :

La sélection se fait par rangement dans les $h\%$ individus de la population qui ont un statut spécial. Ils sont choisis pour la phase de reproduction sans être modifiés (stratégie élitiste). Aussi ces derniers sont choisis suivant la qualité de leurs performances d'identification que nous l'avons défini par l'équation (IV.8). Ce critère adopté porte sur l'erreur carrée moyenne (fonction d'adaptation à minimiser). Les N individus entrent en phase de reproduction ; les individus résultants lors de la génération prendront alors la place des individus les moins bons au sens défini par le critère de l'équation (IV.8).

Croisement :

Après avoir identifié et sélectionné les individus qui ont des bonnes performances, il vient de les combiner grâce au mécanisme de croisement. Comme les individus peuvent avoir des longueurs différentes, il est nécessaire de modifier l'opérateur de croisement traditionnel.

On choisi aléatoirement deux individus dont le premier à une longueur l et le deuxième une longueur l' du même espace codé. Les enfants résultants après avoir transféré les gènes choisis par l'opération de croisement (discret ou continu) avec une probabilité P_c , ont respectivement une longueur $(1-P_c)l + P_c l'$ et $(1-P_c)l' + P_c l$.

Il est raisonnable de penser qu'un individu optimal, peut être obtenu par combinaison de parties (centres, rayons, poids) performantes, chacune dans son domaine d'influence respectif. Par conséquent, une modification majeure a été apportée dans le fonctionnement des algorithmes génétiques. Nous y avons introduit des chromosomes multidimensionnels. On se rappellera que la représentation traditionnelle se base sur des chromosomes en forme de chaîne (unidimensionnel, ce faisant, cette représentation introduit de nouveau liens dans l'espace codé), (voir Fig. IV.4).




Fig. IV.4 : Croisement multidimensionnel de deux individus ont des longueurs différentes.

Mutation :

La mutation est réalisée en choisissant au hasard avec une probabilité P_m des gènes de chaque partie (centre, rayon, poids) de l'individu. Les gènes sont mutés suivant l'équation (III.4) de la section III.6.2 du troisième chapitre.

Les algorithmes génétiques fournissent graduellement les meilleurs paramètres initiaux pour l'algorithme du gradient. En ce sens les points initiaux de départ de l'algorithme du gradient deviennent progressivement ceux qui sont bien placés à l'intérieur du bassin d'attraction du minimum global de J , et évolueront aisément et sûrement vers cet optimum après un certain nombre d'itérations. Les algorithmes génétiques utilisent les résultats obtenus par la méthode du gradient pour la génération de nouveaux individus. (Fig. IV.5)

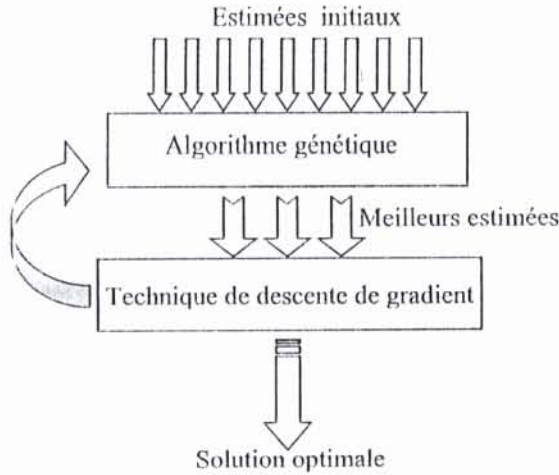


Fig. IV.5 : Combinaison des algorithmes génétiques avec la méthode de descente de gradient

Comme nous avons souligné ci-dessus, les seuls paramètres ajustables par la méthode de descente de gradient au cours de la vie d'un individu i sont les poids w_i .

En se référant aux équations exprimant la sortie \hat{y}_i du réseau en fonction des entrées u_i , les valeurs du gradient sont données par l'équation suivante :

$$\frac{\partial J}{\partial w} = \frac{\partial}{\partial w} \left(\frac{1}{2t} \sum_{i=1}^t \|y_i - \hat{y}_i\|_p^2 \right) = \frac{1}{t} (y - \hat{y}) H \rho^T \quad (IV.15)$$

où :

$$H = \text{diag} \left(\left[\frac{1}{R_1} \quad \frac{1}{R_2} \quad \frac{1}{R_3} \quad \dots \quad \frac{1}{R_t} \right] \right) \quad (IV.16)$$

avec : ρ est une matrice dont les éléments représentent les sorties de la fonction gaussienne à chaque instant.

La correction des poids s'obtient alors par :

$$w^{k+1} = w^k - \eta \left(\frac{\partial J}{\partial w} \right)_{w^k} \quad (IV.17)$$

avec η est le gain d'adaptation et k indice des itérations.

Tous les paramètres d'apprentissage sont les suivants :

Nombre des individus dans la population $N : 55$;

Longueur de chromosome (nombre de centres x nombre de rayons x nombre de poids) : $n_e n_{cc} \times n_e n_{cc} \times n_{cc} n_s$ (multidimensionnel) ;

La probabilité de croisement multidimensionnel en un point $P_c : 0.2$ (par partie de l'individu) ;

- La probabilité de croisement discret P_{cd} : 0.5 ;
- La probabilité de croisement continu P_{cc} : 0.5 ;
- La probabilité de mutation P_m : 0.02 (par individu) ;
- Le nombre de générations T : 500 ;
- Sélection par rangement avec une pression de sélection K_N : 1.6 ;
- L'application de la stratégie élitiste avec $h\%$: 4% ;
- Le gain d'adaptation de descente de gradient η : 10^{-3} ;
- Le nombre d'itérations de la technique de descente de gradient dans chaque génération it : 150 ;

La figure (IV.6) illustre schématiquement le principe de l'identification du système Boiler-Turbine en utilisant le réseau de neurones à base radiale.

IV.1.4. Simulation et comparaison :

Afin de valider la stratégie proposée, on commence par tester l'aptitude du modèle neuronal approché, à reproduire les principales caractéristiques dynamiques du système Boiler-Turbine, représenté par le modèle complexe (IV.1) et (IV.2), nous avons envisagé le cas de simulation suivant pour la phase d'apprentissage :

Phase d'apprentissage : Simulation de l'évolution des différentes variables de sortie pour une variation de type aléatoire appliquée sur une seule entrée.

L'erreur J définie par l'équation (IV.8) est représentée sur la courbe de la figure (IV.7) en fonction du nombre de génération, tandis que l'évolution de la topologie du réseau de neurones est

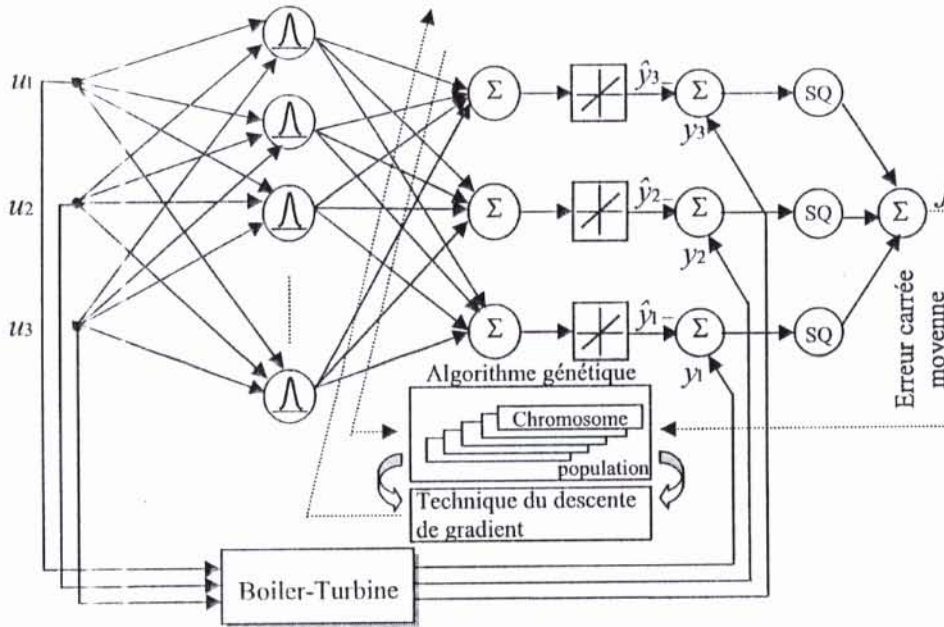


Fig. IV.6 : Architecture de l'identification du système Boiler-Turbine en utilisant un réseau de neurones à fonction de base radiale.

donnée par la figure (IV.3). Les deux figures représentent respectivement l'évolution de l'erreur et l'architecture du réseau du meilleur individu au cours de l'apprentissage.

En examinant la courbe d'apprentissage, on voit clairement que l'erreur J décroît et la topologie stagnera après un nombre de générations. Par conséquent, la répercussion de la méthode du gradient sur la diminution de l'erreur au cours de l'apprentissage mérite d'être signalé.

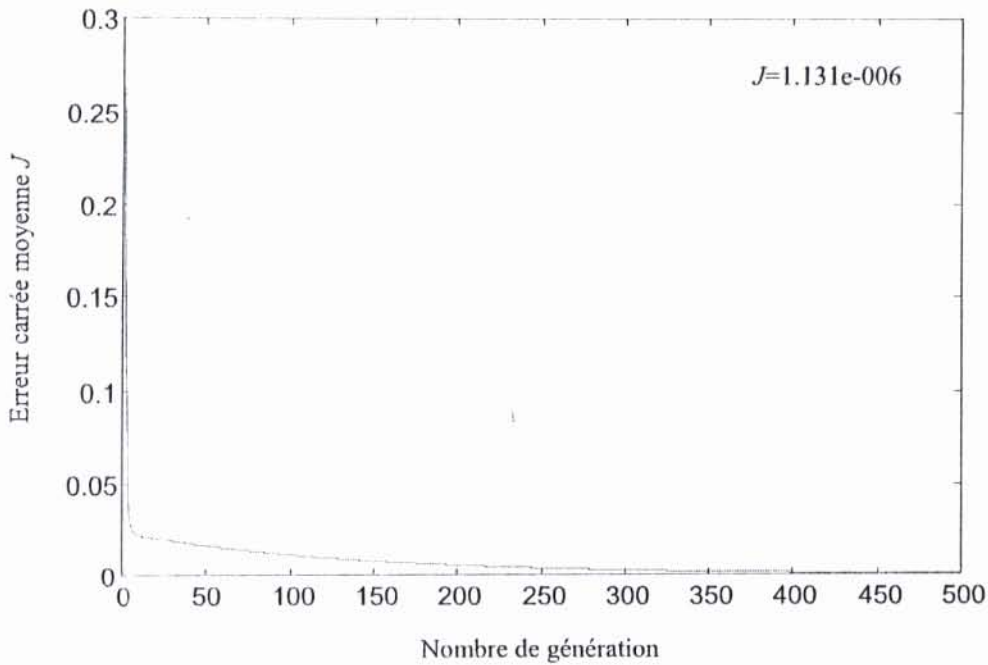


Fig. IV.7 : Evolution de l'erreur carrée moyenne au cours de l'apprentissage




Fig. IV.8 : Evolution de la longueur de meilleur individu au cours de l'apprentissage

La figure (IV.9) illustre les réponses : de la pression P de vapeur dans le ballon, le niveau d'eau l et la puissance électrique W recueillie sur l'arbre de l'alternateur.

D'après les résultats obtenus, il apparaît clairement que les caractéristiques du système Boiler-Turbine décrites par le modèle complexe (IV.1) et (IV.2) sont parfaitement reproduites par le modèle neuronal obtenu après apprentissage.

En fin d'apprentissage, on utilise le meilleur individu trouvé pour estimer les sorties du processus à lequel une excitation aléatoire est appliquée sur les entrées du système envisagées au

premier cas, et on calcule l'erreur moyenne d'identification. Pour cette phase nous avons envisagé le cas de simulation suivant :

Phase de validation : Simulation du comportement dynamique des variables de sortie du système pour une large variation du débit de vapeur par une excitation aléatoire retardée par dix secondes appliquée sur la vanne d'admission dans les limites admissibles.

Les résultats de validation du modèle neuronal sont illustrés par la figure (IV.10), où le nombre d'échantillons de validation choisis uniformément dans l'intervalle $[0,200]$ s est différent des échantillons d'apprentissage.

On constate que pour une large variation (dans les limites admissibles), le modèle neuronal approché a bien reproduit les variables les plus dominantes pour la description du comportement dynamique du Boiler-Turbine. Et en particulier pour l'analyse et le traitement du problème du niveau d'eau dans le ballon. Par conséquent, ces résultats donnent une bonne interprétation au phénomène de gonflement qui caractérise la dynamique de l'eau et qui pose un sérieux problème à la commande. Le modèle neuronal se révèle d'une très grande importance pour la réalisation d'un tel objectif.

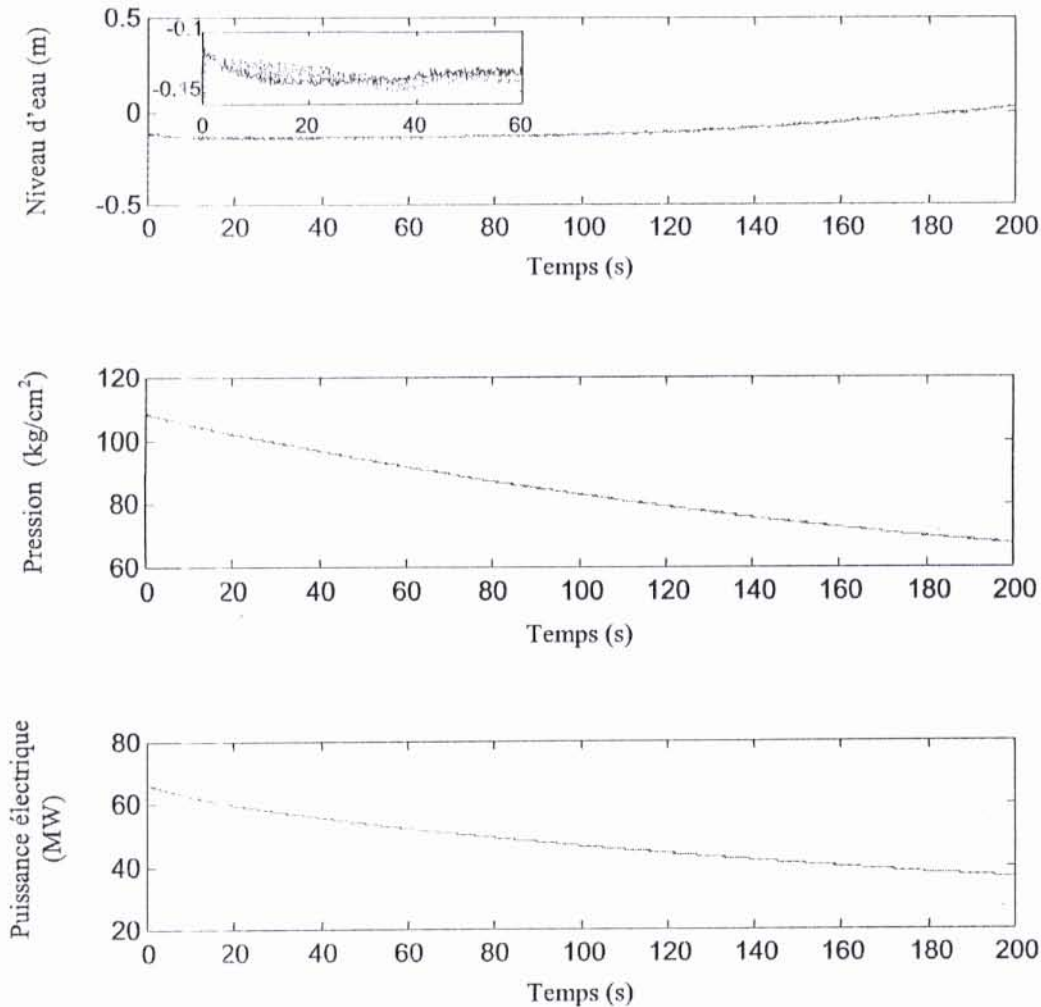


Fig. IV.9 : La variation des différentes variables de sortie de système Boiler -Turbine (—) modèle approché par réseau de neurones, (-----) modèle réel.

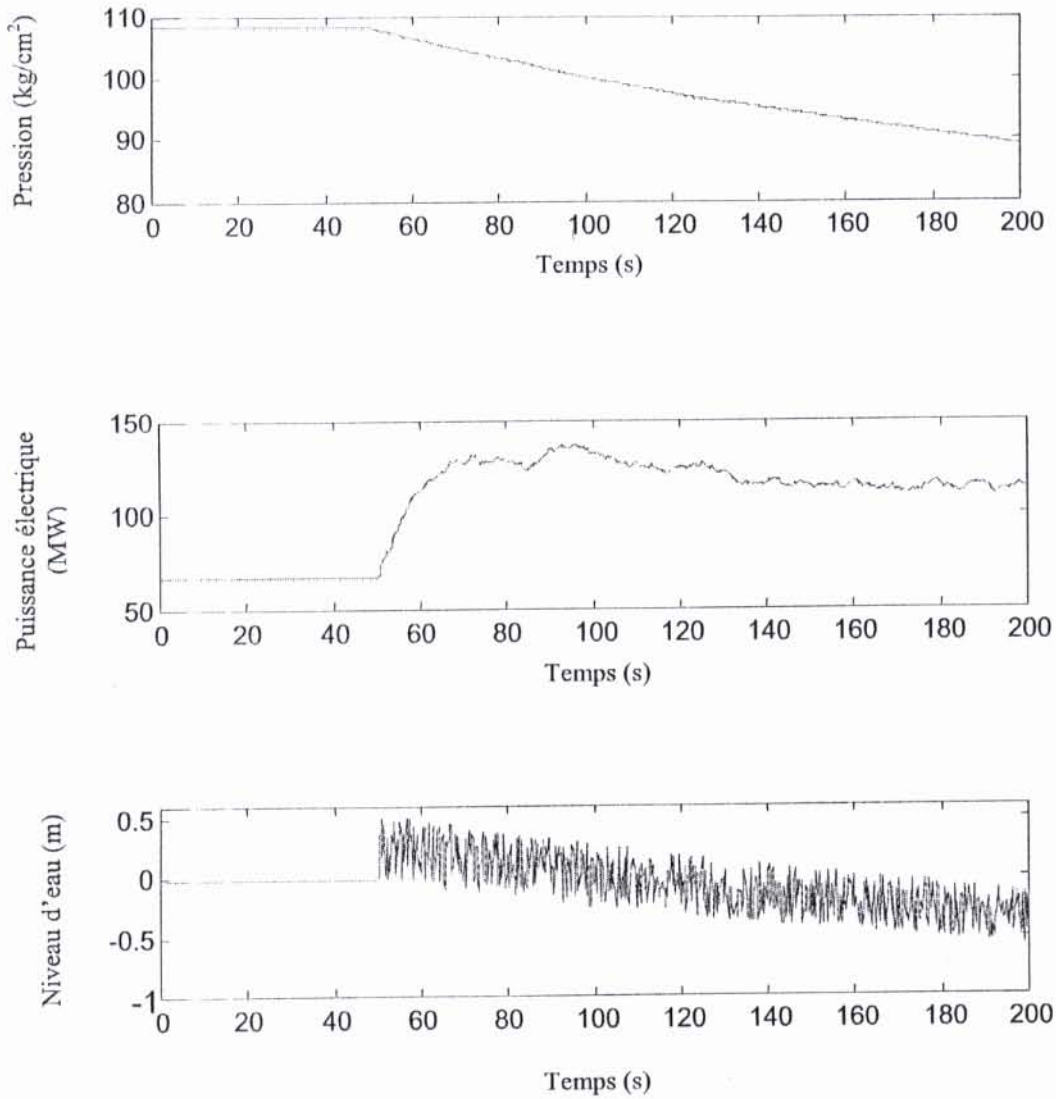


Fig. IV.10 : La variation des différentes variables de sortie de système Boiler-Turbine pour une large variation du débit de vapeur : (—) modèle approché par réseau de neurones, (-----) modèle réel.

IV.2. Stratégie de commande neuronale pour le système Boiler-Turbine :

IV.2.1. Introduction :

Dans un environnement complexe et variable, la conception d'un système de commande avec les propriétés fixées (basées sur les exigences du concepteur et les limites physiques du procédé) capable de conduire le système d'une façon satisfaisante est difficile voire impossible. Elle se base généralement sur un état paramétrique donné du procédé et sous plusieurs hypothèses de simplification.

Chaque modification de ces contributions non accompagnée d'une reparamétrisation de contrôleur susceptible d'en changer les performances et les objectifs de la commande d'une manière générale, cette absence de robustesse vis-à-vis des paramètres du procédé ne permet pas de garantir les spécifications sur les performances de la commande, sachant que l'état paramétrique du procédé, pour lequel est calculé le contrôleur, ne correspond que très rarement en véritable état paramétrique.

C'est dans ce cadre où s'inscrit le problème de commande de système Boiler-Turbine. Ce problème fait l'objet de nombreuses recherches, d'autant que les écarts paramétriques dans ce type de filière énergétique sont très fréquents en raison de leurs diversités et de leurs origines. Il vient s'ajouter à l'ensemble des causes soulignées au paragraphe de ce chapitre, l'influence des caractéristiques du transfert thermique et les écoulements dans les différents faisceaux tubulaires. Cette influence se manifeste par l'apparition du phénomène de gonflement qui rend difficile le contrôle du niveau d'eau. Il se traduit théoriquement par un comportement à non minimum de phase qui met en cause la stabilité de toute l'installation de cogénération pour laquelle se trouve installé le Boiler-Turbine.

Le système de commande du Boiler-Turbine est appelé à réaliser une commande très robuste par rapport à l'état paramétrique du procédé. Le recours à ces stratégies de commandes s'avère plus que nécessaire, en raison de la nature de la production en question et des exigences sévères de sécurité qui y sont requises.

Les techniques développées dans la théorie de commande des systèmes multivariables, à savoir la méthode de découplage, du placement des pôles, du régulateurs LQ, et la méthode de la matrice inverse de Nyquist, sont toutes des stratégies de commandes robustes mais elles s'avèrent inadéquates pour le cas du système Boiler-Turbine, dont la dynamique de l'eau dans le ballon supérieur est caractérisée par un comportement à non minimum de phase. En effet conséquent, 30% des arrêts d'urgences enregistrés dans les installations de cogénération sont dus principalement à la désadaptation du régulateur de niveau d'eau.

Pour remédier à ce problème, Kown et al. envisagent d'employer la technique LQG/LTR. Cette technique reconnue par ses propriétés de robustesse, et relativement insensible aux erreurs de modélisation en comparaison avec les autres techniques citées ci-dessus.

Dans cette veine, nous proposerons une stratégie de commande, en se basant sur celle développée par Kown dans [KOW 89]. Notre élaboration parvient à résoudre efficacement le problème de l'adaptation du contrôleur aux variations paramétriques pour atteindre au mieux les objectifs de synthèse requis.

IV.2.2. Contrôleur auxiliaire :

Les nombreuses applications des réseaux neuronaux à la commande des processus décrites dans la littérature sont le plus souvent des versions plus ou moins modifiées. Chacun y ajoute

quelques améliorations susceptibles d'en améliorer les performances pour son application spécifique.

C'est dans ce cadre où nous proposerons d'introduire un régulateur auxiliaire ayant pour rôle d'interpoler graduellement la stratégie de commande envisagée dans [KOW 89] où elle est basée sur la technique LQG/LTR classique, dans le but d'éviter l'instabilité et d'accélérer l'algorithme l'apprentissage.

La figure (IV.11) illustre le schéma fonctionnel simplifié de la structure de commande robuste LQG/LTR établie pour le système Boiler-Turbine avec l'ajout d'un régulateur neuronal placé en parallèle avec le régulateur linéaire optimal lors de l'apprentissage, tout en optimisant un critère défini sur un horizon temporel, qui s'écrit :

$$J = \frac{1}{2t} \sum_{i=1}^t \|u_i - \hat{u}_i\|_P^2 \quad (IV.18)$$

u_i représente le vecteur de commande linéaire à l'instant i , \hat{u}_i est le vecteur de sortie du régulateur neuronal. t représente l'intervalle de temps pris lors de l'apprentissage et P est une matrice appropriée définie positivement.

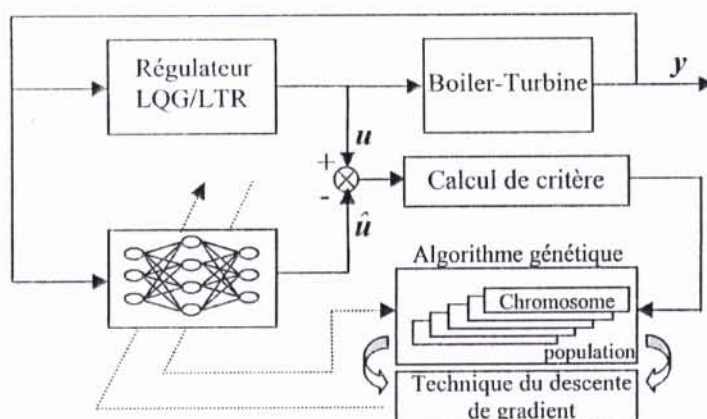


Fig. IV.11 : Schéma de principe d'approximation d'un contrôleur neuronal auxiliaire

le régulateur auxiliaire neuronal consiste en un réseau de neurones à base radiale généralisée comportant trois entrées $y = [y_1, y_2, y_3]^T$ et trois sorties $\hat{u} = [\hat{u}_1, \hat{u}_2, \hat{u}_3]^T$. Par l'application d'une perturbation à l'entrée du système Boiler-Turbine, de type échelon retardé, les valeurs de y prises dans $[0, 200]$ s, sont appliquées à l'entrée du réseau pour évaluer le critère J de l'équation (IV.18). Il est évident de prendre en considération lors de l'apprentissage, les limitations imposées sur l'amplitude de la commande et sur la vitesse d'exécution des actionneurs de position. Elles sont normalisées et données par :

$$\begin{aligned} 0 < u_1 \leq 1, & \quad |v_1| \leq 0.07 / \text{sec} \\ 0 \leq u_2 \leq 1, & \quad -2 / \text{sec} \leq v_2 \leq 0.02 / \text{sec} \\ 0 \leq u_3 \leq 1, & \quad |v_3| \leq 0.05 / \text{sec} \end{aligned}$$

reprenant le même algorithme d'apprentissage cité dans la section précédente de ce chapitre pour approcher le contrôleur neuronal auxiliaire au celui linéaire. Les différents paramètres d'apprentissage sont donnée à l'annexe [A-3].

La figure (IV.12) montre l'évolution de l'erreur carrée moyenne au cours de l'apprentissage du meilleur individu. L'évolution de la longueur du meilleur individu est donnée à la figure (IV.13). Les signaux de commandes neuronales ainsi que ceux de la stratégie de commande LQG/LTR classique y sont aussi représentées sur la figure (IV.14).

Cette phase préliminaire d'intégration d'un contrôleur neuronal en parallèle avec celui linéaire, permet de s'affranchir d'une connaissance à priori des positions des poids de connexion, ainsi que la topologie du régulateur neuronal pour y trouver un convenable, et par conséquent accélérer l'algorithme d'apprentissage.

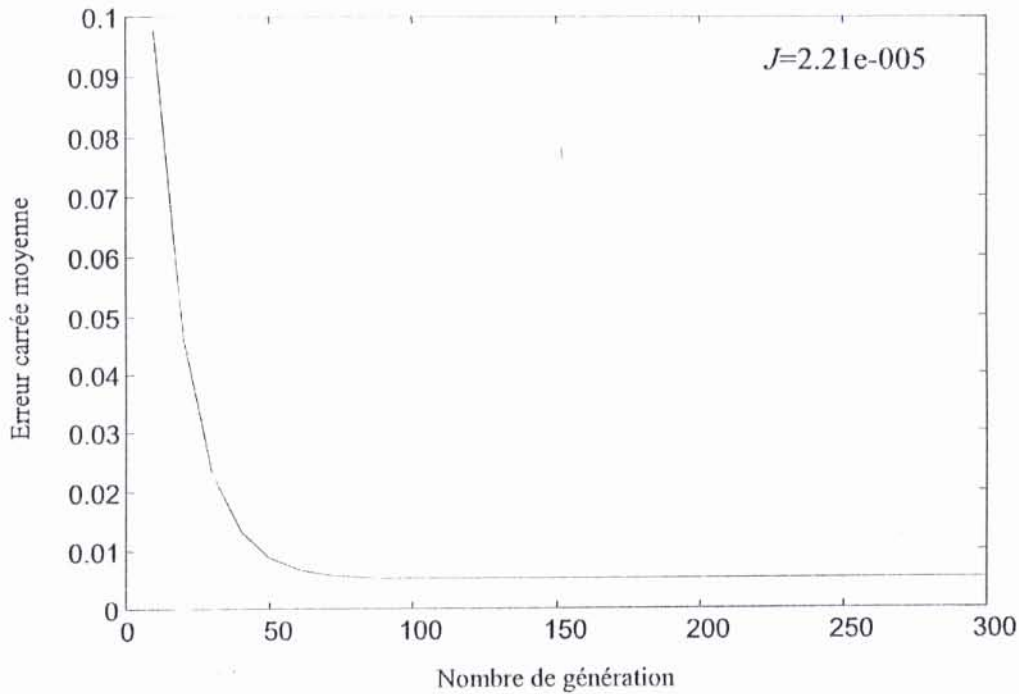


Fig. IV.12 : Evolution de l'erreur carrée moyenne au cours de l'apprentissage




Fig. IV.13 : Evolution de la longueur du meilleur individu au cours de l'apprentissage




Fig. IV.14 : Evolution des signaux de : (----) commande linéaire et (—) commande neuronale

IV.2.3. Stratégie générale de commande du système Boiler-Turbine :

A partir de modèle neuronal que nous avons développé pour le système Boiler-Turbine P16G16 dans la section précédente de ce chapitre, et à partir des résultats obtenus par l'utilisation d'un contrôleur auxiliaire, il est aisé de mettre en œuvre une stratégie générale de commande neuronale sous une forme parallèle avec celle développé par Kown et al.[KOW 89]. A cet effet, on fait appel aux propriétés d'approximation universelle pour synthétisé une fonction de commande dans le but que l'indice de performance soit le plus grand possible au voisinage de $(-\infty)$, et y donnée par :

$$\xi = \hat{J} - J \tag{IV.19}$$

Sur la base des résultats envisagés par Kown, le critère que l'on minimise porte sur la différence entre deux indices de performances. Cependant, l'indice de performance J défini sur un certain horizon est donné par l'équation suivante:

$$J = \int_0^{\infty} y^T(t) Q y(t) + u^T(t) R u(t) dt \quad (IV.20)$$

les matrices de pénalité Q et R sont choisies via plusieurs simulations comme suit :

$$Q = 0.005 \text{diag}([Q_1]) \quad (IV.21)$$

et

$$R = \text{diag}([0.01 \ 0.01 \ 0.5]) \quad (IV.22)$$

Où

$$Q_1 = C^T C \quad (IV.23)$$

Avec C est une matrice de sortie déterminée à partir de la linéarisation du modèle décrit par les systèmes d'équations (IV.1) et (IV.2) au point de fonctionnement nominal. (voir la section précédente).

Cette stratégie générale appliquée à la commande de système de Boiler-Turbine est illustrée sur la figure (IV.15).


IV.2.4. Simulation et comparaison :

Dans une première phase, nous commençons par l'application de la même perturbation appliquée dans la section précédente sur l'entrée du processus. Celle-ci est de type échelon retardé présenté sur une seule entrée :

$$\text{Cas1 : } d_u = [0.1 \ 0 \ 0]^T \Gamma(t-10)$$

Toutes les considérations de l'algorithme d'ajustement dans la partie d'identification relative au mode de croisement, au maintien de la diversité des individus dans la population, il suffit seulement de remplacer le critère J décrit l'équation (IV.8) par celui donné par l'équation (IV.13), d'introduire l'individu/réseau trouvé comme un contrôleur auxiliaire, dans les opérations génétiques de l'algorithme sans hybrider ce dernier avec une des méthodes de grimpeur [A-3].

La figure (IV.16) représente la courbe d'apprentissage (indice de performance définit par l'équation (IV.19) en fonction du nombre de génération), on y trouvera l'évolution de la longueur du meilleur individu sur la figure (IV.17).



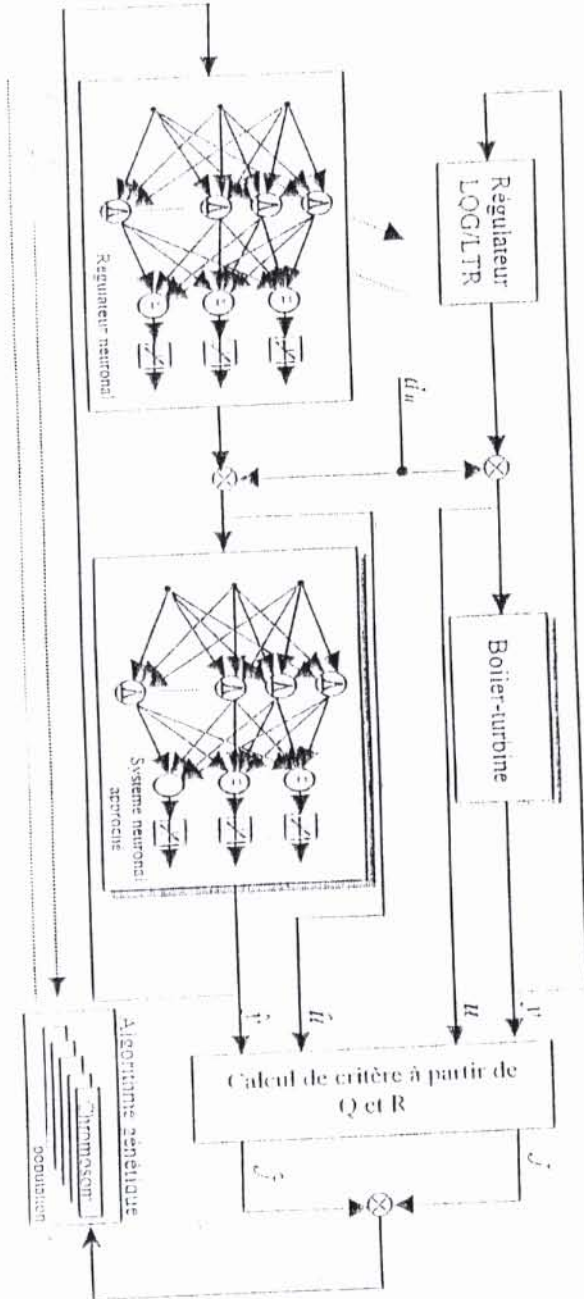


Fig. IV.15 : Schema de principe de la commande par réseau de neurone de système Boiler-Turbine

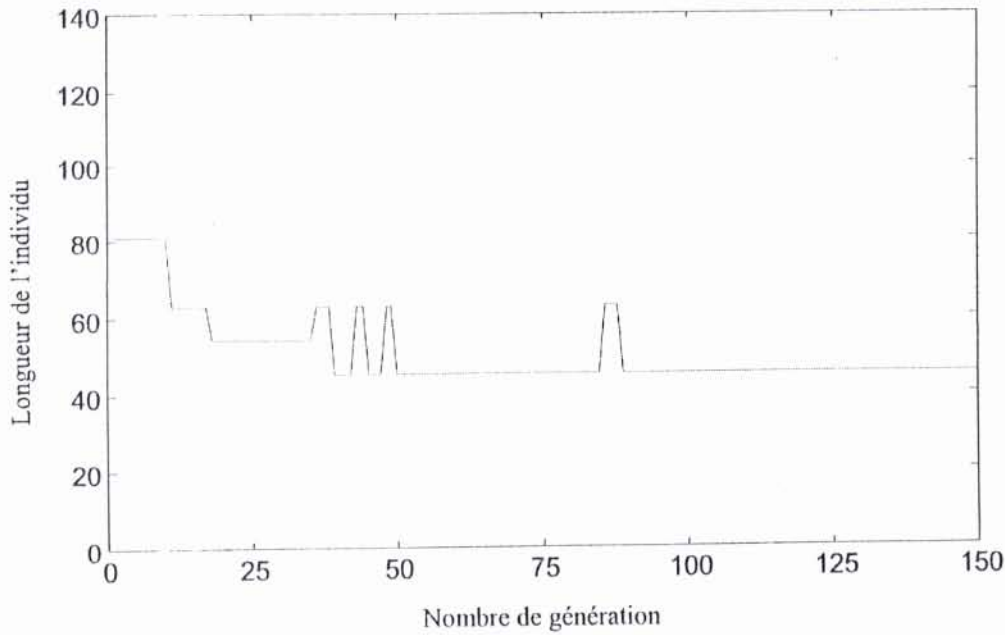


Fig.IV.17 : Evolution de la longueur de meilleur individu au cours de l'apprentissage

Après examen de ces résultats, nous pouvons faire les constatations suivantes :

- Il est avantageux d'utiliser un individu/réseau (contrôleur auxiliaire) lors de l'évolution d'une population. On aboutit ainsi à une solution simple dans le sens d'une présentation minimale, à une charge de calcul moins élevée. Par conséquent une rapidité d'ajustement ;
- La longueur du meilleur individu (régulateur neuronal) stagnera au cours de l'apprentissage, tandis que l'indice de performance ne cesse plus de diminuer, ceci montre le bénéfique retiré du principe de croisement à la base des algorithmes génétiques. Cet algorithme emporte à la fois sur les grimpeurs (descente de gradient) et sur la recherche aléatoire ;
- D'après la figure (IV.18) illustrant les signaux de sortie pour le cas 1, il apparaît clairement que le niveau d'eau atteint plus rapidement son régime nominal d'une façon significativement différente de celle envisagée par la méthode LQG/LTR classique. (conséquence de la simplicité de la représentation de différentes variables et la compensation des incertitudes sur le système, non considérées lors de la conception d'un régulateur linéaire).

Enfin, pour tester les capacités de cette stratégie à réagir correctement face à la modification subite de l'environnement, nous commençons, dans un premier temps, par tester l'aptitude du système de commande neuronale à rejeter les perturbations sur l'entrée du processus. Ainsi, les cas suivants sont considérés :

Cas 2 : $d_u = [0 \ 0.10]^T I(t-10)$

Cas 3 : $d_u = [0 \ 0 \ 0.1]^T I(t-10)$

Dans un deuxième temps, nous considérons le rejet de perturbation sur la sortie du processus. A cet effet nous avons opté pour les cas suivants :

$$\text{Cas 4 : } \mathbf{d}_y = [0.7 \ 0 \ 0]^T \Gamma(t-10)$$

$$\text{Cas 5 : } \mathbf{d}_y = [0 \ 5 \ 0]^T \Gamma(t-10)$$

$$\text{Cas 6 : } \mathbf{d}_y = [0 \ 0 \ 0.07]^T \Gamma(t-10)$$





Il est intéressant de s'attacher fortement aux performances de la stratégie proposée à la commande de processus, ce faisant, nous considérons le problème de poursuite de référence. Les situations suivantes sont prises pour mettre en évidence les propriétés de la commande neuronale :





$$\text{Cas 7 : } \mathbf{y}^r = \mathbf{y}^0 + [0.8 \ 0 \ 0]^T \Gamma(t-10)$$

$$\text{Cas 8 : } \mathbf{y}^r = \mathbf{y}^0 + [0 \ 5 \ 0]^T \Gamma(t-10)$$

$$\text{Cas 9 : } \mathbf{y}^r = \mathbf{y}^0 + [0 \ 0 \ 0.07]^T \Gamma(t-10)$$

Les caractéristiques dynamiques des différentes variables de sortie du système Boiler-Turbine sont montrées sur les figures (IV.18), (IV.19) et (IV.20) pour les différents cas envisagés.















Fig. IV.18 : Evolution des variables de sortie du système Boiler-Turbine pour des perturbations en entrée : (---) régulation LQG/LTR classique, (—) régulation neuronale.















Fig. IV.19 : Evolution des variables de sortie du système Boiler-Turbine pour des perturbations en sortie : (----) régulation LQG/LTR classique, (—) régulation neuronale.





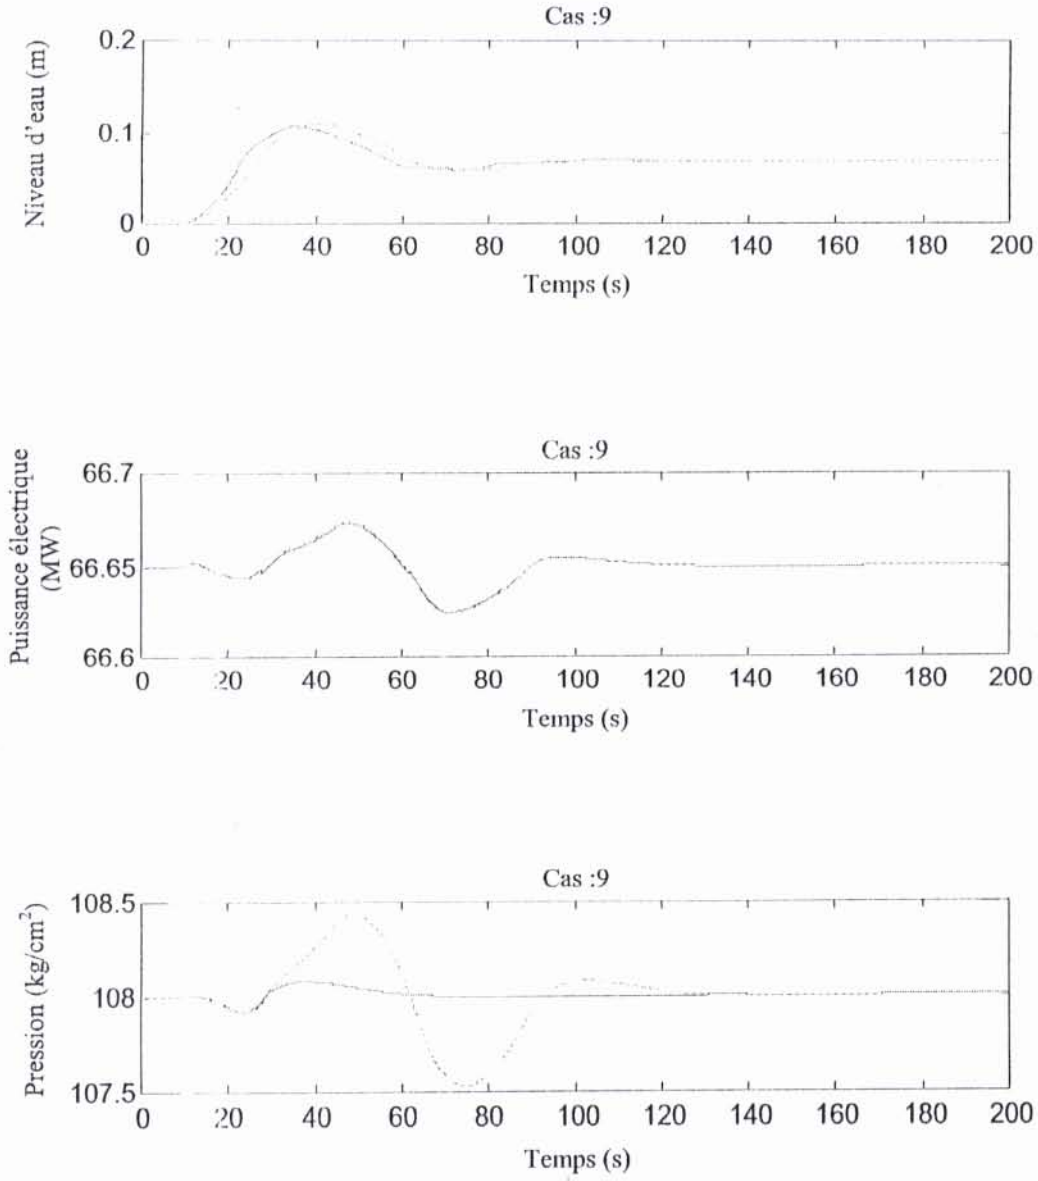


Fig. IV.20 : Evolution des variables de sortie du système Boiler-Turbine dans les cas de poursuite de références : (---) régulation LQG/LTR classique, (—) régulation neuronale.

□ **Interprétation des résultats :**

Comme on vient de souligner précédemment, le contrôle du niveau d'eau constitue l'une des spécifications qui pose de sérieux problèmes à la commande. En effet, suite à l'ouverture de la vanne d'admission, la pression dans le ballon supérieur diminue et le taux massique de l'émulsion (eau-vapeur) traversant les faisceaux tubulaires augmente, ce qui entraîne par conséquent une augmentation considérable du niveau d'eau qui se traduit théoriquement par un comportement dynamique à non minimum de phase. Il convient aussi de souligner que dans l'ensemble des cas considérés, le niveau d'eau et la pression dans le ballon supérieur dans le Boiler atteint plus rapidement le régime nominal avec moins des oscillations.

Les performances en fin d'apprentissage des différentes cas envisagés sont résumées au tableau ci-dessous où sont données les valeurs du critère de chaque technique d'une part, pour une configuration de commande LQG classique et, d'autre part pour une configuration de commande neuronale.

Différentes situations	Indice de performance décrit par l'équation (IV.20)	
	Commande LQG classique	Commande neuronale
Cas 1	101.0239	76.1677
Cas 2	101.1487	71.1475
Cas 3	100.8190	75.4025
Cas 4	109.9687	87.6522
Cas 5	107.7052	77.6573
Cas 6	105.8636	74.8462
Cas 7	117.9351	75.9203
Cas 8	111.9384	78.9384
Cas 9	116.4916	76.4957

Les performances apportées par l'emploi de la stratégie proposée sont cependant nettement améliorées par rapport à celle obtenue par l'emploi de la stratégie de la commande LQG/LTR. Cette amélioration se justifie par l'utilisation du modèle neuronal, vu la précision qu'il apporte sur l'évolution des différentes variables qui se trouve facilement exploitable lors de la synthèse de la commande. De plus, le contrôleur neuronal, a pour fonction de modéliser et de compenser les incertitudes dont le modèle linéaire ne tient pas compte.

Il apparaît clairement d'ailleurs que dans la plupart des situations envisagées, la stratégie proposée n'intervient pas plus efficacement que le contrôleur LQG/LTR, à la commande de la dynamique de la puissance électrique alors que le niveau d'eau et la pression arrivent plus rapidement son régime nominal.

Après avoir examiner ces résultats, nous constatons qu'il y a une forte interaction entre la dynamique du niveau d'eau et la pression, ainsi que leurs représentations mathématiques sont fortement non linéaire. Par ailleurs, un faible couplage entre la puissance électrique et les différentes variables, et une représentation s'avère plus simple.

IV.3. Conclusion :

Ce chapitre a répondu à un des problèmes majeurs qui se posent lors de la recherche d'une représentation mathématique fiable, précise et facilement exploitable en commande, pouvant décrire à un certain degré de satisfaction le comportement dynamique du système Boiler-turbine. En effet, la synthèse d'une loi de commande très appréciable s'avère plus facile pour réaliser les objectifs visés. En pratique, le modèle réel diffère du modèle nominal établi pour la synthèse de la commande. Cet écart paramétrique possède un effet non négligeable sur les performances du système et sur la robustesse de la commande envisagée. Comme nous l'avons d'ailleurs souligné au cours de ce chapitre, la source de complication de la modélisation du système Boiler-Turbine est liée principalement aux imprécisions et aux incertitudes caractérisant le modèle mathématique pour lequel est calculé le système de commande. A l'ensemble de ces imperfections, vient s'ajouter le phénomène très complexe et difficilement contrôlable caractérisant la dynamique du niveau d'eau dans le ballon supérieur du Boiler. Il se traduit physiquement par l'effet du gonflement (voir chapitre I), qui nécessite la mise en œuvre d'un système de contrôle assez robuste. Cette exigence de robustesse ne peut être en aucun cas remplie si l'on adopte pas une stratégie de commande basée fondamentalement sur un modèle de processus qui n'offre plus « le droit à l'erreur ».

C'est dans cette veine qu'on a proposé un modèle neuronal décrivant la dynamique du système Boiler-Turbine. Nous avons toutefois montré que le modèle approché par réseau de neurones illustre clairement dans les deux différentes situations (phase d'apprentissage et celle de validation) son aptitude de reproduire les principales caractéristiques dynamiques de Boiler-Turbine. Cette précision, simplicité, efficacité et robustesse du modèle neuronal repose essentiellement sur la qualité de la stratégie proposée. Néanmoins, les principes d'ajustement paramétrique et architecturale par algorithme génétique plus au moins modifié, sont suffisants pour constituer une méthode puissante et intéressante en point de vue de dépasser les difficultés et les inconvénients lors de la mise en œuvre de réseau de neurones.

L'emploi de ce modèle neuronal a donné lieu à une configuration de commande neuronale basée sur celle de la technique LQG classique, que nous avons bien démontré, à travers les résultats des différents cas envisagés, son efficacité dans la mesure où une amélioration des performances est nettement appréciée. Nous avons toutefois proposé une loi d'apprentissage qui sous certaines conditions offre à la fois des améliorations sur le processus et sur le réseau de neurones.

La base de la stratégie proposée repose principalement sur l'utilisation du modèle neuronal du système Boiler-Turbine avec un contrôleur neuronal, dont le premier a pour rôle de modéliser et de compenser les incertitudes non linéaires du système, non considérées lors de la conception du régulateur linéaire ; et l'autre se charge de compenser l'effet de ces incertitudes. Ceci se répercute sur la bonne caractérisation de la dynamique de l'eau. Par conséquent, le contrôle du niveau d'eau est nettement amélioré par rapport à celui de la commande LQG classique dans la plus part des cas envisagés.

Nous avons établi une phase préliminaire par la combinaison d'un contrôleur neuronal auxiliaire avec celui linéaire, dont le but de trouver une configuration initiale, des poids et de la topologie de réseau, plus proche de la configuration optimale.

Enfin, l'ensemble des résultats qu'on vient d'obtenir ne laisse que confirmer l'aptitude de la combinaison efficace des réseaux de neurones avec les algorithmes génétiques à caractériser les incertitudes et les imprécisions, à traiter et à dépasser les difficultés liées à la synthèse d'une stratégie de commande appropriée des systèmes non linéaires et complexes.

Annexe 1 : Paramètres du Boiler-Turbine

A1.1. Valeurs nominales

<i>Paramètre</i>	<i>Unité</i>	<i>Valeur</i>
Débit de vapeur	Kg/s	60
Pression de vapeur dans le ballon	Kg/cm ²	108
Densité du fluide	Kg/m ³	428
Facteur de qualité de vapeur	-	0.05
Niveau d'eau	%	50
Puissance électrique nominale	MW	66.65
Puissance maximale	MW	160

A1.2. Dimensions physiques

<i>Paramètre</i>	<i>Unité</i>	<i>Valeur</i>
Volume du ballon supérieur	m ³	40
Volume des tubes "risers"	m ³	37
Volume des tubes "downcomer"	m ³	11
Surface du ballon supérieur	m ²	20
Masse totale des tubes	kg	300000
Masse des tubes "risers"	kg	160000

A1.3. Valeurs numériques des termes intervenant dans le calcul des paramètres de la relation (I.10)

Paramètres	$h_c V_{st} \frac{\partial p_s}{\partial p}$	$\rho_s V_{st} \frac{\partial h_s}{\partial p}$	$\rho_w V_{wt} \frac{\partial h_w}{\partial p}$	$m_t C_p \frac{\partial t_s}{\partial p}$	V_t
Valeurs	420	-40	1870	1410	85

Annexe 2 : Nomenclature

A2.1. Variables :

<i>Symbole</i>	<i>Description</i>	<i>Unité</i>
<i>C</i>	chaleur spécifique	kJ/kg.K
<i>h</i>	enthalpie spécifique	kJ/kg
<i>l</i>	niveau d'eau	m
<i>m</i>	masse	kg
<i>p</i>	pression	kg/cm ²
<i>q</i>	débit massique	kg/s
<i>Q</i>	quantité de chaleur	W
<i>S</i>	surface	m ²
<i>T</i>	température	K
<i>t</i>	temps	s
<i>V</i>	volume	m ³
<i>W</i>	puissance électrique	MW
α	facteur de qualité	-
ρ	densité	kg/m ³

A2.2. Indices :

Symbole	Description
<i>a</i>	air
<i>d</i>	ballon supérieur du Boiler (drum)
<i>f</i>	feedwater
<i>fuel</i>	fuel
<i>g</i>	gaz
<i>l</i>	niveau
<i>m</i>	métal
<i>rh</i>	resurchauffeur (reheater)
<i>s</i>	vapeur (steam)
<i>t</i>	total
<i>va</i>	vanne d'admission
<i>w</i>	eau

Annexe 3 : Les paramètres des algorithmes d'apprentissage pour la stratégie de commande neuronale appliquée au système Boiler-Turbine

A3.1 : Les paramètres de l'algorithme d'apprentissage pour le calcul du contrôleur auxiliaire :

Algorithmes génétiques codés-réels hybride ;
 Nombre des individus dans la population N : 75 ;
 Longueur de chromosome (nombre de centres x nombre de rayons x nombre de poids) : $n_e n_{cc} \times n_e n_{cc} \times n_{cc} n_s$ (multidimensionnel) ;
 La probabilité de croisement multidimensionnel en un point P_c : 0.5 (par partie de l'individu) ;
 La probabilité de croisement discret P_{cd} : 0.8 ;
 La probabilité de croisement continu P_{cc} : 0.2 ;
 La probabilité de mutation P_m : 0.02 (par individu) ;
 Le nombre de générations T : 300 ;
 Sélection par rangement avec une pression de sélection K_N : 1.7 ;
 L'application de la stratégie élitiste avec $h\%$: 4% ;
 Le gain d'adaptation de descente de gradient η : 10^{-2} ;
 Le nombre d'itérations de la technique de descente de gradient dans chaque génération it : 15 ;

A3.2 : Les paramètres de l'algorithme d'apprentissage pour le calcul du contrôleur neuronal :

Algorithmes génétiques codés-réels ;
 Nombre des individus dans la population N : 60 ;
 Longueur de chromosome (nombre de centres x nombre de rayons x nombre de poids) : $n_e n_{cc} \times n_e n_{cc} \times n_{cc} n_s$ (multidimensionnel) ;
 La probabilité de croisement multidimensionnel en un point P_c : 0.5 (par partie de l'individu) ;
 La probabilité de croisement discret P_{cd} : 0.5 ;
 La probabilité de croisement continu P_{cc} : 0.5 ;
 La probabilité de mutation P_m : 0.02 (par individu) ;
 Le nombre de générations T : 150 ;
 Sélection par rangement avec une pression de sélection K_N : 1.7 ;
 L'application de la stratégie élitiste avec $h\%$: 5% ;

Bibliographie :

- [AHM 98] M. S. Ahmed and I. A. Tasadduq, "Neural Servocontroller for Nonlinear MIMO Plant", *IEE Proc.-Control Theory Appl.*, Vol. 145, No. 3, p. 277-290, May 1998.
- [ALE 97a] A. Alessandri and T. Parisini, "Nonlinear Modeling of Complex Large Scale Plants Using Neural Networks and Stochastic Approximation", *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, Vol. 27, No. 6, p. 750-757, November 1997.
- [ALE 97b] A. Alessandri, T. Parisini and R. Zoppoli, "Neural Approximator for Nonlinear Finite-Memory State Estimation", *Int. J. Control*, Vol. 67, No. 2, p. 275-301, 1997.
- [AMA 90] Shun-Ichi Amari, "Mathematical Foundation of Neurocomputing", *Proceeding of the IEEE*, Vol. 78, No. 9, p. 1443-1463, September 1990.
- [AOY 96] Azsushi Aoyama, Francis J. Doyle III and Venkat Venkatasubramanian, "Control-Affine Neural Network Approach for Nonminimum-Phase Nonlinear Process Control", *J. Proc. Cont.*, Vol. 6, No. 1, p. 17-26, 1996.
- [AST 00] K. J. Aström & R. D. Bell, "Drum-Boiler Dynamics", *Automatica*, 36, p. 363-378, 2000.
- [BAN 92] Robert M. Banner and Jean-Jaques E. Slotine, "Gaussian Networks for Direct Adaptive Control", *IEEE Transactions on Neural Networks*, Vol. 3, No. 6, p. 817-863, November 1992.
- [BEH 98] L. Behara, S. Chudhury and M. Gopal, "Application of Self-Organising Neural Networks in Robot Tracking Control", *IEE Proc.-Control Theory Appl.*, Vol.145, No. 2, p. 135-140, March 1998 .
- [BEL 87] R. B. Bell, K. J. Aström, "Dynamic Models for Boiler-Turbine Alternator Units : Data Logs and Parameter Estimation for a 160 MW Unit", *Report TFRT-3192, Lund Institute of Technology, Sweden*, 1987.
- [BER 90] Bernard Widrow and michael A. Lehr, "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", *Proceeding of the IEEE*, Vol. 78, No. 9, p. 1415-1442, September 1990.
- [CHU 00] Angela S. Chuang and Felix Wu, "An Extensible Genetic Algorithm Framework for Problem Solving in a Common Environment", *IEEE Transactions on Power Systems*, Vol. 15, No. 1, pp 269-275, February 2000.
- [CYB 89] Cybenko, G., "Approximation by Superposition of a Sigmoid Function", *Mathematics of Control, Signals and Systems*, 2, 1989, pp 303-314.
- [EIK 99] Bernhard Eikens and M. Nazmulkarim, "Process Identification with Multiple Neural Network Models", *Int. J. Control*, Vol. 72, No. 7/8, pp 576-590, 1999.
- [FAN 99] Y. Fang, T. W. S. Chow and X. D. Li, "Use of Recurrent Neural Network in Discrete Sliding-Mode Control", *IEE Proc.-Control Theory Appl.*, Vol. 146, No. 1, p. 84-90, January 1999.
- [FLY 99] M. E. Flynn & M. J. O'Malley, "A Drum Boiler Model for Long Term Power System Dynamic Simulation", *IEEE Transactions on Power System*, Vol. 14, N°. 1, February 1999.
- [FUK 92] Toshio Fukuda and Taknori Shibata, "Theory and Application of Neural Networks for Industrial Control System", *IEEE Transactions on Industrial Electronics*, Vol. 39, No. 6, p. 472-489, December 1992.
- [FUN 89] Funahashi, K. I., "On the Approximate Realization of Continuous Mappings by Neural Networks", *Neural Networks*, 2, 1989, pp 183-191.

- [GIR 90] F. Girosi and t. Poggio, "Networks and the Best Approximation Property", *Biol. Cybern.* 63, p. 169-176, 1990,.
- [HER 94] Jeanny Hérault et Christan Jutten, *Réseau Neuronaux et Traitement de Signal*, Hermès 1994.
- [HOR 89] Hornik K, Stinchcombe M. and white H., "Multilayer Feedforward Networks are Universal Approximator", *Neural Networks*, 2, p. 359-366, 1989.
- [HYL 95] David C. Hyland, Emmanuel G. Collins, Jr, Wassim M. Haddad and Douglas L. Hunter, "Neural Network System Identification for Improved Noise Rejection", *Int. J. Control*, Vol. 68, No. 2, pp 233-258, 1995.
- [KOI 94] H. N. Koivo, "Artificial Neural Networks in Fault Diagnosis and Control", *Control Eng. Practice*, Vol. 2, No. 1, pp 89-101, 1994.
- [KOU 02] A. Kouadri, M. Zelmat, "Radial Basis Function Neural Network for a Boiler-Turbine System using Hybrid Genetic Algorithm", *WSES Int. Multiconference*, Interlaken, Switzerland, February 11-15, 2002.
- [KWO 89] W. H. Kwon, S. W. Kim & P. G. Park, "On the Multivariable Robust Control of a Boiler-Turbine System", *IFAC Power System and Power Plant Control*, p. 219-223, 1989.
- [LEV 93] Asriel U. Leven and Kumpati S. Narendra, "Control of Nonlinear Dynamical Systems using Neural Networks: Controllability and Stabilization", *IEEE Transactions on Neural Networks*, Vol. 4, No. 2, p. 194-206, March 1993.
- [LUO 00] X. luo, A. D. Patton and C. singh, "Real Power Transfer Capability Calculations using Multi-Layer Feedforward Neural Networks", *IEEE Transactions on Power Systems*, Vol. 15, No. 2, p. 903-908, May 2000.
- [NAR 91] Kumpati. S. Narendra and Kannan Parthasarathy, "Gradient Methods for the Optimization of Dynamical Systems Containing Neural Networks", *IEEE Transactions on Neural Networks*, Vol. 2, No. 2, p. 252-262, March 1991.
- [NGU 90] Derrick h. Nguyen and bernard widrow, "Neural Networks for Self-Learning Control Systems", *IEEE Control Systems Magazine*, p. 18-23, April 1990.
- [OUS 94] A. Oustaloup. *La robustesse : Analyse et synthèse de commandes robustes*, Traité des Nouvelles Technologies, Série Automatique, 1994.
- [PAR 95] Moon Ghu Park and Nam Zincho, "Self-Tuning Control of a Nuclear Reactor using a Gaussian Function Neural Network", *Nuclear Technology*, Vol. 110, p. 285-293, May 1995.
- [ROB 89] Robert Hecht-Nielsen, "Theory of Backpropagation Neural Network", *Proc IEEE Int. Conf. On Neural Networks*, p. 593-605, 1989.
- [SAB 00] Angelo M. Sabatini, "A Hybrid Genetic Algorithm for Estimating The Optimal Time Scale of Linear Systems Approximations Using Laguerre Models", *IEEE Transactions on Automatic Control*, Vol. 45, No. 5, p. 1007-1011, May 2000.
- [SHI 94] T. Shibata and T. Fukuda, "Coordination in Evolutionary Multi-Agent-Robotic System Using Fuzzy and Genetic Algorithm", *Control Eng. Practice*, Vol. 2, No. 1, p. 10-111, 1994.
- [SLO 91] Slotine J.-J. and Li W., *Applied Nonlinear Control*, Prentice-Hall, 1991.
- [SON 98] Q. Song, "Robust Training Algorithm of Multilayered Neural Networks for Identification of Nonlinear Dynamic System", *IEE Proc.-Control Theory Appl.*, Vol. 145, No. 1, January 1998.

- [SUN 94] Sunil Elanayar V. T and Yung C. Shin, "Radial Basis Function Neural Network for Approximation and Estimation of Nonlinear Stochastic Dynamic Systems", *IEEE Transactions on Neural Networks*, Vol. 5, No. 4, pp 594-603, July 1994.
- [SUN 00] Sunil Elanayar V. T and Yang C. Shin, "State Estimation of Continuous-Time Radial Basis Function Networks", *Automatica* 36, p. 399-407, 2000.
- [SUY 95] Johan A. K. Suykens, Bart L. R. Demoor and Joos Vandewalle, "Nonlinear System Identification using Neural State Space Models, Applicable to Robust Control design", *Int. J. Control*, Vol. 62, No. 1, p. 129-152, 1995.
- [WEL 00] M. Welsh, P. Mehta and M. K. Darwish, "Genetic Algorithm and Extended Analysis Optimisation Techniques for Switched Capacitor Active Filters – Comparative Study", *IEE Pro.-Electr. Power Appl.*, Vol. 147, No. 1, p. 21-26, January 2000.
- [ZEL 01a] M. Zelmat and A. Kouadri, "A Nonlinear Model for a Drum Boiler-Turbine System Using Neural Network Approach", *3^{ème} Séminaire National en Génie Electrique*, Biskra, 29-31 Octobre 2001.
- [ZEL 01b] M. Zelmat and A. Kouadri, "A Hybrid Genetic Algorithm for Modeling the Boiler-Turbine Using Radial Basis Function Neural Network", *1^{er} Séminaire National sur le Contrôle et les Signaux*, Djelfa, 30-31 Octobre 2001.
- [ZHA 00] P. Zhang and A. H. Coonick, "Coordinated Synthesis of PSS Parameters in Multi-Machine Power Systems Using The Method of Inequalities Applied to Genetic Algorithm", *IEEE Transactions on Power Systems*, Vol. 15, No. 2, pp 811-816, May 2000.