

M0020/95A

الجمهورية الجزائرية الديمقراطية الشعبية  
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي  
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR

ECOLE NATIONALE POLYTECHNIQUE - ALGER -

DEPARTEMENT DE GENIE ELECTRIQUE

## THESE DE MAGISTER

المدرسة الوطنية المتعددة التخصصات  
BIBLIOTHEQUE — المكتبة  
Ecole Nationale Polytechnique

### CONTRIBUTION A L'EVALUATION PAR RESEAU DE NEURONES ARTIFICIELS DE LA SECURITE STATIQUE DES RESEAUX DE TRANSPORT ELECTRIQUE

Soutenu publiquement le 28 juin 1995 par:

Djamel - Eddine BOUROUBA  
*Ingénieur diplômé de l'ENP*

#### MEMBRES DU JURY:

Président:	Mr BOUBAKEUR	-	Maître de conférence	- ENP.
Rapporteur:	Mr HELLAL	-	Chargé de cours (PhD)	- ENP.
Examineurs:	Mr BOUDJEMA	-	Maître de conférence	- ENP.
	Mr BOUCHERIT	-	Chargé de cours (PhD)	- ENP.
	Mr SOUAMI	-	Chargé de cours (PhD)	- ENP.

## REMERCIEMENTS

*Je tiens à remercier avant tout, Docteur AGGOUNE qui m' a intéressé au sujet de l'application des réseaux de neurones dans le domaine des réseaux électriques, et qui m'a proposé d'en faire mon sujet de thèse de magister. Il a été un interlocuteur privilégié, de par sa compétence et ses réflexions.*

*Je remercie Docteur HELLAL, qui a accepté de diriger ce travail, et qui l'a marqué de son intérêt en y apportant de précieux conseils et avis.*

*Je remercie Docteur BENSENOUCI pour avoir co-dirigé ce travail.*

*Monsieur le Docteur MAUN du département de génie électrique de l'Université Libre de Bruxelles m'a accordé un entretien, et m'a procuré une documentation précieuse, lors de mon séjour à Bruxelles en mars 1993. Je l'en remercie tout particulièrement.*

*J'adresse également mes remerciements à Messieurs BOUDJEMA, BOUCHERIT, et SOUAMI pour avoir accepté d'examiner ce travail.*

*Je remercie enfin, mes parents, et mes frère et soeur, pour leur soutien pendant ces années de travail.*

## SOMMAIRE

Chapitre I: INTRODUCTION GENERALE . . . . .	1
I.1. Notions de sécurité statique dans les réseaux électriques . . . . .	1
I.2. Problèmes des études de sécurité statique . . . . .	4
I.3. Etat de l'art . . . . .	5
I.3.a. Les techniques classiques . . . . .	5
I.3.b. Les techniques modernes . . . . .	11
I.4. Formulation de la problématique dans l'optique connexionniste . . . . .	14
 Chapitre II: LES RÉSEAUX DE NEURONES . . . . .	 16
II.1. Présentation . . . . .	16
II.1.a. Neurone formel . . . . .	16
II.1.b. Modes d'apprentissage . . . . .	19
II.1.b.1. Apprentissage supervisé . . . . .	20
II.1.b.2. Apprentissage non-supervisé . . . . .	27
II.2. Les réseaux de Neurones dans l'évaluation de la sécurité statique . . . . .	30
II.3. Discussion . . . . .	31
II.3.a. L'erreur d'échantillonnage . . . . .	31
II.3.b. Le choix de l'espace fonctionnel . . . . .	32
II.4. Conclusion . . . . .	33

Chapitre III: MODELE D'ECOULEMENT DE CHARGE . . . . .	35
III.1.Hypothèses et conditions requises . . . . .	35
III.2.Développement d'un modèle d'écoulement de charge dynamique . . . . .	37
III.2.a.Introduction . . . . .	37
III.2.b.Développement de l'algorithme . . . . .	38
III.2.b.1.Facteurs de participation . . . . .	38
III.2.b.2.Modification de l'écoulement de charge standard (FDLF) . . . . .	40
III.2.c.Performances du modèle . . . . .	48
III.3.Conclusion . . . . .	55
 Chapitre IV: GENERATION DE L'ENSEMBLE DE DONNEES (Application au réseau IEEE 14 noeuds) . . . . .	56
IV.1.Algorithme général . . . . .	56
IV.2.Les différents ensembles générés . . . . .	58
IV.2.a.Variation en profondeur du plan de charge	58
IV.2.b.Variation en surface du plan de charge . . . . .	59
IV.3.Etude de sensibilité . . . . .	63
IV.3.a.Analyse des données . . . . .	63
IV.3.b.Résultats et observations . . . . .	66
IV.4.Conclusion . . . . .	67
 Chapitre V: CONSTRUCTION DU RESEAU DE NEURONES MULTICOUCHES (Application au réseau IEEE 14 noeuds) . . . . .	69
V.1.Dimensionnement de la couche cachée . . . . .	69
V.1.a.Préparation de l'ensemble d'apprentissage et de test . . . . .	69
V.1.b.Principe de la construction incrémentale . . . . .	70
V.1.c.Formation du réseau de neurones . . . . .	72

V.1.c.1. Formation par durée d'apprentissage fixe et erreur libre . . . . .	74
V.1.c.2. Formation par erreur fixe et durée d'apprentissage libre . . . . .	76
V.1.d. Conclusion . . . . .	78
V.2. Amélioration des performances . . . . .	80
V.2.a. Amélioration par dimensions de l'ensemble d'apprentissage . . . . .	80
V.2.b. Amélioration par spécialisation du réseau de neurones . . . . .	83
V.3. Conclusion . . . . .	85
CONCLUSION GENERALE . . . . .	86
A N N E X E . . . . .	89
Formation des matrices [B'] et [B''] de l'écoulement de charge rapide découplé (FDLF) . . . . .	90
Définitions . . . . .	93
Démonstration de l'équation (III.24) . . . . .	94
Données du réseau standard IEEE 14 noeuds . . . . .	95
Données du réseau standard IEEE 30 noeuds . . . . .	97
Résultats du réseau de neurones finale . . . . .	100
Références Bibliographiques . . . . .	103

## LISTE DES FIGURES

Figure I.1 Evolution de l'état d'un réseau . . . . .	3
Figure I.2 Organigramme de filtrage par facteur de performance . . . . .	6
Figure I.3 Erreurs engendrées par les méthodes ordinales. . . . .	8
Figure I.4 Organigramme de sélection des contingences critiques . . . . .	9
Figure I.5 Volume de sécurité à deux dimensions. . . . .	13
Figure II.1 Le neurone formel . . . . .	17
Figure II.2 Fonctions d'activations . . . . .	18
Figure II.3 Réseau de neurones multicouche . . . . .	20
Figure II.4 Séparation de classes à l'aide d'une unité ADALINE . . . . .	21
Figure II.5 Perceptron Multicouche. . . . .	22
Figure II.6 RN multicouches à fonction de transfère sigmoïde . . . . .	24
Figure II.7 Réseau de KOHONEN ou de type carte topologique	28
Figure II.8 Répartition spatiale du facteur d'apprentissage en fonction du degré de voisinage, selon une loi dite du "Chapeau du Mexicain" . . . . .	29
Figure II.9 Répartition spatiale du facteur d'apprentissage en fonction du degré de voisinage selon une loi exponentielle . . . . .	30
Figure II.10 Evolution des critères (erreur) $C(f^{(n)}, K)$ et $C(f^{(n)}, K')$ . . . . .	33
Figure III.1 Organigramme de l'écoulement de charge découplé rapide dynamique (actif). . . . .	46
Figure III.2 Organigramme de l'écoulement de charge découplé rapide dynamique (réactif). . . . .	47
Figure III.8 Réseau IEEE 14 noeuds modifié . . . . .	54
Figure IV.1 Distribution du facteur multiplicateur de puissance apparente . . . . .	59
Figure IV.2 Distribution normale de $\text{tg}(\varphi)$ . . . . .	60
Figure IV.3 Distribution en surface de la charge apparente moyenne (pu) du réseau I3E14 d'étude . . . . .	61

Figure IV.4 Distribution de la charge active moyenne (pu) du réseau I3E14 d'étude . . . . .	61
Figure IV.5 Distribution en surface de la charge réactive moyenne (pu) du réseau I3E14 d'étude. . . . .	62
Figure IV.6 Sensibilité du vecteur caractéristique à la variation et à la modélisation de la charge. . . . .	67
Figure V.1 Performance en fonction de la durée d'apprentissage . . . . .	74
Figure V.2 Performances de mémorisation et de généralisation en fonction de $h$ . (Critère d'arrêt: Durée d'apprentissage). . . . .	75
Figure V.3 Performance totale du RN . . . . .	76
Figure V.4 Performances de mémorisation et de généralisation en fonction de $h$ . (Critère d'arrêt: Erreur REQM). . . . .	77
Figure V.5 Configuration finale du réseau de neurone retenu	78
Figure V.6 Recherche de la dimension optimale de l'ensemble d'apprentissage . . . . .	81
Figure V.7 Construction du réseau spécialisé. . . . .	84

## LISTE DES TABLEAUX

Tableau III.1. Performances de calcul avec B1 comme "slack bus", charges non modélisées. . . . .	48
Tableau III.2. Performances de calcul avec B1 comme "slack bus", charges modélisées. . . . .	49
Tableau IV.1. Résumé des vecteurs caractéristiques . . . . .	66
Tableau V.1. Effectifs des ensembles nécessaires à la formations du réseau de neurones. . . . .	70
Tableau V.2. Evolution des coefficients d'apprentissage. . . . .	72
Tableau V.3.1 Performance du réseau de neurones généraliste, dans l'évaluation de la sécurité statique du réseau I3E14. . . . .	79
Tableau V.3.2. Statistiques des réponses correctes du réseau de neurones généraliste, dans l'évaluation de la sécurité statique du réseau I3E14. . . . .	79
Tableau V.4.1 Performances comparées après augmentation des dimensions de l'ensemble d'apprentissage . . . . .	82
Tableau V.4.2. Statistiques comparées des réponses correctes après augmentation des dimensions de l'ensemble d'apprentissage . . . . .	82
Tableau V.5. Effectif de chaque type de danger dans la base de données . . . . .	84
Tableau A.1. Eléments utilisés pour former [B'] et [B"] dans la variante BB du FDLF. . . . .	91
Tableau A.2. Formation des matrices [B'] et [B"]. . . . .	92
Tableau A.3. Distinction des types de FDLF. . . . .	92

*"L'intelligence, cherche quelquefois des choses qu'elle ne trouve pas, et l'instinct seul, trouve de son côté, ces choses qu'il ne cherche pas"*

*Extrait de "La durée chez Bergson"*  
*Osman E. CHAHINE*

## CHAPITRE I

### INTRODUCTION GENERALE

Le premier objectif d'une compagnie d'électricité est de satisfaire la demande de ses clients en énergie électrique de la façon la plus économique, tout en assurant un niveau acceptable de qualité de service.

Ceci sous-entend une alimentation ininterrompue en énergie électrique dans des conditions strictes de fréquence et de tension.

Malheureusement, une des caractéristiques inhérentes au fonctionnement des réseaux, est la présence constante de perturbations. Ces perturbations peuvent être d'origine interne au système, comme la variation aléatoire de la charge, le fonctionnement intempestif de protections... Ou d'origine externe, tels que la foudre, le vent, avec des conséquences aussi diverses que l'ouverture d'une ligne, la perte d'un générateur...

Pour cela, un certain nombre d'études sont menées hors ligne et en ligne, de façon répétitive, de manière à comprendre et à être capable de prévoir les conséquences des différentes perturbations, de pouvoir les éviter ou y faire face en prenant des décisions adéquates dans la conduite du réseau.

Les études de sécurité font partie des études le plus fréquemment menées.

#### I.1. Notions de sécurité statique dans les réseaux électriques

Les générateurs, les lignes et les transformateurs d'un réseau électrique sont caractérisés par des limites physiques de

production et de transfert, qui ne doivent jamais être dépassées en régime permanent sous peine de détérioration grave.

Pour ces raisons de sécurité des matériels, et d'autres de qualité de service, des limites d'exploitation sont imposées aux transits de puissance (courants) et aux tensions nodales.

Mathématiquement, ceci s'exprime comme suit:

$$CT_{Flow} \leq CT_{lim} \quad \text{et} \quad V_{min} \leq V \leq V_{max} \quad ^1$$

Lorsque toutes ces équations et inéquations sont satisfaites, alors le système est dit en fonctionnement normal (normal operating state).

L'un des buts de la conduite des réseaux est de maintenir ce mode de fonctionnement. Mais en pratique, les perturbations peuvent entraîner le système dans des états indésirables.

Le système sera dit en fonctionnement sûr (secure operating state) ou à l'état préféré, si pour toute perturbation, ce dernier reste en fonctionnement normal, sinon il sera dit en fonctionnement dangereux (insecure operating state) ou en état d'alerte.

Un réseau électrique doit être maintenu donc, en état préféré le plus longtemps possible. Si le système se déplace en état d'alerte des actions de contrôle doivent être entreprises pour le ramener à l'état préféré (Cf. Figure I.1). Sinon, il risque, suite à un événement contingent de se déplacer en état d'urgence, où, une ou plusieurs contraintes électriques apparaissent. Ces dernières doivent être levées le plus vite possible, par des actions correctives, ou de sauvetage, souvent coûteuses, telle que les délestages.

Dans les études de sécurité il est défini trois types de sécurité des réseaux:

---

CT: Capacité de Transit.

V: Tension

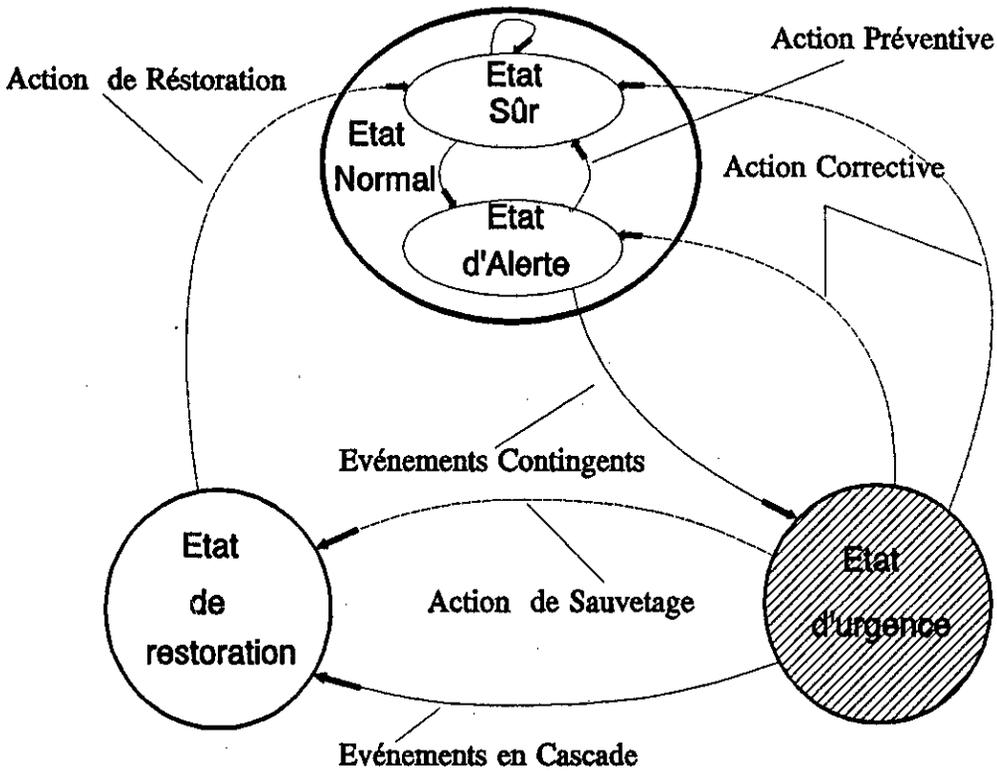


Figure I.1 Evolution de l'état d'un réseau

- La Sécurité Statique : Un système est dit statiquement sûr pour une perturbation, s'il reste en fonctionnement normal après cette dernière, dans l'intervalle de temps qui sépare l'action rapide des régulateurs du réseau pour équilibrer la charge et la production, et les actions lentes telles que celles des régleurs en charge des transformateurs ainsi que les actions humaines.

- La Sécurité Dynamique et/ou Transitoire : Un système est dit dynamiquement sûr ou transitoirement sûr, pour une perturbation donnée, s'il survit du point de vue de la stabilité dynamique et/ou transitoire à cette perturbation.

Lorsqu'on fait une étude de sécurité statique on suppose toujours que le système a survécu à la période transitoire ou dynamique.

## I.2.Problèmes des études de sécurité statique

Le but de l'analyse de la sécurité est de savoir :

- 1- Si le système est en état d'alerte ou pas ?
- 2- Si le système est en état d'alerte, alors comment le ramener à un état de préférence, voir économique ?
- 3- Si une perturbation survient, comment sauvegarder le fonctionnement du réseau à moindre frais ?

Les problèmes des études de sécurité se situent à ces trois niveaux, que cela soit dans une phase de planification, en cherchant à construire le réseau le plus sûr possible ou en phase de conduite, afin de prévenir et pouvoir faire face à toute perturbation.

La réponse à la première question constitue l'axe de ce travail, c'est l'évaluation de la sécurité statique d'un réseau électrique.

Cette dernière tâche est un pré-requis à toute action dans la conduite d'un réseau. Elle consiste en général à simuler des ouvertures de lignes et des décrochages de générateurs, pour en voir les conséquences sur les tensions nodales et la circulation de puissance dans les lignes.

Mais, établir une liste exhaustive des perturbations probables est quelque chose d'impossible, lorsqu'on voit les temps de calcul que cela nécessite à la simulation, et les coûts que cela entraîne pour les grands réseaux.

De plus, dans le contexte opérationnel, la contrainte du temps réel, fait qu'il est très difficile de développer une analyse détaillée des perturbations. D'autant plus que le système est en mouvement constant, et que pour chaque point de fonctionnement, correspond une liste de perturbations critiques différente de celle qu'on pourrait établir lors des études hors ligne.

D'un autre côté, établir une liste restreinte de perturbations ayant le plus d'impact, d'après l'expérience et l'intuition des planificateurs ou des "dispatchers", peut s'avérer inadéquat vu son manque de rigueur et d'objectivité par essence (possibilité d'omission de cas critiques).

Pour ces raisons, différentes approches du problème ont été menées, pour pouvoir définir une méthode objective et efficace d'évaluation de la sécurité statique.

### I.3. Etat de l'art

#### I.3.a. Les techniques classiques

Les méthodes communément utilisées sont des méthodes ordinales ou dites de classement. Ces techniques partent du fait que dans l'ensemble des contingences que peut subir logiquement un réseau, seulement un sous-ensemble de ce dernier est réellement critique.

Le but étant de filtrer cet ensemble de contingences, un facteur de performances  $J$  est défini, afin de servir de critère de classement des perturbations selon leur gravité. Ce facteur  $J$  est calculé pour l'ensemble des contingences possibles, puis classé par ordre décroissant. Choissant un facteur seuil  $J_{th}$ , on extrait le sous-ensemble des contingences critiques, c'est à dire celles qui ont un facteur  $J$  supérieur à  $J_{th}$  ( Cf. Figure I.2) [1], [6], [8].

Une multitude de facteurs de performances ont été utilisés et cités dans la littérature [8] dont la forme générale est :

$$J = \sum_i w_i \cdot \| f_i(z) \|^2 \quad (I.1)$$

où :

$f_i$  : est une fonction linéaire.

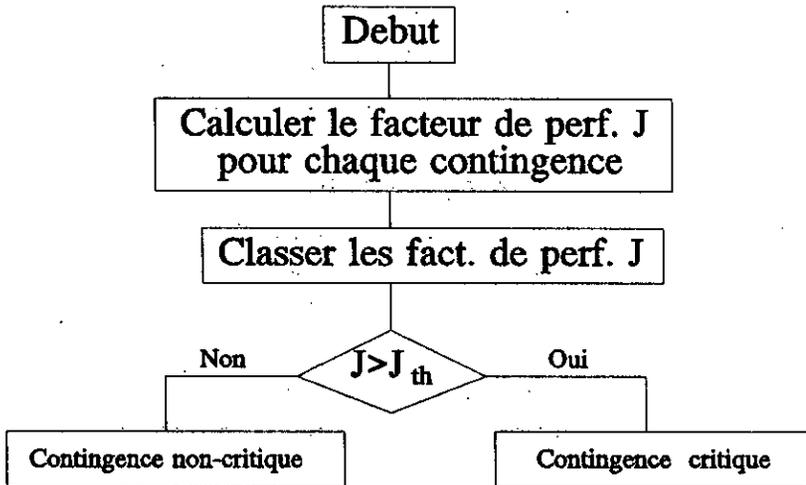


Figure I.2 Organigramme de filtrage par facteur de performance

- $z_i$  :  $P_{li}/CT_{li}$  ( Puissance en circulation dans la ligne l sur la limite de transfert de la ligne l )
- $\Delta V_i/\Delta V_i^{lim}$  ( Ecart entre la tension nodale (i) et la tension nodale nominale sur l'écart limite admis. )
- $w_i$  : Facteur de pondération.
- $|| \cdot ||^m$  : Norme euclidienne d'ordre m.

La différence majeure des différents facteurs de performance réside dans le choix des poids  $w_i$  et de la norme  $p$ .

Les méthodes dites ordinales, diffèrent aussi dans la manière de calculer les variables d'état servant au calcul du facteur de performance.

Ainsi diverses méthodes, de calculs directs, ont été adoptées selon les auteurs pour l'estimation des variables d'état, tel que l'écoulement de charges linéarisé (D.C. Load Flow), ou la méthode des circuits équivalents (Théorème de Tellegen) [6], [24].

D'autres chercheurs, au lieu de calculer les facteurs de performance en valeur absolue, calculent la variation relative de

(ex: supposer que la boule de sécurité est convexe, ou que ses contours sont linéaires ...) [8] ou subjectives ( ex: choix de  $p$  entre 5 et 20 pour minimiser le masquage...).

Ainsi l'organigramme de classification se voit complété comme sur la Figure I.3.

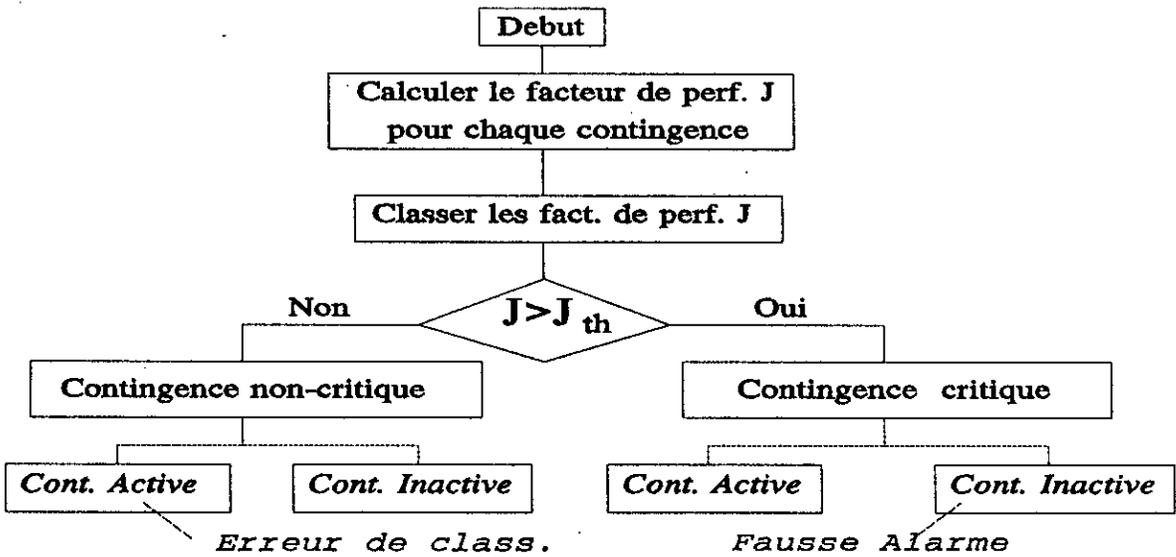


Figure I.3 Erreurs engendrées par les méthodes ordinales.

Enfin, après établissement de la liste critique, le fait d'utiliser des calculs itératifs pour s'assurer du danger d'une contingence donnée, peut s'avérer être un inconvénient en exploitation en ligne.

D'autres méthodes sont utilisées aussi, telles que celles dites de sélection.

Le principe d'extraction du sous-ensemble des contingences critiques est toujours présent, sauf qu'on ne calcul pas de facteur de performance.

L'ensemble total des contingences est passé au crible par un calcul simplifié, non précis, où l'on se base sur la présence de

dépassements éventuels pour lancer un calcul complet pour la contingence soupçonnée.

La plupart de ces techniques adoptent des calculs d'écoulements de charge 1P.1Q, c'est à dire, à une itération en partant des variables d'état du cas de base sain, voir organigramme de la Figure I.3.

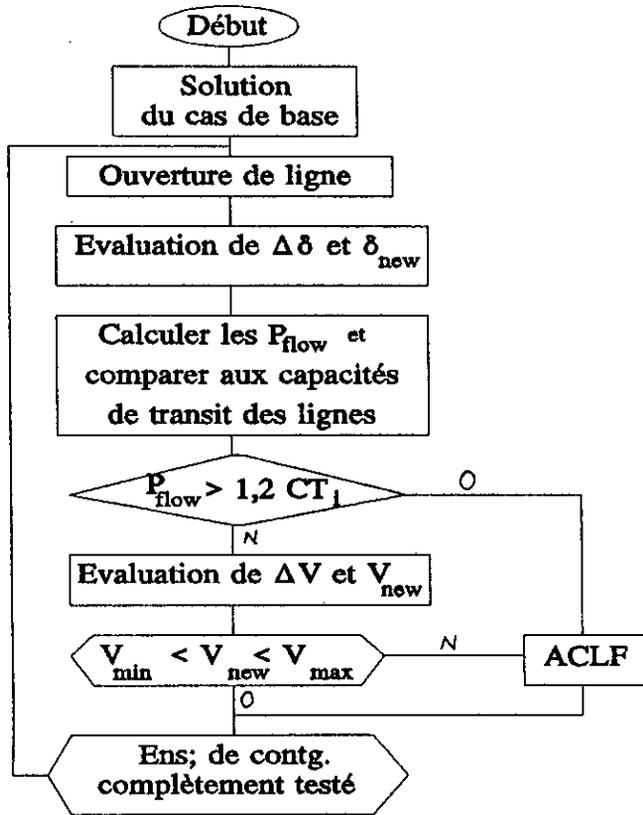


Figure I.4 Organigramme de sélection des contingences critiques

Le calcul des vecteurs  $[\Delta\delta]$  et  $[\Delta V]$  est obtenu en une itération de l'écoulement de charge découplé rapide ("Fast Decoupled Load Flow") (1P.1Q), solution du système suivant [17]:

$$[\Delta P/V] = [B'] \cdot [\Delta \delta]$$

$$[\Delta Q/V] = [B''] \cdot [\Delta V]$$

Lorsqu'il y a changement dans la topologie du réseau, les matrices  $[B']^{-1}$  et  $[B'']^{-1}$  sont modifiées selon la correction de Sherman-Morrison [24], [1]. Ainsi, il n'est pas nécessaire de reconstruire  $[B']$  et  $[B'']$  puis de les inverser à nouveau.

Une simplicité évidente apparaît dans l'approche effectuée, pour le traitement des contingences, d'où une facilité de mise en place et d'intégration dans les centres de conduite.

Néanmoins, le problème majeur qui persiste, c'est le grand nombre de contingences à tester.

C'est ainsi que tous les travaux adoptant les méthodes de sélection, se concentrent sur les moyens d'introduire des pré-filtrages, qui se basent sur la spécificité du réseau, ou sur les cycles annexes de traitements des centres de conduites [2], [4].

Enfin, les techniques de sélection sont plus efficaces que les techniques de classement, déjà dans le taux de capture des contingences critiques, vu que l'estimation du danger d'une contingence se fait en testant toutes les lignes et/ou tous les noeuds, en jugeant sur la première violation rencontrée.

Ainsi, le masquage qu'entraînerait le calcul d'un facteur de performance et le choix d'un seuil limite servant au filtrage, est éliminé. De plus, le temps de calcul nécessaire au traitement des facteurs de performances, la mémoire requise pour le stockage des informations concernant la liste des contingences, se voient sensiblement améliorés [1].

Néanmoins, avec les méthodes de sélection, les temps de calculs, restent encore importants pour des évaluations en temps réel (de l'ordre de la dizaine de minutes). Ceci est dû au nombre important de contingences à tester, surtout lorsqu'on tient compte des combinaisons de ces dernières (c'est à dire: Perte de 2 lignes indépendantes, Perte 1 groupe + 1 ligne ...) [1].

$W=(w_0, w_1, \dots, w_n)^t$  vecteur poids ou paramètres, à déterminer par apprentissage.

Cette fonction de décision répondra, suivant les variables du réseaux  $(z_1, \dots, z_n)$ , à l'évaluation de l'état du réseau, pour savoir si ce dernier est dans un état sûr ou pas.

La réponse sera de type binaire.

ex: Si  $S(Z) \geq 0$  alors l'état est sûr

Si  $S(Z) \leq 1$  alors l'état est d'alerte.

L'apprentissage, est l'opération qui permet de déterminer l'ensemble des poids  $\{w_0, w_1, \dots, w_n\}$ , en fonction d'un ensemble d'apprentissage.

L'ensemble d'apprentissage, est un ensemble formé de plusieurs exemples vecteurs  $Z$ . Chaque vecteur dans cet ensemble, est libellé comme appartenant à l'une des deux classes (sûr, alerte) que devra utiliser le classificateur.

Pour déterminer le vecteur  $W$ , plusieurs techniques sont utilisées. Les plus connues sont la méthode des moindres carrés, ou les méthodes de programmation linéaire. Ces dernières chercheront le vecteur  $W$  qui minimisera le nombre de mauvais classements.

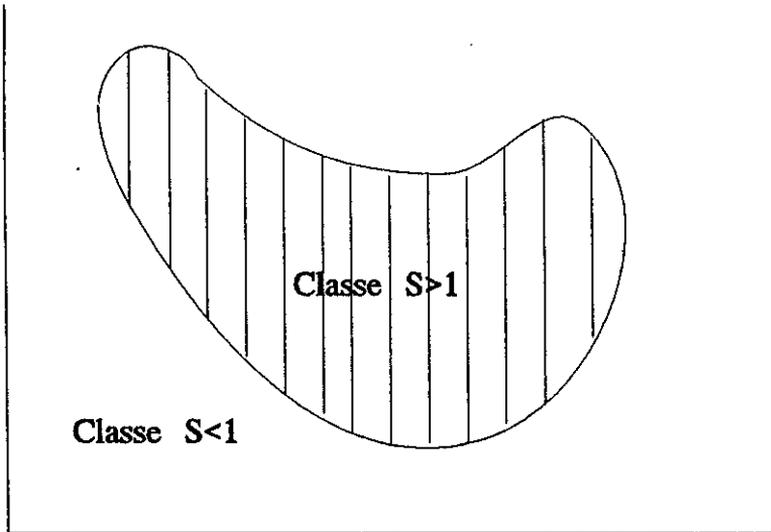
L'approche par la reconnaissance de formes, de la sécurité des réseaux, est une approche originale qui simplifie grandement le problème d'évaluation et d'analyse [14].

Les premiers avantages apportés par ces techniques sont:

- la rapidité de diagnostic,
- la capacité de généralisation,
- la robustesse.

Ces dernières caractéristiques sont essentielles dans l'exploitation en temps réel. Néanmoins, la modélisation de la fonction de décision par une forme linéaire, n'est pas adéquate pour décider de la sécurité d'un réseau, étant donné que les

régions de sécurité sont définies par des hypervolumes concaves et courbes [8].



Il n'existe aucune droite pouvant séparer la surface hachurée du domaine vierge l'entourant.

**Figure I.5** Volume de sécurité à deux dimensions.

De plus, les régions de sûreté et d'alerte sont des régions géométriquement complémentaires. Donc ce type de fonctions est inadéquat, vu que le problème est non séparable linéairement (Cf. Figure I.5).

Les modèles de fonctions utilisés dans le domaine de la reconnaissance de formes, se retrouvent dans les modèles de réseaux connexionnistes, sous le nom d'ADALINE et de MADALINE [25].

Ces derniers sont des réseaux linéaires, mais bien qu'ils soient adaptatifs, ils ne peuvent servir à résoudre des problèmes non séparables linéairement (Cf. problème "XOR" traité par McClelland & Rumelhart [27]).

Par contre, des modèles de fonctions plus appropriés et aussi rapides en calcul ont été apporté par les réseaux de neurones multicouches.

#### I.4. Formulation de la problématique dans l'optique connexionniste

Les réseaux de neurones (RN), sont des modèles connexionnistes inspirés du système nerveux biologique, et sont utilisés pour modéliser des tâches cognitives, tel que la reconnaissance de formes complexes dans des environnements bruités.

Par ces qualités, cet outil se voit être un moyen intéressant dans une utilisation en ligne dans un centre de conduite de réseaux électrique.

Par contre, les inconvénients des RN, apparaissent essentiellement lors de leur conception. Que cela soit, dans le choix des données d'apprentissage, ou bien dans leur dimensionnement (nbre de couches et de neurones).

Il n'y a pas à nos jours, de méthodes systématiques pour lever ces contraintes, et pour peu que l'on ne fasse pas le bon choix de ces paramètres, les résultats fournis par le RN s'en trouvent altérés.

Tenant compte de ces considérations, ce travail, a pour objectif d'appliquer un modèle neuronal à l'évaluation de la sécurité statique des réseaux électriques.

A cette fin, il est particulièrement investi le problème du choix des données à fournir comme base d'apprentissage au réseau de neurones, ainsi que le dimensionnement et l'optimisation des performances de ce dernier.

Cette recherche est menée à travers le réseau standard IEEE 14 noeuds, comme support d'application.

Ce document est structuré comme suit:

Le chapitre suivant est consacré à la théorie des réseaux de neurones, aux problèmes inhérents à ces modèles, ainsi qu'à leur utilisation dans l'évaluation de la sécurité statique des réseaux électriques.

Par la suite, dans le chapitre III, afin de générer une base d'apprentissage aussi riche que possible, il est développé un modèle d'écoulement de charge réaliste, tenant compte du comportement d'un réseau électrique lors de contingences. La modélisation du réglage primaire des générateurs ainsi que la modélisation des charges y sont introduites.

Dans le chapitre IV, une attention particulière est portée à la génération de l'ensemble de données qui servira à extraire l'ensemble d'apprentissage du RN, il y est étudié l'influence de ce dernier sur la construction du modèle neuronal.

Enfin, dans le chapitre V, il est défini une méthode de dimensionnement efficace du modèle connexionniste, de plus il y est tenté d'améliorer ses performances.

## CHAPITRE II

### LES RÉSEAUX DE NEURONES

#### II.1. Présentation

Depuis l'avènement des ordinateurs et malgré leur forte évolution, ces derniers ne peuvent toujours pas égaler l'être humain dans certaines de ces fonctions.

La différence principale qui apparaît lorsque l'on compare le mode de fonctionnement d'un ordinateur et d'un cerveau humain, est que le premier est constitué généralement que d'un processeur qui exécute séquentiellement des instructions complexes programmées, alors que le deuxième est constitué de milliards de cellules nerveuses (neurones), fortement interconnectées, exécutant chacune une fonction très simple, sans programmation préalable, mais subissant plutôt un apprentissage.

Les Réseaux de Neurones Artificiels (RNA) ou réseaux connexionnistes sont des modèles simplistes inspirés des systèmes nerveux biologique, développés dans l'espoir de comprendre le fonctionnement de ces derniers et de pouvoir tirer profit de leurs performances.

#### II.1.a. Neurone formel

On rappelle tout d'abord le modèle du neurone formel introduit en 1943 par Mac Culloch et Pitts. Un neurone formel  $i$  est caractérisé par:

- i) un état interne  $x_i$
- ii) un ensemble de  $n$  voisins  $\{x_j\}$  avec qui des signaux sont échangés

iii) une fonction de transition d'état, dite d'activation, qui permet de calculer l'état interne du neurone formel en fonction des signaux reçus de ses voisins.

L'ensemble des états possibles d'un neurone peut être booléen  $\{0,1\}$  -dans ce cas, l'état interne du neurone formel est dit actif ou inactif- ou bien un intervalle de  $\mathbb{R}$ .

L'évolution de l'état du neurone formel  $i$  est régie par la fonction de transition d'état  $F$  d'expression générale:

$$x_i(t) = F_i( x_i(t-1), x_1(t), \dots, x_n(t) ) \quad (II.1)$$

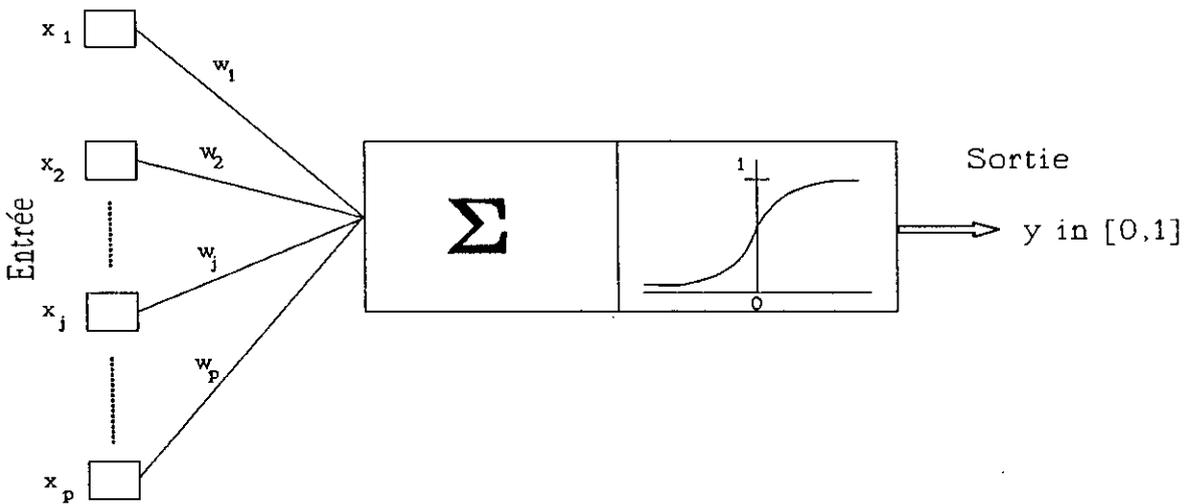


Figure II.1 Le neurone formel

Comme le montre la Figure II.1 , le calcul de la fonction  $F$  se décompose en deux étapes:

-d'une part, la somme sur tous les neurones formels voisins de leur contributions respectives, qui s'écrivent comme le produit entre l'état interne du neurone voisin et le poids de la connexion entre le neurone  $i$  et le neurone voisin  $j$ , noté  $w_{ij}$ :

-d'autre part, la transformation par une fonction  $g$  de la quantité obtenue à la première étape.

On peut donc écrire:

$$x_i = g\left(\sum_j \omega_{ij}x_j + \omega_{i0}\right) \quad (II.2)$$

où  $\omega_{i0}$  représente une valeur constante appelée biais  
 $g$  est la fonction de sortie appelée souvent fonction d'activation.

Lorsque les neurones prennent des valeurs booléennes, les fonctions  $g$  sont des fonctions à seuil de la forme:

$$g(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{si } x \leq 0 \end{cases} \quad (II.3)$$

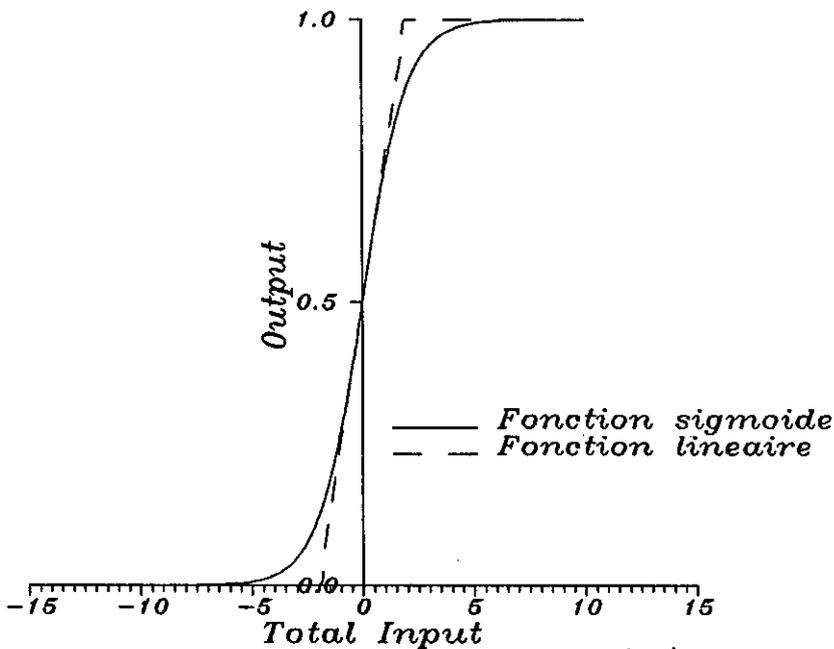


Figure II.2 Fonctions d'activations

Lorsque les neurones prennent leurs valeurs dans un intervalle réel, on peut utiliser des fonctions linéaires à saturation, afin

de garantir que les valeurs des états internes restent à l'intérieur borné, voir Figure II.2.

Cependant, on leur préfère généralement des fonctions non-linéaires et différentiables qui seront plus facile à manier dans les algorithmes d'apprentissage, mais qui aussi confèrent au neurone, à l'instar de la fonction sigmoïde (ou tanh), la capacité de mémorisation et de filtrage [25].

La fonction sigmoïde a pour expression:

$$g(X) = \frac{1}{1 + e^{-w_i^t \cdot X}} \quad (II.4)$$

où

$w_i^t$ : est la transposée du vecteur poids, de l'unité  $i$

$X_i$ : le vecteur d'entrée de l'unité  $i$

(voir Figure II.2).

Un réseau de neurones artificiels est donc défini comme un ensemble de neurones formels interconnectés dont l'évolution est régie par les fonctions de transition d'état associé à chaque neurone.

On désignera plus tard, par neurone ou unité, les neurones formels définis dans cette section.

### II.1.b. Modes d'apprentissage

Plusieurs modes d'apprentissage peuvent être distingués [25]. Ceux-ci se différencient principalement par le type d'exemples disponibles, et par la structure du réseau de neurone que l'on veut construire.

L'apprentissage supervisé, correspond au cas où l'on dispose d'exemples de la forme  $(X^p, Y^p)$ ,  $p=1, \dots, P$  et où l'on cherche à construire un modèle capable de prédire la valeur de  $Y$  connaissant

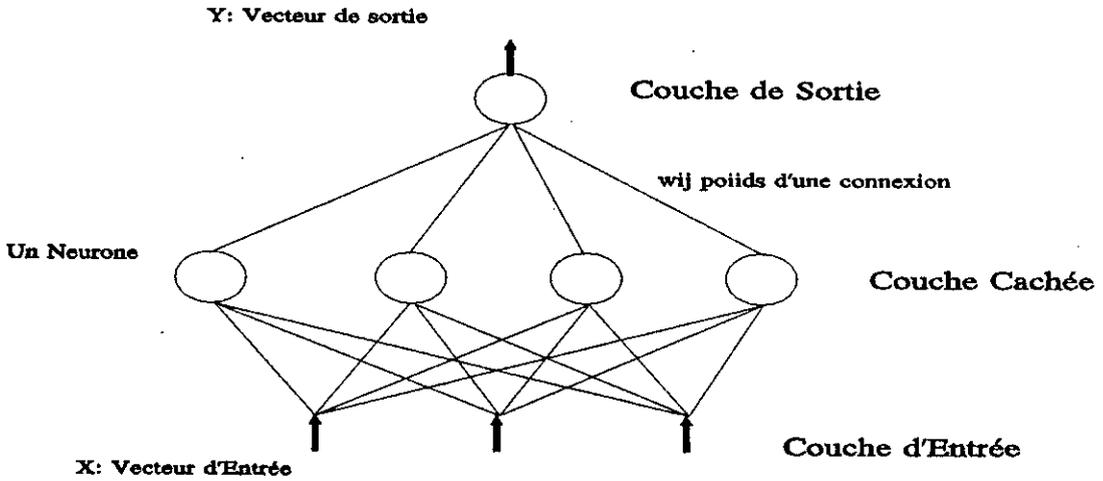


Figure II.3 Réseau de neurones multicouche

celle de X. Quelques modèles d'apprentissage supervisé seront présentés dans la section suivante.

Lorsque l'on ne connaît que les valeurs de X et que l'on cherche à réaliser une classification sur l'ensemble des exemples, on se trouve dans le cas de l'apprentissage non-supervisé.

### II.1.b.1. Apprentissage supervisé

L'apprentissage supervisé sera présenté à travers les quelques modèles connexionnistes d'apprentissage supervisé les plus connus - le Perceptron et les modèles multicouches entraînés par rétropropagation du gradient-.

#### Le Perceptron:

Le premier exemple de réseau construit à partir de neurones formels avait pour nom ADALINE (ADaptateur LINEaire) et visait à classer des catégories d'exemples linéairement séparables [25].

Les unités d'un réseau ADALINE sont réparties entre une couche d'entrée et une couche de sortie. La fonction de transition utilisée est une fonction à seuil qui permet de faire une

distinction entre deux classes et d'affecter un exemple à l'une des classes en fonction du signe de la valeur calculée, comme le montre la Figure II.4.

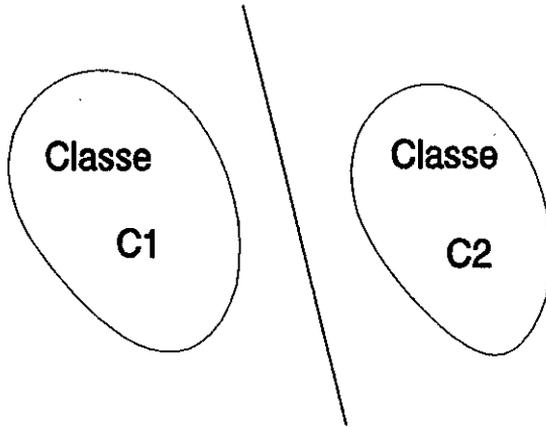


Figure II.4 Séparation de classes à l'aide d'une unité ADALINE

Pour déterminer la matrice des poids  $W$  qui permettra de classer automatiquement un ensemble d'exemples  $\{X^1, \dots, X^P\}$ , on minimise une fonction de coût  $C(W)$  quadratique:

$$C(W) = \frac{1}{2} \sum_p (W^t X^p - Y^p)^2 \quad (II.5)$$

où  $Y^p$  est la classe de  $X^p$ .

On utilise alors une technique de gradient afin de minimiser la fonction coût. On choisit  $W(0)$  de manière arbitraire et on calcule successivement la matrice poids à l'aide de l'expression:

$$W(t+1) = W(t) - \alpha \cdot \nabla C(W(t)) \quad (II.6)$$

où  $\nabla C$  désigne le gradient de  $C$  et  $\alpha$  le module du déplacement.

Après présentation de l'exemple  $X^p$ , on modifie donc la matrice de poids en écrivant:

$$W(t+1) = W(t) - \alpha \cdot \sum_p (W^t X^p - Y^p) X^p \quad (II.7)$$

Cet algorithme est connu sous le nom de WIDROW-HOFF.

Un tel réseau donne de très bons résultats quand les classes d'exemples sont linéairement séparables mais est incapable de traiter des formes complexes.

Pour surmonter en partie cet handicap, une couche intermédiaire est ajoutée, où chaque unité calcule une fonction  $f_i$ , fixée à l'avance, sur les variables d'entrée (voir Figure II.5). L'état des unités de sortie est donnée par:

$$g(X) = \sum_i w_i \cdot f_i(X) \quad (II.8)$$

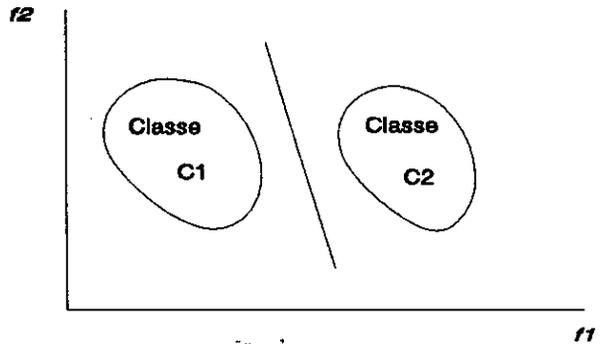
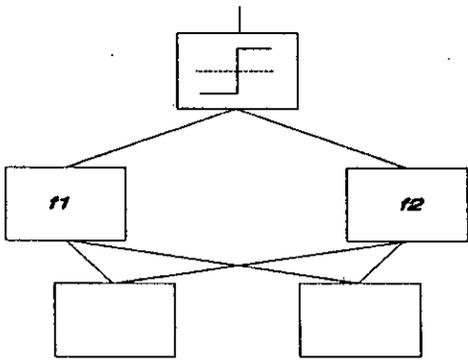


Figure II.5 Perceptron Multicouche.

Un exemple est affecté à l'une des deux classes C1 ou C2 selon que  $g(X)$  est respectivement positif ou négatif, comme le montre la Figure II.5, pour un cas à deux fonctions intermédiaires  $f_1$  et  $f_2$ .

L'algorithme d'apprentissage du perceptron procède par modification des poids des connexions entre la couche intermédiaire et la couche de sortie selon le schéma suivant:

- 1) Initialiser les poids.
- 2) Tant que le critère d'arrêt n'est pas atteint
  - 2.1) Choisir un exemple  $X^k = (x_1^k, \dots, x_n^k)$
  - 2.2) Si  $X^k$  a été bien classé alors  $W(k+1) = W(k)$
  - 2.3) sinon:
    - si  $X^k \in C1$   $g(X^k) < 0$  alors  $w_i(k+1) = w_i(k) + f_i(X^k)$
    - si  $X^k \in C2$   $g(X^k) \geq 0$  alors  $w_i(k+1) = w_i(k) - f_i(X^k)$
- 3) Retour au 2).

Les RN multicouches formés par rétropropagation du gradient:

Les réseaux connexionnistes multicouches constituent une extension du perceptron.

Dans un réseau connexionniste multicouche, les unités sont disposées en couches successives. Les couches d'entrée et de sortie ont un rôle particulier, car elles codent respectivement les vecteurs  $X$  et  $Y$ . On note  $W$  la matrice des poids des connexions entre unités.

L'objectif de l'algorithme de formation des réseaux de neurones sera toujours de minimiser le critère quadratique classique:

$$E = \sum_{p=1}^P (Y^p - f(X^p, W))^2 \quad (II.9)$$

où  $f(X, W)$  est la sortie du réseau de neurones.

L'état des unités d'entrées est obtenue par recopie des valeurs des variables  $x_i$ . Pour les unités des couches supérieures, le calcul se décompose en deux étapes:

- i) sommation sur l'ensemble des unités de la couche précédente  $net_i = \sum w_{ij} x_j$ .
- ii) application de la fonction d'activation  $g$  à la valeur  $net_i$ .

On choisit pour  $g$  une fonction différentiable. En général, on choisit la fonction sigmoïde.

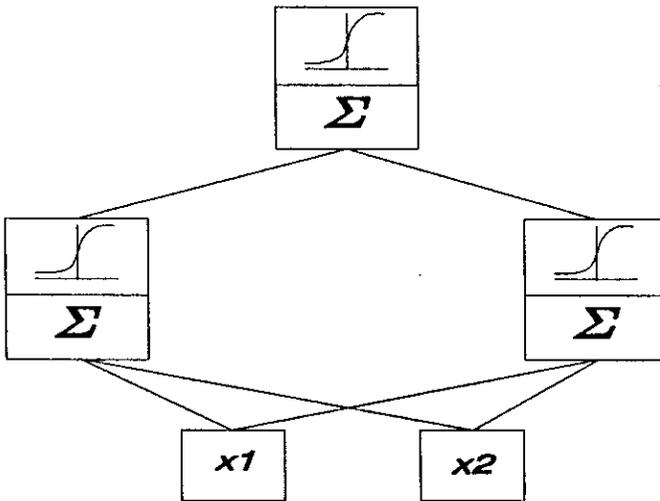


Figure II.6 RN multicouches à fonction de transfère sigmoïde

Apprentissage par rétropropagation du gradient:

- 1) Initialiser les poids.
- 2) Tant que le critère d'arrêt n'est pas atteint ( $E_p < \epsilon$ )
- 3) Pour  $p=1..P$ 
  - 3.1) Prendre  $x^p$
  - 3.2) Propager les valeurs d'entrée ( $x^p_1, \dots, x^p_n$ ) à travers le réseau.

- 3.3) Comparer la sortie du réseau à la sortie voulue, calculer  $\delta_{pj}^o$  et  $\delta_{pj}^h$  (Voir plus loin)
- 4) Déterminer la direction et la valeur de changement de chaque poids du réseau  $\Delta\omega$
- 5) Corriger les poids
- 6) Retour à 2).

Mathématiquement, cela s'exprime comme suit:

On définit l'erreur

$$\delta_{pk} = (y_{pk} - o_{pk}) \quad (II.10)$$

- où
- o: est la sortie produite par le RN.
  - y: est la sortie requise.
  - p: est l'indice de l'exemple introduit.
  - k: l'unité de sortie.

L'erreur à minimiser est donc  $E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2$  par une méthode de gradient.

On aura  $\nabla E_p$ , le gradient de l'erreur par rapport aux poids, qui donnera:

$$\frac{\partial E_p}{\partial \omega_{kj}^o} = -(y_{pk}^h - o_{pk}^h) \frac{\partial f_k^o}{\partial net_{pk}^o} \frac{\partial net_{pk}^o}{\partial \omega_{kj}^o} \quad (II.12)$$

l'exposant "o" renseigne sur la couche traitée, ici o=output.

$$\frac{\partial net_{pk}^o}{\partial \omega_{kj}^o} = \frac{\partial}{\partial \omega_{kj}^o} \left( \sum_{l=1}^L \omega_{kl}^o i_{pl} + \theta_k^o \right) \quad (II.13)$$

$i_{pl}$  est l'"input" du neurone, provenant du neurone  $l$  de la couche précédente, pour l'exemple  $p$ .

En combinant les deux dernières équations, on obtient:

$$-\frac{\partial E_p}{\partial \omega_{kj}^o} = (y_{pk} - o_{pk}) f_k^{o'}(net_{pk}^o) i_{pj} \quad (II.14)$$

Ainsi les poids de la couche de sortie changeront après l'introduction de l'exemple  $p$ , selon:

$$\omega_{kj}^o(t+1) = \omega_{kj}^o(t) + \Delta_p \omega_{kj}^o(t) \quad (II.15)$$

où

$$\begin{aligned} \Delta_p \omega_{kj}^o &= \eta \cdot (y_{pk} - o_{pk}) \cdot f_k^{o'}(net_{pk}^o) \cdot i_{pj} \\ &= \eta \cdot \delta_{pk}^o \cdot i_{pj} \end{aligned} \quad (II.16)$$

$\eta$ : est le pas d'apprentissage.

Pour les poids de la couche cachée (h:"hidden"), on a:

$$\begin{aligned} \frac{\partial E_p}{\partial \omega_{ji}^h} &= \frac{1}{2} \sum_k \frac{\partial}{\partial \omega_{ji}^h} (y_{pk} - o_{pk})^2 \\ &= - \sum_k (y_{pk} - o_{pk}) \frac{\partial o_{pk}}{\partial net_{pk}^o} \cdot \frac{\partial net_{pk}^o}{\partial i_{pj}} \cdot \frac{\partial i_{pj}}{\partial net_{pj}^h} \cdot \frac{\partial net_{pj}^h}{\partial \omega_{ji}^h} \end{aligned} \quad (II.17)$$

d'où

$$\frac{\partial E_p}{\partial \omega_{ji}^h} = - \sum_k (y_{pk} - o_{pk}) f_k^{o'}(net_{pk}^o) \omega_{kj}^o f_j^{h'}(net_{pj}^o) x_{pi} \quad (II.18)$$

En prenant le sens inverse du gradient, on obtient:

$$\begin{aligned} \Delta_p \omega_{ji}^h &= \eta f_j^{h'}(net_{pj}^h) x_{pi} \sum_k (y_{pk} - o_{pk}) f_k^{o'}(net_{pk}^o) \omega_{kj}^o \\ &= \eta \cdot f_j^{h'}(net_{pj}^h) \cdot x_{pi} \cdot \sum_k \delta_{pk}^o \omega_{kj}^o \end{aligned} \quad (II.19)$$

En posant:

$$\delta_{pj}^h = f_j^h(\text{net}_{pj}^h) \cdot \sum_k \delta_{pk}^o \omega_{kj}^o \quad (\text{II.20})$$

on obtient la même expression qu'en (II.15), (II.16) pour la couche de sortie:

$$\Delta_p \omega_{ji}^h = \eta \cdot \delta_{pj}^h \cdot x_{pi} \quad (\text{II.21})$$

Ainsi:

$$\omega_{ji}^h(t+1) = \omega_{ji}^h(t) + \Delta_p \omega_{ji}^h \quad (\text{II.22})$$

Le problème lié à cet algorithme est sa lenteur et le fait que l'on ne dispose pas de garantie de convergence vers le minimum global [9].

De nombreuses améliorations de cet algorithme ont été proposées dans la littérature. La plupart de celles-ci correspondent à des techniques générales d'amélioration de la méthode du gradient, tel que le rajout d'un terme correcteur de direction dans l'équation de mise à jour des poids:

$$\omega(t+1) = \omega(t) + \Delta\omega + \mu\Delta\omega(t-1) \quad (\text{II.23})$$

$\mu$ : appelé moment.

### II.1.b.2. Apprentissage non-supervisé

Le modèle proposé par Teuvo KOHONEN sous le nom de cartes topologiques, est constitué de deux couches, une d'entrée et une de sortie à deux dimensions.

La couche d'entrée a pour rôle de coder l'ensemble des variables décrivant les données, et la couche de sortie est constituée d'unités qui représenteront après apprentissage les différentes classes mises en évidence.

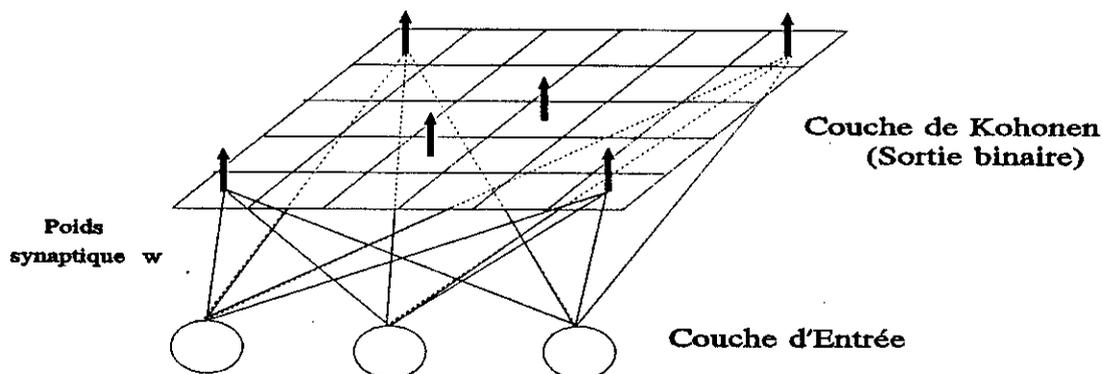


Figure II.7 Réseau de KOHONEN ou de type carte topologique

L'état  $y_i$  de chaque unité de sortie est calculé selon la formule habituelle  $y_i = \sum w_{ij} x_j$ .

L'algorithme, qui procède aux modifications successives des poids des connexions, s'écrit de la manière suivante:

- 1) Initialiser les poids
- 2) Tant que le critère d'arrêt<sup>1</sup> n'est pas atteint .
  - 2.1) Choisir un exemple  $X^p$  .
  - 2.2) Déterminer l'unité  $y_{ip}^*$  la plus excitée:

$$\|X^p - W(y_{pi}^*)\| = \min_i \|X^p - W(y_{pi})\|$$

- 2.3) Modifier les poids des cellules d'un voisinage  $V_p$  de la cellule  $y_{pi}^*$ :

$$\Delta W(y_{p+1,i}) = \alpha_{V_p} [X^p - W(y_{pi})] \quad \text{si } y_{pi} \in V_p$$

- 3) Retour au 2).

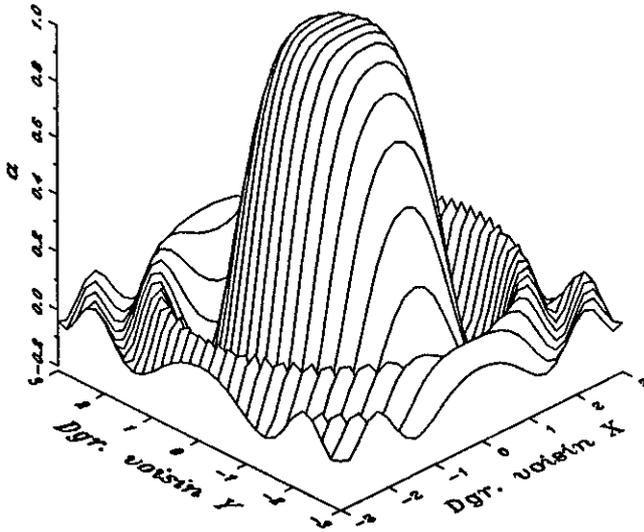
<sup>1</sup> Le critère d'arrêt est en général un certain nombre d'itérations fixées à l'avance.

Après apprentissage, chacun des exemples active préférentiellement une unité de la couche de sortie, qui correspond à sa classe.

Le cas particulier de cette technique, qui consiste à limiter le voisinage  $V_p$  à l'unité  $y^*$  seule, est appelé LVQ (Linear Vector Quantization).

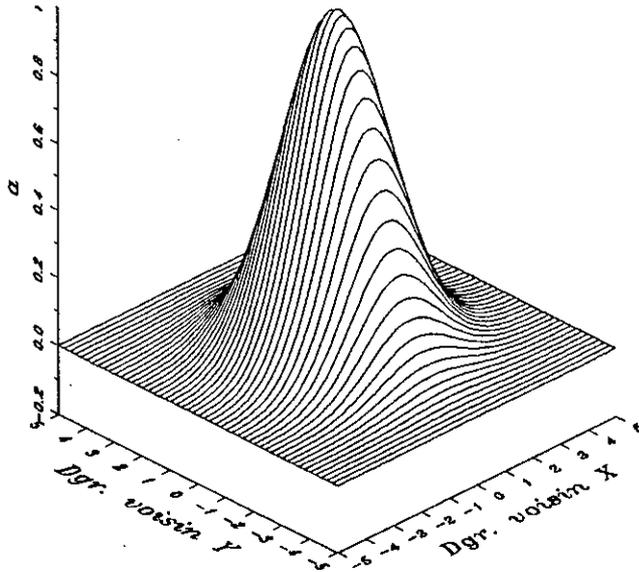
Sinon, en général le voisinage  $V_p$  se réduit au fur et à mesure de l'apprentissage, jusqu'à ne comprendre que l'unité  $y^*$ .

La loi d'évolution du facteur d'apprentissage spatio-temporel  $\alpha$ , est fonction de la proximité du neurone à corriger du neurone le plus excité (espace), ainsi que de l'itération en cours (temps).



**Figure II.8** Répartition spatiale du facteur d'apprentissage en fonction du degré de voisinage, selon une loi dite du "Chapeau du Mexicain"

Théoriquement, pour la dimension spatiale, cette loi est du type "Chapeau du Mexicain", avec un effet pénalisant pour certaines unités (Figure II.8) [25].



**Figure II.9** Répartition spatiale du facteur d'apprentissage en fonction du degré de voisinage selon une loi exponentielle

Mais en général, on utilise une loi exponentielle (Figure II.9) [12] (le voisinage se réduisant linéairement en fonction de l'itération).

## II.2. Les réseaux de Neurones dans l'évaluation de la sécurité statique

L'objectif est de pouvoir reconnaître l'état d'un réseau du point de vu sécurité, à partir d'un vecteur d'état [0], [18].

On peut considérer cette tâche, comme une fonction à modéliser, par identification des différents paramètres du réseau connexionniste. Ces paramètres sont les poids des arcs, et les seuils d'activation des neurones.

En général, en l'absence de données réelles, l'ensemble d'apprentissage est généré par des calculs d'écoulement de

puissance pour différentes perturbations et différents niveaux de charges.

Au préalable, pour chaque plan de charge une simulation est effectuée en régime sain, afin que ses résultats servent comme vecteur d'entrée au réseau de neurones. Le même calcul est effectué après la perte d'un ouvrage, et sert à détecter d'éventuelles violations de limites de sécurité, et constitue ainsi la variable de sortie renseignant sur l'état sécuritaire du réseau [0], [18].

### II.3.Discussion

En général, le nombre limité de réalisations du phénomène à modéliser peut entraîner deux types d'erreurs dans la formation d'un réseau de neurones:

- une erreur d'échantillonnage,
- une erreur liée au choix d'un espace fonctionnel (Dimensions du réseau de neurones),

Il faut rappeler que les imprécisions de mesure commises en observant  $X$  et  $Y$ , contribuent uniquement à augmenter la variance des variables observées, mais n'introduisent pas de biais important dans le choix du réseau de neurone (dimensions).

Par contre les deux points précédents influent sur la procédure de construction du réseau de neurones [22].

#### II.3.a.L'erreur d'échantillonnage

Pour que le réseau de neurones soit correctement formé, il faut que l'ensemble d'apprentissage puisse être assez représentatif du domaine de valeurs qu'on pourrait rencontrer face au système à modéliser. De plus, lors de l'apprentissage, il faudrait que les exemples soient présentés aléatoirement, de manière à ne pas voir le réseau de neurones développer un phénomène de "par coeurisme"

localisé sur des patterns semblables, successifs, et être ainsi incapable de généraliser.

### II.3.b. Le choix de l'espace fonctionnel

On définit le nombre de degré de liberté d'une fonction  $f(x, \theta)$  comme le nombre de paramètres libres  $\theta$  de cette fonction.

Ainsi, l'espace des polynômes à une variable, de degré inférieur à  $n$  a un nombre de degré de liberté maximal égal à  $n+1$ ; de même, l'espace des réseaux connexionnistes complètement connectés entre couches, à  $p$  unités d'entrée,  $q$  unités cachées et  $r$  unités de sortie a un nombre de degrés de liberté maximal égal à  $q(p+r+1)+r$ .

Si le nombre d'exemples est inférieur au nombre de degrés de liberté du réseau de neurones, alors le problème sera sous déterminé. En fait, il y aura dans ce cas une infinité de solutions.

D'autre part, en bornant l'espace fonctionnel  $F$  à un espace de fonctions admissibles, on introduira une erreur, car la fonction à rechercher aura pu être exclue du domaine de recherche.

Il est donc indispensable, qu'une méthode permette d'estimer le taux d'erreur de la fonction  $f^{(n)}$  choisie sur l'ensemble de tous les cas possibles. Pour cela, si l'on dispose de  $N$  exemples d'observations, on les répartira entre une base d'apprentissage  $K$  et une base de généralisation  $K'$ .

L'objectif sera de trouver la dimension  $n=q^1$ , de manière à ce que la fonction  $f^{(n)}$  modélisée par ce réseau de neurones soit celle qui minimise le critère d'erreur sur  $K$  et  $K'$  (Voir Figure II.10).

---

<sup>1</sup> En général  $p$  et  $r$  sont fixés par le type de données d'entrée que l'on possède et du type d'information que l'on veut en sortie.

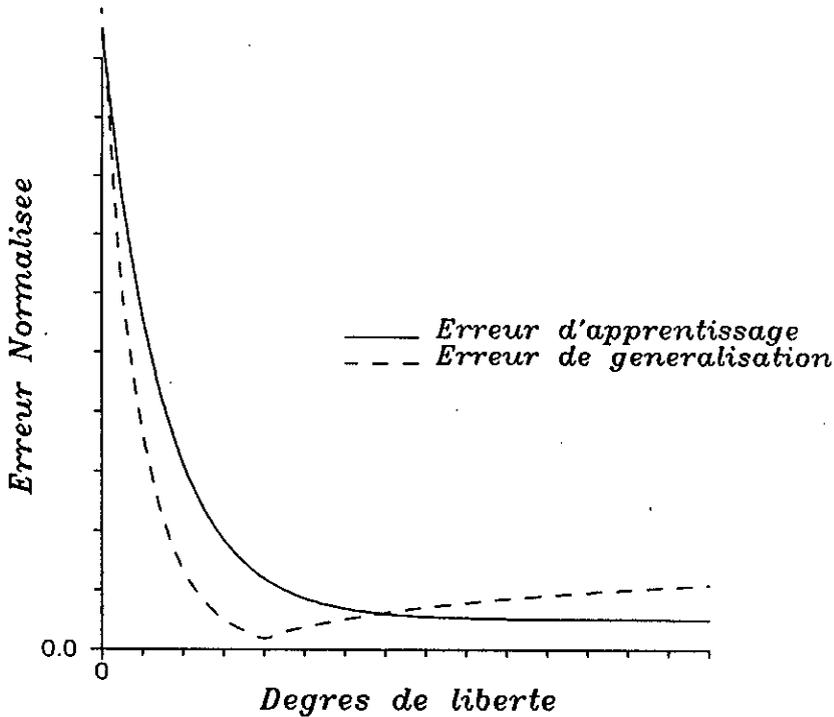


Figure II.10 Evolution des critères (erreur)  $C(f^{(n)}, K)$  et  $C(f^{(n)}, K')$

Il ressort de ce qui précède, que le taux d'erreur calculé sur la base d'apprentissage seule, est trop optimiste. Il faut donc tenir compte du taux d'erreur calculé sur un ensemble de nouveaux exemples, l'ensemble de généralisation  $K'$ , pour conclure quand à la dimension finale du réseau de neurones.

#### II.4. Conclusion

Il y a deux caractères principaux qui permettent de classer les réseaux de neurones:

- la manière dont circule les "stimulis" dans le réseau de neurones, soit tout en avant en passant d'une couche à une autre, en allant de la couche d'entrée à la couche de sortie, soit avec des excitations en retour pouvant aller d'une couche supérieure vers une couche inférieure,

- et la manière dont est fait l'apprentissage, c'est à dire supervisé ou non.

La fonction de transfert dont est muni chaque neurone, constitue un caractère distinctif supplémentaire.

Pour chaque catégorie de réseau de neurones, il existe une multitude d'algorithmes d'apprentissage, tel que la loi de "Rétropopagation du Gradient", et celle de "Linear Vector Quantization LVQ", ... Le nom des algorithmes, ou des auteurs les ayant développés permettent de les identifier.

Connaissant les avantages de rapidité, de robustesse, et de capacité de généralisation des réseaux de neurones, ils ont été investis pour l'évaluation de la sécurité des réseaux électriques en temps réel. Néanmoins, ces derniers posent quand même quelques difficultés à la conception.

En effet, lors de la conception d'un réseau de neurones, il faudra tenir compte, afin de les éviter, de deux types d'erreurs:

- les erreurs d'échantillonnage, pour l'ensemble d'apprentissage,
- et les erreurs dues au choix des dimensions du réseau de neurones.

Dans ce qui suit, nous allons tenter de lever ces contraintes, en utilisant un réseau de neurones multicouches à propagation avant, formé par la loi de "rétropropagation du gradient".

## CHAPITRE III

### MODELE D'ÉCOULEMENT DE CHARGE

La formation d'un réseau de neurones nécessite un ensemble de données décrivant le fonctionnement du réseau électrique d'étude. Il est donc développé dans ce chapitre un modèle de calcul d'écoulement de charge afin de générer rapidement des ensembles de données réalistes.

#### III.1. Hypothèses et conditions requises

Le réseau de neurones doit évaluer la sécurité statique du réseau électrique d'étude sur la base de l'état précédant tout déclenchement. Donc, l'ensemble d'apprentissage sera formé de vecteurs d'état en régime sain et d'un indicateur de sécurité  $(n-1)$ <sup>1</sup> pour chacun de ces vecteurs.

Etant donné qu'il n'existe pratiquement pas de base de données réelle, contenant l'ensemble des variables d'état et de contrôle ( $V$ (tension nodales),  $\delta$ (déphasage des tensions nodales),  $P_G$ ,  $Q_G$ ,  $P_D$ ,  $Q_D$ (puissances actives et réactives générées, demandées)) d'un réseau électrique. Et qu'on ne peut avoir d'indicateur de sécurité  $(n-1)$ , sans simuler tous les déclenchements. Il est donc nécessaire de développer un modèle de calcul d'écoulement de charge, pour déterminer l'état de stabilisation du réseau électrique lors de toute perte d'ouvrage, de transport ou de production.

Ce modèle sera aussi réel que possible, c'est à dire, qu'il devra tenir compte:

---

<sup>1</sup> La sécurité de niveau  $(n-1)$  est celle définie pour la perte d'un ouvrage pris un à la fois, parmi les  $n$  ouvrages du réseau.

- du modèle des lignes en fonction de leur longueur [28],
- de la présence de régleurs en charge de transformateurs [28],
- de la dépendance des charges vis-à-vis de la tension et de la fréquence [7], [5], [13],
- de l'interaction des puissances actives et réactives en circulation dans le réseau,
- des limites de régulation de la tension de sortie des groupes [17],
- de la présence de régulateurs au niveau de chaque groupe couplé au réseau, afin de compenser selon son statisme (voir plus loin), tout excès ou déficit de production vis-à-vis de la charge (pertes incluses) [13], [16], [24], [29], [30].

L'état du réseau perturbé est analysé, après l'action des régulateurs primaires (vitesse) et secondaire (fréquence) des groupes (Cf. annexe), et avant l'action des régleurs en charge des transformateurs.

Tous les groupes sont supposés participer au réglage primaire et secondaire. Ceci amène à négliger l'écart de fréquence  $\Delta\omega$ , qui apparaît pendant un certain temps après toute perturbation [24], [29].

Cette hypothèse étant émise, les charges ne seront modélisées qu'en fonction de la tension, et donc l'autorégulation de ces dernières, comme la variation des caractéristiques des ouvrages par la suite de la variation de fréquence peuvent être négligées.

Les modèles de charges adoptés sont des modèles polynomiaux [5], [7], [13], de la forme:

$$\begin{aligned} P_d &= P_{(1p.u.)} (aV^2 + bV + c) \\ Q_d &= Q_{(1p.u.)} (dV^2 + eV + f) \end{aligned} \tag{III.1}$$

avec  $a+b+c=1$  et  $d+e+f=1$

les tensions étant exprimées en p.u.

Il est important d'attirer l'attention sur le fait que le modèle d'écoulement de charge dont les caractéristiques générales

ont été présentées plus haut, est un modèle statique qui ne tient pas compte de la dynamique du système (aucune constante de temps n'étant mise en jeu) [16]. Il satisfait à l'hypothèse d'étude de la sécurité statique des réseaux émise en introduction générale.

Vu le nombre important de simulations à effectuer pour la génération de l'ensemble de données, il a été adopté le modèle dit de l'écoulement de charge découplé rapide dynamique (Dynamic fast decoupled load flow) développé par R.Ramanathan & al. [16]. Ce modèle a été enrichi pour les besoins de ce travail par l'introduction de la modélisation des charges.

## III.2. Développement d'un modèle d'écoulement de charge dynamique

### III.2.a. Introduction

Les calculs d'écoulement de charge (Load FLOW) pour la détermination de l'état statique des réseaux électriques, sont conventionnellement effectués en supposant que tout écart entre la production et la demande est pris en charge par un générateur idéal, unique, de puissance suffisante, constituant ainsi le noeud balancier (dit: slack bus) [17], [21], [24], [28], [29]. Les charges sont considérées toujours constantes, quelque soit la tension sous laquelle elles se trouvent alimentées [5].

Comme ces modèles négligent la réelle participation de tous les générateurs du réseau, ainsi que la caractéristique des charges, ils se trouvent donc inappropriés pour le calcul et l'analyse d'un nouvel état d'équilibre qui s'établirait après le déclenchement d'un ouvrage important du réseau (ligne ou groupe).

L'idée de distribuer tout surplus ou déficit de puissance dans le réseau à travers l'ensemble des générateurs, et la prise en compte de la caractéristique des charges, a été introduite par M.Okamura & al. en 1975, dans un écoulement de charge basé sur la méthode de Newton-Raphson [13]. Dix ans plus tard (1986), R.Ramanathan & al. ont fait de même dans un écoulement de charge

découplé rapide (Standard Fast Decoupled Load Flow "SFDLF") gagnant ainsi en rapidité de calcul et en besoin de mémoire, mais péchant par la non modélisation des charges.

Dans ce qui suit, il est décrit l'écoulement de charge découplé rapide dynamique (Dynamique Fast Decoupled Load Flow "DFDLF") en incluant les modèles de charges. Le modèle est basé sur la variante BX du "SFDLF", pour éviter toute évolution cyclique non convergente lors du calcul itératif, qui pourrait avoir lieu pour des réseaux dont certaines branches ont un rapport R/X important (supérieur à 0.5) [17], [15], [10], [19].

### III.2.b. Développement de l'algorithme

#### III.2.b.1. Facteurs de participation

Chaque générateur (ou centrale) du réseau est caractérisé par un facteur de participation  $x_i$  qui rend compte de la variation de production du groupe (ou centrale) relativement à la variation totale de puissance du réseau. Ce facteur  $x_i$  peut être mesuré, par exemple, après toute variation de production d'un groupe par régulation, selon le rapport:

$$x_i = \frac{\Delta P_i}{\Delta P} \quad (III.2)$$

où:

$\Delta P_i$ : variation de production du groupe  $i$

$\Delta P$ : Ecart de puissance Production-Charge dans le réseau, ( $\Delta P = \sum \Delta P_i$ ).

On a:

$$\sum_{i=1}^m x_i = 1 \quad (III.3)$$

$m$ : est le nombre de générateurs dans le système

Ce facteur  $x_i$  est fonction du statisme  $\sigma_i$  du régulateur primaire du groupe considéré. Sachant que le statisme d'un groupe est défini par l'expression:

$$\sigma_i = \frac{\Delta f / f_0}{\Delta P_i / P_{mi}} \quad (III.4)$$

$\Delta f$ : variation de la fréquence vis-à-vis de sa valeur initiale.

$f_0$ : la fréquence nominale du réseau.

$P_{mi}$ : la puissance maximale du groupe  $i$ .

Il vient donc, de l'expression précédente:

$$\Delta P_i = \frac{\Delta f}{f_0} \cdot \frac{P_{mi}}{\sigma_i} \quad (III.5)$$

En sommant sur l'ensemble des noeuds générateurs, on obtient:

$$\Delta P = \frac{\Delta f}{f_0} \cdot \sum_{k=1}^m \frac{P_{mk}}{\sigma_k} \quad (III.6)$$

En réutilisant l'équation (III.2), les facteurs de participation peuvent être calculés suivant l'expression:

$$x_i = \frac{\frac{P_{mi}}{\sigma_i}}{\sum_{k=1}^m \frac{P_{mk}}{\sigma_k}} \quad (III.7)$$

### III.2.b.2. Modification de l'écoulement de charge standard (FDLF)

Après toute perturbation dans le réseau, il y a un écart qui apparaît entre la production et la consommation. Cette puissance d'écart, notée  $P_A$ , est appelée la puissance d'accélération ou de décélération selon qu'elle est positive ou négative, et a pour expression:

$$P_A = \sum_{k=1}^m P_{Gk} - \sum_{k=1}^n P_{Dk} - P_L \quad (III.8)$$

- où:  $P_{Gi}$ : est la puissance générée au noeud  $i$ .  
 $P_{Di}$ : est la puissance demandée au noeud  $i$ .  
 $P_L$ : est le total des pertes du réseau.  
 $m$ : le nombre de noeuds générateurs.  
 $n$ : le nombre de noeuds dans le réseau.

La puissance injectée à chaque noeud est:

$$P_{Ii} = P_{Gi} - P_{Di} - x_i P_A \quad (III.9)$$

- où:  $x_i$ : le facteur de participation du noeud  $i$ <sup>1</sup>.

En substituant (III.8) dans (III.9) on obtient:

$$P_{Ii} = P_{Gi} - P_{Di} - x_i \cdot \left( \sum_{k=1}^m P_{Gk} - \sum_{k=1}^n P_{Dk} - P_L \right) \quad (III.10)$$

D'un autre côté, la circulation de puissance active vers le noeud  $i$ , est:

$$P_{Ii} = V_i \sum_{k=1}^n V_k (G_{ik} \cos \delta_{ik} + B_{ik} \sin \delta_{ik}) \quad (III.11)$$

- où:  $G_{ik} + jB_{ik}$ : élément  $(i, k)$  de la matrice d'admittance du réseau.  
 $V_i, \delta_i$ : module et angle de la tension au noeud  $i$ .

---

<sup>1</sup> Les noeuds non producteurs ont un  $x_i$  nul

$$\delta_{ik}: \quad \delta_i - \delta_k$$

De même on a pour la puissance réactive injectée au noeud i:

$$Q_{Ii} = Q_{Gi} - Q_{Di} + 0 \quad (\text{III.12})$$

Le zéro (0) est ici inscrit, pour mettre en évidence le fait que la puissance d'accélération ou de décélération est purement active.

De même qu'en (III.11), on obtient pour la puissance réactive injectée:

$$Q_{Ii} = V_i \cdot \sum_{k=1}^n V_k (G_{ik} \sin \delta_{ik} - B_{ik} \cos \delta_{ik}) \quad (\text{III.13})$$

En identifiant les équation (III.10) à (III.11) et (III.12) à (III.13) on obtient:

$$P_{Gi} - P_{Di} - X_i \left( \sum_{k=1}^m P_{Gk} - \sum_{k=1}^n P_{Dk} - P_L \right) - V_i \sum_{k=1}^n V_k (G_{ik} \cos \delta_{ik} + B_{ik} \sin \delta_{ik}) = 0 \quad (\text{III.14})$$

et

$$Q_{Gi} - Q_{Di} - V_i \sum_{k=1}^n V_k (G_{ik} \sin \delta_{ik} - B_{ik} \cos \delta_{ik}) = 0 \quad (\text{III.15})$$

Ayant n noeuds dans le réseau, on obtient (2n-1) équations en écrivant les deux expressions précédentes en chaque noeud<sup>1</sup>.

Pour trouver V et  $\delta$ , on résout le système formé par les 2n-1 équations précédentes suivant l'algorithme de l'écoulement rapide découplé de STOTT [17], [29].

Le système à résoudre a pour forme générale:

<sup>1</sup> Au noeud référence  $\Delta\delta=0$ , d'où l'équation en moins.

$$\left\{ \begin{array}{l} \left[ \frac{\Delta P_I}{V} \right] = [B'] \cdot [\Delta \delta] \\ \quad \quad \quad i=2, \dots, n \\ \left[ \frac{\Delta Q_I}{V} \right] = [B''] \cdot [\Delta V] \\ \quad \quad \quad i \neq i_{pv} \end{array} \right\} \quad (III.16)$$

où:  $[\Delta P_I]$ : vecteur bilan de puissance active nodale.

$[\Delta Q_I]$ : vecteur bilan de puissance réactive nodale.

$[\Delta V]$ ,  $[\Delta \delta]$ : vecteurs correction de  $[V]$  et  $[\delta]$ .

$[B']$ ,  $[B'']$ : matrices extraites du jacobien du système d'équations (Cf annexe).

En fait le système précédent n'est résoluble que si le total des pertes  $P_L$  est connu, ce qui n'est pas le cas a priori. Il faut donc ajouter une équation de plus au système précédent afin de déterminer cette dernière inconnue. Pour cela, on mène le développement suivant.

### Nouveaux bilans de puissances nodaux<sup>1</sup>

En prenant,  $(.)^*$  pour notation de toute solution, on peut écrire de nouveaux bilans de puissances nodaux à partir de l'équation (III.14):

$$\Delta P_{XI} = \left( P_{Gi} - P_{Di} - X_i \left( \sum_{k=1}^n P_{Gk} - \sum_{k=1}^n P_{Dk} - P_L \right) - P_{Ii} \right) - \left( P_{Gi}^* - P_{Di}^* - X_i \left( \sum_{k=1}^n P_{Gk}^* - \sum_{k=1}^n P_{Dk}^* - P_L^* \right) - P_{Ii}^* \right) \quad (III.17)$$

Comme  $P_{Gi}^* = P_{Gi}$ , et que  $P_{Di}^* = P_{Di}$  à cause de la dépendance de la charge à la tension, on obtient:

<sup>1</sup> "Mismatches"

$$\Delta P_{Xi} = (P_{Ii}^* - P_{Ii}) - X_i (P_L^* - P_L) + (P_{Di}^* - P_{Di}) - X_i \left( \sum_{k=1}^n P_{Dk}^* - \sum_{k=1}^n P_{Dk} \right) \quad (III.18)$$

$$\Delta P_{Xi} = \Delta P_{Ii} - X_i \Delta P_L + \Delta P_{Di} - X_i \sum_{k=1}^n \Delta P_{Dk}$$

De la même manière, pour le réactif des noeuds PQ on obtient de (III.15):

$$\Delta Q_{Xi} = \Delta Q_{Ii} + \Delta Q_{Di} \quad (III.19)$$

Dans (III.17) l'expression à variables étoilées est nulle, car la solution vérifie (III.14), donc on peut écrire:

$$\Delta P_{Xi} = P_{Gi} - P_{Di} - X_i \left( \sum_{k=1}^m P_{Gk} - \sum_{k=1}^n P_{Dk} - P_L \right) - P_{Ii} \quad (III.20)$$

Ce qui représente le nouveau bilan de puissance actif. De même pour le réactif, on a:

$$\Delta Q_{Xi} = Q_{Gi} - Q_{Di} - Q_{Ii} \quad (III.21)$$

#### Calcul du bilan de puissance pertes $\Delta P_L$

Avec (III.18) et (III.20) on a deux expressions d'une même entité. L'équation (III.18) servira à exprimer  $\Delta P_L$ , et (III.20) sera utilisée pour calculer  $\Delta P_{Xi}$  à chaque itération.

A priori dans l'équation (III.18) on a deux inconnues,  $\Delta P_{Ii}$  et  $\Delta P_L$ , car  $\Delta P_{Di}$  est fonction de  $V_i$  (voir eq. III.1), donc:

$$\Delta P_{Di} = \frac{\partial P_{Di}}{\partial V_i} \Delta V_i \quad (III.22)$$

En sommant (III.18) à travers tous les noeuds, et en divisant chaque élément par la tension du noeud correspondant,  $V_k$ , il vient:

$$\sum_{k=1}^n \frac{\Delta P_{Xk}}{V_k} = \sum_{k=1}^n \frac{\Delta P_{Ik}}{V_k} - \sum_{k=1}^n \frac{X_k}{V_k} \Delta P_L + \sum_{k=1}^n \frac{\Delta P_{Dk}}{V_k} - \sum_{k=1}^n \frac{X_k}{V_k} \left( \sum_{k=1}^n \Delta P_{Dk} \right) \quad (III.23)$$

Les inconnues  $\Delta P_{Ii}$  s'éliminent, vu que:

$$\sum_{k=1}^n \frac{\Delta P_{Ik}}{V_k} = 0 \quad (III.24)$$

(Voir Annexe pour démonstration)

Ainsi, il reste uniquement  $\Delta P_L$ .

En considérant (III.16) et (III.17), on obtient pour  $\Delta P_L$  une expression qui permet de calculer  $P_L$ :

$$\Delta P_L = \frac{1}{\sum_{k=1}^n \frac{X_k}{V_k}} \left( - \sum_{k=1}^n \frac{\Delta P_{Xk}}{V_k} + \sum_{k=1}^n \frac{\Delta P_{Dk}}{V_k} - \sum_{k=1}^n \frac{X_k}{V_k} \left( \sum_{k=1}^n \Delta P_{Dk} \right) \right) \quad (III.25)$$

### Algorithme

L'écoulement de charge découplé rapide (FDLF) classique est basé sur les injections de courants  $[\Delta P_I/V]$  et  $[\Delta Q_I/V]$ . On obtient ainsi à partir du système (III.16) en utilisant l'équation (III.18):

$$[B'] \cdot [\Delta\delta] = \left[ \frac{\Delta P_X}{V} \right] + \left[ \frac{X}{V} \right] \cdot \Delta P_L - \left[ \frac{\Delta P_D}{V} \right] + \left[ \frac{X}{V} \right] \cdot \left( \sum_{k=1}^n \Delta P_{DK} \right) \quad (III.26)$$

$$i=2, \dots, n \quad (\delta_0=0)$$

De la même manière, pour le problème réactif, du système (III.16) et de l'équation (III.19), il vient:

$$[B''] \cdot [\Delta V] = \left[ \frac{\Delta Q_X}{V} \right] - \left[ \frac{\Delta Q_D}{V} \right] \quad (III.27)$$

$$i \neq i_{pv}$$

Les tensions et angles seront calculés selon le procédé itératif de l'écoulement de charge rapide découplé, à travers le système formé des deux expressions précédentes. On aura:

$$[V^{new}] = [V^{old}] + [\Delta V]$$

et

$$[\delta^{new}] = [\delta^{old}] + [\Delta\delta] \quad (III.28)$$

Le total de pertes  $P_L$  sera calculé en utilisant l'équation (III.25), suivant:

$$P_L^{new} = P_L^{old} + \Delta P_L \quad (III.29)$$

A noter que la variante BX de l'écoulement de charge rapide découplé de STOTT, s'obtient uniquement en négligeant les résistances dans  $[B'']$ , plutôt que dans  $[B']$ , [10], [19].

Les étapes du nouvel écoulement de charge dynamique dont les équations ont été développées ci-dessus, sont les mêmes que celles définies par STOTT pour son écoulement de charge rapide découplé (FDLF) [17], à quelques exceptions près (voir algorithme en Figure III.1 et Figure III.2 ).

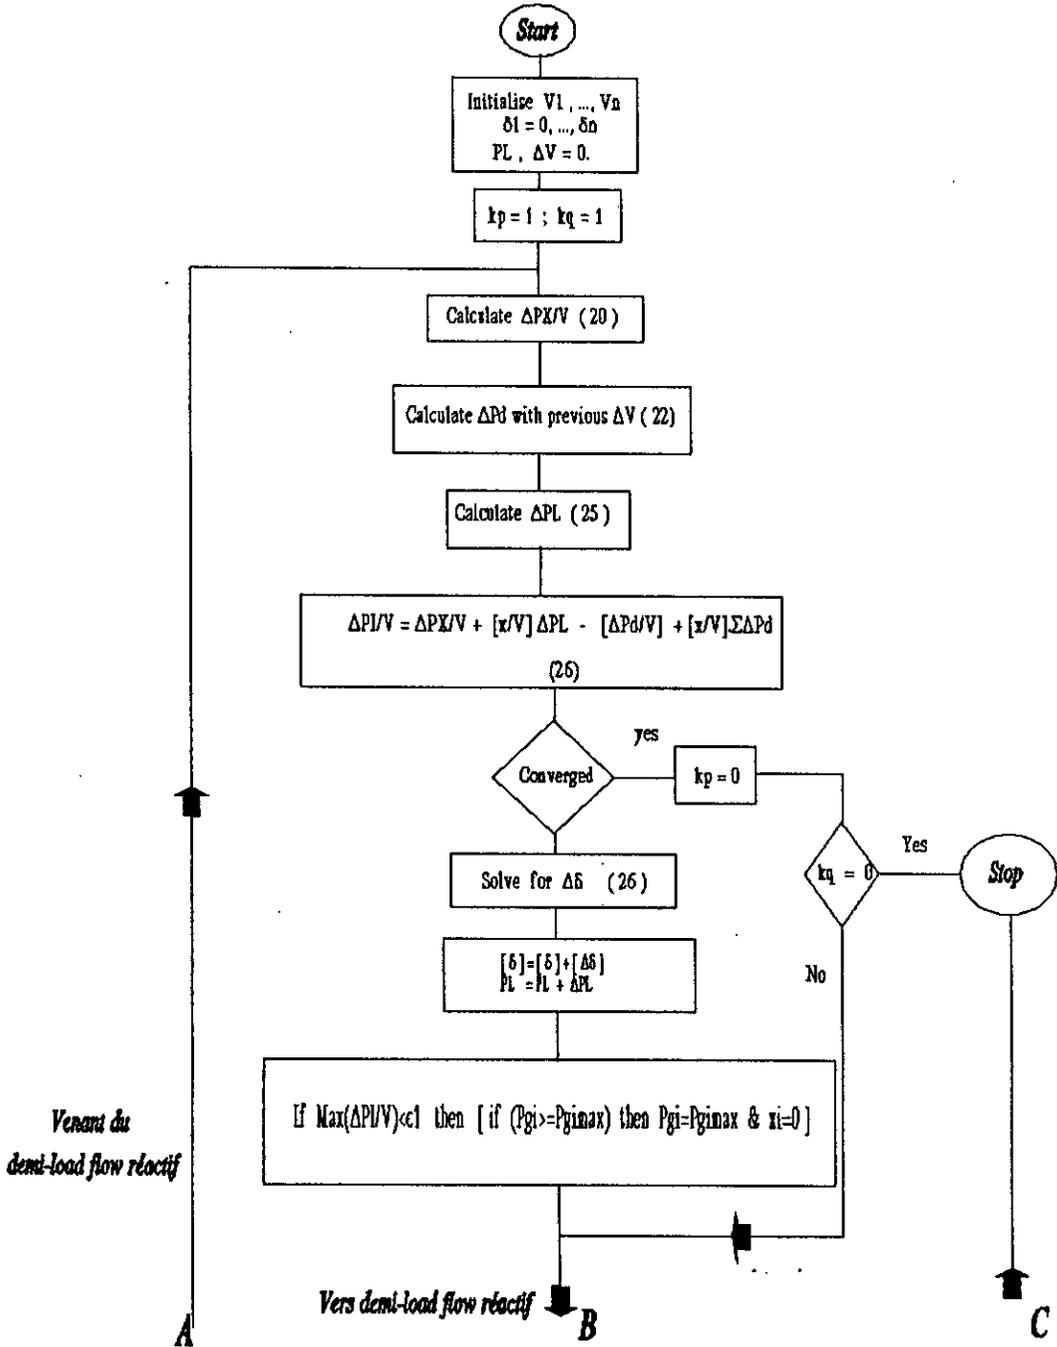


Figure III.1 Organigramme de l'écoulement de charge découplé rapide dynamique (actif).

Allant vers le demi load flow actif

Venant du demi load flow actif

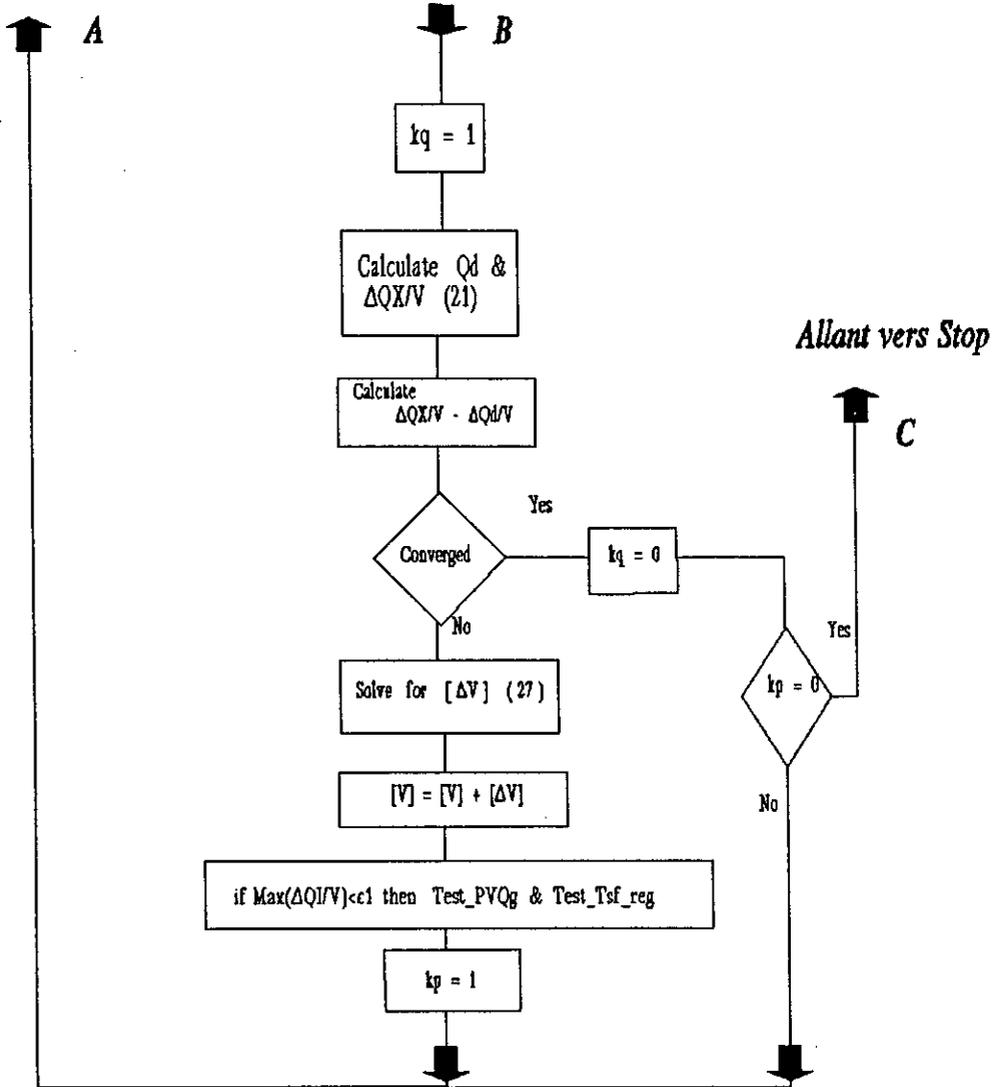


Figure III.2 Organigramme de l'écoulement de charge découplé rapide dynamique (réactif).

### III.2.c. Performances du modèle

Pour mettre en évidence les performances du nouvel algorithme de calcul d'écoulement de charge découplé dynamique (DFDLF: Dynamic Fast Decoupled Load Flow), ce dernier a été testé sur les réseaux standards de référence, 14 et 30 noeuds de l'IEEE (I3E14, I3E30<sup>1</sup>), et comparé à l'écoulement de charge basé sur la méthode de Newton-Raphson (NR) et l'écoulement de charge découplé rapide standard (FDLF: Fast Decoupled Load Flow) version BX [19].

Lorsque les charges ont été modélisées, elles l'ont été dans les trois cas d'études, pour tous les noeuds, comme charges passives ( $a=d=1$ ,  $b=c=e=f=0$  voir eq.(III.1)).

Vu la racine commune de tous les algorithmes d'écoulement de charge, leur différence est souvent minime du point de vue de la programmation. Pour cela le programme informatique a été écrit suivant la philosophie "objet" [32], dans le langage C++ [33].

Les calculs ont été menés sur un PC de type 80486 DX2-66MHz.

Les résultats suivants ont été obtenus:

Type LF	itérations		temps CPU (s)	
	I3E14	I3E30	I3e14	I3E30
NR	4	2	0.504	2.027
FDLF(BX)	7	4	0.095	0.286
DFDLF(BX)	6	6	0.077	0.304

Tableau III.1. Performances de calcul avec B1 comme "slack bus", charges non modélisées.

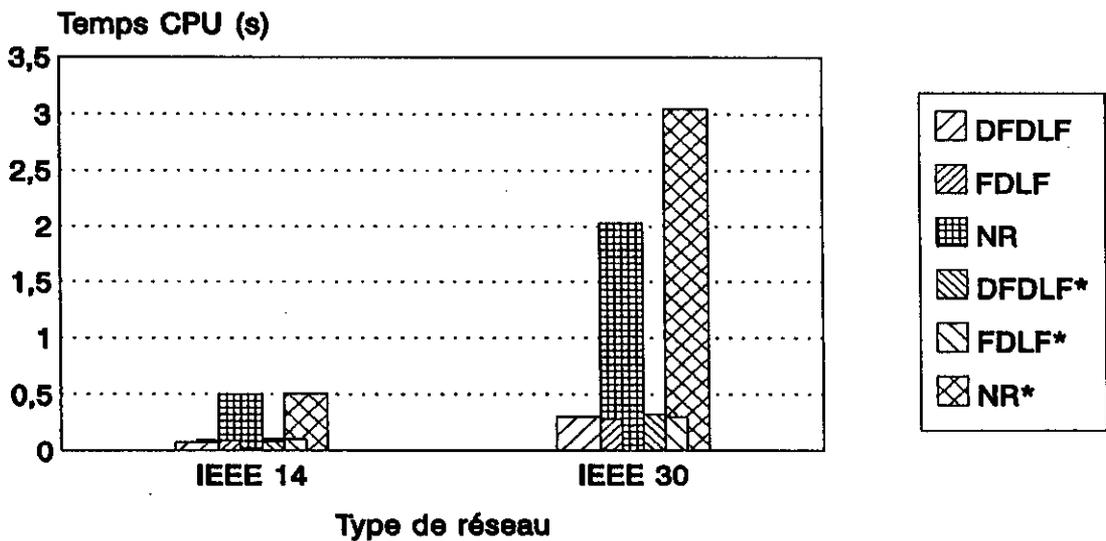
---

<sup>1</sup> Lire: Réseau modèle IEEE 14 noeuds, et réseau modèle IEEE 30 noeuds. Voir données en annexe.

Type LF	itérations		temps CPU (s)	
	I3E14	I3E30	I3e14	I3E30
NR	4	3	0.505	3.046
FDLF(BX)	10	6	0.107	0.305
DFDLF(BX)	7	8	0.084	0.328

Tableau III.2. Performances de calcul avec B1 comme "slack bus", charges modélisées.

### Pérfomances comparées du DFDLF



\*: Charge Modélisée

On voit que la méthode de Newton-Raphson est la plus grosse consommatrice de temps CPU, et que le temps de calcul, en fonction de la dimension du réseau, croit plus vite lorsque la modélisation de la charge est introduite.

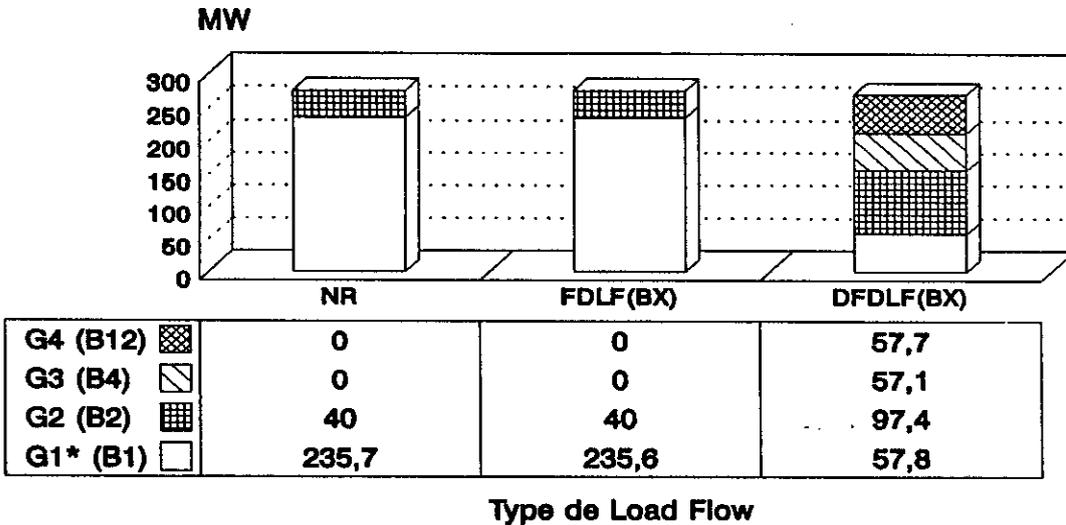
D'autre part, l'écoulement de charge DFDLF est effectué dans des temps de même ordre de grandeur que le standard FDLF, et ceci

malgré son alourdissement par l'introduction de la régulation primaire des groupes.

De plus, le DFDFL est plus stable lorsque le total de puissance active produit est bien différent de la charge, ou lorsque la répartition de la production dans le réseau est inadéquate pour la satisfaction de la demande. En effet, le principe de participation de tous les groupes modélisant le réglage primaire dans le réseau, minimise le risque de divergence du modèle de calcul.

Il est à ajouter à cet avantage, le réalisme du modèle, dans le sens où les résultats qu'il fournit sont indépendants du choix du noeud de référence "slack bus", ce qui est mis en évidence pour le réseau I3E14 à travers ses quatre noeuds générateurs (voir figures et tableaux suivants)<sup>1</sup>.

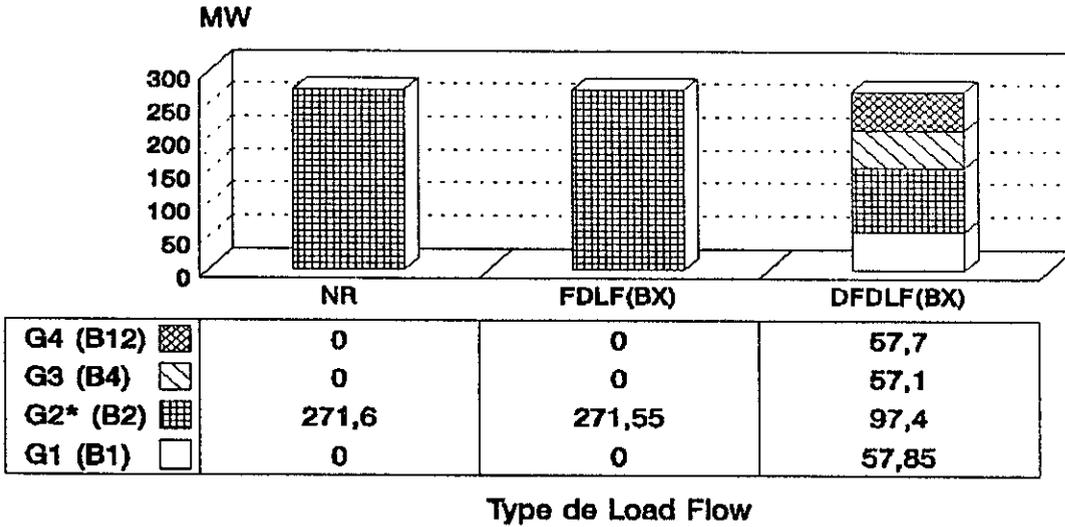
## Génération IEEE 14 (noeud réf.: B1)



<sup>1</sup> Les trois écoulements calculés partent du même point initial.

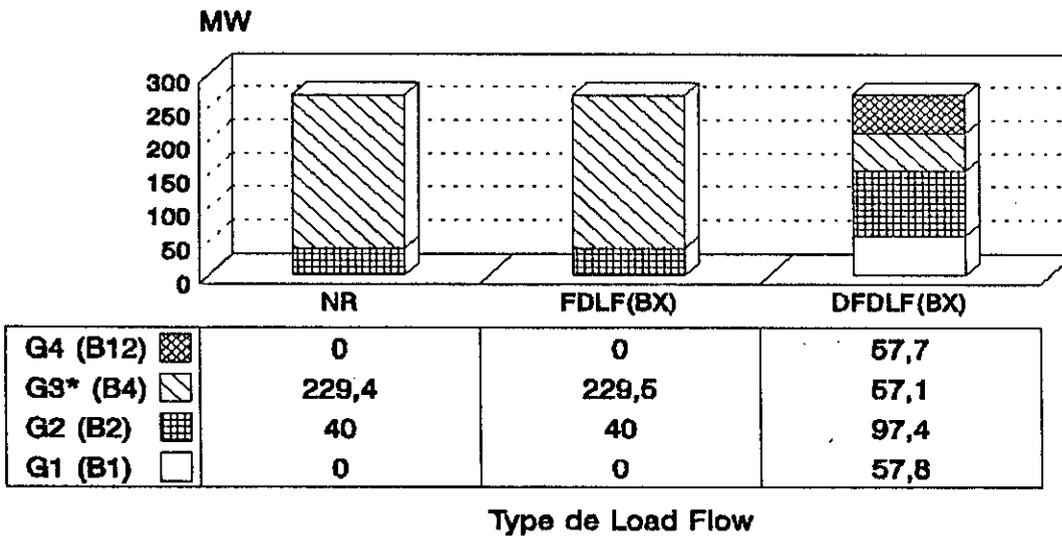
# Générations

## IEEE 14 (noeud réf.: B2)



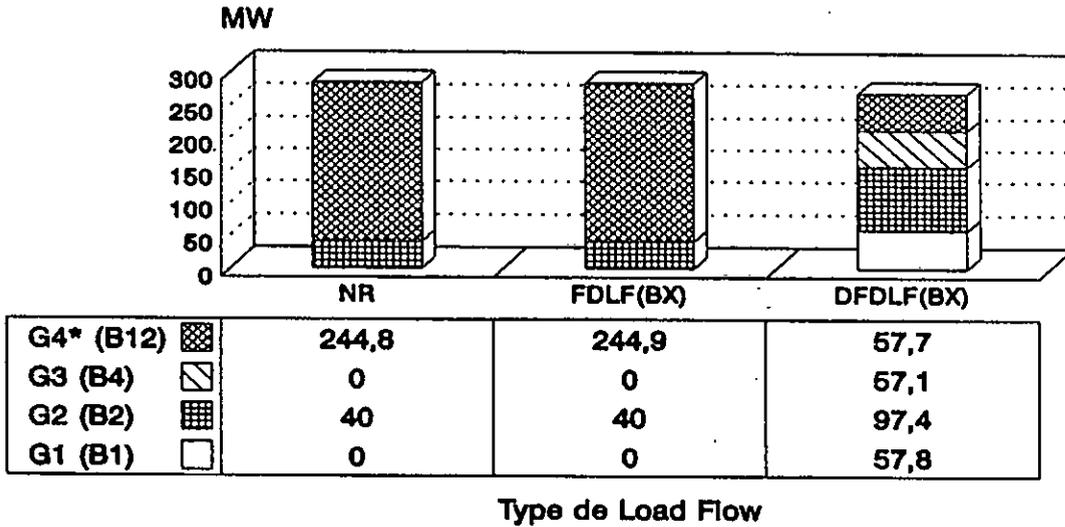
# Générations

## IEEE 14 (noeud réf.: B4)



# Généralisations

## IEEE 14 (noeud réf.: B12)



Avec l'algorithme proposé, la demande totale et les productions sont indépendantes du noeud de référence choisi, alors que les méthodes basées sur un seul noeud régulateur<sup>1</sup> donnent des résultats différents selon la situation géographique de ce dernier dans le réseau.

Le fait de compenser tout écart par un seul noeud entraîne souvent un dépassement de la limite physique de production du noeud régulateur du réseau.

On relève aussi que la demande totale est différente selon la situation du noeud référence, pour l'écoulement de charge de type Newton-Raphson (NR) et découplé rapide (FDLF), car les charges sont fonction de la tension.

<sup>1</sup> Le noeud balancier (régulateur) est le noeud référence pour les NRLF et FDLF.

Ces résultats relatifs, ne peuvent être admis dans les études de sécurité, surtout lorsque le noeud qui a l'habitude d'être pris pour référence est déclenché.

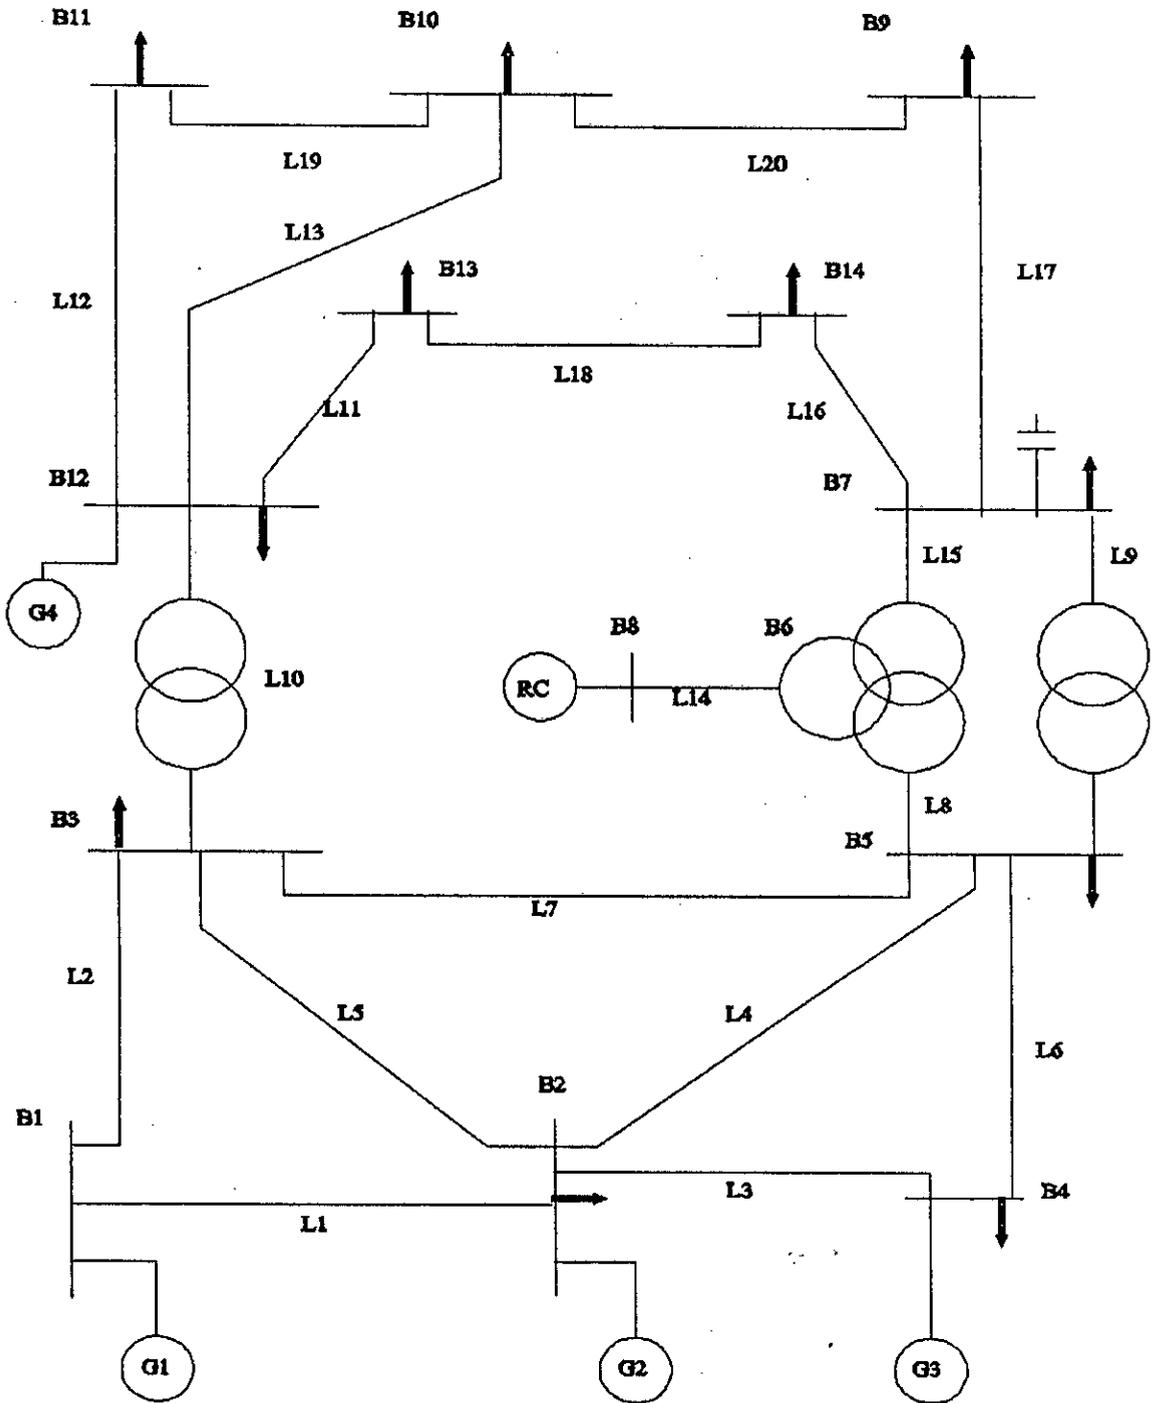


Figure III.8 Réseau IEEE 14 noeuds modifié

### III.3. Conclusion

Dans ce qui précède, il a été mis en avant la nécessité d'utiliser un modèle réaliste d'écoulement de charge dans les études de sécurité.

Pour cela, un modèle dynamique d'écoulement de charge, qui tient compte du réglage automatique des générateurs d'un réseau, et de la réaction de la charge, a été développé.

Le nouveau modèle ayant été dérivé de l'écoulement de charge découplé rapide standard (FDLF type (BX)), il en présente des performances de temps de calculs semblables.

Il reste maintenant à intégrer cet outil dans un algorithme complet d'analyse de sécurité statique et de génération d'ensembles d'apprentissage pour réseaux de neurones.

## CHAPITRE IV

### GENERATION DE L'ENSEMBLE DE DONNEES (Application au réseau IEEE 14 noeuds)

#### IV.1. Algorithme général

Le principe est le suivant:

L'objectif étant de pouvoir évaluer la sécurité statique<sup>1</sup> d'un réseau électrique à tout moment de la journée et de l'année, il est donc nécessaire de soumettre ce dernier à différentes figures de charges lors de la génération des ensembles de données.

Toute figure de charge donnant un fonctionnement sain en présence de tous les ouvrages, c'est à dire une sécurité de niveau (n), sera retenue comme un cas de base sous lequel sera déclenché un à la fois l'ensemble des ouvrages. La sécurité sera bonne s'il n'y a aucune violation de limites pour l'ensemble des déclenchements.

Pour chaque plan de charge un plan de production est établi. Tous les groupes sont supposés avoir le même statisme. Ainsi leur facteur de participation  $x_i$  est proportionnel à leur puissance maximale. Si un groupe se voit affecter une puissance à produire égale à son maximum, ou est déclenché, alors son facteur de participation est annulé.

L'algorithme d'analyse de la sécurité est détaillé ci-après.

---

<sup>1</sup> Dépassement en tension ou en courant après tout déclenchement d'ouvrage.

Algorithme d'analyse de la sécurité

1. Initialiser des indicateurs binaires de sécurité pour la tension et le courant ( $V$ ,  $I$ , et général):  $dg_V=0$ ;  $dg_I=0$ ;  $dg=dg_V+dg_I$ .
2. Varier le plan de charge.
3. Répartir la production sur l'ensemble des générateurs (selon le niveau total de la charge + pertes estimées).
4. Calcul du DFDLF sur le réseau sain (présence de tous les ouvrages).
5. S'il y a un dépassement en tension ( $|V-V_n|>0.05pu$ ) ou en courant ( $I_i>1.0pu$ ), aller en 2 (recherche d'un autre point).
6. Sauvegarder le vecteur d'état et de contrôle (precontingency state and control vector), solution du DFDLF.
  7. Réinitialiser les tensions et désactiver les régleurs en charge des transformateurs s'il ne le sont pas.
  8. Déclencher un ouvrage (suppression d'une ligne ou d'un groupe).
  9. Test de connexité du réseau: Si apparition d'ilots (réseaux séparés) ne pas simuler, aller en 12.
  10. Calcul de l'écoulement de charge selon la méthode découplée rapide dynamique (DFDLF).
  11. Rechercher d'éventuels dépassements de tension ou de transit ( $|V-V_n|>0.10pu$ ,  $I_i>1.2pu$ ). S'il y a dépassement alors mettre:  $dg_V=1$  ou  $dg_I=1$  et  $dg=dg_V+dg_I$ .
  12. Si dernier ouvrage à déclencher, aller en 14.
  13. Réenclencher l'ouvrage déclenché
    - . Réinitialiser les tensions.
    - . Recalculer le cas de base (car les productions ont pu changer par action des régulateurs primaires).
    - . aller en 7.
14. Ajouter au vecteur d'état et de contrôle sauvegardé, les trois (3) indicateurs de sécurité.
15. Si le nombre de points (vecteurs) n'a pas atteint la limite requise aller en 1.
16. fin.

L'algorithme d'analyse de la sécurité étant défini, on peut se poser les deux questions suivantes:

Comment faire varier le plan de charge du réseau ?

Dans quelle mesure le type de variation influencerait l'architecture du réseau de neurones, au-delà de la dimension du réseau électrique traité ?

Nous allons tenter de répondre à ces questions dans ce qui suit à travers un exemple d'étude, en l'occurrence le réseau standard IEEE 14 noeuds.

#### IV.2. Les différents ensembles générés

Pour l'étude de sensibilité de la sécurité, et de suite, de l'architecture du réseau de neurones<sup>1</sup>, vis-à-vis des différentes variables d'état du réseau électrique, il est généré des ensembles de données sous différentes variations du plan de charge.

D'un point de vue pratique, pour un réseau électrique d'étendue géographique restreinte, la variation en profondeur du plan de charge est la plus apte à représenter la variation homogène de la consommation. Par contre, pour un grand réseau, où l'étendue géographique est telle qu'il est possible de parler d'écart horaire, et donc de consommation hétérogène dans le temps, il est préférable d'adopter une variation en surface de la charge.

##### IV.2.a. Variation en profondeur du plan de charge

La variation en profondeur de la charge, s'obtient en générant un nombre aléatoire entre 0.8 et 1.2, suivant une loi de distribution uniforme [31] (voir Figure IV.1), et en multipliant toutes les charges nodales actives et réactives, du plan de charge

---

<sup>1</sup> Dimensions de la couche d'entrée.

de définition du I3E14, par cette valeur. On obtient ainsi une montée ou une descente homogène du plan de charge (Cf. Figure IV.3, Figure IV.4, Figure IV.5), avec conservation du facteur de puissance.

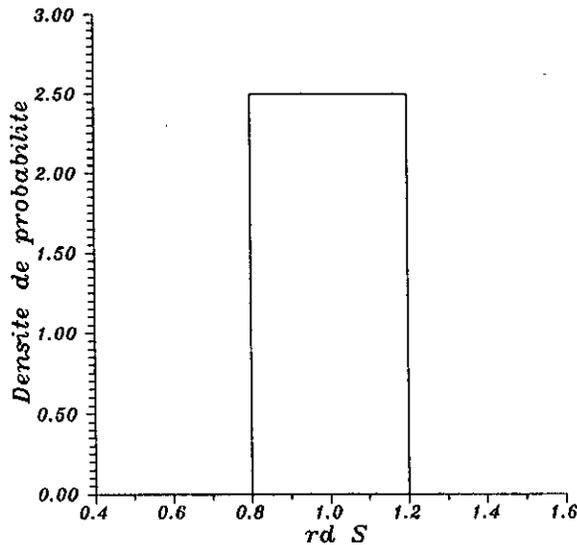


Figure IV.1 Distribution du facteur multiplicateur de puissance apparente

#### IV.2.b. Variation en surface du plan de charge

La variation en surface s'obtient en faisant varier les charges du réseau indépendamment les unes des autres. Pour cela, un nombre aléatoire  $rd_S$  entre 0.8 et 1.2 de loi uniforme [31] (voir Figure IV.1) est généré pour chaque noeud et multiplie ainsi la puissance nodale apparente.

On construit de cette manière deux ensembles distincts. L'un à facteur de puissance constant et l'autre à facteur de puissance variable, obtenu en générant des angles suivant une loi normale centrée [31], le facteur de puissance est obtenu en générant des

tangentes d'angles suivant une loi normale centrée [31] (voir Figure IV.2), dont le segment à  $\pm 3\sigma$  est  $[-1.13, +1.13]$  correspondant à un  $\cos\varphi$  compris dans la frange  $[0.65, 1.00]$  en déphasage avant et arrière.

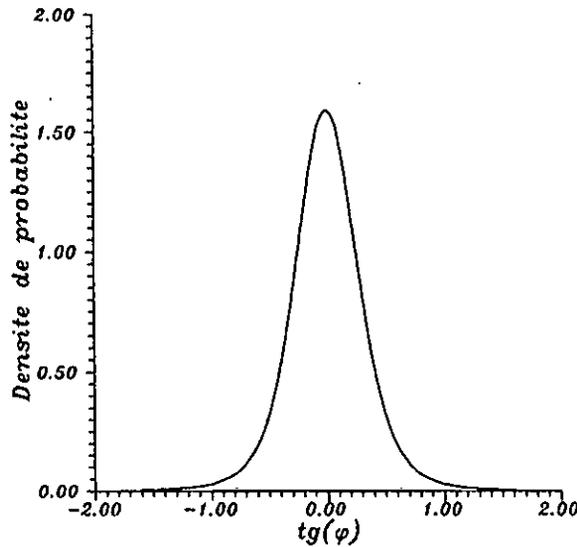


Figure IV.2 Distribution normale de  $\text{tg}(\varphi)$

Chaque type de variation est effectué avec et sans modélisation de la charge. Lorsque la charge est modélisée, elle est considérée passive pour tous les noeuds du réseau, c'est à dire qu'elle consomme une puissance proportionnelle au carré de sa tension d'alimentation, ce qui revient à prendre les coefficients de l'équation (III.1) de la manière suivante ( $a=d=1$ ,  $b=c=e=f=0$ ).

On génère ainsi deux cents (200) plans de charges différents par variation et par modélisation. Le réseau I3E14, comprenant 20 lignes et transformateurs, et 5 machines, on aura 25 déclenchements à effectuer. On évalue ainsi à 5000 ( $200 \times 25$ ) le nombre de calculs d'écoulements de puissance nécessaires pour un plan de charge donné. Ici, l'utilité de l'écoulement découplé rapide dynamique (DFDLF) prend toute sa valeur.

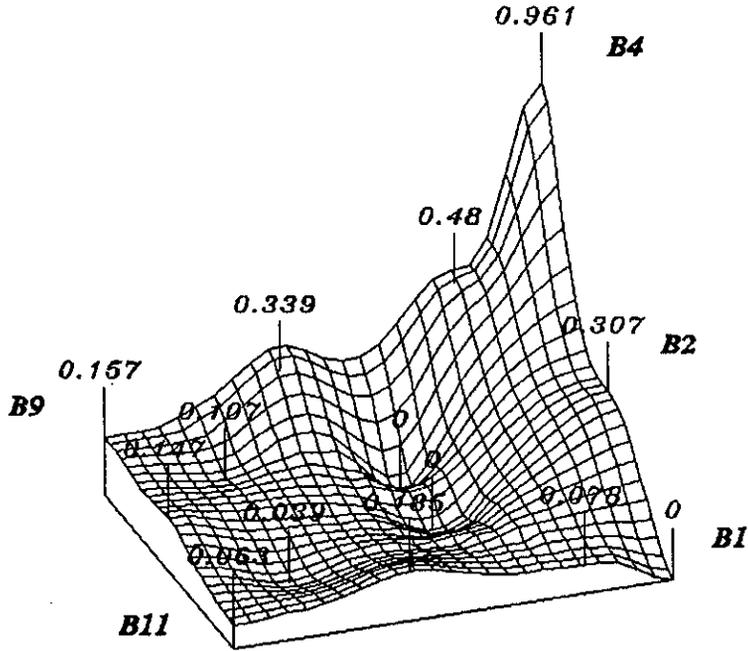


Figure IV.3 Distribution en surface de la charge apparente moyenne (pu) du réseau I3E14 d'étude

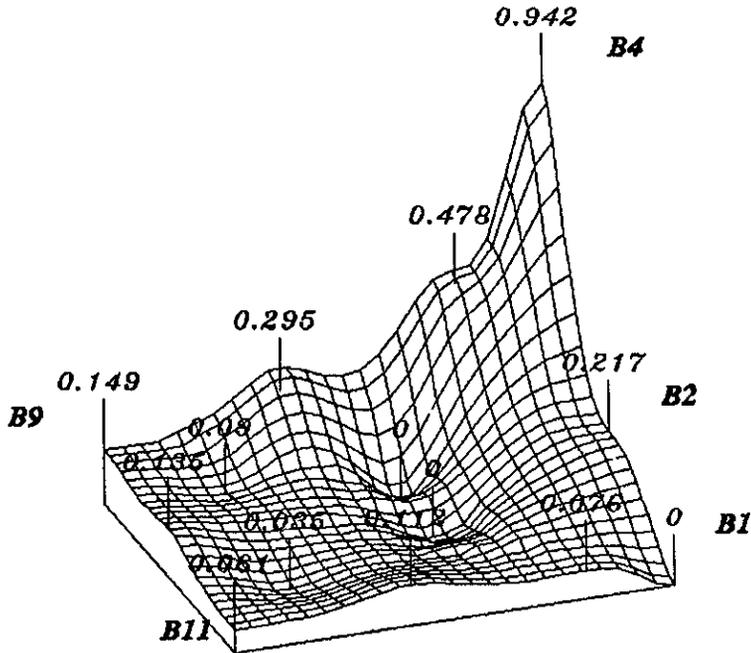


Figure IV.4 Distribution de la charge active moyenne (pu) du réseau I3E14 d'étude

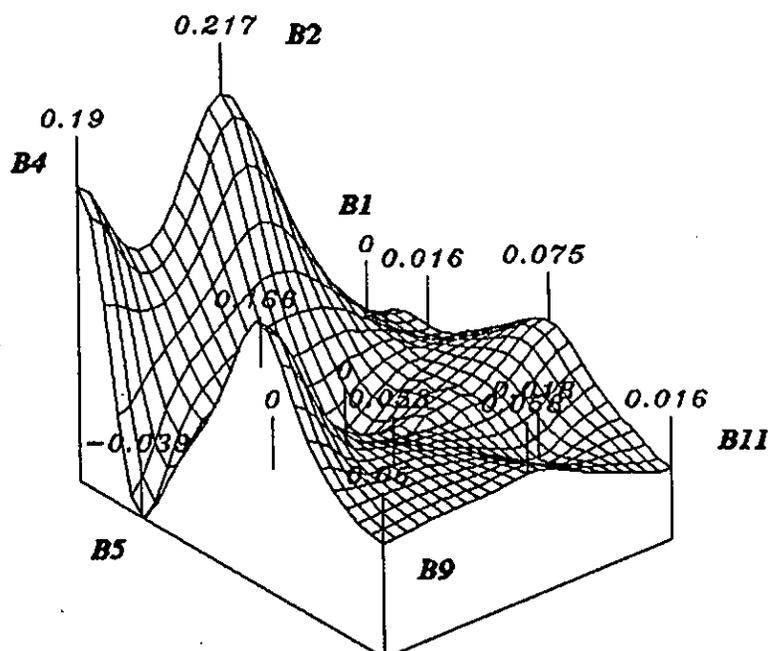


Figure IV.5 Distribution en surface de la charge réactive moyenne (pu) du réseau I3E14 d'étude.

Dans la suite du travail, les différents ensembles générés seront identifiés sur deux caractères, le premier caractère renseignant sur la modélisation ou non de la charge, et le deuxième sur le mode de variation de cette dernière dans le réseau.

Ainsi, on aura:

CP: Charge constante, variation en profondeur.

CS: Charge constante, variation en surface à  $\cos\phi$  constant.

CS': Charge constante, variation en surface à  $\cos\phi$  variable.

MP: Charge modélisée, variation en profondeur.

MS: Charge modélisée, variation en surface à  $\cos\phi$  constant.

MS': Charge modélisée, variation en surface à  $\cos\phi$  variable.

La définition des différents ensembles de données faite, il reste à mener l'étude de sensibilité pour dimensionner le vecteur d'entrée du réseau de neurones.

### IV.3. Etude de sensibilité

#### IV.3.a. Analyse des données

Le vecteur qui décrit l'état d'un réseau électrique est constitué de l'ensemble des puissances de production et de consommation (actives et réactives), de l'ensemble des tensions, des angles, des positions des régleurs en charge, et des totaux des puissances (génération, charge, perte). La dimension de ce vecteur est en général importante. A titre d'exemple pour le réseau I3E14, cette dimension est égale à  $n=72$ .

De l'ensemble de ces variables, certains sont meilleurs indicateurs que d'autres pour l'estimation de la sécurité statique. L'extraction de ce sous-ensemble de description, qui peut être appelé *Ensemble caractéristique*, est un facteur de simplification certain du problème de dimensionnement du réseau de neurones, vu qu'il réduit les dimensions de la couche d'entrée de ce dernier, et par suite le nombre de poids synaptiques à déterminer.

L'extraction de l'ensemble caractéristique, est fait suivant une heuristique statistique permettant de calculer l'influence qu'a une variable donnée dans la classification de l'état du réseau électrique d'étude [14], [18]. Cette méthode est basée sur la notion heuristique de distance interclasses.

La fonction suivante, utilisée dans le domaine de reconnaissance des formes, fournit un moyen simple et puissant de calcul du poids informatif d'une variable donnée dans la classification.

$$F_i = \left| \frac{m_i^{(S)} - m_i^{(T)}}{\sigma_i^{(S)} + \sigma_i^{(T)}} \right| \quad 1 \leq i \leq n \quad (IV.1)$$

où:

$$m_i^{(\cdot)} = \frac{1}{N^{(\cdot)}} \sum_{j=1}^{N^{(\cdot)}} x_{ij}^{(\cdot)}$$

(IV.2)

$$\sigma_i^{(\cdot)} = \sqrt{\frac{1}{N^{(\cdot)}} \sum_{j=1}^{N^{(\cdot)}} (x_{ij}^{(\cdot)} - m_i^{(\cdot)})^2}$$

$m_i^{(\cdot)}$  et  $\sigma_i^{(\cdot)}$  sont la moyenne et l'écart-type de la variable  $x_i$  dans la classe  $(\cdot)$ . L'exposant (S) correspond à l'état sûr ("Secure"), et (I) à l'état dangereux ("Insecure").

$N^{(S)}$  et  $N^{(I)}$  étant les effectifs respectifs des classes S et I, on a  $N = N^{(S)} + N^{(I)}$  effectif de la base de donnée toutes classes confondues (dans notre cas  $N=200$ ).

On calcul ainsi le facteur  $F$  pour toutes les variables de l'ensemble de données. Les variables présentant une valeur importante de  $F$ , sont celles qui apportent le plus d'informations à la classification.

En classant les variables selon leur poids informatif  $F$ , on extrait l'ensemble caractéristique selon l'algorithme suivant:

#### Algorithme d'extraction de l'ensemble caractéristique

1. Calculer  $F_i$  pour toutes les variables  $x_i$  ( $1 \leq i \leq n$ )
2. Etablir par ordre décroissant des  $F_i$  une liste  $\mathcal{F}$  des  $x_i$
3. Pointer sur le premier élément de la liste
4. Calculer le coefficient de corrélation  $C_c$  de toutes les variables inférieures  $x_j$ , vis-à-vis de la variable pointée  $x_i$
5. Eliminer de la liste  $\mathcal{F}$  toutes les variables inférieures ayant un coefficient de corrélation vis-à-vis de  $x_i$ , tel que  $|C_c| > 0.95$

6. Si  $x_i$  est le dernier élément de  $\mathcal{F}$  aller en 8
7. Pointer sur la prochaine variable  $x_i$  de la liste  $\mathcal{F}$ , aller en 4
8. Stop

Le coefficient de corrélation entre la  $i^{\text{ème}}$  et  $j^{\text{ème}}$  variable, permet de mesurer le degré de redondance de l'information qu'apporte chaque variable dans l'évaluation de la sécurité, et de retenir que la variable la plus expressive pour former l'ensemble caractéristique.

Le coefficient de corrélation est défini comme suit [20]:

$$C_{C_{ij}} = \frac{E(x_i x_j) - E(x_i) E(x_j)}{\sigma_i \sigma_j} \quad i, j = 1, \dots, n \quad (IV.3)$$

avec

$$E(x_i x_j) = \frac{1}{N} \sum_{k=1}^N x_{ik} x_{jk}$$

$$E(x_i) = \frac{1}{N} \sum_{k=1}^N x_{ik} \quad (IV.4)$$

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{k=1}^N (x_{ik} - E(x_i))^2}$$

La valeur 0.95 à l'étape 5 est choisie arbitrairement [14], [18]. Elle est un compromis entre la précision et la complexité du réseau de neurones qu'elle va engendrer, vu que lorsque  $C_c$  croit, le nombre de variables retenues augmente et vice versa.

L'ensemble des variables restant dans la liste  $\mathcal{F}$ , constituera le vecteur caractéristique.

### IV.3.b.Résultats et observations

On réduit comme précédemment expliqué, les différents ensembles générés CP, CS, CS', MP, MS, MS'.

Sachant que les six ensembles, sont constitués de vecteurs d'état de dimension  $n=72$ , on obtient après réduction, selon le type d'origine des ensembles de données, différents vecteurs caractéristique (Cf. tableau IV.1).

Type	Vecteur caractéristique	Dim
CP	$Q_{G2}, \delta_4, Q_{G4}$	3
CS	$\delta_9, \delta_{10}, \delta_{14}, \delta_3, \Sigma P_G, P_{D4}$	6
CS'	$\Sigma Q_G, Q_{D4}, \delta_{12}, \delta_3, Q_{D5}, \delta_6, \delta_9, Q_{G2}, P_{D4}, \Sigma Q_G, \Sigma P_D$	11
MP	$Q_{G4}, \delta_4, Q_{G2}$	3
MS	$\delta_{14}, \delta_9, \delta_{12}, \delta_3, \Sigma P_D, \delta_4$	6
MS'	$\Sigma Q_D, \delta_{10}, \delta_9, \delta_3, \delta_6, \Sigma P_D, Q_{G2}, \Sigma Q_G, \delta_4, Q_{D4}$	10

Tableau IV.1. Résumé des vecteurs caractéristiques

A partir du tableau IV.1 et de la Figure IV.6, on peut dire que la dimension du vecteur caractéristique est plus sensible à la manière dont la charge varie, qu'à la modélisation de cette dernière.

La modélisation de la charge, a un effet qualitatif, et non quantitatif sur les variables retenues comme indicateurs. Il suffit, pour voir cela, de comparer des ensembles de même type de variation de charge (CX et MX) (Cf. tableau IV.1).

D'autre part, on voit que plus la variation de la charge est complexe (XP, XS, XS'), plus la dimension du vecteur

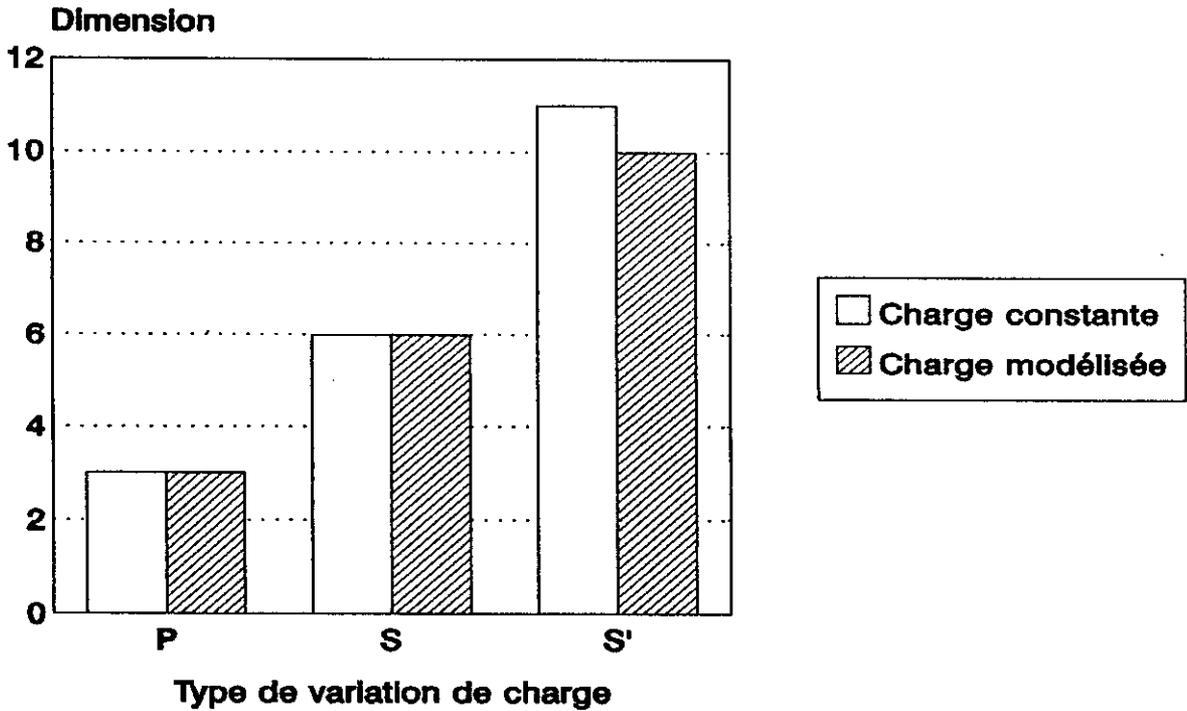


Figure IV.6 Sensibilité du vecteur caractéristique à la variation et à la modélisation de la charge.

caractéristique est grande.

#### IV.4. Conclusion

Par la variation aléatoire de la charge, une approche probabiliste des différents régimes de fonctionnement d'un réseau électrique a été faite.

Cette approche probabiliste, assure de l'exhaustivité de l'échantillonnage, et réduit donc l'erreur lié à la quantité d'information apportée par la base d'apprentissage au réseau de neurones.

D'autre part, l'utilisation d'une heuristique statistique a permis de réduire les dimensions du problème à résoudre, et a permis de tirer des conclusions sur l'effet qu'engendre la manière

dont varie la charge, ainsi que le fait de la modéliser ou pas lors des simulations.

Ainsi, le choix de la dimension de la couche d'entrée du réseau de neurone, ne dépend presque pas de la modélisation de la charge, mais est fortement lié à la manière dont varie l'ensemble des charges du réseau. Autrement dit, ce n'est pas la précision du modèle qui influe sur les dimensions du réseau de neurones, mais le mode de fonctionnement du réseau électrique.

## CHAPITRE V

### CONSTRUCTION DU RESEAU DE NEURONES MULTICOUCHES (Application au réseau IEEE 14 noeuds)

Il a été souligné dans ce qui précède, l'absence de méthode systématique pour la conception de réseaux de neurones multicouches, ainsi que les erreurs qu'engendrait la pratique de ces derniers.

Dans ce chapitre, il va être présenté une heuristique permettant de construire de manière objective un réseau de neurones pour l'évaluation de la sécurité statique, tout en tentant de minimiser le risque d'erreur due au choix de l'espace fonctionnel ainsi qu'aux différents paramètres liés à la formation.

#### V.1. Dimensionnement de la couche cachée

Le dimensionnement de la couche d'entrée étant clarifié précédemment, il reste donc le choix du nombre de neurones de la couche cachée à effectuer. Ceci va être mené sur l'ensemble de données CS, vu la dimension intermédiaire de son vecteur caractéristique.

Il est à signaler que le choix d'un ensemble de type XS', ne fera que compliquer l'apprentissage du réseau de neurones, et non la démarche de dimensionnement.

#### V.1.a. Préparation de l'ensemble d'apprentissage et de test

Après avoir réduit la dimension du vecteur d'entrée, reste à extraire de l'ensemble de données, deux ensembles, l'un de test et l'autre d'apprentissage pour la formation du réseau de neurones.

Le premier ensemble (test), est formé de 10% à 20% des patterns de chacune des deux classes se trouvant dans la base de donnée [26]. Pour cela le tirage pour l'ensemble de test est effectué tous les dix (10) patterns de chaque classe, et surtout sans remise, pour que ces derniers ne se retrouvent pas dans l'ensemble d'apprentissage.

Le deuxième ensemble (apprentissage) doit contenir autant de patterns pour chacune des classes. De plus, il faudrait que ces derniers soient tirés de la base de données à intervalles réguliers dans chaque une des classes, et qu'ils s'alternent dans l'ensemble d'apprentissage. Cette dernière précaution est prise pour qu'il n'y ait pas une tendance à reconnaître une classe plutôt qu'une autre [26].

Les principes sus-cités appliqués à la base de données CS, on obtient pour les ensembles de test (20%) et d'apprentissage les effectifs résumés dans le tableau (V.1) suivants:

Etat du réseau	Base de Don.	Ens. Test	Ens. Appr.
Sûr	56	11	45
Dangereux	144	28	45
Total	200	39	90

Tableau V.1. Effectifs des ensembles nécessaires à la formations du réseau de neurones.

On remarque que, le nombre d'états sûr du réseau étant le plus faible (56), il détermine le nombre de patterns dangereux à prendre pour former l'ensemble d'apprentissage ( $56-11=45$ ), même si ces derniers sont en plus grand nombre (144).

### V.1.b.Principe de la construction incrémentale

La construction incrémentale a pour objectif d'annihiler l'erreur due au choix de l'espace fonctionnel. Elle a pour principe d'augmenter progressivement le nombre de degré de liberté d'une

fonctionnelle, en partant d'une structure minimale jusqu'à atteindre une interpolation optimale de l'ensemble de données présenté [22].

Dans le réseau de neurones à une couche cachée, cette dernière reste la seule à dimensionner lorsque la couche d'entrée et de sortie sont prédéterminées, comme c'est le cas dans notre démarche.

Il va être appliqué ainsi dans ce qui suit la construction incrémentale en partant d'un réseau de neurones à une couche cachée constituée d'un seul neurone.

Les performances du réseau de neurones, que ce soit de mémorisation ou de généralisation<sup>1</sup>, seront évaluées à chaque étape de la construction (incrémentation du nombre de neurones de la couche cachée), par la racine carrée de l'erreur quadratique moyenne (REQM), et/ou par le coefficient de corrélation de Pearson [20], [26].

Ces indicateurs de performance seront calculés entre la sortie fournie par le réseau de neurones et la sortie désirée lors de l'apprentissage et du test. Ils ont pour expression:

Erreur (REQM):

$$\epsilon = \sqrt{\frac{1}{E} \sum_{k=1}^E (d_k - o_k)^2} \quad (V.1)$$

Coef. de corrélation:

$$\rho = \frac{\sum_{k=1}^E (d_k - \bar{d})(o_k - \bar{o})}{\sqrt{\sum_{k=1}^E (d_k - \bar{d})^2 \sum_{k=1}^E (o_k - \bar{o})^2}} \quad (V.2)$$

où:  $o_i$ : est la sortie fournie pour le pattern  $i$   
 $d_i$ : est la sortie désirée pour le pattern  $i$

---

<sup>1</sup> La mémorisation correspond à l'interpolation de l'ensemble d'apprentissage  $K$  et la généralisation à l'interpolation de l'ensemble de test  $K'$  (Cf. chapitre II.3).

$E$ : est l'effectif de l'ensemble d'apprentissage ou de test, selon qu'on évalue la performance de mémorisation ou de généralisation du réseau de neurones.

$d$ : moyenne des  $d_i$

$o$ : moyenne des  $o_i$

Lorsque:  $\rho=1$  la corrélation est parfaite

$\rho=0$  la corrélation est nulle

$\rho=-1$  il y a anti-corrélation

### V.1.c. Formation du réseau de neurones

Dans ce qui suit la construction incrémentale va être menée pour un réseau de neurones formé par rétropropagation du gradient (Cf. chap.II). Cette formation sera menée de deux manières différentes:

- une fois en fixant comme critère d'arrêt, un nombre limite de cycles d'apprentissage,
- une autre fois en fixant une tolérance sur l'erreur  $\epsilon$ .

Les coefficients d'apprentissage (pas et moment) (Cf. chap.II), ont été choisis de manière différente pour chacune des couches, et décroissants en fonction du cycle d'apprentissage [12], [26] (Cf. tableau V.2).

Cycles	0 - 10 000		10 000 - 30 000		30 000 - 70 000	
	cach	sort	cach	sort	cach	sort
Pas $\eta$	0.6	0.4	0.45	0.2	0.25	0.1
Moment $\mu$	0.4	0.2	0.30	0.1	0.16	0.1

Tableau V.2. Evolution des coefficients d'apprentissage.

Il a été choisi des coefficients plus élevés pour la couche cachée, pour que l'apprentissage s'y fasse plus rapidement et

pouvoir filtrer correctement les données d'entrée. Ainsi, il parviendra à la couche de sortie des patterns traités et plus facile à classer [26].

La loi d'apprentissage retenue est la loi "Normal Delta". Cette dernière est une variante de la loi "Delta", par le fait qu'elle met à jour les poids, non pas à chaque présentation de pattern, mais en cumulant les erreurs jusqu'à atteindre le cycle supérieur ou égal à la racine de l'effectif de l'ensemble d'apprentissage [26]. Cette loi est un bon compromis entre la rapidité et le risque d'instabilité de la loi "Delta" d'une part, et, la lenteur et la robustesse de la loi "Cumulative Delta" qui met à jour les poids tous les fins de cycle.

Puisque les données d'entrée peuvent prendre des valeurs positives et négatives, la fonction d'activation des neurones a été choisie de manière à éviter toute saturation prématurée, lors de l'apprentissage. Ainsi la fonction tangente hyperbolique a été préférée à la fonction sigmoïde.

Les données d'entrées sont normalisées entre -1 et +1 selon les valeurs extrêmes qu'elles atteignent dans les ensembles de test et d'apprentissage.

A chaque étape de la construction, vu l'initialisation aléatoire<sup>1</sup> des poids synaptiques, trois tentatives de formation sont effectuées. La performance du réseau de neurones à chaque stade, est calculée par la moyenne des coefficients de corrélation relevés lors des trois essais.

Toutes les simulations ont été effectuées avec "NeuralWorks Professional II/PLUS ver. 4.0", un outil de développement de réseaux de neurones assisté par ordinateur, produit par NeuralWare, Inc.

---

<sup>1</sup>les poids  $w_{ij}$  sont initialisés dans le segment de valeurs  $[-0.1, 0.1]$ , proche de zéro [9], [25], [26].

V.1.c.1. Formation par durée d'apprentissage fixe et erreur libre

La construction commence avec un seul neurone dans la couche cachée, sans seuil d'activation (biais). Ce dernier est ajouté et maintenu pour le reste des étapes. On identifiera la toute première étape par l'étape "0" puis toutes les autres, selon le nombre de neurones de la couche cachée ( $h$ ).

Le nombre de cycles d'apprentissage est fixé à 35000. Le choix de cette dernière valeur est dicté par le souci d'avoir des facteurs de performance d'apprentissage stabilisé (Cf. Figure V.1).

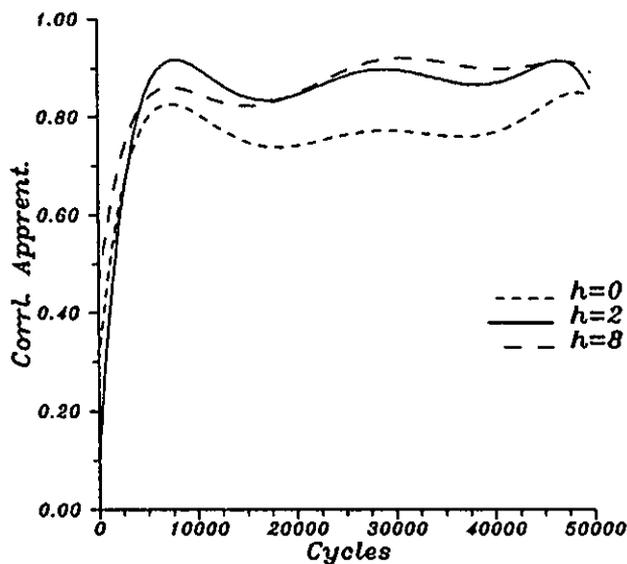
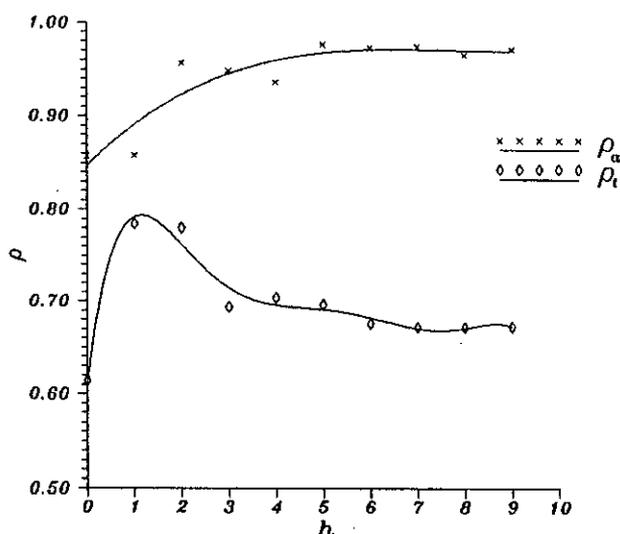


Figure V.1 Performance en fonction de la durée d'apprentissage

L'évolution des coefficients de corrélation d'apprentissage et de test obtenus, en fonction du nombre de neurones " $h$ " de la couche cachée, est représentée dans la Figure V.2. Les résultats confirment la théorie (Cf. chap.II.3) [22], qui stipule que la performance d'interpolation d'une fonctionnelle croît en fonction du nombre de degrés de libertés de cette dernière, et tend à

l'infini, à l'interpolation parfaite (voir  $\rho_a$ ). Par contre la performance de généralisation croit jusqu'à atteindre un maximum, puis décroît quand le nombre de degrés de liberté augmente<sup>1</sup> ( $\rho_t$ ).



**Figure V.2** Performances de mémorisation et de généralisation en fonction de  $h$ . (Critère d'arrêt: Durée d'apprentissage).

Le tracé des performances de mémorisation ( $\rho_a$ ) et de généralisation ( $\rho_t$ ) du réseau de neurones permet de choisir de manière optimale la dimension de la couche cachée.

En effet, le but étant de maximiser la capacité du réseau de neurones à reconnaître les différents états d'un réseau électrique d'un point de vue sécurité statique, on peut choisir la dimension de la couche cachée, en sommant  $\rho_a$  et  $\rho_t$  et retenir la dimension qui en donne la somme la plus élevée.

<sup>1</sup>On parle alors d'"over-fitting".

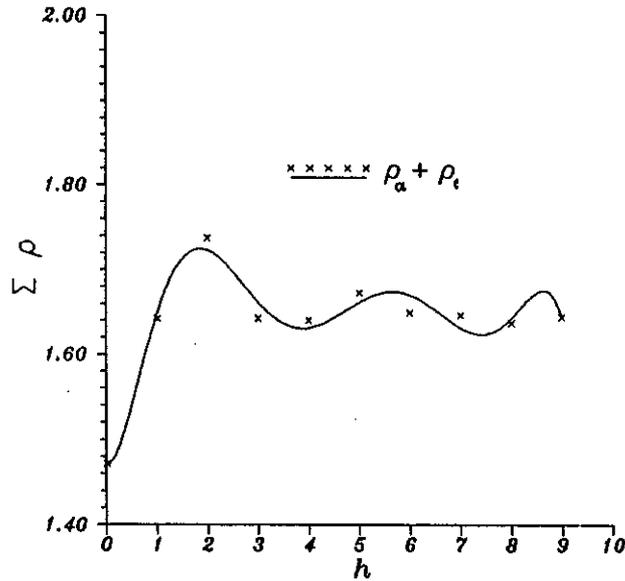


Figure V.3 Performance totale du RN

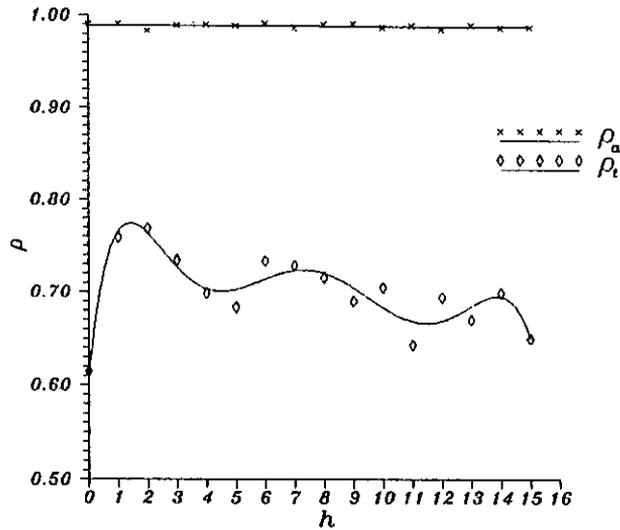
Dans notre cas en l'occurrence, la dimension optimale de la couche cachée est,  $h=2$  (Cf. Figure V.3).

#### V.1.c.2. Formation par erreur fixe et durée d'apprentissage libre

Si l'on est contraint par la durée d'apprentissage, alors on peut choisir comme critère d'arrêt l'erreur  $\epsilon$  REQM (voir équation (V.1)).

Comme la sortie de notre réseau de neurones est comprise dans le segment  $[0,1]$ , on pourra considérer toute sortie comprise entre 0.55 et 1.0, comme identifiant correctement un cas de danger (1), et toute sortie entre 0.0 et 0.45 comme un cas sûr (0).

Pour arriver à cette performance, la valeur 0.15 a été choisie comme erreur REQM d'arrêt d'apprentissage. Cette valeur correspond au tiers de l'intervalle de confiance (0.45). Ces deux valeurs sont prises arbitrairement à ce stade, et peuvent être revues si les performances obtenues ne sont pas satisfaisantes.



**Figure V.4** Performances de mémorisation et de généralisation en fonction de  $h$ . (Critère d'arrêt: Erreur REQM).

On procède, après le choix de l'erreur (REQM), de la même manière que précédemment, à la construction incrémentale de la couche cachée. On obtient alors, les performances représentées dans la Figure V.4.

On voit à partir de la Figure V.4, qu'en choisissant un seuil d'erreur comme critère d'arrêt, cela équivaut à fixer le coefficient de corrélation d'apprentissage  $\rho_a$ . Le fait que  $\rho_a$  soit proche de un (1), nous rassure quand au choix du niveau d'erreur accepté comme seuil.

Le coefficient mesurant la performance de mémorisation étant invariant, le choix de la dimension de la couche cachée du réseau de neurones se fait uniquement à partir de sa performance  $\rho_t$  de généralisation. On relève pour cela le point maximal de la courbe  $\rho_t(h)$  de la Figure V.4, et on retient ainsi, comme précédemment, la valeur de  $h=2$ .

V.1.d.Conclusion

La construction incrémentale a permis de trouver par deux approches différentes la dimension de la couche cachée du réseau de neurones multicouches, formé par la loi "Normal Delta"variante de la loi "Delta" de rétropropagation du gradient.

La dimension finale du réseau de neurone pour l'évaluation de la sécurité statique du réseau I3E14 est:

- Nombre couches cachées: 1
- Nombre de neurones entrée: 6
- Nombre de neurones cachée: 2
- Nombre de neurones sortie: 1

SA (U+I) Mod.Load=N0 & Pertb.Load=Surface

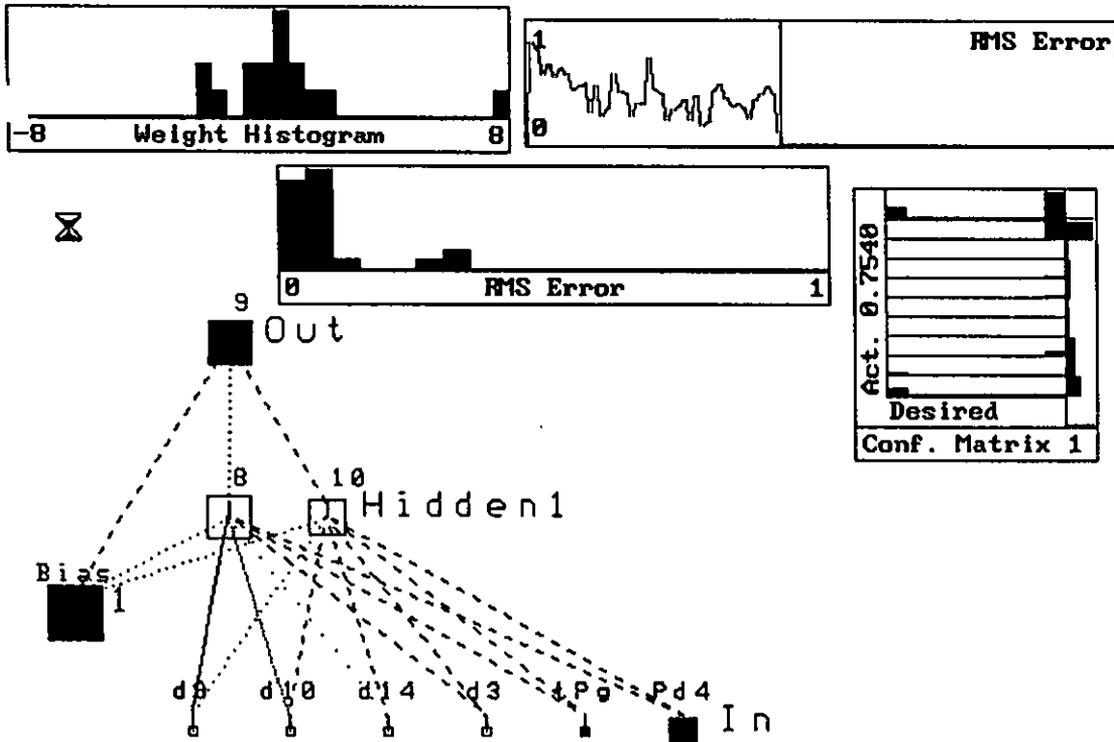


Figure V.5 Configuration finale du réseau de neurone retenu

Les performances obtenues pour cette structure, sont les suivantes:

	Cycle fixe- err.libre	Err.fixe- cycle libre
$\rho_a$ moyen	0.9570	0.9833
$\rho_t$ moyen	0.7802	0.7689
REQM <sub>a</sub>	/	0.15

**Tableau V.3.1.** Performance du réseau de neurones généraliste, dans l'évaluation de la sécurité statique du réseau I3E14.

	Durée fixe - Erreur libre		Erreur fixe - Durée libre	
	Statistique	%	Statistique	%
Bon class <sup>mt</sup> appr.	87/90	96.7	86/90	95.6
Bon class <sup>mt</sup> test	33/39	84.6	33/39	84.6
Bon class <sup>mt</sup> appr.+ test	120/129	93.0	119/129	92.3

**Tableau V.3.2.** Statistiques des réponses correctes du réseau de neurones généraliste, dans l'évaluation de la sécurité statique du réseau I3E14.

Le niveau de performance de mémorisation atteint est très bon. Par contre, le niveau de performance de généralisation pourrait éventuellement être amélioré (tableau V.3.1).

On peut à travers les résultats statistiques des réponses correctes (tableau V.3.2), apprécier la performance de la structure du réseau de neurones obtenue. Selon l'une ou l'autre des approches de formation, les résultats sont similaires. Ils sont très bons pour la mémorisation de l'ensemble d'apprentissage, puisque le réseau de neurones, classe correctement en moyenne 96% des patterns, mais comme conclu à travers les coefficients de

corrélation, la capacité à généraliser à des situations non rencontrées lors de l'apprentissage reste moyen vu que 84.6% des exemples de l'ensemble de test sont correctement classés.

## **V.2. Amélioration des performances**

Comme les performances de mémorisation sont très bonnes ( $\rho_a$  in  $[0.95, 1.00]$ ), il n'est pas nécessaire pour le réseau de neurones précédent de changer de procédure d'optimisation (algorithme de formation).

Néanmoins, il pourrait être tenté d'améliorer les performances de généralisation, sans détériorer ceux de mémorisation. Ceci pourrait être obtenu en jouant sur la quantité d'informations présente dans l'ensemble d'apprentissage<sup>1</sup>, ou bien en simplifiant le problème d'évaluation de la sécurité, en spécialisant le réseau de neurone afin qu'il évalue uniquement, les dangers de tension, ou de courant.

### **V.2.a. Amélioration par dimensions de l'ensemble d'apprentissage**

L'objectif est de trouver la quantité optimale d'informations devant être dans l'ensemble d'apprentissage, afin que le contour de l'hypervolume de sécurité soit suffisamment décrit pour que le réseau de neurones soit capable d'une bonne généralisation. D'autre part, il ne faut pas qu'il y ait surplus de patterns à tel point que l'allure de l'enveloppe de sécurité soit "imperceptible" par la dimension actuelle du réseau de neurones.

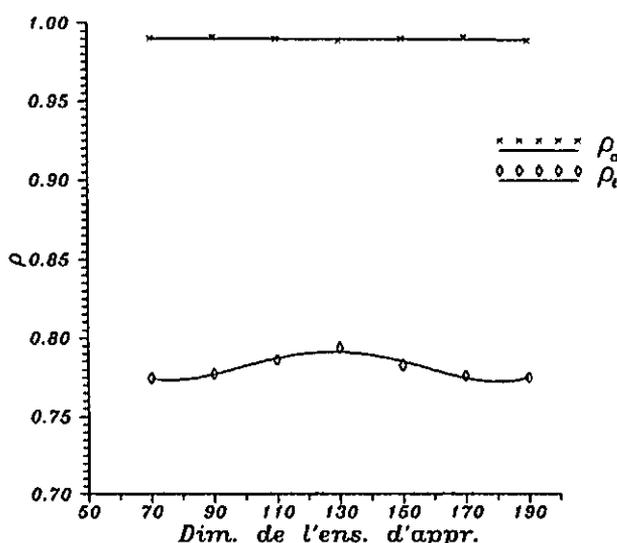
Les dimensions des ensembles d'apprentissage et de test réunies pouvant dépasser, dans la recherche, la dimension de la base de donnée (200), une base plus grande (400) a été générée

---

<sup>1</sup>La quantité d'informations présente dans l'ensemble d'apprentissage est proportionnelle à sa dimension.

selon l'algorithme exposé dans le chapitre précédent (Cf. section IV.1). L'ensemble retenu est toujours de type CS.

La recherche systématique de la dimension optimale de l'ensemble d'apprentissage est effectuée avec la structure du réseau de neurones précédemment obtenue (Cf. section V.1). Pour préserver la même performance de mémorisation, on garde toujours la même erreur ( $\epsilon=0.15$ ) comme critère d'arrêt de l'apprentissage.



**Figure V.6** Recherche de la dimension optimale de l'ensemble d'apprentissage

De la Figure V.6, on remarque que l'ensemble d'apprentissage de dimension égale à 130, présente une valeur maximum du coefficient moyen de corrélation, sur l'ensemble de test.

Il est à signaler que la dimension de l'ensemble de test utilisé pour la recherche de la dimension optimale d'apprentissage est égale à 72, vu que la base de données a augmenté.

Afin de juger correctement de l'éventuelle amélioration des performances du nouvel apprentissage, selon le nouvel ensemble (130), on lui présente après formation, les mêmes ensembles

d'apprentissage (90) et de test (39) ayant servi précédemment. On obtient les résultats suivants:

	Dim. Appr.=130	Dim. Appr.=90
$\rho_a$ moyen	0.9809	0.9833
$\rho_t$ moyen	0.8036	0.7689
$\epsilon_a$ (REQM)	0.15	0.15

**Tableau V.4.1.** Performances comparées après augmentation des dimensions de l'ensemble d'apprentissage

	Dim. Appr.=130		Dim. Appr.=90	
	Statistique	%	Statistique	%
Bon class <sup>mt</sup> appr.	85/90	94.4	86/90	95.6
Bon class <sup>mt</sup> test	36/39	92.3	33/39	84.6
Bon class <sup>mt</sup> appr.+test	121/129	93.8	119/129	92.3

**Tableau V.4.2.** Statistiques comparées des réponses correctes après augmentation des dimensions de l'ensemble d'apprentissage

A *idem* ensemble de test, on remarque qu'en prenant comme dimension d'ensemble d'apprentissage  $E_a=130$ , on améliore sensiblement les performances de généralisation, sans pour autant détériorer la performance de mémorisation. Cette dernière qualité a été obtenue par un choix identique de l'erreur  $\epsilon$  (REQM), comme critère d'arrêt de l'apprentissage.

### V.2.b. Amélioration par spécialisation du réseau de neurones

Il est possible d'améliorer les performances d'un réseau de neurones en lui simplifiant la fonction qu'il doit modéliser. Pour cela, on forme, un réseau de neurones évaluant la sécurité statique d'un point de vue dépassement de limites de tension uniquement.

L'analyse des données du point de vue sécurité de tension, pour le dimensionnement de la couche d'entrée, donne les mêmes résultats que pour la sécurité totale (tension + courant). On obtient le même vecteur caractéristique, pour le réseau I3E14, soit:

$$\delta_9, \delta_{10}, \delta_{14}, \delta_3, \Sigma P_G, P_{D4}$$

L'ensemble d'apprentissage est construit de manière à ce qu'il ne contienne que des états sains et de danger par dépassement des limites de tension.

Les ensembles d'apprentissage et de test ont les mêmes dimensions (90/39) que lors de la formation du réseau généraliste, afin que les performances soient comparables.

Le critère d'arrêt étant l'erreur (REQM) fixée à 0.15, la dimension optimale de la couche cachée, obtenue par construction incrémentale, est  $h=1$ , avec un coefficient de corrélation moyen  $\rho_t=0.7736$  (Cf. Figure V.7).

La performance réalisée selon la même méthode de formation pour l'évaluation de la sécurité totale, est à peine dépassée.

La simplification espérée, en éliminant de la base de données les dangers de transits, n'a pas porté ses fruits, vu que tous les dangers de type "courant" surviennent accompagnés de danger de type "tension" (Cf. tableau V.5).

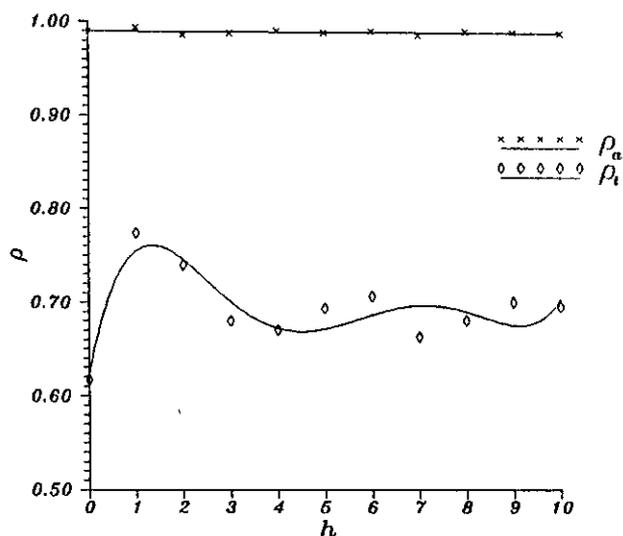


Figure V.7 Construction du réseau spécialisé.

Type de danger	Courant	Tension	Cour. & tens.
Effectif ds la base données	41	144	41

Tableau V.5. Effectif de chaque type de danger dans la base de données

Ainsi, la tentative d'éliminer de la base de données les patterns relatifs à des dépassements de courants sera inutile, vu que ces mêmes patterns renseignent sur des dépassements de tension, et donc aucune différence ne sera obtenue entre l'ensemble de données originel et l'ensemble de données filtré. Ainsi, les ensembles d'apprentissage du réseau de neurones généraliste et spécialiste, ne sont pas différents du point de vue de la tendance de l'information. D'où, l'identité des performances obtenues.

L'idée de former un réseau de neurones spécialisé pour la reconnaissance de danger de courants a été écartée, vu le nombre insuffisant de patterns de ce type, et d'où l'impossibilité de mener une étude comparative au réseau de neurones généraliste.

Cette dernière contrainte, heureuse d'un point de vue exploitation électrique, mais pas du point de vue neuronal est due à la spécificité du réseau électrique d'étude I3E14, dont les limites de transit des lignes sont assez hautes.

Ce cas particulier, montre que la spécialisation systématique d'un réseau de neurones n'est pas un facteur d'amélioration automatique de ces performances, ce que préconise la littérature en général [18], [22]. Il est donc important de savoir *a priori* si le réseau électrique que l'on traite présente suffisamment de cas de danger de tension et de transit indépendants, pour penser à séparer l'évaluation de la sécurité.

### V.3. Conclusion

Il a été défini et appliqué dans ce qui précède une heuristique permettant de construire de manière objective un réseau de neurones à une couche cachée, formé par rétropropagation du gradient.

La couche de sortie étant définie par la nature du problème, la couche d'entrée par analyse des données, il a été déterminé par construction incrémentale, la dimension optimale de la couche cachée.

La construction du réseau de neurones étant achevée, il a été montré qu'on pouvait améliorer les performances de généralisation de ce dernier, par la recherche de la dimension optimale de l'ensemble d'apprentissage, et que la spécialisation du réseau de neurones n'améliorait pas automatiquement ses performances.

## CONCLUSION GENERALE

Ce travail, avait pour objectif d'utiliser un modèle neuronal pour l'évaluation de la sécurité statique des réseaux électriques.

Il y a été donc particulièrement investi le problème du choix des données à fournir comme base d'apprentissage au réseau de neurones, ainsi que le dimensionnement et l'optimisation des performances de ce dernier.

Cette recherche a été menée à travers le réseau standard IEEE 14 noeuds, comme support d'application.

Connaissant les avantages de rapidité, de robustesse, et de capacité de généralisation des réseaux de neurones, ils ont été investis pour l'évaluation de la sécurité des réseaux électriques en temps réel. Néanmoins, ces derniers posent quand même quelques difficultés à la conception.

En effet, lors de la conception d'un réseau de neurones, il faudra tenir compte, afin de les éviter, de deux types d'erreurs:

- les erreurs d'échantillonnage, pour l'ensemble d'apprentissage,
- et les erreurs dues au choix des dimensions du réseau de neurones.

Pour parer à ces contraintes, il a été mis d'abord en avant la nécessité d'utiliser un modèle réaliste d'écoulement de charge pour les études de sécurité.

Dans un premier temps, un modèle dynamique d'écoulement de charge, qui tient compte du réglage automatique des générateurs d'un réseau, et de la réaction de la charge, a été développé. Ce nouvel outil, a été par la suite, intégré à un algorithme complet d'analyse de sécurité statique, et de génération d'ensembles d'apprentissage pour réseaux de neurones.

Puis dans un deuxième temps, par la variation aléatoire de la charge, une approche probabiliste des différents régimes de fonctionnement d'un réseau électrique a été faite. Cette approche probabiliste, assure de l'exhaustivité de l'échantillonnage, et réduit donc l'erreur lié à la quantité d'information apportée par la base d'apprentissage au réseau de neurones.

Pour ce qui est du dimensionnement du réseau de neurones, l'utilisation d'une heuristique statistique a permis de réduire les dimensions du problème à traiter, et a permis de tirer des conclusions sur l'effet qu'engendre la manière dont varie la charge, ainsi que le fait de la modéliser ou pas lors des simulations.

Ainsi, le choix de la dimension de la couche d'entrée du réseau de neurone, ne dépend presque pas de la modélisation de la charge, mais est fortement lié à la manière dont varie l'ensemble des charges du réseau (en surface ou en profondeur). Autrement dit, ce n'est pas la précision du modèle qui influe sur les dimensions du réseau de neurones, mais plutôt le mode de fonctionnement du réseau électrique.

Une deuxième heuristique permettant de dimensionner de manière objective la couche cachée d'un réseau de neurones, a été définie et appliquée.

La couche de sortie étant définie par la nature du problème, et la couche d'entrée par analyse des données, il a été déterminé par construction incrémentale, la dimension optimale de la couche cachée.

La construction du réseau de neurones étant achevée, il a été montré par la suite, qu'on pouvait améliorer les performances de généralisation de ce dernier, par la recherche de la dimension optimale de l'ensemble d'apprentissage, et que la spécialisation du réseau de neurones n'améliorait pas automatiquement ses performances.

Au delà de ce travail, il serait intéressant, pour améliorer le réalisme du modèle d'écoulement de charge proposé, d'y introduire la modélisation de la fréquence, pour l'analyse de situations de contingences où le réglage secondaire n'aurait pas pris encore effet. Ainsi, on disposerait d'un simulateur complet, de régimes statiques de réseau électrique.

D'autre part, étant donné que la spécialisation sur le caractère du danger (tension ou courant), n'est pas source d'amélioration systématique des performances du réseau de neurones, il serait bon de tenter une spécialisation par ouvrage déclenché.

Ainsi, il y aurait autant de réseaux de neurones qu'il y a de groupes et de lignes confondus, qui évalueraient en même temps, la sécurité du réseau électrique selon la perte de l'ouvrage auquel ils sont liés.

L'avantage qui en résulterait, en plus de l'amélioration éventuelle des performances du réseau généraliste, serait qu'il y ait possibilité d'identifier le ou les ouvrages sensibles, entraînant par leur perte une situation d'urgence.

La topologie d'un réseau électrique étant changeante (à cause de la maintenance de ses ouvrages), il serait judicieux d'associer à chaque plan de charge un certain nombre de topologies. Ces dernières seraient déterminées par un coefficient de disponibilité lié à chaque ouvrage.

Ainsi, comme il a été menée une variation aléatoire de la charge pour la génération de l'ensemble d'apprentissage de la fonction de sécurité, on adjoindrait à cette variation, une variation aléatoire de la structure du réseau, pour couvrir tout le domaine de fonctionnement possible de ce dernier.

Enfin, ce travail ne pourrait être considéré comme complet, que suite à une application réelle de cet outil, dans un centre de conduite d'énergie, afin de juger de ses capacités.

## **ANNEXE**

**Formation des matrices [B'] et [B''] de l'écoulement de charge rapide découplé (FDLF)**

Le système d'équations donnant solution de l'écoulement de charge classique a pour expression:

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} H & N \\ J & L \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (A.1)$$

Le système précédent est découplé sachant que:

$$\begin{aligned} \cos(\delta_{ij}) \approx 1 ; \quad G_{ij} \ll B_{ij} \\ \text{et} \quad V_i \approx 1 \end{aligned} \quad (A.2)$$

où:  $G_{ij} + jB_{ij}$  est l'élément  $ij$  de la matrice admittance du réseau.

$\delta_{ij}$  est l'écart angulaire entre les tensions nodales  $V_i$  et  $V_j$ .

Le système (A1) s'écrit alors, comme suit:

$$\begin{bmatrix} \Delta P/V \\ \Delta Q/V \end{bmatrix} = \begin{bmatrix} B' & 0 \\ 0 & B'' \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (A.3)$$

Il faut noter que STOTT préconise de ne pas représenter dans [B'], les éléments liés à l'écoulement de MVar, tel que les shunts et les régleurs en charge des transformateurs. De même dans [B''], tout élément lié à l'écoulement de MW est omis, tel que les déphaseurs de transformateurs.

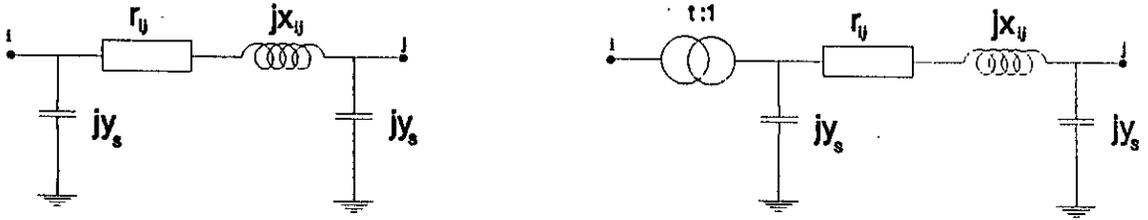


Schéma en  $\pi$  d'une ligne et d'un transformateur

	[B']		[B'']	
	Ligne	Transfo.	Ligne	Transfo.
$b_{ij}$	$\frac{-X_{ij}}{r_{ij}^2 + X_{ij}^2}$	$\frac{-X_{ij}}{r_{ij}^2 + X_{ij}^2}$	$\frac{-X_{ij}}{r_{ij}^2 + X_{ij}^2}$	$\frac{-X_{ij}}{r_{ij}^2 + X_{ij}^2} \cdot \frac{1}{t}$
$b_{ii}$	$\frac{X_{ij}}{r_{ij}^2 + X_{ij}^2}$	$\frac{X_{ij}}{r_{ij}^2 + X_{ij}^2}$	$\frac{X_{ij}}{r_{ij}^2 + X_{ij}^2} + y_s$	$\left\{ \begin{array}{l} \left( \frac{X_{ij}}{r_{ij}^2 + X_{ij}^2} + y_s \right) \cdot \frac{1}{t^2} \quad (a) \\ \frac{X_{ij}}{r_{ij}^2 + X_{ij}^2} + y_s \quad (b) \end{array} \right.$
				1

Tableau A.1. Eléments utilisés pour former [B'] et [B''] dans la variante BB du FDLF.

<sup>1</sup> (a): si le régleur est du côté i;  
 (b): si le régleur est du côté j.

	[B']	[B'']
$B_{ij}$	$b_{ij}$	$b_{ij}$
$B_{ii}$	$\begin{cases} \sum b_{ii} \\ 10^{+10} \quad (i=\text{réf.}) \end{cases}$	$\begin{cases} \sum b_{ii} + \sum y_{si} \\ 10^{+10} \quad (i=\text{réf. ou PV}) \end{cases}$

Tableau A.2. Formation des matrices [B'] et [B''].

Les différentes variantes de l'écoulement de charge rapide découplé se distinguent par l'annulation des résistances des branches de [B'] ou de [B''] (Cf. tableau A.3).

Type de FDLF	[B']	[B'']
BB	$r_{ij} \neq 0$	$r_{ij} \neq 0$
BX	$r_{ij} \neq 0$	$r_{ij} = 0$
XB	$r_{ij} = 0$	$r_{ij} \neq 0$
XX	$r_{ij} = 0$	$r_{ij} = 0$

Tableau A.3. Distinction des types de FDLF.

## Définitions

### Réglage primaire:

Il s'agit de la régulation de vitesse des groupes, par l'action sur les vannes d'admission de la turbine. Ce réglage permet d'ajuster la puissance mécanique fournie au groupe à la puissance électrique demandée; Il limite les écarts de vitesse (et donc de fréquence) lors d'à coups importants sur le réseau. Le déclenchement d'un groupe en est un. Le temps de réponse du réglage primaire est de l'ordre de 10s. Ce réglage est de type proportionnel.

### Réglage secondaire:

Il intervient avec un temps de réponse de l'ordre de la minute pour régler la fréquence du réseau et les échanges sur les lignes d'interconnexion avec les réseaux voisins. Il a pour but d'annuler la dérive de fréquence et les échanges programmés. Ce réglage est de type integral.

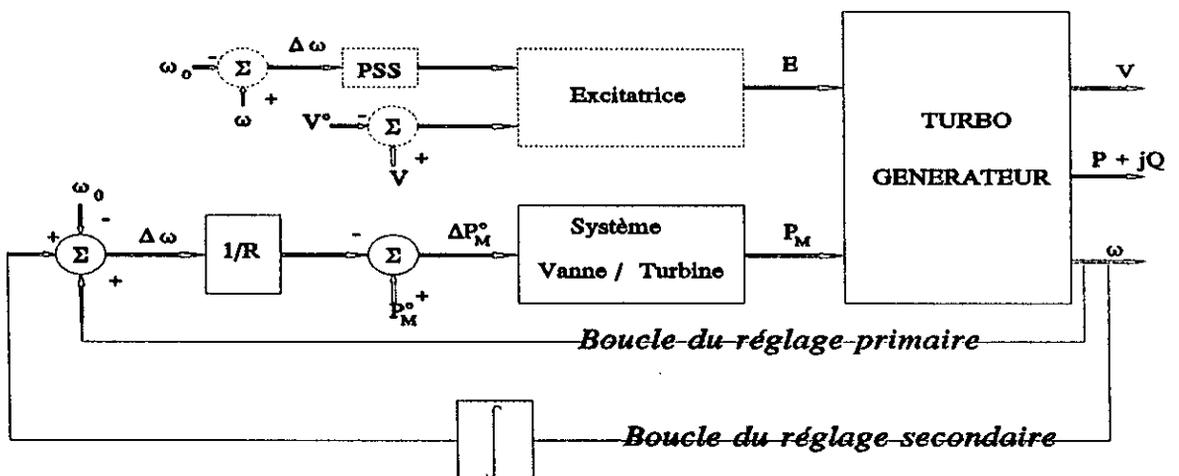


Schéma bloc d'un groupe générateur électrique

### Démonstration de l'équation (III.24)

Nous pouvons écrire pour le noeud de référence (1), l'équation suivante:

$$\Delta P_{I1} = \left[ \frac{\partial P_{I1}}{\partial \delta} \quad \frac{\partial P_{I1}}{\partial V} \right] \cdot \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (\text{A.10})$$

Selon le modèle d'écoulement de charge découplé rapide de Stott [17], on obtien de l'équation précédente l'expression qui suit:

$$\Delta P_{I1}/V_1 = [-B_{12} \dots -B_{1n}] \cdot [\Delta \delta] \quad (\text{A.11})$$

En concidérant les équations (III.16) et (A.11), on peut écrire:

$$\Delta P_{I1}/V_1 = [-B_{12} \dots -B_{1n}] \cdot [B']^{-1} [\Delta P_I/V] \quad (\text{A.12})$$

On peut réécrire l'équation précédente, sous la forme suivante:

$$\Delta P_{I1}/V_1 = [\gamma] \cdot [\Delta P_I/V] \quad (\text{A.13})$$

où

$$[\gamma] = [-B_{12} \dots -B_{1n}] \cdot [B']^{-1}$$

Si la matrice [B'] est symétrique, ce qui est vrai dans la plus part des réseaux de transport, c'est-à-dire sans présance de transformateurs déphaseur dans le réseau, alors:

$$[\gamma] = [-1] \quad \text{pour } i=2..n.$$

Ainsi, on obtient l'équation (III.24).

Données du réseau standard IEEE 14 noeuds

B U S D A T A

Bus No.	Bus <sup>1</sup> type	Pd (pu)	Qd (pu)	V_init (pu)	Comp. (pu)	Pg_max (pu)	Qg_min (pu)	Qg_max (pu)	fact. part.x
B1	SW	0	0	1.045	0	1.50	-0.15	0.50	0.25
B2	GN	0.217	0.217	1.045	0	1.50	-0.15	0.50	0.25
B3	LD	0.076	0.016	1.000	0	0	0	0	0
B4	GN	0.942	0.190	1.020	0	1.50	0	0.40	0.25
B5	LD	0.478	-0.039	1.000	0	0	0	0	0
B6	LD	0	0	1.000	0	0	0	0	0
B7	LD	0.295	0.166	1.000	0.190	0	0	0	0
B8	SC	0	0	1.045	0	0	-0.06	0.24	0
B9	LD	0.149	0.050	1.000	0	0	0	0	0
B10	LD	0.135	0.058	1.000	0	0	0	0	0
B11	LD	0.061	0.016	1.000	0	0	0	0	0
B12	GN	0.112	0.075	1.020	0	0.50	-0.06	0.24	0.25
B13	LD	0.035	0.018	1.000	0	0	0	0	0.
B14	LD	0.090	0.058	1.000	0	0	0	0	0

L I N E D A T A

Line No	Bus No. from	to	R (pu)	X (pu)	B (pu)	Limit (pu)
1	1	2	0.0194	0.0592	0.0264	1.00
2	1	3	0.0540	0.2230	0.0246	1.00
3	2	4	0.0470	0.1980	0.0219	1.00
4	2	5	0.0581	0.1760	0.0187	1.00
5	2	3	0.0569	0.1740	0.0170	1.00
6	4	5	0.0670	0.1710	0.0173	1.00

<sup>1</sup> SW: Swing Bus, GN: Generator, SC: Synchron. Compensator, LD: Load.

Line No	Bus No. from	Bus No. to	R (pu)	X (pu)	B (pu)	Limit (pu)
7	3	5	0.0133	0.0421	0.0064	1.00
8	5	6	0	0.2090	0	1.2
9	5	7	0	0.5560	0	1.2
10	3	12	0	0.2520	0	1.2
11	12	13	0.0950	0.1990	0	0.40
12	12	11	0.1230	0.2560	0	0.40
13	12	10	0.0662	0.1300	0	0.40
14	6	8	0	0.1760	0	0.40
15	6	7	0	0.1100	0	0.40
16	7	14	0.0318	0.0845	0	0.40
17	7	9	0.1270	0.2700	0	0.40
18	14	13	0.0821	0.1920	0	0.40
19	11	10	0.2210	0.2000	0	0.40
20	10	9	0.1710	0.3480	0	0.40

Sbase: 100 MVA

TRANSFORMERS DATA

Bus No		Tap. ratio.	
from	to	Min	Max
3	12	1.05	0.90
5	7	1.05	0.90
6	7	1.05	0.90

Données du réseau standard IEEE 30 noeuds

B U S D A T A

Bus No.	Type	Pd (pu)	Qd (pu)	V_init (pu)	Comp. (pu)	Pg_max (pu)	Qg_min (pu)	Qg_max (pu)	Part. fact. x
1	SW	0	0	1.05	0	2.000	-10.000	10.000	0.33
2	GN	0.217	0.127	1.05	0	2.000	-0.400	0.600	0.33
3	LD	0.024	0.012	1.00	0	0	0	0	0
4	LD	0.076	0.016	1.00	0	0	0	0	0
5	SC	0.942	0.190	1.00	0	0	-0.400	0.600	0
6	LD	0	0	1.00	0	0	0	0	0
7	LD	0.228	0.109	1.00	0	0	0	0	0
8	LD	0.300	0.300	1.00	0	0	0	0	0
9	LD	0	0	1.00	0	0	0	0	0
10	LD	0.058	0.020	1.00	0.190	0	0	0	0
11	SC	0	0	1.05	0	0	-0.060	0.400	0
12	LD	0.112	0.075	1.00	0	0	0	0	0
13	GN	0	0	1.05	0	2.000	-0.100	0.500	0.33
14	LD	0.062	0.016	1.00	0	0	0	0	0
15	LD	0.082	0.025	1.00	0	0	0	0	0
16	LD	0.035	0.018	1.00	0	0	0	0	0
17	LD	0.090	0.058	1.00	0	0	0	0	0
18	LD	0.032	0.009	1.00	0	0	0	0	0
19	LD	0.095	0.034	1.00	0	0	0	0	0
20	LD	0.022	0.007	1.00	0	0	0	0	0
21	LD	0.175	0.112	1.00	0	0	0	0	0
22	LD	0	0	1.00	0	0	0	0	0
23	LD	0.032	0.016	1.00	0	0	0	0	0
24	LD	0.087	0.067	1.00	0.043	0	0	0	0
25	LD	0	0	1.00	0	0	0	0	0
26	LD	0.035	0.023	1.00	0	0	0	0	0
27	LD	0	0	1.00	0	0	0	0	0
28	LD	0	0	1.00	0	0	0	0	0
29	LD	0.024	0.009	1.00	0	0	0	0	0
30	LD	0.106	0.019	1.00	0	0	0	0	0

L I N E    D A T A

Line No.	Bus from	Bus to	R (pu)	X (pu)	B (pu)	Limits (pu)
1	1	2	0.0192	0.0575	0.5280	1.30
2	1	3	0.0452	0.1852	0.0408	1.00
3	2	4	0.0570	0.1737	0.3680	0.72
4	2	5	0.0472	0.1983	0.0418	1.30
5	2	6	0.0581	0.1763	0.0374	1.00
6	3	4	0.0132	0.0379	0.0084	1.00
7	4	6	0.0119	0.0414	0.0090	1.05
8	4	12	0.0000	0.2560	0.0000	0.65
9	5	7	0.0460	0.1160	0.0204	1.30
10	6	7	0.0267	0.0820	0.0170	1.30
11	6	8	0.0120	0.0420	0.0090	0.65
12	6	9	0.0000	0.2080	0.0000	0.65
13	6	10	0.0000	0.5560	0.0000	0.32
14	6	28	0.0169	0.0599	0.0130	0.72
15	8	28	0.0636	0.2000	0.0428	0.65
16	9	10	0.0000	0.1100	0.0000	0.65
17	9	11	0.0000	0.2080	0.0000	0.65
18	10	17	0.0324	0.0845	0.0000	0.32
19	10	20	0.0936	0.2090	0.0000	2.00
20	10	21	0.0348	0.0749	0.0000	0.32
21	10	22	0.0727	0.1499	0.0000	0.32
22	12	13	0.0000	0.1400	0.0000	1.30
23	12	14	0.1231	0.2559	0.0000	0.65
24	12	15	0.0662	0.1304	0.0000	0.65
25	12	16	0.0945	0.1987	0.0000	0.65
26	14	15	0.2210	0.1997	0.0000	0.32
27	15	18	0.1070	0.2185	0.0000	0.32
28	15	23	0.1000	0.2020	0.0000	2.00
29	16	17	0.0824	0.1932	0.0000	0.65
30	18	19	0.0639	0.1292	0.0000	0.32
31	19	20	0.0340	0.0680	0.0000	0.32
32	21	22	0.0116	0.0236	0.0000	0.32
33	22	24	0.1150	0.1790	0.0000	0.32
34	23	24	0.1320	0.2700	0.0000	0.32

Line No.	Bus from	Bus to	R (pu)	X (pu)	B (pu)	Limits (pu)
35	24	25	0.1885	0.3292	0.0000	0.32
36	25	26	0.2544	0.3800	0.0000	0.32
37	25	27	0.1093	0.2087	0.0000	0.32
38	27	29	0.2198	0.4153	0.0000	0.32
39	27	30	0.3202	0.6027	0.0000	0.32
40	28	27	0.0000	0.3960	0.0000	0.65
41	29	30	0.2399	0.4533	0.0000	2.00

Sbase = 100 MVA

TRANSFORMER DATA

Bus from	Bus to	Tap.	Tap. change	
			Min	Max
4	12	0.932	1.1	0.9
6	9	0.978	1.1	0.9
6	10	0.969	1.1	0.9
12	13	1.000	1.0	1.0
28	27	0.968	1.1	0.9

## Résultats du réseau de neurones finale

## Sortie requise vs sortie du RNA

! Date: Thu Mar 09 12:20:31 1995  
! Result File: perf\_tot.nnr Input File: perf\_tot.nna  
! Network: SSA (V+I) Mod.Load=NO & Pertb.Load=Surface  
! Cycles: 35000  
! Error: free

## !Learn results

0.000000	-0.010551
1.000000	1.093793
0.000000	-0.019101
1.000000	1.122689
0.000000	0.033353
1.000000	1.122429
0.000000	0.201809
1.000000	1.084576
0.000000	-0.015732
1.000000	1.119544
0.000000	0.145967
1.000000	1.117022
0.000000	0.213134
1.000000	1.122715
0.000000	-0.019952
1.000000	1.120559
0.000000	0.047286
1.000000	1.119218
0.000000	0.041366
1.000000	1.101627
0.000000	0.025843
1.000000	1.109724
0.000000	0.131515
1.000000	1.075870
0.000000	0.126049
1.000000	1.074898
0.000000	0.002284
1.000000	1.073033
0.000000	0.348895
1.000000	1.057325
0.000000	0.282175
1.000000	0.855317
0.000000	0.026091
1.000000	1.119039
0.000000	0.183084
1.000000	1.118451
0.000000	-0.005034
1.000000	-0.011170
0.000000	0.344980
1.000000	1.121747
0.000000	0.156834
1.000000	1.110912
0.000000	-0.009937
1.000000	1.093979
0.000000	0.412045
1.000000	1.046925
0.000000	-0.011690
1.000000	0.968015
0.000000	0.048103
1.000000	1.077136
0.000000	-0.011104
1.000000	1.118317
0.000000	0.201345

1.000000	1.121009
0.000000	0.263711
1.000000	1.109375
0.000000	-0.005347
1.000000	0.014326
0.000000	0.180806
1.000000	0.829339
0.000000	-0.016683
1.000000	0.609481
0.000000	0.020501
1.000000	1.114757
0.000000	-0.004169
1.000000	0.841535
0.000000	-0.012996
1.000000	1.120461
0.000000	0.033597
1.000000	1.122725
0.000000	0.007866
1.000000	1.120832
0.000000	-0.020457
1.000000	1.092453
0.000000	0.001141
1.000000	1.122161
0.000000	-0.019930
1.000000	1.120552
0.000000	0.033223
1.000000	0.691516
0.000000	0.060619
1.000000	1.044702
0.000000	-0.020157
1.000000	1.027464
0.000000	0.011463
1.000000	0.455663
0.000000	0.061821
1.000000	1.119447
0.000000	0.052097
1.000000	1.044295

!Test results

0.000000	-0.002365
0.000000	0.015901
0.000000	-0.005104
0.000000	0.299041
0.000000	0.335785
0.000000	0.160701
0.000000	0.021124
0.000000	0.007436
0.000000	0.126539
0.000000	0.009224
0.000000	0.148865
1.000000	0.783938
1.000000	0.841033
1.000000	1.121066
1.000000	1.103390
1.000000	1.053304
1.000000	0.313231
1.000000	1.122712
1.000000	1.122024
1.000000	0.406344
1.000000	1.117835
1.000000	1.119310
1.000000	1.122617
1.000000	1.063708
1.000000	1.122701
1.000000	1.120788
1.000000	0.355262
1.000000	0.025840
1.000000	1.122724

1.000000	1.061734
1.000000	1.121867
1.000000	1.122739
1.000000	0.889754
1.000000	0.514162
1.000000	1.071133
1.000000	0.411603
1.000000	1.006217
1.000000	0.762511
1.000000	1.105984

## Références Bibliographiques

- [0] AGGOUNE M.E., ATLAS, COHN L.E., DAMBORG D.A., EL-SHARKAWI M.J., MARKS R.S., "Artificial neural networks for power systems static security assessment", *International Symposium on Circuits and Systems, Portland, OR, 1989.*
- [1] BILLINTON R., KHAN E., AGARWAL S.K., "Contingency cut-off criteria in transmission system adequacy assessment", *IEE PROCEEDING, Vol 136, Pt.C, No 4, JULY 1989.*
- [2] BRANDWAJN V., LIU Y., LAUBY M.G., "Pre-screening of single contingencies causing network topology changes", *IEEE Trans. on PAS, 1991.*
- [3] CHANG C.S., "Application of pattern recognition techniques for on-line security-economy & reactive control of power systems", *IEE proceedings-CVol 138, No 1, Jan 1991.*
- [4] CHEN Y., BOSE A., "An adaptive prefilter for the voltage contingency selection function", *IEEE Trans. on Power Sustems, Vol. 5, No 4, Nov. 1990.*
- [5] DIAS L.G., EL-HAWARY M.E., "Effects of load modeling in security constrained OPF studies", *IEEE Trans. on PS, Vol. 6, No 1, Feb. 1991.*
- [6] EJEBE G.C., WOLLENBERG B.F., "Automatic Contingency Selection", *IEEE Trans. on PAS, Vol. PAS-98, No 1, Jan/Feb 1979.*
- [7] IEEE Task Force on Load Representation for Dynamic Performances, "Load representation dor dynamic performances analysis", *IEEE Trans. on PS, Vol 8, No 2, May 1993.*

- [8] HALPIN T.F., FISCHER R., FINK R., "Analysis of Automatic Contingency Selection Algorithms", *IEEE Trans. on PAS*, Vol PAS-103, No 5, May 1984.
- [9] HUSH R.D., HORN B., SALAS J.M., "Error Surfaces for multilayer Perceptrons", *IEEE Tran. on Systems, Man, & Cybernetics* Vol. 22, No 5 Sept/Oct 1992.
- [10] MONTICELLI A., GRACIA A., SAAVEDRA O.R., "Fast Decoupled Load Flow: Hypothesis, Derivations & Testing", *IEEE Trans. on PS*, VOL 5, No 4, Nov. 1990.
- [11] NARA K., TANAKA K., SHOULTS R.R., CHEN M.S., VAN GLINDA P., "On-line contingency selection algorithm for voltage security analysis", *IEEE Trans. on PAS*, Vol. PAS 104, No 4, April 1985.
- [12] NIEBUR D., GERMOND A.J., "Power sytem static security assessment using the kohonen neural network classifier", *IEEE Trans. onPS*, Vol 7, No 2, May 1992.
- [13] OKAMURA M., O-URA Y., HAYASHI S., UEMURA K., ISHIGURO F., "A new power flow model and solution method -Including load and generation characteristics and effects of system control devices-", *IEEE Trans. on PAS*, Vol PAS 94, No 3, May/June 1975.
- [14] PANG C.K., PRABHAKARA F.S., EL-ABIAD A.H., KOIVO A.J., "Security evaluation in power systems using pattern recognition", *IEEE Power Engeneering Society Winter meeting NY*, Jan 1973.
- [15] RAJICIC D., BOSE A., "A modification to the fast decoupled power flow for networks with high r/x ratios", *IEEE Trans. onPS*, Vol 3, No 2, May 1988.
- [16] RAMANATHAN R., RAMCHANDANI H., SACKETT S.A., "Dynamic load flow technique for power system simulators", *IEEE Trans. on PS*, Vol PWRS-1, No 3, August 1986.

- [17] STOTT B., ALSAC O., "Fast decoupled load flow", *IEEE Trans. on PAS*, Vol PAS-93, 1974.
- [18] WEERASOORIYA S., EL-SHARKAWI M.A., DAMBORG M., MARKS II R.J., "Towards static-security assessment of a large-scale power system using neural networks", *IEE Proceedings.....*
- [19] VAN AMERONGEN R.A.M., "A general purpose version of the fast decoupled load flow", *IEEE Trans. on PAS*, No 2, May 1989.
- [20] DROESBEKE J.J., "Eléments de statistique", Editions de l'Université de Bruxelles 1988 - Réédition Office des Publication Universitaires, Alger.
- [21] ARRILLAGA J. & ARNOLD C.P., "Computer Analysis of Power System", *John Wiley & Sons*.
- [22] BOCHEREAU L., "Conception et interprétation de réseaux connexionistes multicouches", Thèse de Doctorat de l'université Paris 6 - Spécialité Informatique - 1991.
- [23] CEGRELL T., "Power System Control, Technology", *Prentice/Hall International (UK) 1986*.
- [24] DEBSS A.S., "Modern Power System Control and Operation", *Kluwer Academic Publishers, Boston, 1988*.
- [25] FREEMAN J.A. & SKAPURA D.M., "Neural Networks, Algorithms, Application, & Programming Techniques", *Addison- Wesley Publishing Company, 1992*.
- [26] NeuralWare Inc, "Using NWorks, An Extended Tutorial for NeuralWorks Professional II/plus", *NeuralWare Inc., 1991*.
- [27] RUMELHART D.E., HINTON G.E., & WILLIAMS R.J., "-Chapter 8: Learning Internal Representations by Error Propagation- in Parallel Distributed Processing: exploitation of the microstructure of cognition. Vol II, by Mc Clelland J.M.C.,

- Rumelhart & the PDP Research Group", *Bradford books, Cambridge, MA 1986.*
- [28] STEVENSON W.D.Jr, "Elements of Power System Analysis", *Mc Graw-Hill International Book Company, 1982.*
- [29] WOOD A.J. & WOLLENBERG B.F., "Power Generation, Operation, and Control", *John Wiley & Sons, 1984.*
- [30] BOUROUBA Dj.E., BENSENOUCI A., AGGOUNE M.E., "A realistic power flow with general load model for futur ANN training in static security assessment", in *International Conference on Electrical & Electronic Engineering ICEEE, USTO Oran 1-3 octobre 1994.*
- [31] KNUTH D.E., "The art of Computer Programming" Vol 2, *Semi-numerical Algorithms, Addison-Wesley Publishing Company, 1969.*
- [32] MEYER B. "Conception et Programmation par Objets"
- [33] Borland Corp., "Borland C++ -Guide du programmeur-", *Borland Corp., 1992.*