

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي و البحث العلمي



BADJI MOKHTAR ANNABA UNIVERSITY

جامعة باجي مختار – عنابة

UNIVERSITE BADJI MOKHTAR – ANNABA

Année 2010

FACULTE DES SCIENCES DE L'INGENIEUR
Département d'électrotechnique

Mémoire

Présenté en vue de L'Obtention Du Diplôme De Magister

Modélisation et détection des modes de défaillance dans un système complexe par les méthodes graphiques: Application au réseau électrique Sonelgaz

(Option : Commande Eléctrique)

Présenté Par :

DENDANI HAYETTE

Dirigé Par : Dr. LAKEL Rabah

MC Université Badji Mokhtar Annaba

DEVANT LE JURY

Président : Mr DEBBACHE Nacer Eddine

PR Université Badji Mokhtar Annaba

Examineurs : Mrs RAMDANI Messaoud

MC Université Badji Mokhtar Annaba

ABDERREZEK Abdallah

MC Université Badji Mokhtar Annaba

BAHI Tahar

MC Université Badji Mokhtar Annaba

صيانة الأنظمة الصناعية مهمة حاسمة للإنتاجية وجودة المنتجات والخدمات المقدمة. ومع ذلك فهو أيضا مهمة معقدة تلزم ضرورة استعمال عدة أنظمة كمبيوتر و التي يجب أن تتعايش.

يؤكد هذا التقرير عملنا الذي يستهدف تحقيق نظام يجمع المعرفة والدراية في مجال التشخيص للعطب والانهيـار ضمن شبكة الكهرباء وتوزيع الطاقة الكهربائية على مستوى شركة سونلغاز.

في النظم الصناعية المعقدة المؤطرة على شكل شبكات مثل إنتاج وتوزيع الطاقة الكهربائية على مستوى أي بلد, كشبكات الاتصالات, الطرق البيانية للتأطير والنمذجة مثل شبكات نورون و شبكات بايز أثبتت قوتها في مجال الصيانة للكشف عن العيوب و نمذجة تلك التوزيعات . هذه القوة نابعة من شدة الترابط و التقارب بين الشبكة الصناعية المدروسة و الشبكة البيانية المستعملة لتشكيل نموذج لهم.

كلمات رئيسية: التشخيص، شبكات بايز,, شبكات نورون ,الطاقة الكهربائية.

Abstract

The maintenance of industrial systems is crucial for productivity, products quality and supplied services. Numerous computer systems are therefore developed for the task and must, in most cases, collaborate with each other. In the light of this statement, our work aims at realizing a system which consists in gathering the knowledge and the know-how in the field of fault diagnosis or abnormality within the electricity network distributing the electrical energy at the level SONALGAZ. For the complex industrial systems structured in networks such as the production and the distribution of the electrical energy on a country, that the telecommunication networks, the graphic methods of modelling such as the Bayesians Networks, Neurons Networks, proved their power in the field of the maintenance to detect the failures and model their distributions. This power emanates from very strong spatial correlation between the studied industrial network and the graphic network used to model them.

Keywords : Fault diagnosis, , Bayesians network, Neurons Networks, Electrical energy.

Résumé

La maintenance des systèmes industriels est une fonction cruciale pour la productivité, la qualité des produits et des services fournis. Toutefois c'est aussi une fonction complexe, que de nombreux systèmes informatiques sont devenus nécessaires et doivent cohabiter.

Fort de ce constat, notre travail vise à réaliser un système qui consiste à rassembler le savoir et le savoir-faire dans le domaine de diagnostic de panne ou d'anomalie au sein du réseau électrique distribuant l'énergie électrique au niveau Sonelgaz.

Pour les systèmes industriels complexes structurés en réseaux tels que la production et la distribution de l'énergie électrique à l'échelle d'un pays , ou les réseaux de télécommunications , les méthodes graphiques de modélisation tels que les réseaux de neurones et les réseaux de bayes ont prouvé leur puissance dans le domaine de la maintenance pour détecter les défaillances et modéliser leurs propagations . cette puissance émane de très forte corrélation spatiale entre le réseau industriel étudié et le réseau graphique utilisé pour les modéliser.

Mots-clés :Diagnostic, Réseaux bayésiens , Réseaux de neurones ,l'Energie électrique

Dédicace

Je dédie ce mémoire

À mes chers parents pour tout ce qu'ils ont fait pour moi et que dieu les accueille dans son vaste paradis,

A toute ma famille et belle famille , sœurs, frères, belles sœurs , beaux frères ,mes neveux et mes nièces .

A ma petite famille : mon mari Rochdi et à mes enfants Zied , Sami et la nounou Hadil .

Remerciements

Je tiens tout d'abord à exprimer ma gratitude à mon encadreur Mr LAKEL RABAH pour la confiance qu'il m'a accordée, ses encouragements, et ses précieux conseils.

Je tiens également à remercier Monsieur DEBBACHE NacerEdine Professeur, à l'Université Badji-Mokhtar Annaba ,d'avoir accepté de participer au jury et d'en avoir assuré la présidence et à Messieurs : RAMDANI Messaoud, Maître de conférence à l'Université Badji-Mokhtar Annaba, ABDERREZEK Abdallah ,Maître de conférence à l'Université Badji-Mokhtar Annaba ,BAHI Tahar, Maître de conférence à l'Université Badji-Mokhtar Annaba, d'avoir accepté également d'être membre de ce jury et d'avoir répondu favorablement à ma demande et d'avoir examiné mon mémoire.

Il me serait difficile de ne pas associer à ces remerciements ma famille, et mes collègues de travail pour leur encouragement, patience et leur compréhension, dont ils ont fait preuve tout au long de mes études.

Liste des tableaux

Tableaux	Titres	N°
1	- Tableau des Probabilités	2.1
2	- Tableau des probabilités conditionnelles	2.2
3	- Estimation de la matrice de probabilité de notre réseau	3.1
4	- Estimation de la matrice de probabilité de la variable CdPi conditionnellement à la variable Réseau	3.2
5	- Estimation de la matrice de probabilité de la variable conditionnellement à la variable Réseau. S.D.	3.3
6	- Estimation de la matrice de probabilité de la variable conditionnellement à la variable Réseau. S.O	3.4
7	- Estimation de la matrice de probabilité de la variable S.N conditionnellement à la variable Réseau	3.5

Liste des figures

Figures	Titres	N°
1	- Méthodes et outils en diagnostic	1.1
2	- Similitude entre réseau électrique et Réseau de neurone	2.1
3	- Représentation d'un neurone formel	2.2
4	- Les différentes fonctions d'activation	2.3
5	-Représentation du neurone de Mc Culloch et Pitts	2.4
6	- Représentation d'un réseau de neurones en matlab	2.5
7	- Apprentissage supervisé	2.6
8	- Apprentissage non supervisé	2.7
9	- Représentation de poids des connections	2.8
10	- Exemple de réseau bayésien	2.9
11	-La représentation graphique du modèle causal utilisé par M. Holmes	2.10
12	-Circulation des informations.	2.11
13	-Modélisation en ligne pour la détection de fraude	2.12
14	- Les états de fonctionnement d'un système électrique	3.1
15	- Présentation de la consommation en état normal	3.2
16	- Présentation de la production en état défaillant	3.3
17	- Classification des surcharges	3.4
18	- Classification des surcharges (réseau électrique)	3.5
19	- Similitude entre réseau électrique et R.B	3.6
20	- Graphe d'indépendance conditionnelle entre les variables Réseau et CdP.	3.7
21	- Réseau PMC utilisé.	3.8
22	- Représentation des fonctions d'activation utilisées	3.9
23	- Modélisation et saisie de la TPC sous BayesiaLab	4.1
24	- Modélisation et saisie de la TPC sous BayesiaLab Exemple voiture en fonctionnement normal	4.2
25	- Exemple voiture fonctionnement en mode défaillant	4.3

26	- Mode de fonctionnement normal exemple moteur à aimant permanent	4.4
27	- Mode de fonctionnement anormal (présence d'une défaillance)	4.5
28	- Modélisation de réseau électrique à l'aide du « BayesiaLab »	4.6
29	- Validation du réseau électrique en état normal .	4.7
30	-Représentation de la production régionale du 3 février 2003	4.8
31	-Représentation de la production et la consommation nationale	4.9
32	- Validation du réseau électrique en état de surcharge	4.10
33	- Représentation de la consommation et la production de la base d'apprentissage	4.11
34	-Représentation de la consommation et la production de la base validation	4.12
35	- Evolution de l'erreur d'apprentissage et de validation (MSE)	4.13
36	- Représentation de la consommation et la production de la base d'apprentissage	4.14
37	-Représentation de la consommation et la production de la base validation	4.15
38	- Evolution de l'erreur d'apprentissage et de validation (MSE)	4.16
39	- Représentation de la consommation et la production de la base d'apprentissage	4.17
40	-Représentation de la consommation et la production de la base validation	4.18
41	- Evolution de l'erreur d'apprentissage et de validation (MSE)	4.19
42	- Représentation de la consommation et la production de la base d'apprentissage	4.20
43	-Représentation de la consommation et la production de la base validation	4.21
44	- Evolution de l'erreur d'apprentissage et de validation (MSE)	4.22
45	- Représentation de la consommation et la production de la base d'apprentissage	4.23
46	-Représentation de la consommation et la production de la base validation	4.24
47	- Evolution de l'erreur d'apprentissage et de validation (MSE)	4.25
48	- détection d'une surcharge nationale (black out)	4.26

Liste des Symboles

Symbole	Désignation
FDI	Fault Detection and Isolation
RN	Réseaux de neurones
W	les poids des différents neurones
PMC	les perceptrons multicouches
RB	Réseaux bayesiens
N1 ,N2,N3,.....NI	Des nœuds dans RB
K2	Un algorithme d'apprentissage
TP	Table de probabilité
TPC	Table de probabilités conditionnelles
SN	Surcharge nominale
SD	Surcharge destinataire
SO	Surcharge originale
SG	Surcharge globale
SR	Surcharge régionale
Ek	l'erreur quadratique moyenne (MSE)
∇E_k	Gradient de l'erreur

Table des matières

Liste des tableaux	VII
Liste des figures	VIII
Liste des Symboles	X
Introduction générale	1

Chapitre 1 Diagnostic des systèmes

1.1 Introduction	4
1.2 Terminologie	5
1.3 Méthodes de diagnostic	6
1.3.1 Méthodes à base de modèle	7
1.3.2 Méthodes à base de connaissance	8
1.3.3 Modèles à base de données	9
1.4 Conclusion	11

Chapitre 2 Les méthodes graphiques utilisées : Réseaux de Neurones et Réseaux Bayésiens

2.1 Réseaux de neurones	13
2.1.1 Introduction	13
2.1.2 Terminologie	18
2.1.3 Quelques réseaux célèbres	20
2.1.4 Exemples d'applications des réseaux de neurones	22
2.2 Les réseaux bayésiens	23
2.2.1 Introduction	23
2.2.2 L'inférence bayésienne	25
2.2.3 Circulation de l'information	27
2.2.4 Mise en œuvre des réseaux bayésiens	29
2.2.5 Application des réseaux bayésiens	33
2.2.6 Apprentissage	34
2.2.7 Conclusion	35

Chapitre 3

Présentation et Modélisation de la base de données du réseau électrique Algérien par les RB ET RN

3.1.1 Classification des modes de fonctionnement	38
3.1.2 Mode de fonctionnement normal.....	39
3.1.3 Mode de fonctionnement anormal.....	40
3.1.3.a Cause initiales des pannes	41
3.1.3.b Type des surcharges.....	41
3.1.3.c Mode de fonctionnement en surcharge.....	42
3.2 Réseau Bayésien	43
3.2.1 Introduction	43
3.2.3 Construction d'un réseau bayésien	44
3.2.4 Graphe d'indépendance	45
3.2.5 Matrices de probabilités conditionnelles	46
3.3 Réseaux de neurones.....	49
3.4 Conclusion	52

Chapitre 4

Application et Résultat de Simulations

4.1 Introduction	54
4.2 Apprentissage	56
4.3 Exploitation.....	57
4.4 Analyse	59
4.5 Exemple d'application	60
4.6 Application du réseau électrique avec « Bayesialab ».	64
4.7 Résultat de simulation du réseaux électrique avec le réseau de neurone	68
4.8 Interprétation des résultats.....	74
4.9 Conclusion	76

Conclusion générale et perspectives

Bibliographie 80

Introduction générale

La complexité de plus en plus croissante des systèmes industriels, ajoutée aux contraintes liées à la compétitivité et à la législation en vigueur en terme de respect de l'environnement, ont poussé les industriels et la communauté scientifique à chercher des solutions pouvant rendre ces systèmes plus performants, plus compétitifs et plus sûrs. L'un des points sur lesquels les travaux de recherche sont orientés est la maintenance conditionnelle dans laquelle sont menés des travaux sur le diagnostic de défaillances.

Le diagnostic de défaillances des systèmes industriels a pour rôle de détecter et de localiser les défaillances qui surviennent sur le système et aussi d'identifier les causes de ces défaillances. Effectuer un diagnostic de défaillances sur un système donné ; c'est identifier le mode de fonctionnement dans lequel il se trouve. Les premières méthodes de diagnostic furent basées sur la redondance de matériels jugés critiques pour le fonctionnement du système. La redondance matérielle est très répandue dans les domaines où la sûreté de fonctionnement est cruciale pour la sécurité des personnes et de l'environnement, comme dans l'aéronautique ou le nucléaire. Les principaux inconvénients de la redondance matérielle sont liés aux coûts dus à la multiplication des éléments ainsi que l'encombrement et aux poids supplémentaires qu'elle génère. Le développement des calculateurs numériques permet aujourd'hui la mise en œuvre, dans le milieu industriel, des méthodes modernes de l'automatique et de l'intelligence artificielle.

Cette nouvelle approche permet d'éliminer en partie, voire même en totalité, la redondance matérielle pour le diagnostic des systèmes industriels. Globalement, on distingue deux approches de diagnostic (Isermann, 2005), (Isermann, 1997),: l'approche quantitative utilisant principalement des modèles analytiques (espace de parité, observateurs, estimation des paramètres, etc.), et l'approche qualitative faisant appel à des méthodes sans modèles analytiques (basées essentiellement sur les techniques de l'intelligence artificielle) (Piechowiak, 2003). Dans la première approche, quantitative, il est indispensable d'avoir un modèle mathématique des phénomènes physiques qui s'y déroulent pour réaliser un diagnostic. La qualité des résultats obtenus dépend alors fortement de la qualité du modèle utilisé. Cependant, il est très difficile, voire même impossible dans certains cas, d'obtenir un modèle qui traduit fidèlement le comportement du système. La seconde approche, qualitative, est quant à elle exploite les données disponibles pour faire de l'apprentissage ou encore, l'expertise qu'on a du système pour construire des règles. Mais, dans le cas où la base de données est incomplète ou insignifiante, ou encore si plusieurs cas sont possibles (explosion combinatoire), ces méthodes deviennent difficilement applicables et peuvent conduire à des conclusions erronées.

Dans le cas des systèmes complexes où des connaissances expertes sont disponibles, il est possible d'utiliser des outils graphiques bien adaptés :

1-les réseaux bayésiens (Pearl, 1988), (Naïm et al., 2004). [1]

Ces derniers permettent de représenter graphiquement cette connaissance en tenant compte des incertitudes. Dans mon mémoire nous verrons comment les réseaux bayésiens sont utilisés pour faire du diagnostic (de la localisation principalement) sur un réseaux électrique. Il s'agit principalement d'exploiter la structure graphique du modèle obtenu et d'utiliser les algorithmes d'inférence existants pour calculer des probabilités a posteriori de l'état du système suite à une ou plusieurs observations .

2- Les réseaux de neurones artificiels peuvent apprendre à prédire certaines sorties qui tendent à apparaître lorsqu'une certaine combinaison d'entrées lui est présentée. Les RNA peuvent parfois même déduire certaines sorties pour des vecteurs d'entrées qui ne leur ont pas été présentés lors de leur phase d'apprentissage. Les RNA sont donc capables de généraliser. Dans mon mémoire nous verrons comment les RNA de type perceptron multicouches PMC (noté MLP pour Multi Layer Perceptron en anglais) sont tout à fait populaires et utilisés pour le travail de diagnostic (détection et localisation d'une défaillance au sein des systèmes complexes (réseau électrique algérien).

Dans ce contexte, le mémoire comporte quatre chapitres et organisé de la façon suivante :

Chapitre 1

Ce chapitre présente l'état de l'art des techniques de diagnostic à base de données.

Chapitre 2

Ce chapitre servira, dans un premier lieu, pour l'introduction du langage de modélisation par les réseaux de neurones et les réseaux bayésiens et à la description de ses concepts de base. Nous allons voir qu'il est possible de décrire le comportement d'un système complexe par une base de données en utilisant ces méthodes graphiques.

Chapitre 3

Nous nous intéressons dans ce chapitre aux méthodes de diagnostic à base des réseaux de neurones et réseaux bayésiens utilisant une base de données décrivant le réseau électrique Algerien .

Chapitre 4

Dans ce chapitre, on applique les techniques de diagnostic présentées dans les chapitres précédents sur le réseau électrique algérien ,en utilisant une plate forme logicielle bayésialab et un réseau de neurones perceptron multi couches (PMC).

- une conclusion générale et des perspectives sont données à la fin du mémoire.

1

Diagnostic des systèmes

1.1 Introduction

Les systèmes conçus et fabriqués par l'homme (véhicules, avions, réseaux de télécommunications, usines...) sont de plus en plus complexes. Cette complexité est due au grand nombre de composants constituant ces systèmes. Malgré les besoins de haute sécurité, la réduction des coûts d'exploitation et la maîtrise de la disponibilité des équipements, ces systèmes ne sont pas à l'abri de défaillances. C'est pourquoi les activités de surveillance, diagnostic (détection, localisation, identification de défaillances), réparation ou reconfiguration sont très importantes. Ces activités permettent de détecter et localiser les défauts, de minimiser le temps de réparation, et de fournir un diagnostic fiable et facilement interprétable malgré la complexité des équipements.

De nos jours, l'implémentation des systèmes automatisés suppose la mise en place d'outils importants pour le diagnostic et la surveillance pour aider les entreprises dans leur recherche permanente d'un meilleur fonctionnement de leurs systèmes à moindre coût.

Dans ce contexte, de nombreuses approches ont été développées, en vue de la détection de défauts et du diagnostic, par différentes communautés de recherche en automatique.

Ces approches peuvent être classées, de manière générale, comme des méthodes à base de modèles, à base de reconnaissance de formes, à base de réseaux bayésiens, à base de cas, et des méthodes à base d'arbre de décision. Les méthodes à base de modèles considèrent le modèle de comportement du système basé sur des principes physiques fondamentaux.

Ces modèles peuvent être de type quantitatif exprimés sous forme d'équations mathématiques (contraintes) ou bien de type qualitatifs, exprimés par exemple sous forme de relations logiques. Les méthodes à base de reconnaissance de formes visent à identifier les zones d'un espace de valeurs qui correspondent à des états défaillants. Les méthodes à base de réseaux bayésiens sont des méthodes probabilistes qui peuvent aider à faire le diagnostic. Les méthodes à base d'arbre de décision consistent à construire un arbre à questions successives. Selon la réponse, cet arbre peut être construit et il permet de réaliser le diagnostic. Les méthodes à base de cas consistent à enregistrer dans une base de connaissances les effets observés des défauts qui se sont produits dans le passé. Puis, lorsqu'un fait anormal se produit, on cherche des cas similaires dans la base de connaissances pour trouver les diagnostics possibles.

1.2 Terminologie

Comme étape vers une terminologie unifiée, le "Technical Committee of International Federation of Automatic Control" (IFAC) SAFEPROCESS a suggéré des définitions préliminaires dans le domaine du diagnostic de défaut [2].

– **Analyse structurelle :**

Analyse des propriétés structurales des modèles, c'est-à-dire des propriétés qui sont indépendantes des valeurs réelles du paramètre.

– **Défaillance :**

Une interruption permanente de la capacité du système à remplir une fonction requise dans des conditions d'opérations spécifiées.

– **Défaut :**

Un écart non permis d'au moins une propriété structurale ou d'un paramètre caractéristique du système par rapport au comportement nominal (usuel ou acceptable).

– **Détection de défaut :**

La détermination de la présence de défauts et de l'instant de leurs occurrences.

– **Isolation de défaut :**

La détermination du type, de la localisation et de l'instant d'occurrence d'un défaut.

– **Identification :**

La détermination de la taille et du comportement temporel d'un défaut.

– **Diagnostic :**

La détermination du type, de la taille, de la localisation et de l'instant d'occurrence d'un défaut ; il suit la détection de défauts et inclut l'isolation et l'identification.

– **Effet de défaillance :**

La conséquence d'un mode de défaillance sur l'opération, la fonction, ou le statut d'une variable.

– **Modèle qualitatif :**

Un modèle de système décrivant le comportement avec des relations entre des variables et des paramètres du système en termes heuristiques tels que des causalités ou des règles.

– **Modèle quantitatif :**

Un modèle de système décrivant le comportement avec des relations entre des variables et des paramètres du système en termes analytiques tels que des équations différentielles ou aux différences.

– Modélisation du défaut :

Détermination d'un modèle mathématique pour décrire un effet spécifique du défaut.

– Reconfiguration :

Changement de la structure et des paramètres du contrôleur. L'objectif original de commande est atteint bien que l'exécution puisse être dégradée.

– Redondance analytique :

Détermination d'une variable par la mesure ou par l'utilisation d'un modèle mathématique du processus considéré.

1.3 Méthodes de diagnostic

Le diagnostic est un thème de recherche fédérant différentes communautés scientifiques (Automatique, Informatique, Productique...), aujourd'hui au cœur des préoccupations industrielles. Le diagnostic a pour but d'établir un lien entre un symptôme observé, la défaillance qui est survenue et ses causes.

Au sein de la communauté automatique du continu, le diagnostic se retrouve sous l'appellation FDI « Fault detection and Isolation », regroupant à la fois la détection d'une déviation de comportement qui donne lieu à la génération d'un symptôme (fonction détection) et l'isolation de la défaillance qui mène à la localisation de l'élément responsable de cette défaillance (fonction diagnostic). Pour la communauté automatique des systèmes à événements discrets, à laquelle nous appartenons, le diagnostic se différencie bien de la détection de défaillance qui caractérise le fonctionnement du système comme normal ou anormal.

Les activités de recherche que nous présentons ici, couvrent ces deux aspects :

détection et diagnostic.

De nombreuses méthodes sont à la base des travaux en diagnostic. Sans vouloir être exhaustif mais de manière à mieux les situer nous pouvons les scinder en trois grandes familles en fonction du type de connaissance a priori sur le système [3] :

1. Les approches à base de modèles, qui reposent sur des modèles quantitatifs basés sur les principes physiques fondamentaux ou qualitatifs basés sur la structure du système et les liens entre composants.

Ces méthodes utilisent un modèle décrit par des relations mathématiques représentant les différentes relations physiques du procédé. Généralement, ces relations physiques découlent de l'application de lois fondamentales de divers domaines (physique, chimie, électricité, thermodynamique, mécanique, etc.). Ainsi, il est possible de créer une modélisation du système qui, en lui appliquant les entrées U similaires au système réel (lois de commande, paramètres du procédé, etc.), fournit une réponse estimée du système \hat{Y} . Il est alors possible de calculer l'écart entre la réponse réelle du système (Y) et sa réponse estimée (\hat{Y}). Cet écart est usuellement appelé résidu (R).

En d'autres termes, on peut dire que les résidus sont les écarts entre les observations du système et le modèle mathématique. L'objectif de ce type d'approche est de réussir à faire la distinction entre les résidus causés par des fautes (causes assignables) et les résidus causés par les autres sources de variation précédemment citées (causes aléatoires).

Les résidus sont relativement élevés lorsqu'une faute est présente dans le procédé, et sont plutôt faibles en l'absence de faute. Dans ce cas, la présence de faute est détectée en appliquant des seuils adéquats sur les résidus.

Il existe plusieurs approches de génération de résidus, cependant trois sont vraiment essentielles, il s'agit de :

-Estimation de paramètres : Les résidus sont la différence entre les paramètres nominaux du modèle et les paramètres estimés du modèle.

-Observateurs : Les méthodes à base d'observateurs reconstruisent une estimation de la sortie à partir de toutes ou parties des sorties réelles du système. Les résidus sont alors classiquement la différence entre les sorties mesurées et les sorties estimées .

-Equations de parité : Cette méthode consiste à vérifier l'exactitude des équations mathématiques du modèle en se basant sur les sorties du procédé .

Lorsque le modèle mathématique du système est disponible, ces méthodes à base de modèles analytiques sont très performantes. Elles sont généralement intitulées FDI (Fault Detection and Isolation). En effet, alors que pour la notion de détection de fautes toutes les communautés scientifiques partagent la même définition, pour ce qui est du diagnostic beaucoup de divergences apparaissent. Il semble donc important de définir ici ce qui est entendu par isolation de faute.

L'isolation de faute est la détermination du lieu exact de la faute afin de déterminer quel(s) composant(s) du système est/sont défectueux. L'isolation de faute fournit plus d'informations que la phase d'identification de variables, mais moins que la phase de diagnostic toute entière puisque celle-ci comprend également les notions d'emplacement, d'amplitude et de durée de la faute.

Comme nous l'avons déjà signalé, l'approche à base de modèles analytiques donne des résultats supérieurs aux autres méthodes (connaissances ou données). Mais, ceci n'est vrai que lorsque le modèle est bien construit. Or, la construction du modèle pour des systèmes complexes et/ou de grandes envergures, devient presque impossible. De plus, même si l'on arrive à bâtir un modèle, il n'est que rarement assez détaillé et précis pour permettre d'obtenir des résultats satisfaisants.

2. Les approches à base de connaissance, qui s'appuient sur les connaissances et les raisonnements experts, Dans le cas où un modèle analytique du procédé n'est pas disponible, une solution est l'exploitation de la connaissance humaine disponible sur le procédé. Il existe alors des méthodes exploitant les connaissances qualitatives que détiennent des experts sur le procédé étudié. On peut notamment citer quelques techniques telles que les systèmes experts [4], l'AMDE (Analyse des Modes de Défaillance et de leurs Effets) [5], l'AMDEC (Analyse des Modes de Défaillance, de leurs Effets et de leurs Criticités) [5], ainsi que les arbres de défaillances [6].

Les systèmes experts sont des techniques d'intelligence artificielle, basés sur les connaissances, permettant d'imiter le raisonnement humain pour la résolution d'un problème. Un système expert bien conçu est capable de représenter l'expertise humaine existante, prendre en compte des bases de données existantes, d'acquérir de nouvelles connaissances, d'effectuer de l'inférence logique, de donner des suggestions, et finalement de prendre des décisions basées sur un raisonnement.

L'avantage principal dans l'utilisation d'un système expert est que l'expert humain n'a plus besoin d'être physiquement présent, puisqu'il est là virtuellement par le biais du système de connaissance. Mais, l'élaboration de la base de connaissance pour des systèmes de grandes tailles est une tâche très ardue, ce qui dans la pratique limite l'application de cette technique à des systèmes avec un nombre d'entrées-sorties restreint.

Cependant, certains auteurs affirment que les systèmes experts représentent une approche devant se développer fortement dans le futur.

L'AMDE [5] est une technique issue de la communauté de la sûreté de fonctionnement.

Elle permet une analyse systématique et très complète, composant par composant, de tous les modes possibles de défaillance et précise leurs effets sur le système global. L'AMDE consiste à établir sous forme de tableau l'ensemble des différentes défaillances de chaque composant du système, et d'en analyser les conséquences (effets) directes sur le système et son entourage (notamment l'opérateur).

Il est possible de renforcer l'AMDE par une étude de la criticité, obtenant ainsi l'AMDEC [5]. L'étude de criticité détermine quels sont les modes de défaillances les plus critiques en prenant en compte les notions de gravité des différents modes couplées à des notions de probabilité (fréquence d'apparition).

Une fois l'AMDEC réalisée, on l'utilise afin de diagnostiquer des situations hors contrôle du procédé. Ainsi, en partant des effets observés, on peut remonter rapidement vers la cause de ces effets grâce au tableau réalisé.

Cette méthode est très puissante car dès l'apparition d'effets indésirables sur le procédé elle permet de rapidement remonter vers les causes ayant engendrées ces effets. Mais, plusieurs inconvénients rendent cette démarche non réalisable sur des systèmes trop complexes. En effet, l'établissement d'un tableau AMDEC pour des systèmes de grandes échelles demande un investissement beaucoup trop lourd afin de référencer toutes les défaillances possibles ainsi que les relations causes-effets de celles-ci. De plus, cette méthode ne permet pas la prise en compte de combinaisons de plusieurs défaillances.

Un autre outil issu de la sûreté de fonctionnement sont les arbres de défaillances [90].

Un arbre de défaillance se présente sous la forme d'un diagramme logique ou un événement indésirable (une faute précise) est placé au sommet. Ensuite, les causes immédiates de cette faute sont reliées grâce à des connecteurs logiques "ET" et "OU", et ainsi de suite jusqu'à atteindre, à la base, un ensemble d'événements élémentaires. Cet outil présente les mêmes avantages et les mêmes inconvénients que l'AMDEC.

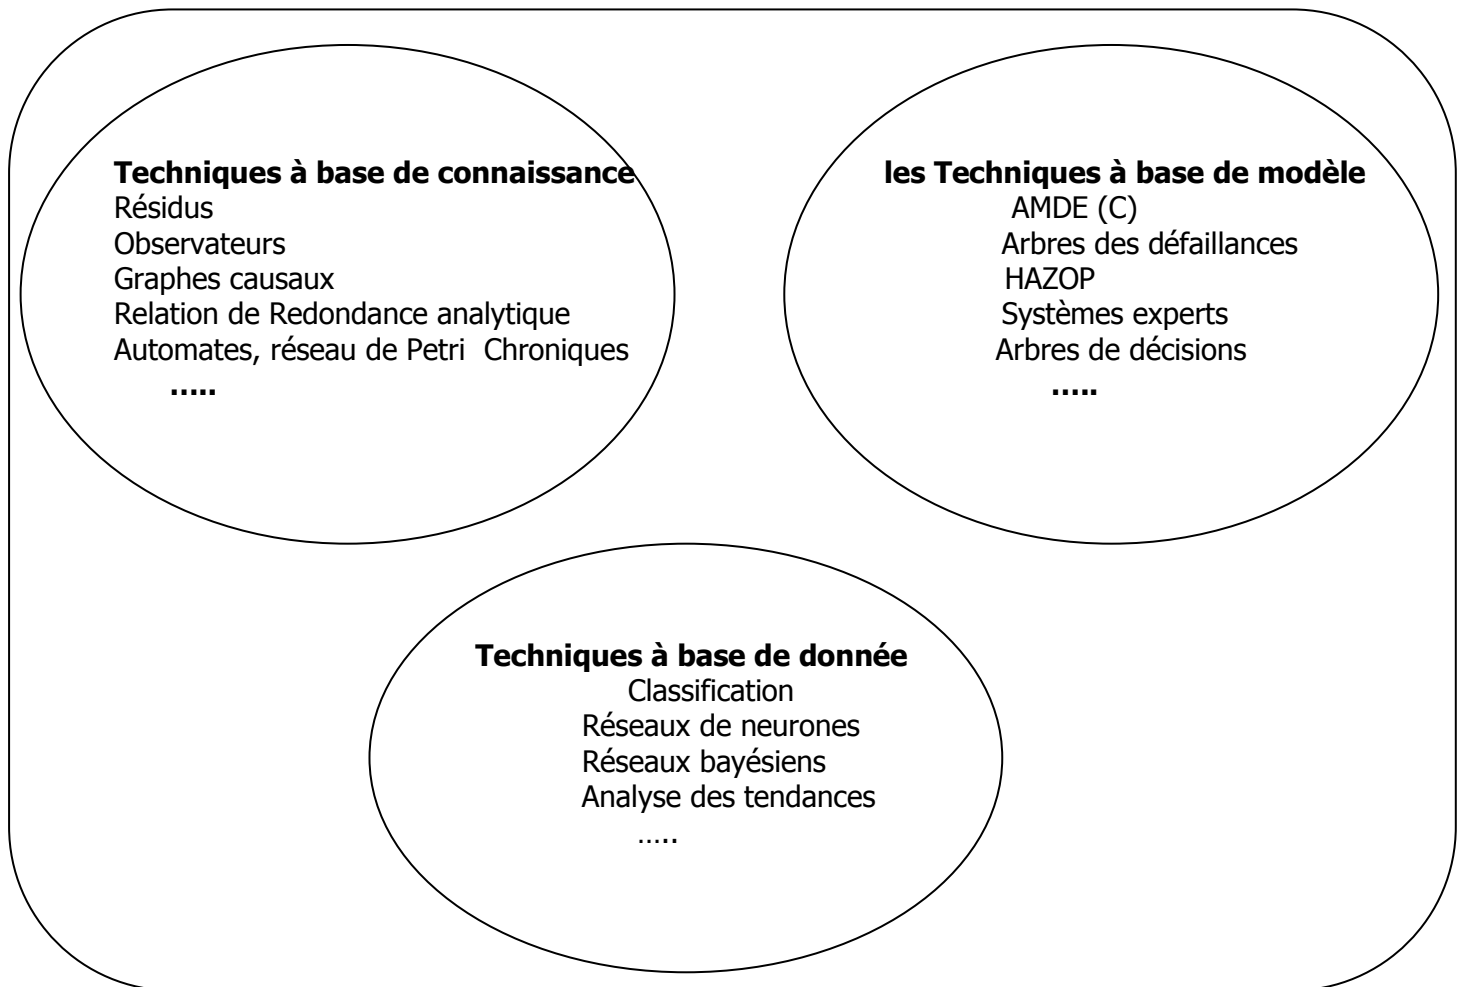
3. Les approches à base de données, qui à partir de données historiques réalisent une extraction des caractéristiques. En terme de méthodes de diagnostic, nos travaux se rangent dans les techniques à base de données. De nos jours, les procédés sont de plus en plus automatisés, permettant ainsi la récupération d'une quantité non négligeable de données. Il est donc naturel de surveiller le procédé avec des méthodes se basant sur ces données. En effet, la masse de données à traiter est tellement importante qu'un opérateur ne peut pas directement suivre chaque variable du procédé. Nous faisons donc appel à des techniques basées sur les données pour représenter en quelques valeurs judicieuses, l'information exprimée par toutes les variables du procédé. Certaines de ces techniques permettent la détection alors que d'autres s'intéressent au diagnostic. Parmi, ces méthodes, nous pouvons notamment citer les approches par cartes de contrôle, par analyse en composantes principales et par projection dans les structures latentes pour la phase de détection, alors que pour la phase de diagnostic, nous retrouvons principalement des outils de classification tels que l'analyse discriminante ou les réseaux de neurones [6].

Du point de vue du diagnostic, nous nous intéressons aux différentes techniques de classification [7]. En effet, une faute apparue dans un procédé couvre un lieu de l'espace décrit par les variables du procédé. Une autre faute couvre un autre lieu de cet espace ou bien le même lieu mais sous une autre forme ou une autre dispersion [8].

Le diagnostic peut se voir comme la tâche de classer un nouvel individu déclaré hors contrôle dans une des classes du procédé. Un système de classification évolué doit être capable de traiter plusieurs notions:

Parmi les classifieurs les plus connus, on peut citer : l'analyse discriminante [9], les k plus proches voisins [10], les arbres de décisions [11], les machines à vecteurs supports [12], les réseaux de neurones [13] ainsi que les réseaux bayésiens [14].

Figure 1.1 : méthodes et outils en diagnostic



1.4 Conclusion :

Ce chapitre introductif n'est qu'une revue non exhaustive des méthodes de détection et de la localisation de défauts. Nous avons expliqué, de façon sommaire, les outils dont nous disposons ainsi que les étapes méthodologiques (détection et localisation) à suivre pour mener à terme une démarche de diagnostic.

Cependant, le diagnostic des systèmes à base de données par les réseaux de neurones et les réseaux bayésiens nécessite une connaissance approfondie des éléments de bases constituant ces approches .

Dans le chapitre suivant, nous allons présenter les concepts de base de la modélisation et diagnostic des systèmes en utilisant des méthodes graphiques telles que les réseaux de neurones et les réseaux bayésiens.

2

les méthodes graphiques utilisées

Réseaux de neurones
Réseaux bayésiens

2.1 Réseaux de neurones

2.1.1 Introduction

Modélisation pour la détection d'anomalies

Un processus industriel moderne est souvent très instrumenté ; il fournit en permanence les résultats de nombreuses mesures, apportant à son pilote une grande quantité d'informations, quasiment en temps réel, qui sont souvent difficiles à exploiter : c'est notamment le cas lorsqu'une anomalie de fonctionnement se traduit par de faibles écarts simultanés sur plusieurs mesures, voire par des évolutions normales pour chaque mesure prise séparément, mais dont l'apparition simultanée traduit cette anomalie.

Pour automatiser la détection de telles situations, plusieurs approches peuvent être envisagées :

- l'utilisation de systèmes experts (éventuellement flous) : une telle approche nécessite une formalisation (éventuellement incertaine) de l'expertise ; elle est difficilement applicable lorsqu'un grand nombre de grandeurs doivent être prises en considération ;

- **l'utilisation de classifieurs** (éventuellement neuronaux) capables de discriminer les situations normales de situations anormales ; la limitation fondamentale de cette approche réside dans le fait que ces méthodes statistiques exigent des bases d'exemples ; or, s'il est très facile de trouver de nombreux exemples de situations normales, il est souvent - heureusement - très difficile de disposer, en nombre équivalent, d'exemples des différentes situations anormales susceptibles de se présenter (on ne les connaît d'ailleurs pas forcément) ;

- l'utilisation d'un modèle précis du comportement normal du processus, les anomalies étant détectées en comparant les prédictions du modèle et les mesures effectuées sur le processus ; cette méthode nécessite évidemment un modèle précis en temps réel, mais elle évite de collecter des exemples de fonctionnement anormal. L'ensemble d'apprentissage doit couvrir l'ensemble du domaine de comportement normal du processus.

La similitude des systèmes industriels complexes structurés en réseaux tels que les réseaux électriques, les réseaux de télécommunications,, les méthodes graphiques telles que les réseaux de neurones ont prouvé leurs puissances dans le domaine de diagnostic et la détection des défaillances.




Figure 2.1 Similitude entre réseau électrique et réseau bayésien

Définition :

Qu'est-ce qu'un neurone artificiel ? Qu'est-ce qu'un réseau de neurones ?

Ce que l'on désigne habituellement par "réseau de neurones" (neural network), ou réseau neuromimétique est un réseau de neurones artificiels basé sur un modèle simplifié de neurone. Ce modèle permet certaines fonctions 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'activation membranaire ou la structuration prénatale des neurones, par conséquent les réseaux de neurones actuels sont loin d'avoir les possibilités du cerveau).

Voici comment sont généralement modélisés les neurones (de manière logicielle, ou matérielle par des automates) [13] :

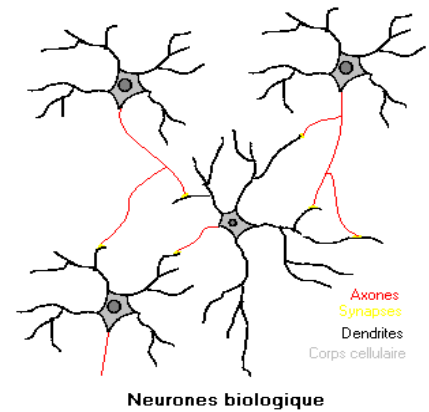
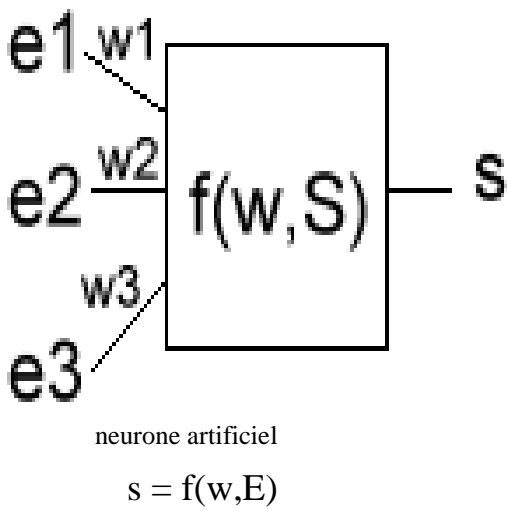


Figure 2.2 représentation d'un neurone formel

$s = f(w_1 * e_1 + w_2 * e_2 + w_3 * e_3)$, avec f fonction d'activation
 +

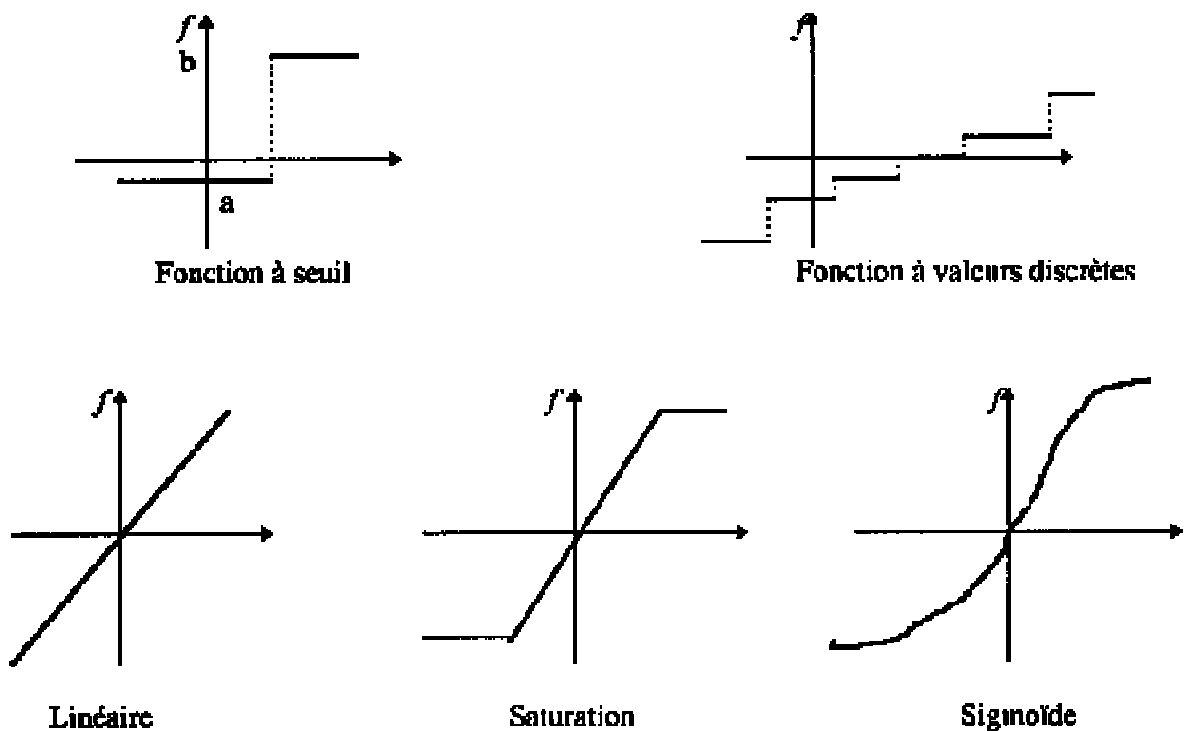


Figure2. 3 :les différentes fonctions d'activation

Un réseau de neurones reprend pour schéma le fonctionnement des cellules nerveuses du cerveau. Décrivons simplement ces genres de cellules. Ces cellules se nomment des neurones et sont constituées de quatre éléments distincts. La partie centrale contenant le noyau, les dendrites, un(e) axone, des synapses. Les synapses servent à l'interconnexion entre les différents neurones. Les dendrites reçoivent les informations d'autres neurones tandis que l'axone (qui est nécessairement seul) envoie l'information après traitement par la cellule nerveuse à d'autres neurones. Sans entrer dans le détail, il faut aussi savoir qu'une synapse (qui est le point de passage obligé de l'influx nerveux) peut être inhibitrice ou excitatrice. C'est à dire qu'elle peut amoindrir ou non un message de l'influx nerveux. C'est l'interaction entre toutes les cellules et leurs façon d'être interconnecté qui permet de traiter une information.

Un réseau de neurones peut donc être représenté par les poids synaptiques (w) des différents neurones. Ces poids varient au cours du temps, en fonction des entrées présentées (E). Le grand problème étant de savoir comment modifier ces poids (c'est à dire trouver une loi équivalente à $dw/dt=g(E,w)$)

Les premiers réseaux de neurones formels ont été conçus par W. McCulloch et W. Pitts en 1943.




Figure 2.4 représentation du neurone de Mc Culloch et Pitts

Le premier modèle mathématique du neurone a été donné par McCulloch et Pitts en 1943

- $I_i \in \mathbb{R}$: entrées du neurones ;
- $W_i \in \mathbb{R}$: poids correspondant à chacune des entrées ;
- θ : seuil ;
- $O \in \mathbb{R}$: sortie du neurone ;
- $f(x)$: détermination de O avec $\forall x, x > \theta, f(x) = 1$ et $f(x) = 0$ sinon.

Le neurone formel de McCulloch et Pitts a alors pour expression :

$$O = f\left(\sum_i W_i I_i\right)$$

En mathématiques un neurone peut se représenter par une fonction à plusieurs variables. Les valeurs en entrée peuvent alors correspondre aux excitations des synapses du neurone biologique. L'unique valeur calculée par la fonction (donc le résultat) correspondra à l'excitation de l'axone. La formule mathématique modélisera la réponse du neurone biologique. Un réseau de neurones consiste à mettre en relation plusieurs de ces neurones formels comme l'illustre le schéma ci-dessous (tiré du guide utilisateur de la toolbox sur les réseaux de neurones de MatLab) la formule mathématique associée étant donnée en bas de la figure avec une notation matricielle :

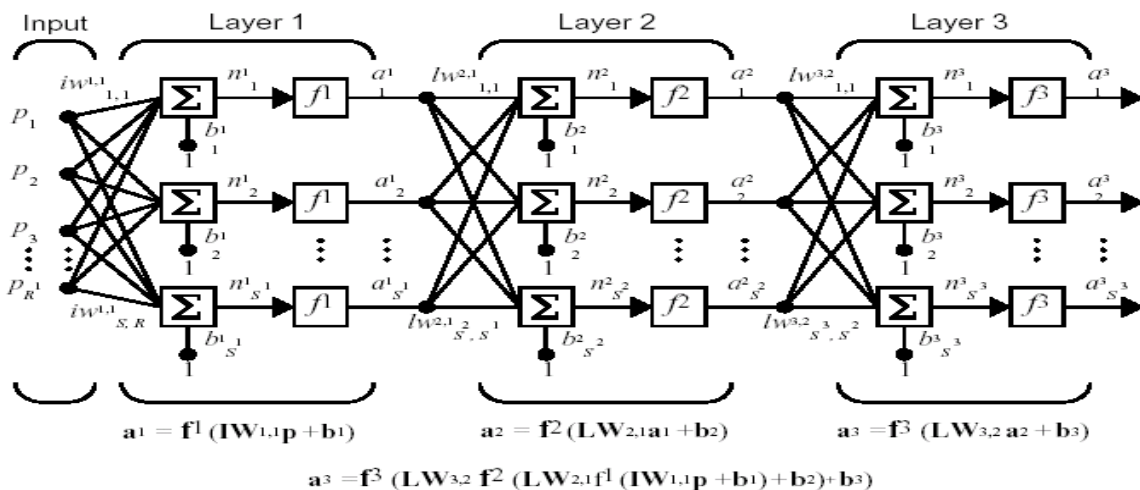


Figure 2.5 : Représentation d'un réseau de neurones en matlab

2.1.2. Terminologie :

Apprentissage, mémoire et oubli

Une caractéristique des réseaux de neurones est leur capacité à apprendre (par exemple à reconnaître une lettre, un son...). Mais cette connaissance n'est pas acquise dès le départ. La plupart des réseaux de neurones apprennent par l'exemple (de la même manière qu'un enfant apprend à reconnaître un chien à partir d'exemples de chiens qu'il a vu). Ils ont donc une capacité à classer, généraliser, à mémoriser et aussi à oublier. Un réseau de neurones reconnaîtra d'autant plus facilement un objet qu'il l'aura " vu " souvent.

Connectivité : La connectivité des réseaux, c'est à dire la manière dont les neurones sont connectés, peut être totale (tous les neurones sont connectés entre eux) ou par couche (les neurones d'une couche ne sont connectés qu'aux couches suivantes - il existe des réseaux monocouches ou multicouches (multi layer networks)).

Apprentissage supervisé / non supervisé

Les réseaux de neurones se divisent en deux principales classes, les réseaux à apprentissage supervisés (supervised learning) et les réseaux à apprentissage non supervisés (unsupervised learning).

Pour les réseaux à apprentissage supervisés (Perceptron, Adaline, etc.), on présente au réseau des entrées, et au même temps les sorties que l'on désirerait pour cette entrée. Par exemple on lui présente en entrée une lettre " a " manuscrite et en sortie un code correspondant à la lettre " a ". Le réseau doit alors se reconfigurer, c'est-à-dire calculer ses poids afin que la sortie qu'il donne corresponde bien à la sortie désirée.

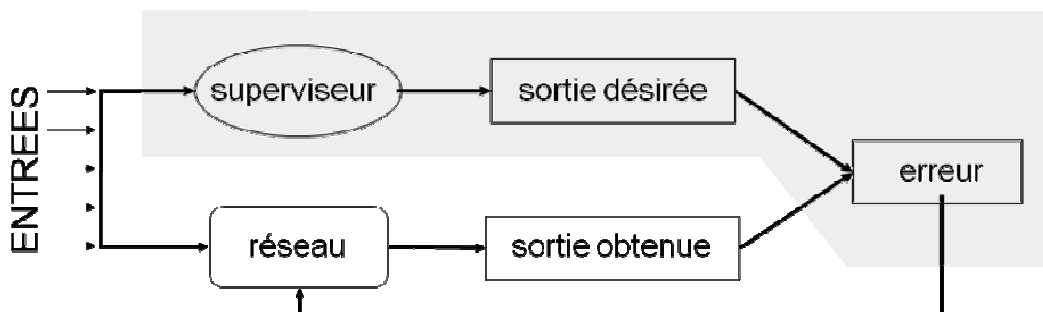


Figure 2.6 apprentissage supervisé

La rétropropagation (backpropagation) est une méthode de calcul des poids pour un réseau à apprentissage supervisé qui consiste à minimiser l'erreur quadratique de sortie (somme des carrés de l'erreur de chaque composante entre la sortie réelle et la sortie désirée).

Pour les réseaux à apprentissage non supervisé (Hopfield, Kohonen, etc.), on présente une entrée au réseau et on le laisse évoluer librement jusqu'à ce qu'il se stabilise. Il existe aussi des réseaux à apprentissage dit semi-supervisés (renforcement learning) qui ne tiennent compte que d'une évaluation partielle ou qualitative des sorties.

Calcul des poids synaptique:

D'autres méthodes de modification des poids sont plus "locales", chaque neurone modifie ses poids en fonction de l'activation ou non des neurones proches. C'est le cas des réseaux suivant la règle de Hebb (Hebbian rule) ou les réseaux de Kohonen.




Figure 2.7 apprentissage non supervisé

Sur apprentissage :

Il arrive qu'à faire apprendre un réseau de neurones toujours sur le même échantillon, celui-ci devienne inapte à reconnaître autre chose que les éléments présents dans l'échantillon. On parle alors de sur apprentissage : le réseau est devenu trop spécialisé et ne généralise plus correctement.

Les règles d'apprentissage :

L'apprentissage consiste à modifier le poids des connections entre les neurones.




Figure 2.8 Représentation de poids des connections

Il existe plusieurs règles de modification :

- Loi de Hebb : $\Delta w_{ij} = R a_i a_j$ Si deux unités connectées sont actives simultanément, le poids de leur connexion est augmenté ou diminué. R est une constante positive qui représente la force d'apprentissage (learning rate).
- Règle de Widrow-Hoff (delta rule) : $\Delta w_{ij} = R(d_i - a_i)a_j$
 a_i activation produite par le réseau
 d_i réponse désirée par l'expert humain

Par exemple si la sortie est inférieure à la réponse désirée, il va falloir augmenter le poids de la connexion à condition bien sûr que l'unité j soit excitatrice (égale à 1). On est dans l'hypothèse d'unités booléennes $\{0,1\}$.

- Règle de Grossberg : $\Delta w_{ij} = R(a_j - w_{ij})a_i$

On augmente les poids qui entrent sur l'unité gagnante a_i s'ils sont trop faibles, pour les rapprocher du vecteur d'entrée a_j . C'est la règle d'apprentissage utilisée dans les cartes auto organisatrices de Kohonen

2.1.3 Quelques réseaux célèbres

Le Perceptron

C'est un des premiers réseaux de neurones, conçu en 1958 par Rosenblatt. Il est linéaire et monocouche. Il est inspiré du système visuel. La première couche (d'entrée) représente la rétine. Les neurones de la couche suivante sont les cellules d'association, et la couche finale les cellules de décision.

Les sorties des neurones ne peuvent prendre que deux états (-1 et 1 ou 0 et 1). Seuls les poids des liaisons entre la couche d'association et la couche finale peuvent être modifiés.

La règle de modification des poids utilisée est la règle de Widrow-Hoff : si la sortie (celle d'une cellule de décision donc) est égale à la sortie désirée, le poids de la connexion entre ce neurone et le neurone d'association qui lui est connecté n'est pas modifié. Dans le cas contraire le poids est modifié en fonction de l'entrée :

$w_{ij} \leftarrow w_{ij} + k(d_i - s_i)a_j$ avec k : constante positive
 s_i : sortie et d_i : sortie désirée

En 1969, Papert et Minsky (un des pères des systèmes experts) démontrent les limites du perceptron classique, incapable, par exemple de simuler la fonction ou exclusif (xor).

Les perceptrons multicouches (PMC)

Ils sont une amélioration du perceptron comprenant une ou plusieurs couches intermédiaires dites couches cachées. Ils utilisent, pour modifier leurs poids, un algorithme de rétropropagation du gradient, qui est une généralisation de la règle de Widrow-Hoff. Il s'agit toujours de minimiser l'erreur quadratique, ce qui est assez simple quand on utilise une fonction f dérivable (la sigmoïde par exemple). On propage la modification des poids de la couche de sortie jusqu'à la couche d'entrée. Les PMC agissent comme un séparateur non linéaire et peuvent être utilisés pour la classification, le traitement de l'image ou l'aide à la décision.

Les réseaux de Hopfield :

Un réseau de Hopfield réalise une mémoire adressable par son contenu. Il s'agit d'un réseau constitué de neurones de McCulloch et Pitts (à deux états -1 et 1 ou 0 et 1), dont la loi d'apprentissage est la règle de Hebb (1949), qui veut qu'une synapse améliore son activité si et seulement si l'activité de ses deux neurones est corrélée (C'est à dire que le poids w_{ij} d'une connexion entre un neurone i et un neurone j augmente quand les deux neurones sont activés au même temps).

Les réseaux de Kohonen :

Contrairement aux réseaux de Hopfield où les neurones sont modélisés de la façon la plus simple possible, on recherche ici un modèle de neurone plus proche de la réalité.

Ces réseaux sont inspirés des observations biologiques du fonctionnement des systèmes nerveux de perception des mammifères.

Une loi de Hebb modifiée (tenant compte de l'oubli) est utilisée pour l'apprentissage. La connexion est renforcée dans le cas où les neurones reliés ont une activité simultanée, et diminuée dans le cas contraire.

$d w_i / dt = k S e_i - B(S) w_i$ avec $B(S)$ la fonction d'oubli

S : sortie (toujours positive)

Une loi d'interaction latérale (observée biologiquement) est aussi modélisée. Les neurones très proches (physiquement) interagissent positivement (le poids des connexions est augmenté autour quand une synapse est activée), négativement pour les neurones un peu plus loin, et pas du tout pour les neurones éloignés. Ceci crée un "amas" de neurones activés et contribue à spécialiser certains neurones: pour une entrée donnée, une sortie particulière sera activée et pas les autres. On utilise aussi parfois des lois de concurrence entre les neurones (création et destruction de neurones selon certains critères, par exemple la règle du "winner-take-all"). Ceci permet de résoudre certains problèmes, dits NP complets, tels le problème du voyageur de commerce (comment relier n villes par le chemin le plus court). Les réseaux de Kohonen ont des applications dans la classification, le traitement de l'image, aide à la décision et l'optimisation.

2.1.4. Exemples d'applications des réseaux de neurones

Se trouvant à l'intersection de différents domaines (informatique, électronique, science cognitive, neurobiologie et même philosophie), l'étude des réseaux de neurones est une voie prometteuse de l'Intelligence Artificielle I.A., qui a des applications dans de nombreux domaines :

Industrie : contrôle qualité, **diagnostic de panne**, corrélations entre les données fournies par différents capteurs, analyse de signature ou d'écriture manuscrite (Pour plus de détails voir par exemple l'article du n° 678 du magazine Mesures (Octobre 95) intitulé : " Vision Industrielle : les réseaux de neurones font leurs preuves ")

Finance : prévision et modélisation du marché (cours de monnaies...), sélection d'investissements, attribution de crédits.

Télécommunications et informatique : analyse du signal, élimination du bruit, reconnaissance de formes (bruits, images, paroles), compression de données

Environnement : évaluation des risques, analyse chimique, prévisions et modélisation météorologiques, gestion des ressources.

2.2 Les réseaux bayésiens

2.2.1 Introduction :

Un réseau bayésien RB est un système représentant la connaissance et permettant de calculer des probabilités conditionnelles apportant des solutions à différentes sortes de problématiques.

La structure de ce type de réseau est simple : un graphe dans lequel les nœuds représentent des variables aléatoires, et les arcs (le graphe est donc orienté) reliant ces dernières sont rattachées à des probabilités conditionnelles. Notons que le graphe est acyclique : il ne contient pas de boucle. Les arcs représentent des relations entre variables qui sont soit déterministes, soit probabilistes. Ainsi, l'observation d'une ou plusieurs causes n'entraîne pas systématiquement l'effet ou les effets qui en dépendent, mais modifie seulement la probabilité de les observer. L'intérêt particulier des réseaux bayésiens est de tenir compte simultanément de connaissances a priori d'experts (dans le graphe) et de l'expérience contenue dans les données. [14]

Construction d'un réseau bayésien :

Construire un réseau bayésien c'est donc :

- Définir le graphe du modèle.
- Définir les tables de probabilités de chaque variable, conditionnellement à ses causes.

Le graphe est aussi appelé la "structure" du modèle, et les tables de probabilités ses "paramètres".

Généralement, la structure est définie par des experts et les tables de probabilités calculées à partir de données expérimentales. Il est possible d'utiliser des algorithmes tels que K2, le recuit simulé ou encore certains algorithmes génétiques pour construire le réseau. [15]

La figure 2 est une illustration d'un exemple de réseau bayésien.




Figure 2.9 :Exemple de réseau bayésien

Nous pouvons voir sur cet exemple qu'il y existe deux types de nœuds :

- Les nœuds « racine » (N1, N2) : ce sont des nœuds qui n'ont pas de parents. Ils sont associés à des variables aléatoires définies par des observations.
- Les nœuds « enfants » (N3, N4, N5, N6) : ce sont les nœuds qui ont des parents. Ils représentent des hypothèses.

L'utilisation d'un tel réseau nécessite la spécification complète du modèle probabiliste (apprentissage du réseau). En effet, pour tous les nœuds racines il faut définir les tables de probabilités (TP) (Tab 1.1). Leur taille dépend du nombre n d'états de la variable. Nous avons alors besoin de $(n-1)$ probabilités (Car la somme des probabilités doit être égale à 1).

En ce qui concerne les nœuds enfants, il faut définir les tables de probabilités conditionnelles (TPC) (Tab1.2). La taille des TPC dépend du nombre de parents, du nombre d'états de chaque parent et du nombre d'états de la variable considérée. Si nous posons n le nombre d'états du nœud étudié, n_i ($i \in [1, m]$) le nombre de chaque état des parents et m le nombre de parents du nœud considéré, nous avons alors besoin de $(n - 1) \prod_{i=1}^m n_i$ probabilités pour déterminer toutes les combinaisons possibles. Ainsi, la taille des TPC augmente de manière exponentielle avec le nombre de parents.

Ce qui nous motive à choisir, pour un problème donné, la structure du RB présentant le minimum possible de nœuds parents pour chaque nœud. [16]

Tab 2.1 : Exemple

Tableau des Probabilités

Etat 1	Etat 2	...	Etat i
P1	P2	...	Pi

Tab 2.2 : Exemple**Tableau des Probabilités Conditionnelles**

	Etats des nœuds parents			
Etats Des	P11	P12	...	Pi
nœuds	P21	P22	...	Pi+1
étudié
	Pn1	Pn2	...	Pnj

2.2.2 L'inférence bayésienne :

L'inférence bayésienne est basée sur l'utilisation d'énoncés probabilistes, qui dans le cas général sont trouvés par des experts étudiant un système qui leur ait connu. Ces énoncés doivent être clairs et précis afin d'éviter toute confusion dans les relations de dépendance qui en découleront. L'inférence bayésienne est particulièrement utile dans les problèmes d'induction, car se basant sur des cas particuliers et n'a de validité qu'en terme probabiliste. Les méthodes bayésiennes se distinguent des méthodes dites standard par l'application systématique de règles formelles de transformation des probabilités. On cherche à induire sur un système bayésien aussi bien par le haut que par le bas, aussi bien les conséquences que les causes, du graphe de dépendance. Les règles de la logique des probabilités utilisées sont les suivantes :

- La règle d'addition :

$$p(A \cup B|C) = p(A|C) + p(B|C) - p(A \cap B|C)$$

- La règle de multiplication :

$$p(A \cap B) = p(A|B)p(B) = p(B|A)p(A)$$

Le concept de base du traitement Bayésien de l'incertitude dans les réseaux causaux est donc la probabilité conditionnelle. Chaque fois que l'expression de la probabilité $P(A)$ d'un des nœuds est donnée, celle-ci doit être conditionnée par d'autres facteurs[15]

La sémantique de la probabilité conditionnelle est la suivante : « Sachant l'événement B, la probabilité de l'événement A est égale à x ». La notation de cette expression est :

$$P(A/B) = x.$$

Une règle fondamentale des probabilités dite « règle du produit » fournit :

$$P(A/B) P(B) = P(A, B).$$

Avec $P(A, B)$ la probabilité de l'événement $A \wedge B$. Dans cette formule, nous cherchons à déterminer le lien entre la plausibilité du produit logique AB et les plausibilités séparées de A et B . On s'intéresse pour cela à $P(A, B/C)$.

Ainsi, décider que AB est vrai peut être décomposé en décisions élémentaires sur A et B séparément. On peut ainsi décider que B est vrai. Puis, après avoir accepté que l'événement B soit réalisé, décider que A est vraie.

Ou bien d'une manière équivalente, décider que A est vraie. Puis, après avoir accepté que l'événement A soit réalisé, décider que B est vraie. [17]

En tenant compte de la remarque relative au conditionnement de $P(A)$ par d'autres facteurs, les probabilités doivent être conditionnées par le fait C ; ainsi nous obtenons la formule de la « règle du produit » suivante :

$$P(A/B, C) P(B/C) = P(A, B/C)$$

D'après la relation précédente nous obtenons :

$$P(A/B, C).P(B/C) = P(B/A, C).P(A/C)$$

Ceci mène au théorème de Bayes :

$$P(B/A, C) = \frac{P(A/B, C) P(B/C)}{P(A/C)}$$

$P(B/C)$ est appelée probabilité «a priori ».

$P(A/B, C)$ est appelée probabilité « directe » ou la « vraisemblance ».

$P(B/A, C)$ est la probabilité « a posteriori ». $P(A/C)$ est le coefficient de normalisation.

Ainsi pour déterminer la probabilité a posteriori nous avons besoin non seulement de $P(A/B, C)$ mais aussi des probabilités a priori $P(B/C)$ et $P(A/C)$.

Cette équation décrit un mécanisme fondamental d'inférence à partir de données expérimentales[18].

Si nous considérons maintenant un nœud parent N_i qui a pour unique enfant le nœud N_j , il faut alors définir pour chaque état de la variable N_j , la probabilité a priori d'avoir un état de N_j connaissant l'état de N_i . D'autre part il faut préciser la vraisemblance de certaines variables. Par exemple, celles qui n'ont pas de lien avec un parent. C'est l'instanciation du réseau [19].

2.2.3 Circulation de l'information :

Nous allons à présent étudier de plus près comment l'information circule au sein d'un graphe causal. Pour cela, nous allons utiliser un exemple, extrêmement classique dans la littérature sur les réseaux bayésiens :

Ce matin-là, alors que le temps est clair et sec, M. Holmes sort de sa maison. Il s'aperçoit que la pelouse de son jardin est humide. Il se demande alors s'il a plu pendant la nuit, ou s'il a simplement oublié de débrancher son arroseur automatique. Il jette alors un coup d'œil à la pelouse de son voisin, M. Watson, et s'aperçoit qu'elle est également humide. Il en déduit alors qu'il a probablement plu, et il décide de partir au travail sans vérifier son arroseur automatique.

La représentation graphique du modèle causal utilisé par M. Holmes est la suivante :




Figure 2.10 La représentation graphique du modèle causal utilisé par M. Holmes

Dans ce graphe le nœud A représente l'événement que M. Holmes a oublié de débrancher son arroseur automatique, le nœud P représente l'événement qu'il a plu cette nuit, le nœud J représente l'événement que l'herbe de son jardin est humide, le nœud W représente l'événement que l'herbe du jardin de M. Watson est humide.

Comment l'information peut circuler dans ce graphe ? Évidemment l'information peut circuler depuis les causes vers les effets, d'ailleurs on remarque M. Holmes a décidé d'aller au bureau sans vérifier son arroseur après avoir su que l'herbe du jardin de M. Watson est humide aussi. C'est-à-dire la connaissance de W peut modifier la connaissance de P, ou autrement dit l'information peut circuler dans la direction inverse.

Les chemins de circulation d'information :

Dans l'exemple ci-dessus, nous avons vu qu'une information certaine se propage dans un graphe en modifiant les croyances que nous avons des autres faits.

Nous allons étudier quels chemins cette information peut prendre à l'intérieur d'un graphe. Nous allons considérer les trois cas suivants, qui décrivent l'ensemble des situations possibles faisant intervenir trois événements.




Figure 2.11 Circulation des informations.

D-séparation :

On dira que A et C sont d-séparés par B si pour tous les chemins entre A et C, l'une au moins des deux conditions suivantes est vérifiée :

- Le chemin converge en un nœud W, tel que $W \perp B$, et W n'est pas une cause directe de B.
- Le chemin passe par B, et est soit divergent, soit en série au nœud B.

On a prouvé que si A et C sont d-séparés par B, alors A et C sont indépendants Conditionnellement à B. [17].

Ce résultat est très important, car il permet de limiter les calculs de probabilités grâce à des propriétés du graphe. Supposons que A et C soient d-séparés par B, et que B soit connu.

Supposons, par ailleurs, que je vienne de calculer $p(A|B)$. Si une nouvelle information sur C est alors connue, ce résultat me permet de conserver mon calcul de $p(A|B)$ comme valeur de $p(A|B,C)$.

Combiné avec un autre résultat, qui établit qu'un nœud est d-séparé du reste du graphe par l'ensemble constitué de ses parents, de ses enfants, et des autres parents de ses enfants, cette propriété permet de rendre locaux tous les calculs de probabilités dans un graphe causal. [19]

2.2. 4 Mise en œuvre des réseaux bayésiens :

Nous abordons maintenant la mise en œuvre des réseaux bayésiens dans des applications pratiques. Dans cette partie, nous présentons essentiellement des aspects méthodologiques, en essayant de répondre aux trois questions : pourquoi, ou (dans quelles applications) et comment utiliser des réseaux bayésiens ?

Pourquoi utiliser des réseaux bayésiens ?

Selon le type d'application, l'utilisation pratique d'un réseau bayésien peut être envisager au même titre que d'autres modèles : réseaux neuronaux, système expert, arbre de décision, modèles d'analyse de données, arbre défaillances, modèles logiques, etc.

Naturellement, le choix de la méthode fait intervenir différents critères, comme la facilité, le coût et le délai de mise en œuvre d'une solution. En dehors de toute considération théorique, les aspects suivants des réseaux bayésiens les rendent, dans de nombreux cas, préférables à d'autres modèles

➤ Acquisition des connaissances :

La possibilité de rassembler et de fusionner des connaissances de diverse nature dans un même modèle : retour d'expérience (données historiques ou empiriques), expertise (exprimée sous forme de règles logiques, d'équations, de statistiques ou probabilités subjectives), observations.

Dans le monde industriel par exemple, chacune de ces sources d'information, quoique présente, est souvent insuffisante individuellement pour fournir une représentation précise et réaliste du système analysé.

➤ Représentation des connaissances :

La représentation graphique d'un réseau bayésien est explicite, intuitive et compréhensible par un non spécialiste, ce qui facilite à la fois la validation du modèle, ses évolutions éventuelles et surtout son utilisation. Typiquement, un décideur est beaucoup plus enclin à s'appuyer sur un modèle dont il comprend le fonctionnement qu'à faire confiance à « une boîte noire ».

➤ Utilisation des connaissances :

Un réseau bayésien est polyvalent : on peut se servir du même modèle pour évaluer, prévoir, diagnostiquer, ou optimiser des décisions, ce qui contribue à « rentabiliser » l'effort de construction du réseau bayésien.

➤ Qualité de l'effort en matière de logiciels :

Il existe aujourd'hui de nombreux logiciels pour saisir et traiter des réseaux bayésiens. Ces outils présentent des fonctionnalités plus ou moins évoluées : apprentissage des probabilités, apprentissage de la structure du réseau bayésien, possibilité d'intégrer des variables continues, des variables d'utilité et de décision, etc.

Où utiliser les réseaux bayésiens

Les propriétés étudiées ci-dessus nous permettent de définir les caractéristiques générales d'une application ou il est intéressant d'utiliser les réseaux bayésiens en les préférant à une autre technique. Les types d'applications relevant de cette approche sont listés plus loin.

❖ Caractéristiques générales :

➤ Une connaissance explicite ou implicite du domaine :

Dans la mesure où un réseau bayésien peut être construit soit à partir de données, par apprentissage, soit à partir d'une modélisation explicite du domaine, il suffit qu'une des formes de connaissances ou une combinaison des deux soit disponible pour pouvoir envisager d'utiliser cette technique dans une application.

En partant d'une connaissance explicite même incomplète, et en utilisant la capacité d'apprentissage incrémental des réseaux bayésiens, on peut développer une approche de modélisation en ligne, c'est-à-dire sans archiver les exemples mêmes. En effet, un réseau bayésien n'est rien d'autre que la représentation d'une distribution de probabilité. Si la structure de cette distribution est imposée, on peut directement calculer l'impact de chaque nouvel exemple sur les paramètres de cette distribution.

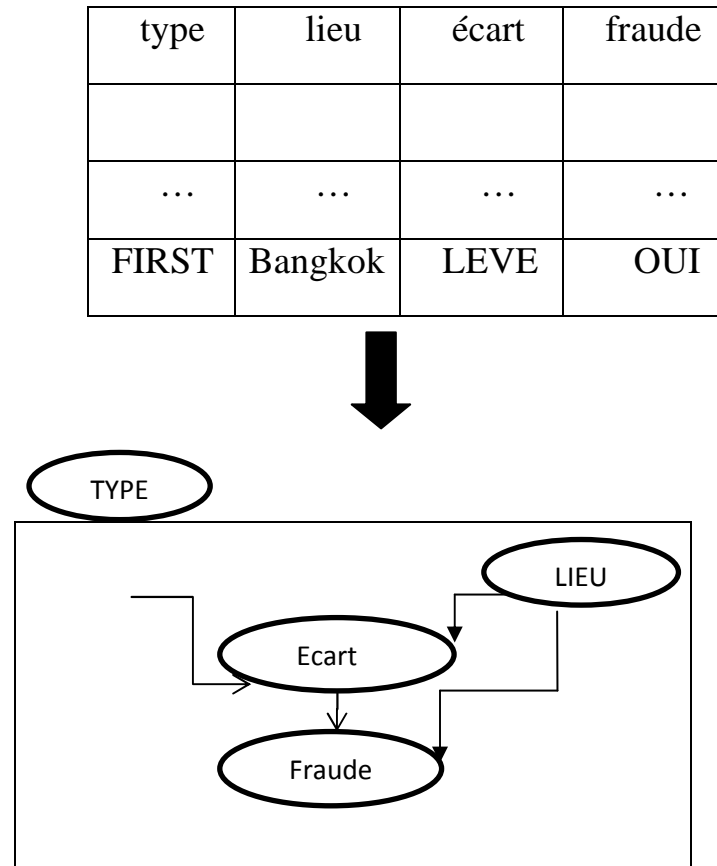


Figure 2.12 Modélisation

la détection de fraude.

en ligne pour

Ce type d'approche peut être envisagé dans des applications de prévision de comportements d'achat ou de détection de fraudes, par exemple dans le cas du commerce électronique. Le schéma ci-dessus montre un exemple très simple d'une telle application :

- On cherche à modéliser la distribution de probabilité liant le type d'une carte de crédit, le lieu de la transaction, l'écart du montant de la transaction par rapport à la moyenne, et l'existence d'une fraude.
- La structure de cette distribution est supposée fixée
- . Le flux des transactions enregistrées modifie les tables de probabilités conditionnelles

Cet exemple suppose cependant une historisation partielle des informations, puisque le retour sur la fraude effective ne peut intervenir immédiatement.

➤ Une utilisation complexe ou évolutive :

En termes d'utilisation du modèle, l'avantage essentiel des réseaux bayésiens par rapport aux autres techniques est de permettre une formalisation complète d'un domaine de connaissance sous forme de graphe causal. Ce graphe peut être utilisé ensuite pour effectuer des raisonnements, en formulant des requêtes relativement complexes.

Cependant cette technologie reste aujourd'hui relativement difficile à maîtriser pour des problèmes de grande taille. Il nous semble donc qu'elle ne doit être considérée que là où les techniques plus simples ne peuvent pas donner satisfaction.

Par exemple, dans un problème de prévision ou de classification spécifié de façon claire, et pour lequel la connaissance des règles sous-jacentes n'est pas essentielle, il nous semble préférable d'utiliser un modèle de régression ou un réseau de neurones.

Enfin, dans certaines applications, la formulation initiale du besoin peut masquer des évolutions pour lesquelles des requêtes complexes sur le modèle peuvent s'avérer nécessaires.

Comment utiliser des réseaux bayésiens ?

Malgré la diversité des applications, la construction d'un réseau bayésien se réalise, schématiquement en trois étapes essentielles

- 1- Identification des variables et leur espace d'états.
- 2- Définition de la structure du réseau bayésien.
- 3- Définition de la loi de probabilité conjointe des variables

Chacune des trois étapes implique un recueil d'expertise, au moyen de questionnaires écrits, d'entretiens individuels. Préconiser, dans un cadre général, l'une ou l'autre de ces approches serait pour le moins hasardeux. [1]

2.2.5 Applications des RB :

Les réseaux bayésiens trouvent des applications dans de nombreux domaines tels que :

- Diagnostic de pannes en fonction de mesures du système
- Diagnostic médical :
 - * probabilité d'une maladie en fonction de symptômes ;
 - * aide à l'évaluation de la gravité chez des patients atteints de douleurs et qui se présentent aux urgences.
- Fusion de données:
 - * N experts donnent un avis (plus ou moins sure) sur une question
 - * déterminer la probabilité d'un phénomène à partir de N indices plus ou moins bien observés.
- Microsoft :
 - * Windows : identification de problèmes d'impression
- NASA : aide au diagnostic de pannes en temps réel pour les systèmes de propulsion de la navette spatiale.
- système de contrôle d'un véhicule sous-marin autonome (déterminer les actions futures du véhicule selon son état).
- ATT : Détection de fraudes (mauvais payeurs) pour les factures de téléphone. [20]

2.2.6 Apprentissage :

Dans la première partie de ce chapitre on a montré qu'un réseau bayésien est constitué à la fois d'un graphe et d'un ensemble de probabilités conditionnelles. L'apprentissage d'un réseau bayésien doit donc répondre aux deux questions suivantes :

- Comment estimer les lois de probabilités conditionnelles ?
- Comment trouver la structure du réseau bayésien ?

Nous allons donc séparer le problème de l'apprentissage en deux parties :

- * L'apprentissage des paramètres, où nous supposerons que la structure du réseau a été fixé, et où il faudra estimer les probabilités conditionnelles de chaque nœud du réseau.
- * L'apprentissage de la structure, où le but est de trouver le meilleur graphe représentant la tâche à résoudre. [19].

2.2.7 Conclusion :

Selon le type d'application, l'utilisation pratique des réseaux bayésiens peut être envisagée au même titre que celle d'autres modèles : réseaux de neurones, systèmes experts, arbres de décision, etc. Les aspects suivants des réseaux bayésiens les rendent, dans de nombreux cas, préférables à d'autres modèles :

- Acquisition des connaissances : Les réseaux bayésiens donnent la possibilité de rassembler et de fusionner des connaissances de diverses natures dans un même modèle : retour d'expérience (données historiques ou empiriques), expertise (exprimée sous forme de règles logiques, d'équations, de statistiques ou de probabilités subjectives), observations. Dans le monde industriel, chacune de ces sources d'information est souvent insuffisante individuellement pour fournir une représentation précise et réaliste du système analysé.
- Représentation des connaissances : La représentation graphique d'un réseau bayésien est explicite, intuitive et compréhensible par un non spécialiste, ce qui facilite à la fois la validation du modèle, ses évolutions éventuelles et surtout son utilisation. Typiquement, un décideur est beaucoup plus enclin à s'appuyer sur un modèle dont il comprend le fonctionnement qu'à faire confiance à une «boîte noire».
- Utilisation des connaissances : Un réseau bayésien est polyvalent : on peut se servir du même modèle pour évaluer, prévoir, diagnostiquer, ou optimiser des décisions, ce qui contribue à rentabiliser l'effort de construction du réseau bayésien.
- Qualité de l'offre en matière de logiciels : Il existe aujourd'hui de nombreux logiciels pour saisir et traiter des réseaux bayésiens. Ces outils présentent des fonctionnalités plus ou moins évoluées : apprentissage des probabilités,
- Apprentissage de la structure du réseau bayésien, possibilité d'intégrer des variables continues, des variables d'utilité et de décision etc. Mais les réseaux bayésiens ont pas mal d'inconvénients surtout la complexité des algorithmes.

- Les variables continues : La plupart des algorithmes développés pour l'inférence et l'apprentissage dans les réseaux bayésiens, aussi bien que les outils disponibles sur le marché pour mettre en œuvre ces algorithmes utilisent des variables discrètes.

En effet, les algorithmes d'inférence sont essentiellement fondés sur une algèbre de tables de probabilités. De même, les algorithmes d'apprentissage modélisent en général les distributions de probabilités discrètes. Même s'il est théoriquement possible de généraliser les techniques développées aux variables continues, il semble que la communauté de recherche travaillant sur les réseaux bayésiens n'a pas encore vraiment intégré ces problèmes.

- La complexité des algorithmes : La généralité du formalisme des réseaux bayésiens aussi bien en termes de représentation que d'utilisation les rend difficiles à manipuler à partir d'une certaine taille. La complexité des réseaux bayésiens ne se traduit pas seulement en termes de compréhension par les utilisateurs. Les problèmes sont pratiquement tous de complexité non polynomiale, et conduisent à développer des algorithmes approchés, dont le comportement n'est pas garanti pour des problèmes de grande taille. [21]

Dans le chapitre suivant nous proposons d'appliquer les réseaux graphiques développés dans cette partie de mémoire pour détecter les défaillances dans le réseaux électriques de Sonelgaz et modéliser leurs propagation .

3

Présentation et Modélisation de la base de donnés du réseau électrique algérien par RB et RN

3.1 Présentation et Modélisation de la base de données :

3.1.1 Classification des modes de fonctionnement :

Dans cette partie nous allons déterminer et caractériser les classes de consommation et les modes de défaillances dans le réseau électrique en général :

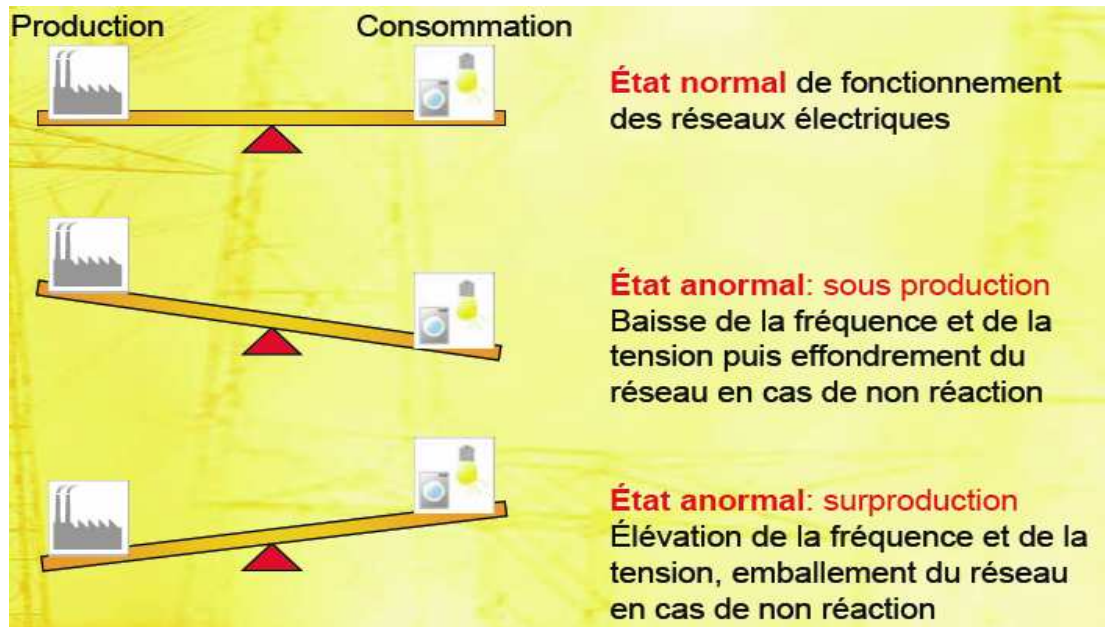


Figure 3.1 les états de fonctionnement d'un réseau électrique [22]

- Le réseau électrique est dans un état normal de fonctionnement (équilibre entre la production et la consommation)
- Le réseau électrique est dans un état anormal de fonctionnement (déséquilibre entre la production et la consommation) .

En exploitant d'une part les données fournies par l'entreprise Sonelgaz, couvrant les années : [2000-2004], Le réseau électrique Algérien est structurellement dans le deuxième état (état anormal).mais il réagit la plupart du temps convenablement, sauf des rares exceptions (black out 2003).on pense que le problème de la modélisation de la consommation et donc de la production est un ouvert et d'actualité.

➤ 3.1.2 Modes de fonctionnement normal :

Après avoir exploité les données fournies par l'entreprise Sonelgaz, couvrant les années : [2000-2004], et d'autre part les avis d'expert dans le domaine de la production et du transport de l'énergie électrique, nous sommes arrivés aux résultats suivants :




Figure3.2 présentation de la consommation journalière en état normal.

D'après la fig3.2. Nous constatons trois classes de consommation stables d'énergie électrique :

- ❖ Classe1 [00H00 → 07H00[: Cette classe correspond à la consommation de la nuit d'énergie électrique.
- ❖ Classe2 [09H00 → 15H00[: Cette classe correspond à la consommation du jour d'énergie électrique.
- ❖ Classe3 [18H00 → 22H00[: Cette classe correspond à la consommation des heures de pointe d'énergie électrique.

Le niveau de consommation de l'énergie électrique dans ces trois classes de fonctionnement dépend de la saison et des conditions climatiques.

L'allure de la courbe de production reste globalement fidèle et semblable à celle présentée à la figure 3.2 .Et comme nous savons que le réseau électrique est un système continu, pour l'évolution d'une classe à une autre nous passons par des phases de transitions.

➤ 3.1.3 Modes de fonctionnement anormal :

Dans cette partie de ce chapitre en va étudier les différentes causes des pannes et les différents types des surcharges et les modes de défaillances qui peuvent être induites par ces surcharges




Figure 3.3 présentation de la production journalière en état défaillant (Black out total année 2003).

Dans les données en notre possession , nous avons surtout observé le cas où le système était dans l'état de sous production et la figure 3.3 met en évidence le cas le plus grave celui du black out total.

3.1.3. a. Causes initiales des pannes :

Ce déséquilibre entre la production et la consommation peut être provoqué par :

- L'état du matériel de production et transport (poste de production vieillissement : sous investissement)
- Les conditions climatiques pour les Lignes aériennes (foudre, végétation, tempêtes, neige, glace, etc.).
- Le non respect du programme de délestage national (une zone de consommation importante n'a pas été déconnecté alors qu'elle était dans le programme de délestage national entraînant par effet le black out total du 03 Février 2003).

3.1.3. b. Types des surcharges :

A partir des mesures de la consommation d'énergie électrique on a constaté cinq types de surcharges :

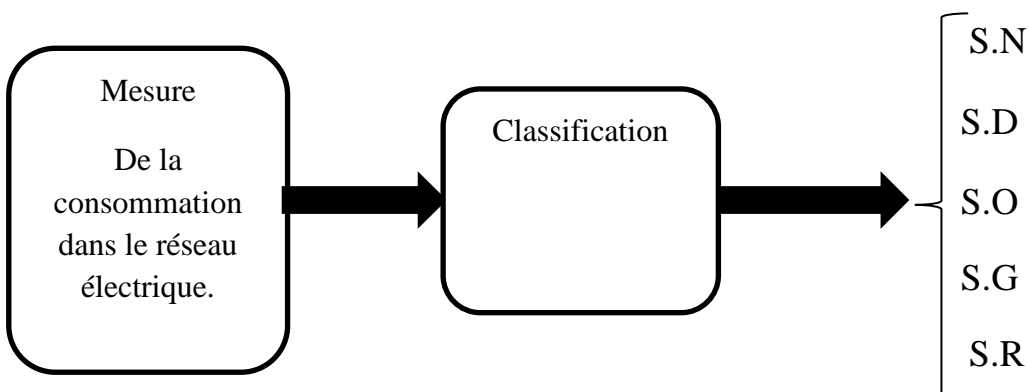


Figure 3.4 classification des surcharges.

- Surcharge nominale (S.N.) : c'est une défaillance de la production (totale), ou c'est une coupure d'énergie électrique sur les lignes de production, où bien c'est une défaillance d'un alternateur d'un groupe.

- Surcharge destinataire (S.D.) :c'est une défaillance due à une grande demande d'énergie électrique d'un pays voisin, par exemple : Maroc, Tunisie, Italie, avec lesquels notre réseau électrique est interconnecté.
- Surcharge origine (S.O.) :c'est une surcharge dans le centre de production (central électrique), ou un défaut du matériel des lignes (câbles et postes), autrement dit c'est un vieillissement.
- Surcharge globale (S.G.) :c'est une perte de production (réseaux isolés) ou la demande est supérieure à la production, et ce type de surcharges on le rencontre dans la période des fêtes.
- Surcharge régionale (S.R.) : c'est une défaillance de la production ou l'exploitation d'énergie électrique à longue distance, ou c'est des problèmes de court circuit et chute de tension dans une région.

3.1.3.c. Mode de fonctionnement en surcharge :

La production nationale est réalisée principalement par 06 centres à savoir : Oran- Alger- Sétif- Ourgla –Annaba- Constantine.....

Les modes de surcharge par rapport à chaque centre sont :

- Surcharge nominale (S.N.) : La production régionale est nominale et correspond à un mode de fonctionnement normal et c'est une forte augmentation de la demande qui est responsable de cette surcharge.
Cette augmentation de la demande peut provenir de la défaillance de production d'un autre centre régional ou de la demande d'un pays voisin dans le réseau électrique a une connection avec le notre.
- Surcharge origine (S.O.) : la demande régionale est une demande normale pour la saison et c'est une défaillance de la production régionale (coupure d'énergie sur les lignes de production ou défaillance d'un alternateur dans un groupe)

De même pour le réseau national on définit : comme étant une augmentation de la demande provenant d'un pays voisin connecté à notre réseau ou bien de l'augmentation de la demande nationale provenant d'une région sensée être en situation de délestage .

- Surcharge nominale (S.N.) : comme étant une augmentation de la demande provenant d'un pays voisin connecté à notre réseau ou bien de l'augmentation de la demande nationale provenant d'une région sensée être en situation de délestage.
- Surcharge origine (S.O.) : Comme étant la défaillance de la production dans un centre régional , évidemment cette défaillance régionale va provoquer des surcharges nominales dans les autres centres de production .




Figure 3.5 classification des surcharges (réseau Algérien)

3.2 Réseaux bayésiens :

3.2.1 Introduction :

La modélisation de la propagation des défaillances dans un réseau (électrique, téléphonique,...) par un réseau bayésien est une approche récente permettant la mise à jour des règles d'exploitation du réseau électrique. Cette étude s'appuyait sur l'analyse d'un échantillon de plusieurs situations du réseau électrique en Algérie. [22]

La similitude entre le réseau électrique et le réseau bayésien (Fig.3.5) permet de tenir compte de la corrélation spatiale au sein du réseau de production et de distribution de l'énergie électrique, et de considérer les dépendances entre les différentes lignes et poste de transformation du réseau électrique.

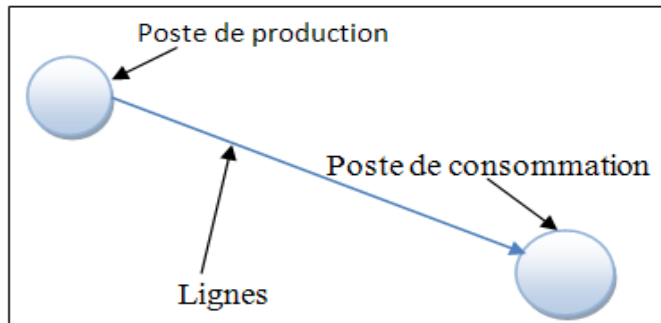


Figure3.6 similitude entre réseau électrique et R.B

- Les nœuds présentent les postes de production.
- L'arc présente ligne de transport d'énergie.

Comme nous le rappelons dans le chapitre 2, un réseau bayésien est un graphe causal permettant d'effectuer un raisonnement probabiliste. L'avantage de ce type de réseau se situe tout d'abord dans l'algorithme d'inférence. L'inférence peut se faire dans n'importe quel sens (et pas uniquement dans le sens entrée-sortie : cas des réseaux de neurones). L'autre grand avantage des réseaux bayésiens est de pouvoir prendre en compte l'incertitude que l'on peut avoir sur les variables comme, par exemple le fait que certaines variables ne soit pas connus ou ambiguës.

3.2 Construction d'un réseau bayésien

Pour construire un réseau de ce type il faut commencer par définir clairement les variables qui nous intéressent. La seconde étape consiste à établir le graphe d'indépendance conditionnelle entre les variables (graphe causal). Pour finir, il faut déterminer les matrices de probabilités conditionnelles.

L'estimation de la situation du réseau a une date future peut ainsi être assimilée à un vecteur comprenant plusieurs dizaines à plusieurs centaines de variables. Ces variables sont du point de vue de l'exploitant de réseau, entachées de nombreuses incertitudes :

- Variabilité de la consommation : Il est difficile de prévoir avec une grande précision le niveau et la répartition de la consommation, même à court terme. Un exemple souvent cité à ce sujet est la suivant : en hiver, une baisse d'un degré Celsius de la température en Algérie augmente la consommation nationale d'environ 500MW, soit d'ordre de la production d'un réacteur nucléaire.
- Indisponibilité fortuites : Le système électrique est affecté par des événements imprévisibles, comme les défaillances de ligne, de postes de transformation ou de groupe de production, qui entraînent des indisponibilités fortuites.
- Incertitude sur la production : la programmation de la production est basée sur des modèles approximatifs de la consommation (estimation de la consommation sur la même période de l'année passée avec ajout d'un pourcentage). Actuellement Sonelgaz avec des équipes de recherche essaient d'établir un modèle prédictif de la consommation basée sur l'exploitation des séries temporelles associées à des réseaux de neurones.

Il apparaît donc raisonnable de modéliser par des variables aléatoires les différents paramètres qui caractérisent la situation de réseau. D'une manière générale l'existence de ces incertitudes renforce la pertinence des méthodes probabilistes pour les études de conception ou de fonctionnement des systèmes électrique, ce constat se généralise à d'autres « industries de réseau » dans le domaine des transports, ou des télécommunications par exemple. [1]

3.2.2 Graphe d'indépendance :

Le graphe d'indépendance est le moyen le plus pratique pour construire un réseau bayésien, les liaisons entre les différentes variables est d'utiliser une propriété de ces réseaux, le critère de d-séparation, qui s'appuie sur les dépendances conditionnelles entre les variables.

Dans cette partie de ce chapitre on va établir le lien de dépendance conditionnelle entre la variables Réseau et les variables CdP (centres de productions). Lorsque l'on connaît la valeur de Réseau, les valeurs des CdP deviennent indépendantes : lorsqu'on sait que le Réseau n'est pas en surcharge globale, il n'est pas utile par exemple de connaître l'état du centre d'Alger pour connaître celui d'Oran .

Dans le réseau électrique algérien on a six centrales de production qui sont : Oran, Alger, Sétif, Annaba, Constantine et Ouargla. La figure montre comment relier les variables Réseau et CdP.

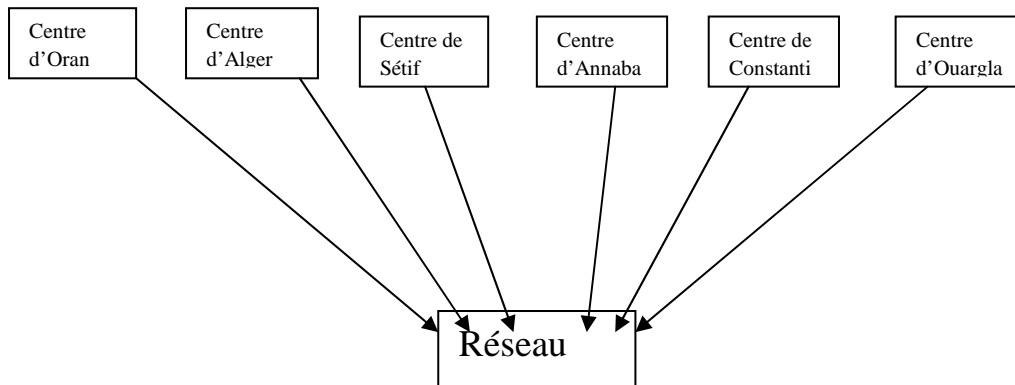


Figure 3.7 : graphe d'indépendance conditionnelle entre les variables Réseau et CdP.

3.2.3 Matrices de probabilités conditionnelles

Pour que le réseau bayésien soit défini il faut déterminer la matrice de probabilité conditionnelle P (nœud/parent). cette matrice revient à déterminer la probabilité des surcharges du réseau P (réseau = surcharge) et son complémentaire P (réseau = OK). Nous ne possédons malheureusement pas statistiques poussées sur l'état du réseau pour déterminer réellement ces valeurs, il faut donc les estimer.

En considérant qu'on a une surcharge globale un jour par an, nous fixons alors :

	S.G	OK
P (réseau)	$1/365 = 0.0027$	$364/365 = 0.9973$

Table 3.1 : Estimation de la matrice de probabilité de notre réseau.

Pour les centres de production (CdP), il faut déterminer la matrice de probabilité $P(\text{CdPi}/\text{Réseau})$. La valeur la plus facile à fixer est $p(\text{CdPi} = \text{SG}/\text{Réseau} = \text{SG}) = 1$: Lorsque le réseau est globalement surchargé, tous les CdPi le sont aussi. Par contre dans le cas contraire, il reste à déterminer $p(\text{CdPi} = \text{SR}/\text{Réseau} = \text{OK})$ et son complémentaire : $p(\text{CdPi} = \text{OK}/\text{Réseau} = \text{OK})$

Comme le cas précédent, nous n'avons pas de statistique avancées sur l'état des centres de production, nous fixerons donc ces valeurs identiques pour tous les centres de production, en considérant que chaque centre est surchargé dix jours par an. La table 4 donne la matrice de probabilité conditionnelle résultante :

		SG	OK
$P(\text{CdPi} \text{Réseau})$	SG	1	0
	SR	0	$10/365 = 0.0274$
	OK	0	$355/365 = 0.9726$

Table3.2 : Estimation de la matrice de probabilité de la variable CdPi conditionnellement à la variable Réseau.

Maintenant en considérant qu'on a une surcharge destinataire deux jours par an, la table 5 donne la matrice de probabilité conditionnelle résultante :

		SG	OK
$P(\text{S.D} \text{Réseau}) =$	SG	1	0
	SD	0	$2/365 = 0.0054$
	OK	0	$363/365 = 0.9945$

Table 3.3 : Estimation de la matrice de probabilité de la variable S.D. conditionnellement à la variable Réseau.

Et on considère qu'on a une surcharge originale quatre jours par an, la table 6 donne la matrice de probabilité conditionnelle résultante :

		SG	OK
P (S.O Réseau) =	SG	1	0
	SO	0	4/365 = 0.0109
	OK	0	361/365 = 0.9890

Table 3.4 : Estimation de la matrice de probabilité de la variable S.O conditionnellement à la variable Réseau.

Enfin en considérant qu'on a une surcharge nominale sept jours par an, table 7 donne la matrice de probabilité conditionnelle résultante :

		SG	OK
P (S.N Réseau) =	SG	1	0
	SN	0	7/365 = 0.0191
	OK	0	358/365 = 0.9808

Table 3.5 : Estimation de la matrice de probabilité de la variable S.N conditionnellement à la variable Réseau.

Une fois le graphe construit, l'utilisation du réseau bayésien repose sur un algorithme d'inférence qui calcule les états de chaque variable en fonction de leur valeur supposée.

3.3 Réseaux de neurone :

Les RNA ont été développés sous forme de modèles parallèles de réseau distribué basés sur l'apprentissage biologique du cerveau humain. Il y a de nombreuses applications d'RNA dans l'analyse de données , Parmi les différents types d'RNA, le perceptron multicouches (noté MLP pour Multi Layer Perceptron en anglais) sont tout à fait populaires et utilisés pour le travail actuel.

Dans Mon travail , j'ai utilisé ce genre de réseaux qui se compose d'une couche d'entrée de neurones de source, une ou plusieurs couches cachées et d'une couche de sortie. Le nombre des neurones dans la couche d'entrée et de sortie dépend du nombre de variables d'entrée et de nombre des classes désirées respectivement. Le nombre de couches cachées et le nombre de neurones dans chaque couche cachée affectent les possibilités de généralisation du réseau. Pour un plus petit nombre de couches cachées et de neurones, l'exécution peut ne pas être proportionnée .Considérant qu'avec trop de neurones cachés peuvent avoir le risque de sur-ajustement de précision des données. Il y a de diverses méthodes, heuristiques et systématiques, pour choisir le nombre de couches cachées et de neurone .

Le réseau de neurone MLP, utilisé dans ce travail, est composé de trois couches : entrée, cachée et sortie.

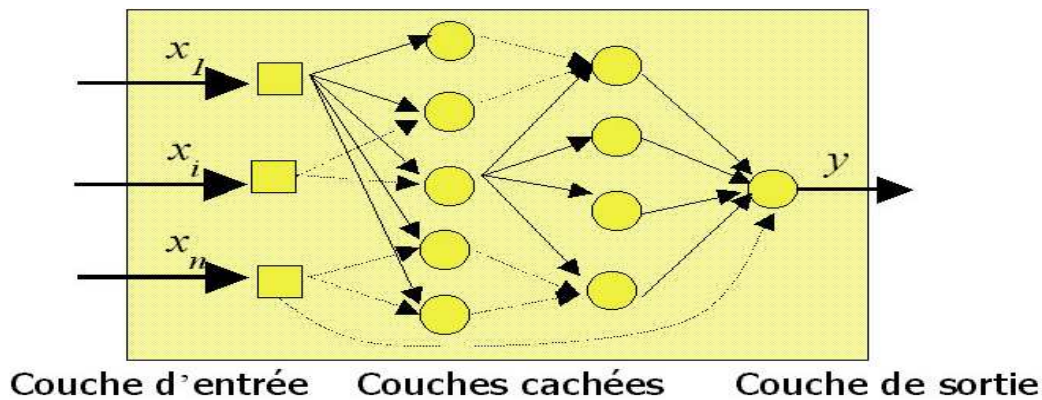


Figure 3.8 réseau PMC utilisé

On a procédé classiquement ou il faut scinder la base de données en deux parties distinctes et complémentaires (Apprentissage et test ou validation), on a utilisé une nouvelle fonction **train** qui permet d'intégrer les processus de validation et d'apprentissage simultanément (au niveau de chaque époque).Ceci est très utile car la base de données est assez conséquente 35040 lignes et permet de réaliser un arrêt prématuré (Early stopping).

L'apprentissage de réseau MLP implique de trouver des valeurs des poids de raccordement, qui réduisent au minimum la fonction erreur entre les résultats réels produit (calculés) et les valeurs à atteindre (désirés) correspondantes dans l'ensemble de l'apprentissage. Une des fonctions erreur largement répandues est l'erreur quadratique moyenne (MSE) $E^k = \frac{1}{2} \sum (d_i^k - y_i^k)^2$ (1) et les algorithmes s'exerçant le plus généralement utilisés sont basés sur la règle de delta aux réseaux à couches cachées s'appelle la règle de la rétro propagation (back propagation) , pour minimiser cette erreur il faut calculer son gradient qui est donné par cette fonction :

$$\nabla E^k (W) = \frac{\partial E^k}{\partial W(k)} \quad (2)$$

Le réseau de neurone ainsi conçu permet de détecter les modes de surcharge .La fonction Train permet de détecter les ruptures dans les séquences temporelles , les ruptures correspondant à l'arrivée d'un mode de surcharge à différencier des transitions douces entre les modes de fonctionnement normal .

Cette fonction est ajustée par 04 paramètres (**train**(net,P',T',[],[],v)), qui permet d'intégrer la validation au niveau de chaque époque. Les 4 paramètres utilisés sont décrits en ce qui suit :

net : Le réseau choisi.

net=newff (pr,[1,2,1],{'logsig' 'logsig' 'purelin'}).

newff est une fonction qui permet de créer un réseau de neurones feed forward avec 1 neurone dans la couche d'entrée, 2 neurones dans la couche cachée et un seul neurone dans la couche de sortie .

'logsig' 'logsig' 'purelin' : sont respectivement les 3 fonctions d'activation en Matlab des trois couches du réseau




Figure 3.9 Représentation des fonctions d'activation utilisées

LE réseau PMC (MLP) a été créé, formé et mis en application à l'aide de la boîte à outils de réseau de neurones de Matlab.

Pr = [0,1] pour normaliser la base de données

P` transposée du vecteur de la base d'apprentissage

T` transposée du vecteur de la base validation (test)

[] vecteur par défaut

V : La validation liée aux données de la base de validation .

```
%net.performFcn = 'sse';      /* si on active cette ligne on obtiendra l'évolution de
                                cette erreur pour les deux bases(apprentissage et validation).
```

```
net.trainParam.show =5;      /* visualise les erreurs chaque 5 époques*/
```

```
net.trainParam.epochs = 200; /* 200 époques*/ le nombre d'époques est fixé au préalable
```

3.4 Conclusion :

Dans ce chapitre, nous avons passé par une étude avec une méthode qui permet de tenir compte des dépendances qui peuvent exister dans une structure industrielle ou dans un système complexe.

Nous avons tout d'abord pris en compte la classification des données de notre réseau électrique et les modes de fonctionnement normal, ensuite nous avons classifié les surcharges et les modes de défaillances.

Finalement nous avons pris en considération les dépendances conditionnelles entre la variable réseau et les différentes surcharges qui existent dans ce type de système complexe.

Les réseaux bayésiens sont donc un outil de choix dans la représentation et l'exploitation des connaissances en plus, ils représentent un outil fort puissant :

- Pour réfléchir à un niveau intuitif.
- Pour améliorer la modélisation des défaillances des systèmes dans le cadre des modèles graphique.
- Pour échanger avec des non spécialistes de la formalisation (raisonner efficacement dans l'incertain).
- Pour construire une modélisation complexe.

Les réseaux de neurones sont aussi des approximateurs universels, leur utilisation doit aller de paire avec une méthodologie stricte qui permet de capter les relations fondamentales des données Les réseaux de neurones sont de puissants outils de modélisation et de prédiction. Ils ont été adoptés dans divers champs d'application et nous croyons que l'industrie de l'assurance est sur le point de faire de même.

Dans notre application L'intégration du processus de validation au fur et à mesure de celui d'apprentissage en intégrant l'arrêt prématuré est réalisé par la fonction `train` (**train** (**net,P',T',[],[],v**)) ;qui nous a donné de très bon résultats et une meilleure prévision. Ce qui implique une très grande performance du réseau

Dans le dernier chapitre, nous présentons les résultats de simulations en utilisant logiciel« BayesiaLab » qui traite les réseaux bayésiens et le Matlab utilisant le réseaux de neurones .

4

Application et résultat de simulation

Les chapitres précédents ont permis de présenter les méthodes de diagnostic à base de données , dans ce chapitre , nous allons illustrer avec des exemples d'applications basées sur l'utilisation des réseaux de neurones et réseaux bayésiens .

4.1. Introduction:

BayesiaLab est un produit de Bayesia (<http://www.bayesia.com>), entreprise française dédiée l'utilisation des méthodes d'aide à la décision et d'apprentissage issues de l'intelligence artificielle ainsi qu'à leurs applications opérationnelles (industrie, services, finance, etc.).

BayesiaLab se présente comme un laboratoire complet de manipulation et d'étude de réseau bayésien. Il est développé en Java, et est actuellement disponible en version française ou anglaise. BayesiaLab permet de traiter l'ensemble de la chaîne d'étude de la modélisation d'un système par réseau bayésien : modélisation, apprentissage automatique, analyse et utilisation.[23]

Modélisation :

BayesiaLab est avant tout un environnement graphique. L'ensemble des outils sont donc des outils interfacés graphiquement soit directement avec la souris (création de nœuds, création d'arcs, etc.) soit par l'intermédiaire de boîtes de dialogue (pour la saisie des probabilités par exemple).

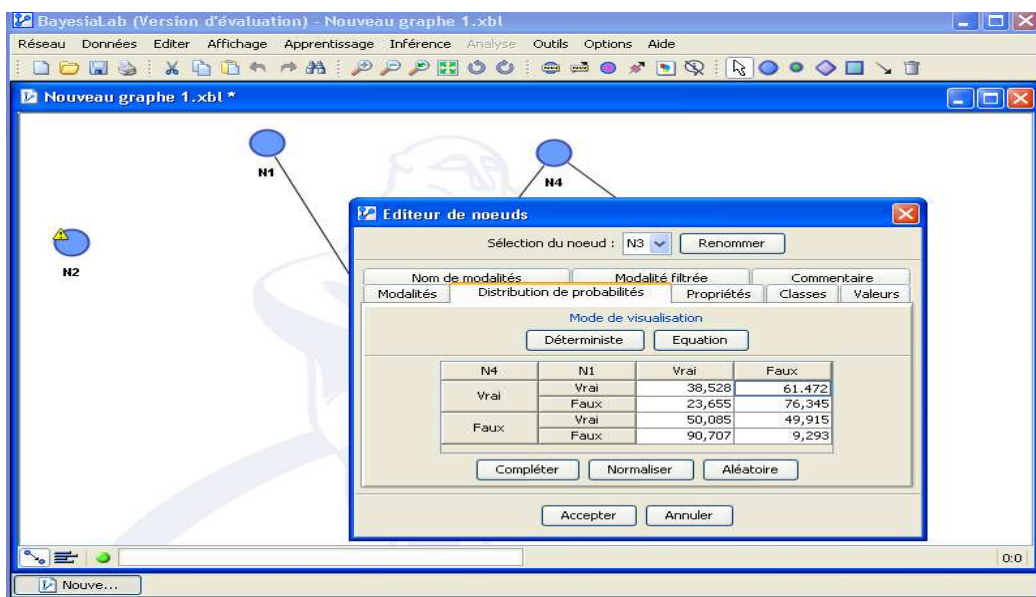


Figure 4.1 Modélisation et saisie de la TPC sous BayesiaLab

Pour la modélisation rapide d'un réseau, BayesiaLab propose beaucoup de raccourcis clavier (N+click crée un nœud, L+ drag crée un arc, etc.). Il possède également un outil de positionnement automatique des nœuds (raccourci P) qui facilite grandement la construction de tels réseaux.

Il gère un certain nombre de types de nœuds : nœud variable, nœud label, nœud intervalle, nœud contrainte pour l'expression de contraintes existant entre des nœuds, nœud d'utilité pour la qualification des états. Il permet également de donner la définition d'un coût / gain d'observation pour chaque nœud.

Pour l'édition des nœuds, il propose :

- Des assistants pour la génération et nomination des nœuds Label et intervalle.
- Différents modes de saisie des distributions de probabilité conditionnelles : probabiliste, déterministe et équation.
- Un éditeur de formules puissant doté d'une librairie complète de fonctions et d'opérateurs (fonction probabilistes discrètes et continues, fonctions arithmétiques et trigonométriques, etc.).
- Des outils de complétion et de normalisation de tables, copier/coller entre tables et applications externes (type tableur ou traitement de texte.).
- Des fonctionnalités de documentation et de traçabilité des modèles par le biais des commentaires hypertextes associés aux nœuds et aux graphes.
- Le marquage des nœuds par couleur pour le typage de variables.

4.2 Apprentissage :

L'apprentissage est un des points les plus forts de BayesiaLab. Il utilise des méthodes et des algorithmes qui sont à la pointe de la recherche dans le domaine (les fondateurs de Bayesia étant des chercheurs spécialisés dans l'apprentissage de réseaux bayésiens).

L'apprentissage dans BayesiaLab prend comme entrée un fichier texte ou un lien ODBC décrivant l'ensemble des cas (un cas par ligne ou un cas par colonne). Ce fichier peut intégrer un caractère particulier indiquant les valeurs manquantes.

Les assistants d'importation permettent la configuration de la lecture (séparateur, ligne de titre, valeur manquante, transposition), la sélection et le type des colonnes à importer, l'apport de premières informations statistiques, des fonctions de filtrages des données importées (ex : rejet des jeunes de moins de quinze ans qui fument) et le choix de la méthode de discrétisation des variables continues : égales largeurs, égales fréquences et discrétisation

Intelligente par arbre de décision. Afin de garder l'ensemble de ces ajustements, il est possible d'enregistrer la base de données associée au réseau avec les différents traitements subis (discrétisation, filtrages,...)

A partir de ce fichier, le logiciel propose :

- Une gestion rigoureuse des valeurs manquantes,
- Un apprentissage des paramètres (table de probabilités),
- La découverte d'associations (avec variables cachées). Un expert peut proposer une structure ou des associations initiales qui pourront ou non être remises en causes lors de l'apprentissage,
- Une recherche de caractérisation d'un nœud cible.

- Le clustering (création automatique d'un nœud cluster dont les modalités (en nombre calculé) représentent les différentes classes discernées par l'apprentissage dans les données). De même, la base de données et les méthodes d'apprentissages peuvent être appliquées à un réseau déjà construit en y associant une base de données, avec gestion des nouvelles modalités (ajoutées, ignorées, remplacées),
- Des outils de variation pour l'évolution des modèles obtenus (matrice de confusion, courbes de lift, Roc).

En tant que laboratoire d'étude de réseaux bayésiens, BayesiaLab offre un large choix dans les algorithmes à utiliser. Ainsi, il met en œuvre trois méthodes d'apprentissage non supervisé pour la découverte des associations (recherche dans les classes d'équivalence, recherche Tabou dans l'espace des RB et recherche Taboo dans l'espace des ordres de nœuds), cinq méthodes d'apprentissage supervisé pour la caractérisation d'un nœud cible (du naïf à la couverture de Markov augmentée, en passant par le naïf augmenté), un ensemble de méthodes de clustering (nombre de classes fixé, sélection automatique, spécification de la longueur de la marche aléatoire, spécification de la taille des échantillons pour la recherche d'une solution).

4.3 Exploitation :

Le logiciel gère deux types d'inférence : exacte (basée sur l'arbre de jonction) et une inférence approchée (pour des réseaux de complexité trop grande, par exemple dans les réseaux dynamiques).

L'exploitation nécessite la possibilité d'insérer des observations dans le réseau. BayesiaLab permet d'insérer des évidences certaines (ce nœud à cette valeur), des évidences négatives (ce nœud n'a pas ces valeurs) et, plus généralement, des vraisemblances.

BayesiaLab exploite le réseau bayésien en interactif (entrer des observations à partir des « moniteurs ») ou en « batch » (effectuer une série d'évaluations de variables à partir d'un fichier d'observations).

En mode interactif :

- L'affichage des probabilités a posteriori ainsi que l'insertion des observations (certaines) se fait à partir des moniteurs. Ces moniteurs peuvent indiquer aussi les sens de variation des probabilités entre deux inférences consécutives.
- Un coût d'observation peut être associé à chaque nœud, permettant la génération automatique d'un questionnaire adaptatif centré sur une variable cible («quelle est la séquence dynamique de questions à poser pour estimer, au mieux et à moindre coût, la valeur de la variable cible»). Il permet donc directement de transformer un réseau bayésien en outil de diagnostic automatique.

En mode batch :

- le mode batch fonctionne comme un étiquetage hors-ligne d'une base de données : le logiciel propose donc des valeurs pour les variables manquantes de chaque ligne de la base de données.
- Il est également possible de créer une base de cas correspondant à la distribution de probabilités par le réseau.

4.4 Analyse :

Des outils d'analyse très intéressants et assez innovants sont intégrés également dans BayesiaLab. On peut citer :

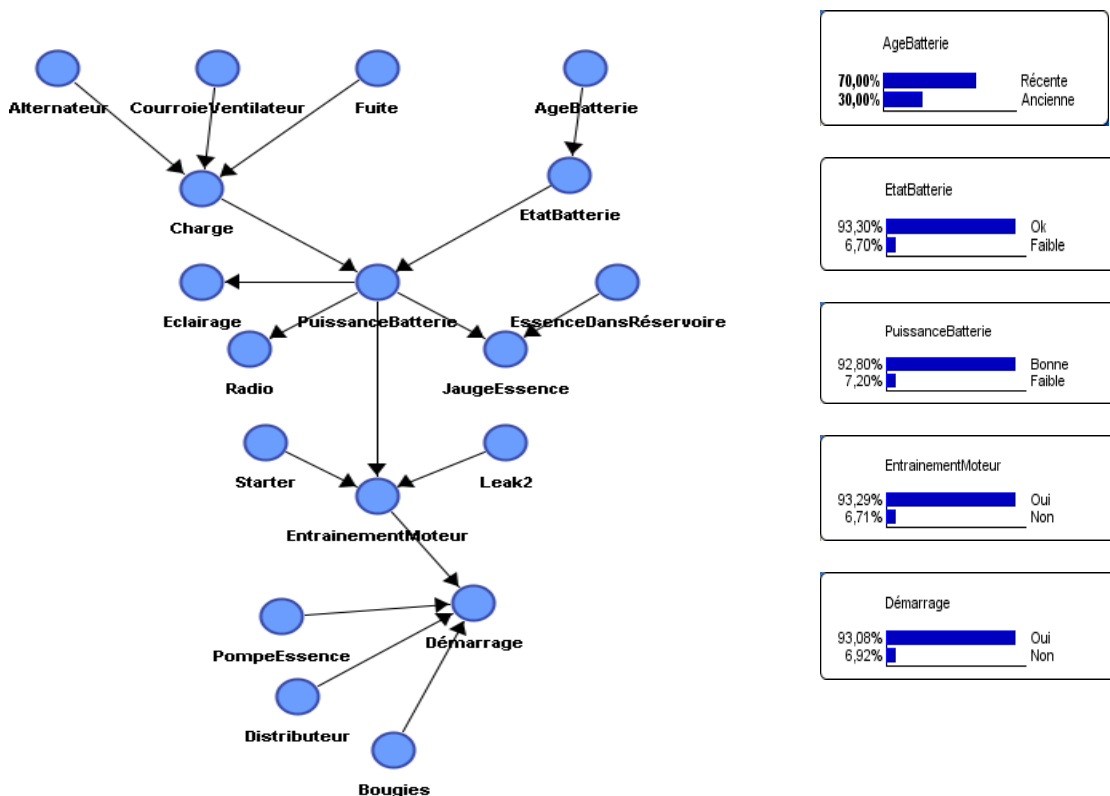
- Force des arcs. On parle ici d'importance de l'arc pour la loi de probabilité exprimée par le réseau bayésien. Cette valeur peut servir à modifier le positionnement automatique des nœuds (plus la force est grande, plus les nœuds sont proches).
- Apport d'information pour le nœud / modalité cible. Pour chaque nœud on peut indiquer à tout moment quel est son apport à la connaissance du nœud cible.
- Typage des relations probabilistes.
- Rapports complets d'analyse.
- Visualisation du graphe essentiel. Cette visualisation permet une première approche de la causalité dans le réseau bayésien. L'outil permet également de choisir l'ensemble des orientations de la structure avec mise à jour des tables de probabilités.

4.5 Exemple d'application :

- voiture :

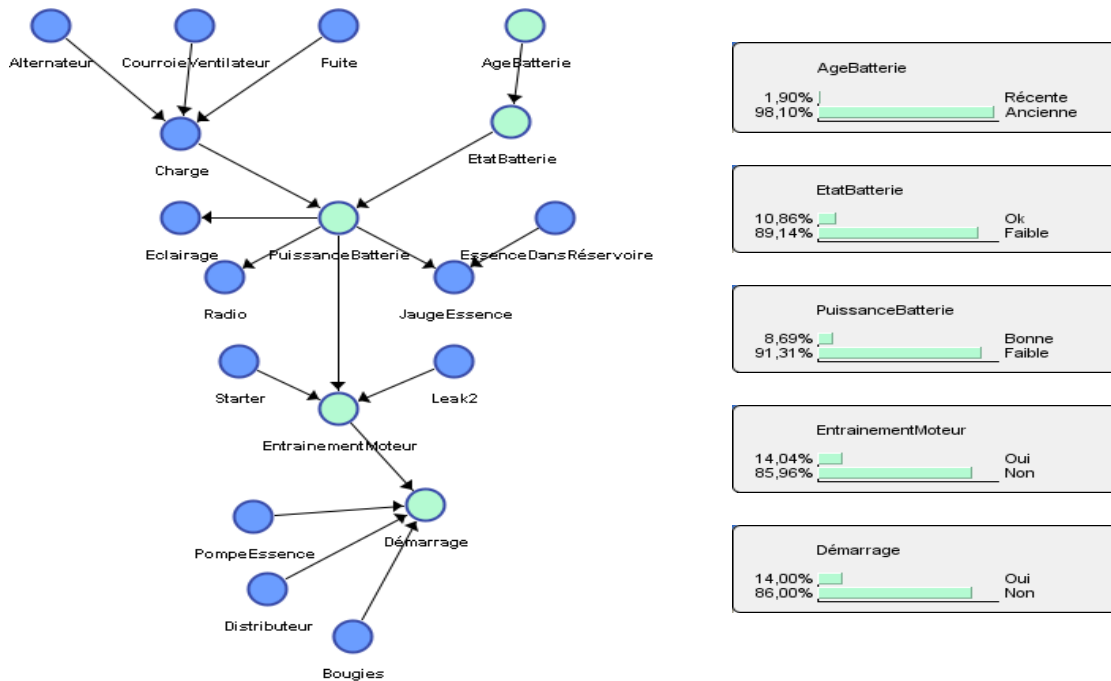
Prenant l'exemple d'une voiture qui est composé principalement de plusieurs éléments dont sa base de données existe sous le bayésialab , on distingue deux scénario :

1- **Fonctionnement en mode normal** : on a pris le nœud age batterie comme nœud d'entrée. La modélisation des composants essentiels de la voiture après avoir fait l'apprentissage ainsi les probabilités conditionnels calculées après avoir fait l'inférence. Sont illustrées sur la figure suivante :



**Figure 4.2 Modélisation et saisie de la TPC sous BayesiaLab
Exemple voiture en fonctionnement normal**

2-Fonctionnement en mode défaillant : on remarque ici s'il y a un changement sur l'état du nœud age batterie les états des autres nœuds changeront aussi donc on aura de nouvelles valeurs des probabilités jointes et conditionnelles associées .



**Figure 4.3 Modélisation et saisie de la TPC sous BayesiaLab
Exemple voiture fonctionnement en mode défaillant**

- **Moteur à aimant permanent :**

L'objectif principal de cette application est de réaliser un diagnostic de défaillances sur le mouvement de rotation de l'arbre du moteur (on s'intéressera à la disponibilité ou non du mouvement de rotation). [24]

1-Mode de fonctionnement nominal :

Ce scénario correspond au mode de fonctionnement nominal du moteur (le mouvement de rotation est supposé disponible). Le réseau bayésien relatif à ce mode est donné à la figure 3.

Dans ce mode, étant donné qu'aucune anomalie n'est observée, la probabilité jointe du système complet est égale à 1. Des probabilités marginales sont calculées pour différents nœuds .

Les résultats obtenus (figure 4.4) montrent que la probabilité concernant la disponibilité du mouvement de rotation est de 95.40% et que celles du stator, du rotor et de l'arbre de transmission (mode OK) sont égales à 99.98%, 95.51% and 99.90% ; respectivement.

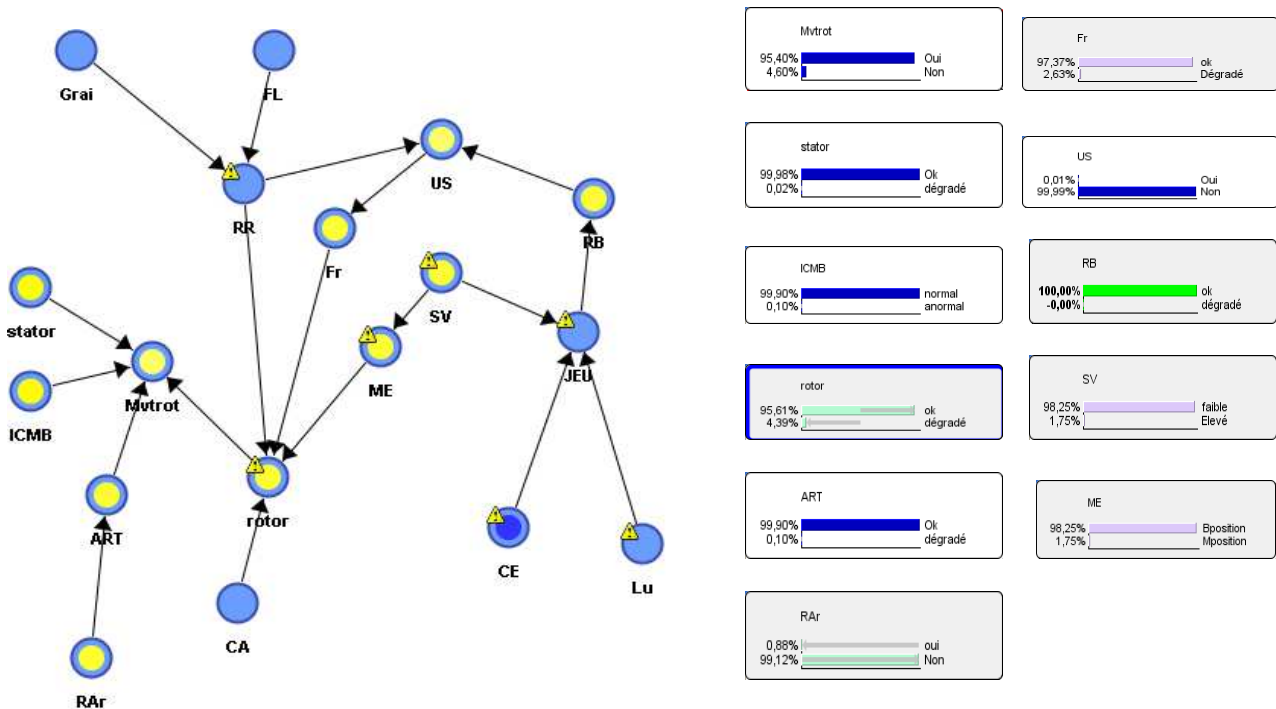


Figure 4.4 Mode de fonctionnement normal

2- Localisation d'une défaillance :

Nous considérons dans ce scénario que le mouvement de rotation de l'arbre de rotation n'est pas disponible ($P(\text{MvtRot} = \text{Non}) = 1$). De plus, nous supposons qu'il existe un capteur qui permet de mesurer le spectre vibratoire (noeud SV sur le réseau de la figure 4.5). Dans le cas où de fortes vibrations sont détectées (observation ou évidence), la probabilité du noeud SV change et devient donc une certitude $P(\text{SV} = \text{Elevé}) = 1$. L'actualisation du réseau bayésien conduit à de nouveaux résultats de simulation donnés à la figure 4.5. Ces résultats montrent dans ce cas que le rotor serait la cause la plus probable du dysfonctionnement. En effet, de fortes vibrations peuvent causer d'une part, des dégradations au niveau des roulements et d'autre part, un mal positionnement des masses d'équilibre qui, à leur tour, causent la dégradation du rotor. Cela justifie donc la probabilité que le rotor soit la cause la plus probable de l'indisponibilité du mouvement de rotation .

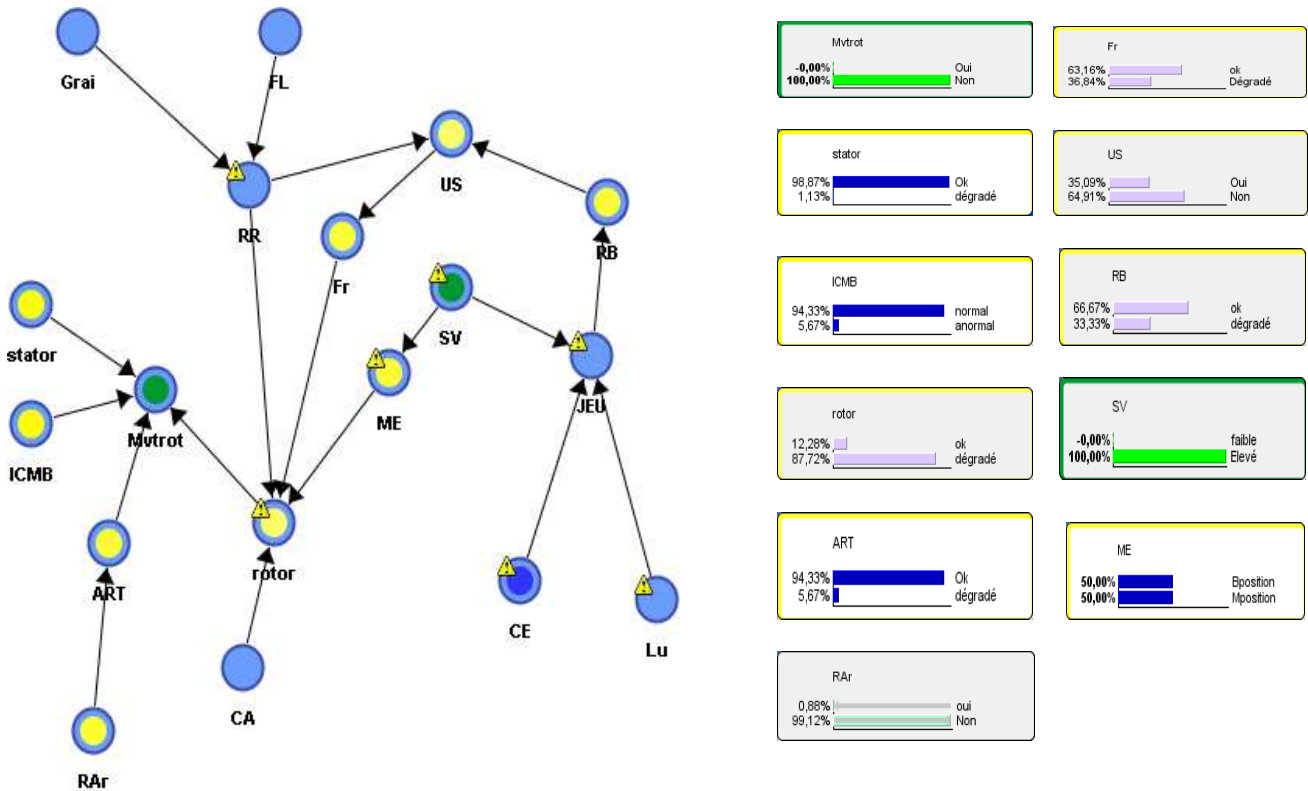


Figure 4.5 Mode de fonctionnement anormal (présence d'une défaillance)

Avec ces deux exemples on déduit la puissance de cette approche et qu'on peut diagnostiquer n'importe quel système statique ou dynamique à condition qu'on possède une version dynamique de cet outil de modélisation Bayésialab .

4.6 Applications du réseau électrique dans « BayesiaLab » :

D'après les données recueillies par les services de Sonelgaz, Le réseau électrique Algérien est structurellement dans le deuxième état (état anormal).mais il réagit la plupart du temps convenablement, sauf des rares exceptions (black out 2003).on pense que le problème de la modélisation de la consommation et donc de la production est un ouvert et d'actualité

Construction du réseau sous BayesiaLab :

Maintenant, on va modéliser le réseau électrique à l'aide du logiciel BayesiaLab, et nous avons édité tout les nœuds avec les données du Sonelgaz dans un état de fonctionnement normal :

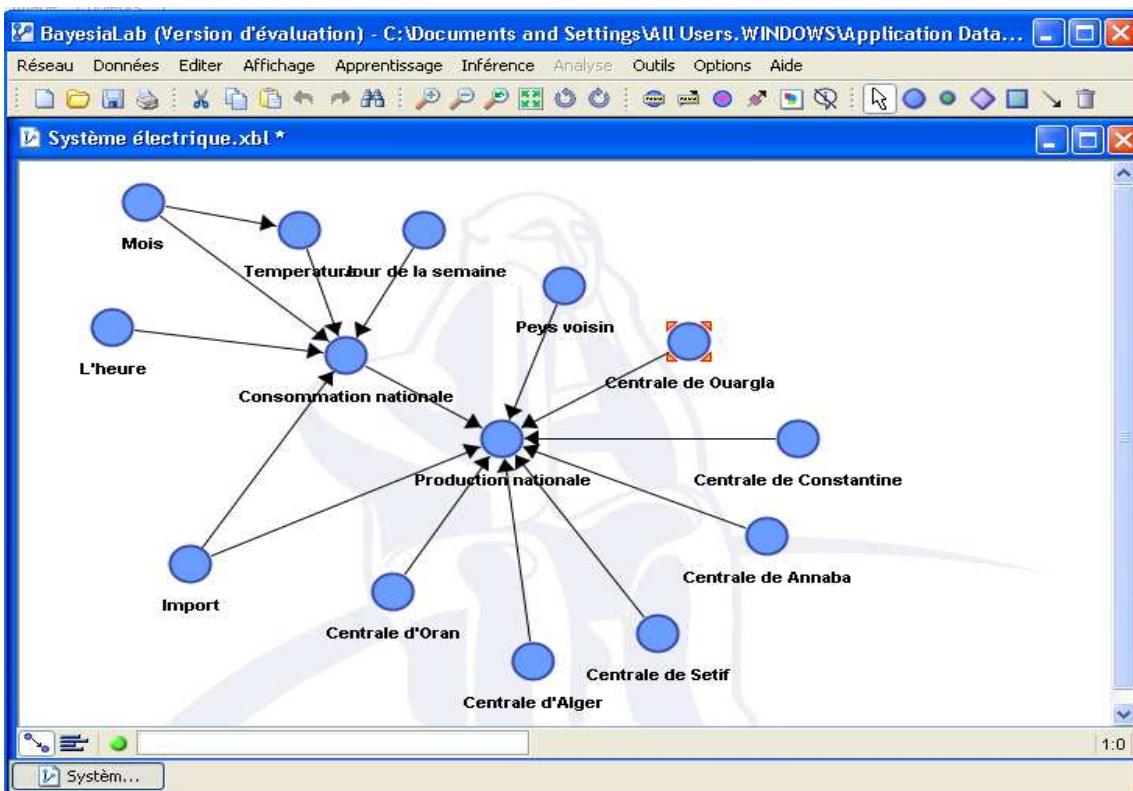


Figure 4.6 : Modélisation de réseau électrique à l'aide du « BayesiaLab ».

Validation du réseau construit en état normal :

Ensuite, en va valider notre réseau pour voir les probabilités jointes :

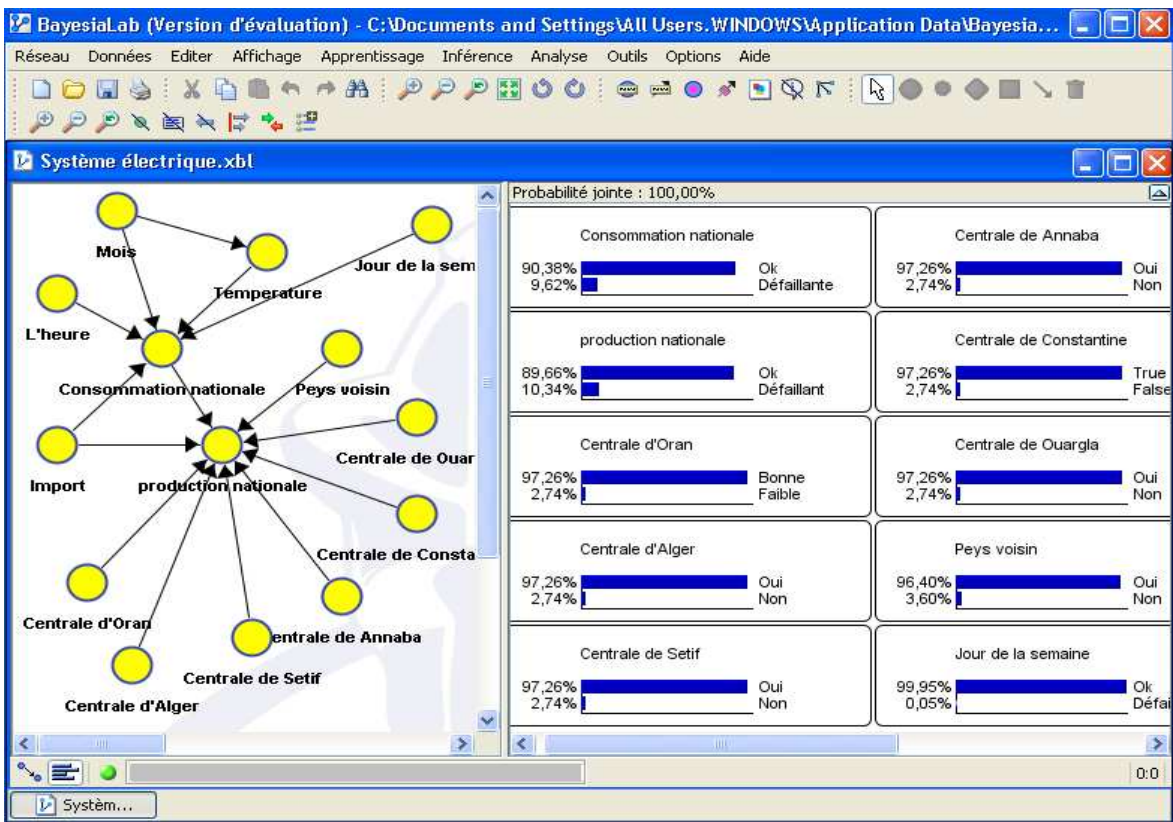


Figure 4.7 : validation du réseau électrique en état normal.

Validation du réseau construit en état défaillant :

Dans cette partie on va utiliser les données du Black out enregistrées en 2003 (le 3 février).

Tel que plus de 30 millions de personnes en Algérie ont été privées d'électricité pendant plusieurs heures, et la cause de cette surcharge est un programme de délestage automatique de consommation qui n'a pas été respecté et qui a provoqué une surcharge régionale à Alger -après cette surcharge régionale est transformée en une surcharge globale. Cette dernière a provoqué une coupure d'énergie électrique dans tout le réseau national. Les figures 4.8, 4.9 sont des illustrations du cas de black out.




Figure 4.8 Représentation de la production régionale du 3 février 2003.




Figure 4.9 Représentation de la production et la consommation nationale.

Maintenant, on va exploiter ces données à l'aide du logiciel BayesiaLab et de valider le réseau construit ,On obtient les résultats suivants :

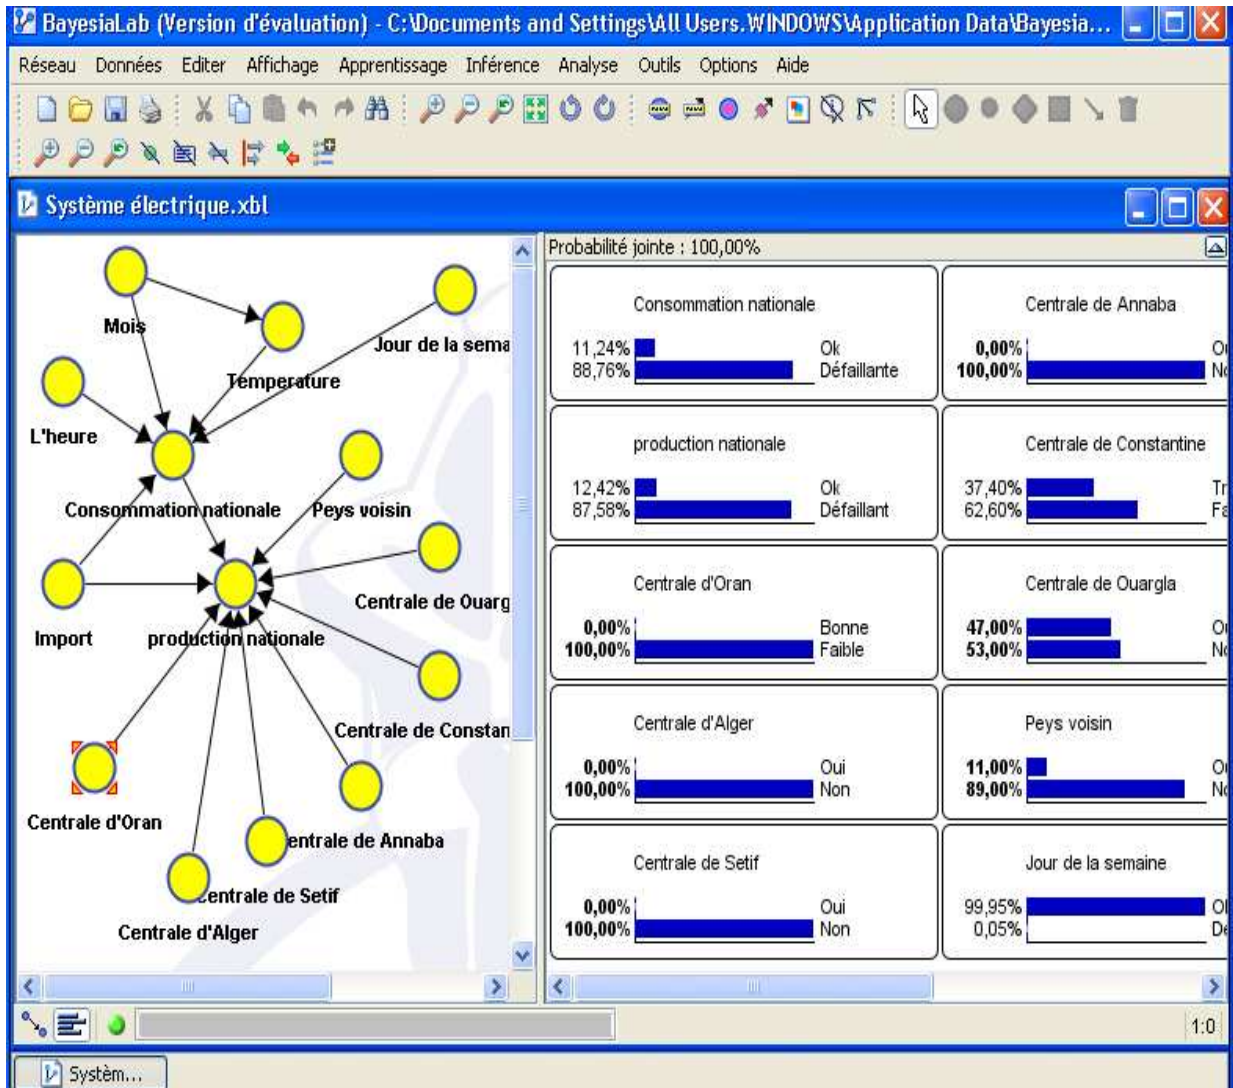


Figure 4.10 : validation du réseau électrique en état de surcharge

4.7 Résultat de simulation du réseau électrique avec le réseau de neurone :

On va traiter les données recueillies par Sonelgaz couvrant les années [2000-2004]:

pour chaque année , j'ai fait un programme qui utilise un réseau de neurone PMC ou on fait varier que la base de données .

Pour chaque année on aura donc trois figures : la première qui traite la grosse partie de la base de données pour l'apprentissage , la deuxième qui traite le reste de la base de données pour la validation (test) et la troisième illustre le training (voir les performances du réseau choisi – erreurs-)

donc on aura :

Pgmr0.m : programme pour l'année 2000 ou on charge la base de données de l'année 2000

Après avoir fait le découpage 70% de la base pour l'apprentissage et 30% de la base pour le test

Pgmr1.m : programme pour l'année 2001 ou on charge la base de données de l'année 2001

Après avoir fait le découpage 70% de la base pour l'apprentissage et 30% de la base pour le test

Pgmr2.m : programme pour l'année 2002 ou on charge la base de données de l'année 2002

Après avoir fait le découpage 70% de la base pour l'apprentissage et 30% de la base pour le test

Pgmr3.m : programme pour l'année 2003 ou on charge la base de données de l'année 2003

Après avoir fait le découpage 70% de la base pour l'apprentissage et 30% de la base pour le test

Pgmr4.m : programme pour l'année 2004 ou on charge la base de données de l'année 2004

Après avoir fait le découpage 70% de la base pour l'apprentissage et 30% de la base pour le test

On aura les résultats suivants pour chaque année :

Année2000 :

Charge Electrique (MWatts)




Figure 4.11: Représentation de la consommation et la production de la base d'apprentissage

Charge Electrique (MWatts)




Figure 4.12: Représentation de la consommation et la production de la base validation

Training-Blue Validation-

Performance is 0.0115472, Goal is 0




Figure4.13 : Evolution de l'erreur d'apprentissage et de validation (MSE)

Année 2001 :

Charge Electrique (MWatts)




Figure 4.14: Représentation de la consommation et la production de la base d'apprentissage

Charge Electrique (MWatts)




Figure 4.15: Représentation de la consommation et la production de la base validation

Training-Blue Validation-




Figure 4.16: Evolution de l'erreur d'apprentissage et de validation (MSE)

Année 2002 :

Charge Electrique (MWatts)




Figure 4.17: Représentation de la consommation et la production de la base d'apprentissage

Charge Electrique




Figure 4.18: Représentation de la consommation et la production de la base validation

Training-Blue Validation-

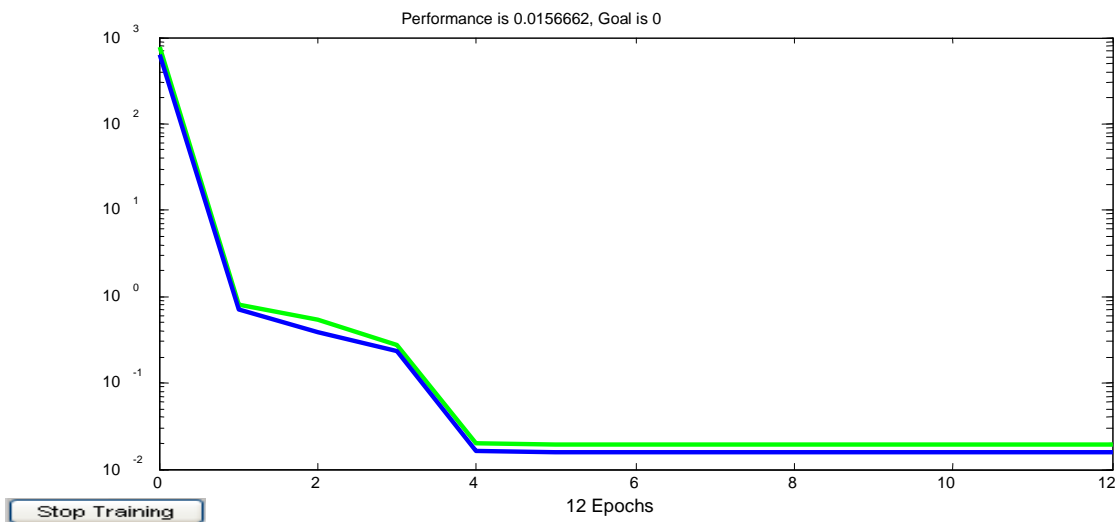


Figure4.19 : Evolution de l'erreur d'apprentissage et de validation (MSE)

Année 2003 :




Figure 4.20: Représentation de la consommation et la production de la base d'apprentissage




Figure 4.21: Représentation de la consommation et la production de la base validation




Figure4.22 : Evolution de l'erreur d'apprentissage et de validation (MSE)

Année 2004 :




Figure 4.23: Représentation de la consommation et la production de la base d'apprentissage.




Figure 4.24: Représentation de la consommation et la production de la base validation




Figure 4.25: Evolution de l'erreur d'apprentissage et de validation (MSE)

4.8 Interprétation des résultats :

D'après les résultats obtenus on remarque que le fonctionnement est normal du réseau électrique durant les années 2000-2001-2002-2004 et que ces résultats sont très satisfaisants et que les valeurs de la consommation et la production de la base de validation sont approximatives, Ce qui implique que la performance de notre réseau est très grande, mais pour l'année 2003 on distingue un disfonctionnement(détection d'une défaillance) du réseau électrique à l'échelle national car il ya eu une surcharge à l'échelle régional qui a provoqué un black out national durant quelque heures .

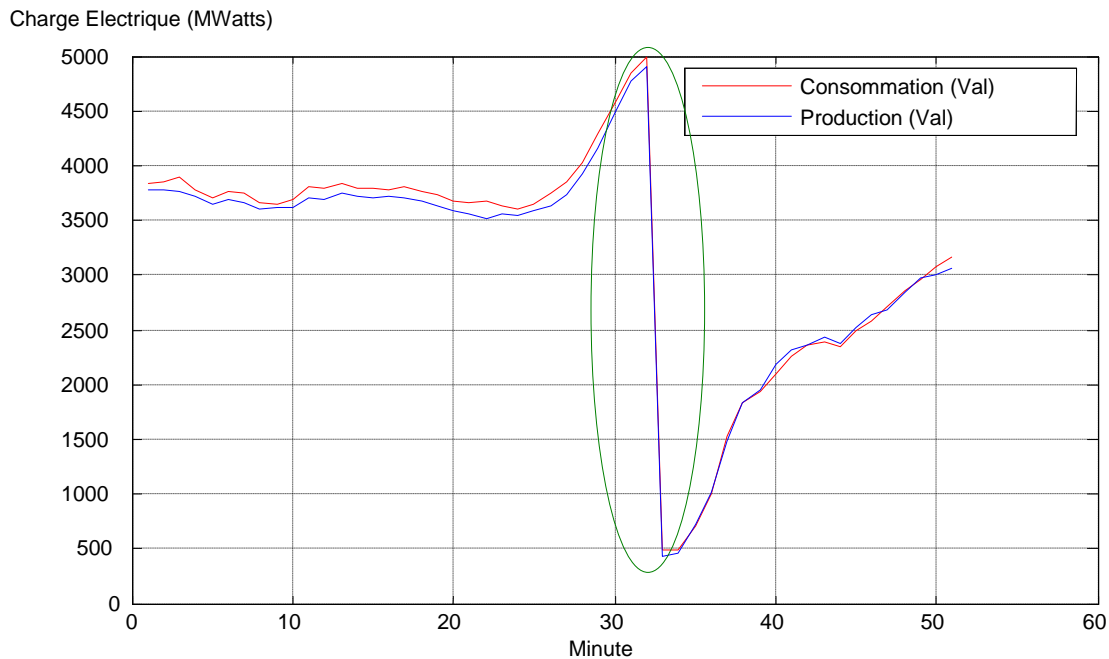


Figure 4.26: détection d'une surcharge nationale (black out)

En ce qui concerne le training pour chaque années :

Année2000 : On peut remarquer l'arrêt du processus d'apprentissage à l'époque 55 qui implique un arrêt prématuré réalisé par cette fonction avant d'atteindre le nombre d'époques fixé au préalable (200) (*net.trainParam.epochs = 200;*). L'arrêt prématuré nous conduit vers le phénomène de sur apprentissage à l'époque 55 où l'erreur de généralisation a commencé d'augmenter avec une erreur de généralisation minimale égale à 0.0115472 . Cette fonction modifiée réalise automatiquement l'arrêt prématuré quand elle détecte un sur apprentissage.

Le réseau **net** enregistre automatiquement les poids de cette époque (55) pour obtenir un réseau performant.

Année2001 : On peut remarquer l'arrêt du processus d'apprentissage à l'époque 22 qui implique un arrêt prématuré réalisé par cette fonction avant d'atteindre le nombre d'époques fixé au préalable (200) (*net.trainParam.epochs = 200*;). L'arrêt prématuré nous conduit vers le phénomène de sur apprentissage à l'époque 22 où l'erreur de généralisation a commencé d'augmenter avec une erreur de généralisation minimale égale à 0.00850314 . Cette fonction modifiée réalise automatiquement l'arrêt prématuré quand elle détecte un sur apprentissage.

Le réseau **net** enregistre automatiquement les poids de cette époque (22) pour obtenir un réseau performant.

Année2002 : On peut remarquer l'arrêt du processus d'apprentissage à l'époque 12 qui implique un arrêt prématuré réalisé par cette fonction avant d'atteindre le nombre d'époques fixé au préalable (200) (*net.trainParam.epochs = 200*;). L'arrêt prématuré nous conduit vers le phénomène de sur apprentissage à l'époque 12 où l'erreur de généralisation a commencé d'augmenter avec une erreur de généralisation minimale égale à 0.0156662 . Cette fonction modifiée réalise automatiquement l'arrêt prématuré quand elle détecte un sur apprentissage.

Le réseau **net** enregistre automatiquement les poids de cette époque (12) pour obtenir un réseau performant.

Année2003 : On peut remarquer l'arrêt du processus d'apprentissage à l'époque 103 qui implique un arrêt prématuré réalisé par cette fonction avant d'atteindre le nombre d'époques fixé au préalable (200) (*net.trainParam.epochs = 200*;). L'arrêt prématuré nous conduit vers le phénomène de sur apprentissage à l'époque 103 où l'erreur de généralisation a commencé d'augmenter avec une erreur de généralisation minimale égale à 0.0115472 . Cette fonction modifiée réalise automatiquement l'arrêt prématuré quand elle détecte un sur apprentissage.

Le réseau **net** enregistre automatiquement les poids de cette époque (103) pour obtenir un réseau performant.

Année2004 : On peut remarquer l'arrêt du processus d'apprentissage à l'époque 91 qui implique un arrêt prématuré réalisé par cette fonction avant d'atteindre le nombre d'époques fixé au préalable (200) (*net.trainParam.epochs = 200*;). L'arrêt prématuré nous conduit vers le phénomène de sur apprentissage à l'époque 91 où l'erreur de généralisation a commencé d'augmenter avec une erreur de généralisation minimale égale à 0.00989555. Cette fonction modifiée réalise automatiquement l'arrêt prématuré quand elle détecte un sur apprentissage.

Le réseau **net** enregistre automatiquement les poids de cette époque (91) pour obtenir un réseau performant.

4.9 Conclusion :

Bien que dernier arrivé sur la scène des logiciels de manipulation de réseaux bayésiens, BayesiaLab a beaucoup d'atouts et se démarque par des fonctionnalités originales et une intégration poussée de l'ensemble du processus, de la modélisation à l'utilisation.

En tant que laboratoire de modélisation, d'apprentissage et d'analyse de réseaux bayésiens , BayesiaLab fournit l'un des environnements les plus complets et les plus professionnels du marché.

Nous l'avons utilisé et adopté pour des raisons simples : d'une part il est disponible gratuitement en version d'essais (<http://www.bayesia.com>), et d'autre part il est en langue française ce qui nous permet de l'exploiter facilement.

Pour ceux intéressés par les autres plates formes, nous leurs donnons à titre indicatif les sites suivantes :

- Hugin : <http://www.hugin.com>
- Bayesia : <http://www.bayesia.fr>
- ProBayes : <http://probayes.com>
- Netica : <http://www.norsys.com>
- Elvira : <http://leo.ugr.es/~elvira>
- Bayes Net Toolbox: <http://bnt.sourceforge.net/>
- Structure Learning Package: <http://bnt.insa-rouen.fr/>

On remarque aussi que les résultats obtenus par les réseaux de neurones confirment les résultats obtenus avec les réseaux bayésiens .

Donc on constate que les réseaux de neurones sont aussi des méthodes ou approches qui peuvent détecter un dysfonctionnement ou anomalie dans les systèmes complexes , mais avec l'utilisation et l'ajout de nouvelles fonctions et travailler avec les séries temporelles .

Conclusion générale et perspectives

Conclusion générale :

Ce travail de recherche, nous a permis de découvrir les difficultés de la maîtrise des risques dans le domaine industriel. Il nous a permis aussi de maîtriser l'utilisation de manière pratique une méthode connexionniste (méthode bayésienne) pour un système complexe (le réseau électrique).

La sûreté de fonctionnement du système électrique est donc d'assurer le fonctionnement normal du système et de limiter les nombres d'incidents et de réduire la gravité de leurs conséquences.

Les réseaux bayésiens sont actuellement une des techniques les plus intéressantes de l'intelligence artificielle, car ils permettent la représentation de la connaissance par un graphe causale intuitif et compréhensible. De plus ils sont basés sur des probabilités, ils intègrent l'incertitude dans le raisonnement

Ce puissant outil permet d'une part la modélisation des défaillances dans les structures interconnectées, et d'autre part il permet d'intégrer les informations fournies par les experts ou par retour d'expérience, en plus c'est un moyen concis de représenter les relations d'indépendance conditionnelle.

On a aussi trouvé beaucoup de difficultés, car les données de Sonelgaz n'étaient pas suffisamment riches en situations et adaptables dans notre recherche.

Après cette approche, pour aller plus loin, il serait intéressant de se pencher sur les réseaux bayésiens dynamiques. Ceux-ci sont une répétition du réseau classique dans lesquels on rajoute un lien causal d'un pas de temps à l'autre.

L'objectif aussi de notre travail est de montrer que les réseaux de neurones reposent à présent sur des bases mathématiques solides qui permettent d'envisager des applications industrielles à grande échelle, notamment dans le domaine de la modélisation. Si la résolution de problèmes difficiles nécessite toujours - et nécessitera encore très longtemps - beaucoup de travail et un éventail étendu de connaissances en statistiques, traitement du signal, automatique, Les réseaux de neurones permettent une approche efficace et générique des problèmes non linéaires et de déceler les ruptures dans les séquences temporelles.

L'association des réseaux de neurones pour détecter l'événement des modes défaillants avec des réseaux de bayes modélisant leurs propagation à travers le réseau de distribution permettent de concevoir et développer de nouveaux systèmes de diagnostic .

Pour conclure, nous estimons que les réseaux Bayésiens et les réseaux de neurones sont des outils prometteurs dans le domaine de la surveillance des procédés complexes, une nouvelle voie malheureusement très peu exploitée jusqu'à présent et qui mériterait d'être davantage approfondie dans l'avenir.

Ce sujet, modélisation des défaillances et leur propagation dans les structures industrielles interconnectées, mérite d'être poursuivi et approfondi.

Bibliographie :

- [1] «Réseaux Bayésiens » : Patrick Naim, Pierre-Henri Wuillemin, Philippe Leray, Olivier Pourret, Anna Becker. 2004 Eddition Eyrolles
- [2] Isermann, R. and P. Balle (1997). Trends in the Application of Model-Based Fault Detection and Diagnosis of Technical Processes, Control Engineering, institute of Automatic Control, Laboratory of Control Engineering and Process Automation, Darmstadt University of Technology, Landgraf-Georg. Str. 4, D-64283, Darmstadt, Germany –sciencedirect 7 may 1998
- [3] Verron, S. Diagnostic et surveillance des processus complexes par réseaux bayésiens.Thèse de doctorat de l’Université d’Angers, 2007.
- [4] Jean-Noël Chatain. Diagnostic par système expert. Traité des nouvelles technologies. Série Diagnostic et maintenance. Hermes Sciences Publications, 1993.
- [5] Jean Faucher. Pratique de l’AMDEC. Dunod, 2004.
- [6] Gilles Zwingelstein. Diagnostic des défaillances, théorie et pratique pour les systèmes industriels. Ed. HERMES, 1995.
- [7] R.O.Duda, P. E. Hart, et D. G. Stork. Pattern Classification 2nd Edition.Wiley,2001.
- [8] Bernard Dubuisson. Diagnostic, intelligence artificielle et reconnaissance des formes.Traité IC2 information. Série productique.Hermès sciences publications2001
- [9] JEROME H. FRIEDMAN . Regularized discriminant analysis. J. Amer. Statist. Assoc, Department of Statistics and Stanford Linear Accelerator Center Stanford University, Stanford CA 94309 -1989
- [10] T.M. Cover et P.E. Hart. Nearest neighbor pattern classification. IEEE Transactions on Information Theory, 13 :21–27, 1967.
- [11] Antoine Cornuéjols, Laurent Miclet, et Yves Kodratoff. Apprentissage artificiel : concepts et algorithmes. Eyrolles, 2002.
- [12] Vladimir N. Vapnik. The Nature of Statistical Learning Theory.books Springer-Verlag New York, Inc. New York, NY, USA 1995
- [13] Gérard Dreyfus, Jean-Marc Martinez, Manuel Samuelides, Mirta Gordon, Fouad Badran, Sylvie Thiria, et Laurent Hérault. Réseaux de neurones : Méthodologie et applications. Eyrolles, 2éme édition, 2004.

- l'article du n° 678 du magazine Mesures (Octobre 95) intitulé : " Vision Industrielle : les réseaux de neurones font leurs preuves ")
- [14] N. Friedman, D. Geiger, et M. Goldszmidt. Bayesian network classifiers. *Machine Learning*, 29(2-3) :131–163, 1997.
- [15] Olivier Parent et Julien Eustache «Réseaux Bayésiens à la recherche de la vérité» http://liris.cnrs.fr/~amille/enseignements/master_ia/rapports_2006/ReseauBayesien-SYNTHESE-ECRITE.pdf
- [16] Thèse Abeljabbar Bensalem Université Henri Poincaré - Nancy I (07/03/2008), Benoît IUNG (Dir.) Modèle probabiliste de séquences temporelles et fusion de décision. application à la classification de défauts de rail et leur maintenance
- [17] Thèse de Doctorat de l'Institut National Polytechnique de Toulouse. Stéphanie Jonquière :Applications des réseaux bayésiens à la reconnaissance active d'objet 3D ». 14 Janvier 2004
- [18] Andres L. Madsen and Lars Nielson: «Deep green a bridge playing system based on Bayesian networks». 2008
- [19] Alain BOUCHER : Rapport du travail d'intérêt personnel «Réseaux Bayésiens ». http://www2.ifi.auf.org/rapports/tpe-promo10/tipe-nguyen_trung_thanh.pdf
- [20] Philippe Leray : «Réseaux Bayésiens définition-inférence », <http://asi.insa-rouen.fr/enseignement/siteUV/rna/Cours2/08-RB-Def-Inf.pdf> .
- [21] Jean Baptise : « Les réseaux bayésiens Introduction élémentaire et intuitive ». http://www2.agrocampus-ouest.fr/math/donnees/RB/td.09_11_10.rb_agrorennes.pdf
- [22] Michel Aguet : «Sûreté des grands réseaux électrique ». 1er Juillet 2005. <http://lme.epfl.ch/webdav/site/lme/users/wetter/public/forum05/agueta1.pdf>
- [23] BayesiaLab documentation. Copyright 2001-2008 copyright BayesiaSA
- [24] Kamel Medjaher « Diagnostic et pronostic de défaillances par réseaux bayésiens » published in "Journées Francophone sur les Réseaux Bayésiens, Lyon : France (2008)"