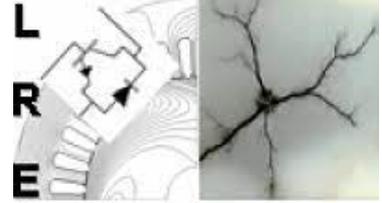




المدرسة الوطنية المتعددة التقنيات
École nationale Polytechnique
Département d'Électrotechnique
Laboratoire de Recherche en
Électrotechnique



Mémoire de projet de fin d'études

Pour l'obtention du diplôme d'Ingénieur d'État en Electrotechnique

Evaluation de la Stabilité de Tension par les Réseaux de Neurones Artificiels

Réalisé par :

Mlle. CHAACHOUA SAMEUT Manal

Mlle. BOUMAZA Maroua

Encadré par :

Pr. HELLAL Abdelhafid

Présenté et soutenu publiquement le 20 Juin 2023

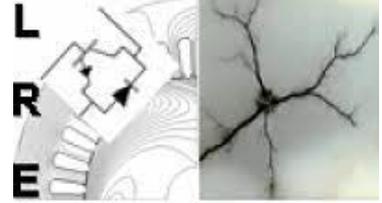
Composition du Jury :

Président	Pr.Lazhari NEZLI	ENP
Examineur	Dr. Rabie BELKACEMI	ENP
Rapporteur	Pr. Abdelhafid HELLAL	ENP

ENP 2023



المدرسة الوطنية المتعددة التقنيات
École nationale Polytechnique
Département d'Électrotechnique
Laboratoire de Recherche en
Électrotechnique



Mémoire de projet de fin d'études

Pour l'obtention du diplôme d'Ingénieur d'État en Electrotechnique

Evaluation de la Stabilité de Tension par les Réseaux de Neurones Artificiels

Réalisé par :

Mlle. CHAACHOUA SAMEUT Manal
Mlle. BOUMAZA Maroua

Encadré par :

Pr. HELLAL Abdelhafid

Présenté et soutenu publiquement le 20 Juin 2023

Composition du Jury :

Président	Pr.Lazhari NEZLI	ENP
Examineur	Dr. Rabie BELKACEMI	ENP
Rapporteur	Pr. Abdelhafid HELLAL	ENP

ENP 2023

Dédicaces

*À mes chers parents **Ahmed et Naima**, qui ont été ma source d'inspiration, mes piliers inébranlables. Votre amour, vos sacrifices, votre soutien inconditionnel et vos prières m'ont porté tout au long de ce chemin vers la réussite.*

*À mes sœurs **Hamida, Ikram, Hadil et Hiba**, vous avez été mes compagnes de vie, mes confidentes et mes plus grandes admiratrices. Vos encouragements constants et votre soutien moral m'ont donné la force nécessaire pour persévérer.*

*À ma tante **Bouchra**, votre bienveillance et vos précieux conseils ont contribué à mon épanouissement académique. Votre soutien indéfectible m'a encouragé à repousser mes limites.*

*À mon amie **Feriel**, tu as été là à chaque étape, m'apportant ton amitié sincère et ta confiance inébranlable. Ton soutien et tes encouragements m'ont donné la motivation nécessaire pour surmonter les difficultés.*

*À mon binôme **Maroua**, notre collaboration a été un moteur essentiel dans ma réussite. Ensemble, nous avons surmonté les défis et accompli de grandes choses. Merci pour ta confiance et ton travail acharné.*

À tous ceux qui me sont chers, je vous suis infiniment reconnaissant. Vos sourires, vos mots d'encouragement et votre présence ont illuminé mon parcours. Sans vous, rien de tout cela n'aurait été possible.

Merci.

-Manal

Dédicaces

*À mes parents bien-aimés **Mohamed** et **Nadjia**, qui ont été une présence éternelle dans ma vie, pour leurs efforts inestimables, leur affection, leur soutien, et leurs précieux conseils tout au long de mon parcours éducatif.*

*À mes chères sœurs **Ikram**, **Douaa** et **Wissal**, qui sont la source de joie et de bonheur dans ma vie, pour leur soutien constant et leur encouragement moral.*

*À ma **grand-mère** que Dieu prolonge leur vie et à ma tante **Houria**.*

*À ma binôme **Manel**, nos échanges, nos discussions et nos efforts communs resteront gravés dans ma mémoire. Tu es une part essentielle de ma réussite et de mes souvenirs. merci d'avoir partagé cette expérience inoubliable avec moi.*

*À mes précieux **amis** qui m'ont accompagné et poussé à avancer tout au long de mon cheminement.*

À tous ceux qui occupent une place chère dans mon cœur, qui ont laissé une empreinte dans ma vie et éclairé mon chemin.

Je vous suis profondément reconnaissante.

-Maroua

Remerciements

Nous exprimons toute notre gratitude, reconnaissance et remerciement à Allah, le Tout-Puissant, qui nous a accordé la force, la patience, le courage et la volonté pour mener à bien ce travail.

Nos sincères remerciements vont à notre promoteur, **Abdelhafid Hellal**, Professeur à l'École Nationale Polytechnique, d'avoir accepté de nous encadrer et d'avoir été présent à chaque étape de la réalisation de ce travail. Nous le remercions également pour ses encouragements constants, son soutien moral et ses remarques pertinentes. Sa disponibilité et ses conseils précieux nous ont permis de mener ce travail à terme avec succès.

Nous tenons également à exprimer notre gratitude envers Monsieur **Lazhari Nezli**, Professeur à l'École Nationale Polytechnique, d'avoir accepté de présider notre jury, ainsi que Monsieur **Belkacemi Rabie**, Docteur à l'École Nationale Polytechnique, pour l'intérêt qu'il a porté à nos travaux en acceptant d'être l'examineur.

Nous sommes reconnaissants envers toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail et qui ont apporté leur soutien et leurs conseils précieux.

ملخص

يتناول هذا البحث تحليل وتوقع استقرار الجهد في أنظمة الطاقة الكهربائية. يعتبر استقرار الجهد عنصرًا حاسمًا في موثوقية وأداء الشبكات الكهربائية، ومن الضروري أن تتمكن من التنبؤ بالاستقرار هذا بدقة لضمان استقرار تشغيل الشبكة.

في هذه الدراسة، يتم تقديم طرق تحليل الاستقرار التقليدية المختلفة، بما في ذلك الطرق المعتمدة على مؤشرات الاستقرار التي تستخدم لتحديد العقد والخطوط التي تعاني من مشاكل في الجهد. بعد ذلك، يتم تطبيق الشبكات العصبية على مؤشر محدد لإظهار فعاليتها في تحليل وتوقع استقرار الجهد. تم تطبيق هذه الدراسة على شبكة اختبار قياسية تحتوي على 14 عقدة (IEEE 14 نقطة) باستخدام آماطلاب. تقدم النتائج المحصل عليها آفاقًا جديدة لتحسين إدارة وتحكم الشبكات الكهربائية، من خلال التعرف المبكر على مشاكل الاستقرار واتخاذ قرارات مدروسة للحفاظ على استقرار الشبكة.

كلمات مفتاحية : استقرار الجهد، الطرق التقليدية، الشبكات العصبية، مؤشرات الاستقرار، التشغيل الثابت.

Abstract

This thesis focuses on the analysis and prediction of voltage stability in electrical systems. Voltage stability is a crucial element in the reliability and performance of electrical networks, and it is essential to accurately predict this stability to ensure a stable operation of the network.

In this study, different conventional methods of stability analysis are presented, including methods based on stability indices used to identify nodes and lines experiencing voltage problems. Then, neural networks are applied to a specific index to demonstrate their effectiveness in analyzing and predicting voltage stability. This study was applied to a standard 14-node test network (IEEE 14 Bus) using "MATLAB". The obtained results offer new perspectives to improve the management and control of electrical networks, by enabling early detection of stability issues and informed decision-making to maintain network stability.

Key words : Voltage stability, Conventional methods, Neural networks, Stability indices, Stable operation.

Résumé

Ce mémoire se concentre sur l'analyse et la prédiction de la stabilité de tension dans les systèmes électriques. La stabilité de tension est essentielle pour garantir la fiabilité et les performances des réseaux électriques.

L'étude présente différentes méthodes conventionnelles d'analyse de stabilité, y compris l'utilisation d'indices pour identifier les nœuds et les lignes présentant des problèmes de tension. Les réseaux de neurones sont également utilisés pour démontrer leur efficacité dans l'analyse et la prédiction de la stabilité de tension. L'étude a été réalisée sur un réseau test standard de 14 nœuds (IEEE14) en utilisant MATLAB. Les résultats obtenus offrent de nouvelles perspectives pour améliorer la gestion et le contrôle des réseaux électriques en détectant précocement les problèmes de stabilité et en prenant des décisions éclairées pour maintenir la stabilité du réseau.

Mots clés : Stabilité de tension, Méthodes conventionnelles, Réseaux de neurones, Indices de stabilité, fonctionnement stable.

Table des matières

Table des figures

Liste des tableaux

Liste des sigles et acronymes

Introduction générale	13
1 Analyse de la stabilité de tension par les méthodes conventionnelles	17
1.1 Introduction	18
1.2 Problème de la stabilité des réseaux électrique	18
1.3 Classification de la stabilité de réseau d'énergie électrique	19
1.3.1 Stabilité angulaire	20
1.3.2 Stabilité de fréquence	21
1.3.3 Stabilité de tension	21
1.4 Causes d'instabilité de tension	22
1.4.1 Tension trop basse au niveau des unités de production	23
1.4.2 Charge appelée trop importante	23
1.4.3 Production trop éloignée à la consommation	23
1.4.4 Manque local de la puissance réactive	24
1.5 Blackouts dans le monde	24
1.6 Méthodes conventionnelles	25
1.6.1 Courbe P-V	25
1.6.2 Courbe Q-V	28
1.6.3 Ecoulement de puissance continu	30
1.6.3.1 Introduction	30
1.6.3.2 Reformulation des équations d'écoulement de puissance	31
1.6.3.3 Prédiction de la solution suivante	33
1.6.3.4 Correction	34
1.6.3.5 Choix de paramètre de continuation	35
1.7 Exemple d'application	37
1.7.1 Courbe P-V	37
1.7.2 Courbe Q-V	39
1.7.3 Ecoulement de puissance continu	41
1.8 Conclusion	43
2 Indices de stabilité de tension électrique	44
2.1 Introduction	45
2.2 Classification des indices de stabilité	45
2.3 Indices de stabilité basés sur l'écoulement de puissance	46

2.3.1	Facteur de stabilité de ligne (LQP)	47
2.3.2	Indice L	48
2.3.2.1	Généralisation à un Système de n noeuds :	50
2.3.3	Indice de stabilité de tension (VSI)	51
2.3.4	Indice de stabilité de la tension (SI)	53
2.3.5	Indice de capacité de charge (Li)	55
2.3.6	Indice de stabilité de tension rapide (FVSI)	56
2.4	Etude de cas	57
2.5	Conclusion	60
3	Réseaux de neurones artificiels	61
3.1	Introduction	62
3.2	Définition	62
3.3	Historique	62
3.4	Neurone biologique et artificiel	63
3.5	Structure du RNA	66
3.5.1	Sélection des couches cachées	67
3.5.2	Sélection des nœuds dans les couches cachées	67
3.6	Architecture d'un RNA	68
3.6.1	Réseaux récurrents Feed-back	69
3.6.2	Réseaux propagation vers l'avant Feed-forward	69
3.7	Apprentissage	70
3.7.1	Règles d'apprentissage :	70
3.7.2	Types d'apprentissage	72
3.8	Rétro-propagation du gradient d'un PMC	74
3.8.1	Principe	74
3.8.2	Algorithme	74
3.8.2.1	Définition du réseau	75
3.8.2.2	Propagation	75
3.8.2.3	Erreur quadratique moyenne	75
3.8.2.4	Rétro-propagation	76
3.8.3	Résumé de l'algorithme de rétro-propagation	80
3.9	Avantages et inconvénients des réseaux de neurones	80
3.9.1	Avantages	80
3.9.2	Inconvénients	82
3.10	Conclusion	82
4	Application du RNA dans le calcul des indices de stabilité de tension	83
4.1	Introduction	84
4.2	Architecture du PMC	84
4.3	Analyse du modèle PMC proposé pour le calcul d'indice de stabilité de tension (FVSI)	85
4.3.1	Base de données	85
4.3.2	Procédure d'apprentissage	86
4.3.3	Réseau 14 nœuds	87
4.3.3.1	Résultats des tests	88
4.4	Comparaison entre PV et indices	91
4.4.1	Discussions	92

Conclusion générale	93
Bibliographie	95
Annexe	100
A Données du système de test	101
A.1 Données du réseau 14 nœuds (point de fonctionnement standard)	101
A.2 Données des nœuds	102
A.3 Données des lignes	102

Table des figures

1.1	Classification des types de stabilité des réseaux électriques [8].	20
1.2	Réseau électrique à deux noeuds	26
1.3	Courbe P-V	28
1.4	Courbe Q-V pour différents niveaux de puissance active	29
1.5	La technique prédiction-correction [22].	30
1.6	Algorithme de l'écoulement de puissance continu	36
1.7	Les courbes PV pour chaque ligne du système IEEE 14	37
1.8	Les courbes PV pour chaque ligne du noeud 5	38
1.9	Les courbes PV pour chaque ligne du noeud 14	38
1.10	Les courbes QV pour un système IEEE 14	39
1.11	Les courbes QV pour chaque ligne du noeud 14	40
1.12	Les courbes QV pour chaque ligne du noeud 5	40
1.13	Profil du module de tension de l'état initial et l'état de marge de stabilité pour le réseau 14 noeuds.	42
1.14	Courbe CPF pour les noeuds 9,10 et 14	42
2.1	Classification des indices de stabilité de tension et la relation entre eux.	46
2.2	Circuit équivalent d'une seule branche dans un réseau interconnecté.	47
2.3	Circuit équivalent d'une seule ligne de transmission	48
2.4	L'évaluation des indices FVSI en fonction de la variation de la puissance réactive Q.	58
2.5	L'évaluation des indices LQP en fonction de la variation de la puissance réactive Q.	58
2.6	Comparaison des indices pour la ligne 6-13 en fonction de la variation de la puissance réactive Q.	59
2.7	Comparaison des indices et variation de tension pour la ligne 3-4 en fonction de l'augmentation de la puissance réactive Q.	59
3.1	Modèle de McCulloch-Pitts	64
3.2	Différents types de fonctions d'activation de RNA	65
3.3	Mise en correspondance neurone biologique / neurone artificiel [39].	65
3.4	Structure générale d'un RNA avec deux couches cachées. [40]	67
3.5	Topologies des réseaux de neurones artificiels.	68
3.6	Cas de neurone entre la couche de sortie et la couche cachée précédente [53].	76
3.7	Cas de neurone entre la couche cachée et la couche d'entrée [53].	78
4.1	Procédure d'apprentissage du réseau de neurones du système électrique [60].	86
4.2	Architecture du (PMC) proposée pour le calcul d'indice de stabilité de tension (FVSI).	87
4.3	Comparaison entre valeurs désirées de l'indice FVSI et valeurs calculées durant la phase de test.	90

A.1 Schéma unifilaire pour un réseau électrique standard à 14 nœuds. 101
--	---------------

Liste des tableaux

1.1	Effondrement de tension dans le monde [19].	24
1.2	Résultats du système	41
3.1	Exemple de différents types d'apprentissages en mode supervisé [42].	73
3.2	Exemple de différents types d'apprentissages en mode non supervisé [42].	74
4.1	Paramètres optimaux pour le réseau 14 noeuds.	88
4.2	Les résultats des tests.	89
4.3	Le résultat de test pour le réseau 14 noeuds standard.	91
4.4	Résultats de comparaison.	91
4.5	Comparaison d'indices FVSI et PMC	92
A.1	Données des noeuds.	102
A.2	Données des lignes.	102

Liste des sigles et acronymes

CPF	Continuation Power Flow
IA	Intelligence Artificielle
RNA	Réseaux de Neurones Artificiels
FVSI	Fast Voltage Stability Index
LQP	Line Quality Proximity
FACTS	Flexible AC Transmission System
HVDC	High Voltage Direct Current
PMU	Phasor Measurement Unit
VSI	Voltage Stability Index
SI	Stability Index
PQ	Noeuds de charge
PV	Noeuds de génération
SPL	Single-Layer Perceptron
PMC	Perceptron Multi Couche

Introduction générale

Introduction générale

L'intégration croissante des sources d'énergie renouvelable, telles que l'énergie solaire et éolienne, ainsi que l'évolution des besoins en énergie, ont entraîné une complexification significative des réseaux électriques. Cette évolution s'est caractérisée par une décentralisation des systèmes de production et une augmentation de la variabilité de la production d'énergie. Parallèlement, la gestion et le contrôle des réseaux électriques sont devenus plus complexes en raison de la croissance de la demande en énergie, des enjeux environnementaux, des changements dans le bilan énergétique et de la déréglementation des marchés de l'énergie. Ces facteurs ont entraîné des violations fréquentes de la stabilité des systèmes électriques, les plaçant souvent près de leur limite de capacité. Dans ces conditions, de légères variations de charge peuvent provoquer des fluctuations incontrôlées de la tension, pouvant entraîner un effondrement du système et des conséquences coûteuses pour les services publics et les consommateurs.

Afin d'assurer la fiabilité des systèmes électriques, il est essentiel de surveiller en permanence leur état et d'alerter les opérateurs en cas d'urgence ou de défaillance susceptibles d'indiquer une instabilité de la tension. Lorsqu'une perturbation survient, que ce soit une augmentation de la demande de charge ou un changement de l'état du système, la tension peut commencer à diminuer de manière progressive et incontrôlable, pouvant éventuellement conduire à un effondrement complet de la tension. Il est donc crucial de maintenir des magnitudes de tension stables et acceptables à tous les points du réseau, dans des conditions normales de fonctionnement et après avoir subi une perturbation. Cela garantit que le système reste dans un état de stabilité de tension, évitant ainsi les conséquences néfastes d'une instabilité électrique.

L'évaluation de la stabilité de la tension détermine si des conditions de fonctionnement données de la tension sont sûres ou non. De plus, l'étude de la stabilité de la tension permet de savoir jusqu'où le système peut s'éloigner du point de fonctionnement actuel tout en restant sur la connaissance de la marge de stabilité de tension est d'une importance vitale pour les services publics afin d'exploiter leur système avec un maximum de sécurité et de fiabilité. L'opérateur du système doit disposer d'une méthode précise et rapide pour prédire la marge de stabilité de la tension afin d'initier les actions de contrôle nécessaires.

Plusieurs travaux ont été menés précédemment pour prédire la stabilité de la tension et la proximité des conditions d'effondrement en se basant sur des techniques conventionnelles. Mais, comme elles prenaient beaucoup de temps pour les systèmes électriques à grande échelle, il était nécessaire de disposer d'un outil en ligne rapide.

Les méthodes d'apprentissage par ordinateur, associées aux méthodes d'analyse traditionnelles, telles que la reconnaissance des formes, les systèmes experts, les réseaux d'intelligence artificielle, les systèmes flous et les programmes évolutifs peuvent être combinées avec succès les unes avec les autres pour résoudre les problèmes de stabilité de tension des systèmes électriques.

Au cours des dernières années, l'intelligence artificielle (IA) a émergé comme une solution prometteuse pour relever les défis liés à la stabilité de tension. Les techniques d'apprentissage automatique, en particulier les réseaux neuronaux artificiels (RNA), offrent de nouvelles opportunités pour analyser et prédire la stabilité de tension de manière plus précise et efficace. Ces méthodes basées sur l'IA sont capables de traiter de grandes quantités de données, d'identifier des modèles complexes et de prendre des décisions en temps réel, ce qui les rend idéales pour la surveillance et la gestion des réseaux électriques. Ces avancées technologiques permettent une détection plus rapide et précise des risques potentiels, ce qui aide les opérateurs de réseau à prendre des mesures préventives pour maintenir la stabilité du réseau électrique et éviter les coûts liés aux perturbations. Parmi les architectures de RNA les plus connues dans la littérature pour surveiller la stabilité de tension, le perceptron multicouches et la fonction de base radiale sont couramment cités. Cette combinaison de l'IA avec les méthodes traditionnelles offre une approche plus complète et efficace pour garantir la stabilité du réseau électrique et assurer un fonctionnement optimal.

Le mémoire présenté se concentre sur l'analyse de la stabilité de la tension dans les réseaux électriques en utilisant des réseaux de neurones. Dans un premier temps, nous étudions l'évolution de la tension en utilisant des méthodes conventionnelles telles que les indices de stabilité de tension et les courbes (PV) et (QV). Cependant, ces approches nécessitent un temps de calcul important. Nous abordons également le problème de la divergence du flux de charge près du point d'inflexion de la courbe PV, que nous résolvons grâce à la méthode du flux de puissance continu (CPF), cette méthode nous permet de déterminer la répartition de la charge et de trouver la marge de charge assurant la stabilité de la tension en régime permanent. Par la suite, nous explorons l'utilisation des réseaux de neurones artificiels (RNA) pour surveiller la stabilité de la tension. Dans ce contexte, la sélection des variables d'entrée joue un rôle crucial. En exploitant les avantages des réseaux de neurones, nous visons à améliorer l'analyse de la stabilité de la tension dans les réseaux électriques, en fournissant des résultats plus précis et efficaces tout en réduisant le temps de calcul requis.

A cet effet, nous avons organisé le travail conduit pour réaliser ce mémoire en quatre chapitres :

- Le premier chapitre du mémoire se focalise sur l'analyse de la stabilité de tension à travers des méthodes conventionnelles. Il aborde la classification de la stabilité de tension en mettant en évidence les différentes catégories existantes et en identifiant les principales causes d'instabilité de tension. Les conséquences potentielles de cette instabilité sont également mises en évidence, tout en discutant des méthodes traditionnellement utilisées pour évaluer la stabilité de tension. De plus, une simulation dans "MATLAB" est réalisée pour analyser les courbes (PV), (QV) et (CPF) dans un réseau de 14 nœuds.
- Le deuxième chapitre se concentre sur les indices de stabilité de tension. Il présente certains indices et leurs démonstrations, qui sont utilisés pour évaluer la stabilité de tension dans les réseaux électriques. Des simulations sont effectuées à l'aide de "MATLAB" pour calculer les indices (FVSI) et (LQP) dans un réseau de 14 nœuds. Ensuite, ces indices sont comparés aux courbes (QV) afin d'évaluer leur efficacité dans la détection de l'instabilité de tension.

- Le troisième chapitre introduit les notions de base des réseaux de neurones artificiels (RNA), en mettant en évidence leurs avantages et inconvénients.
- Dans le quatrième chapitre, l'application des réseaux de neurones artificiels (RNA) au calcul de l'indice de stabilité de tension (FVSI) est abordée en utilisant "MATLAB". Une phase d'entraînement spécifique des (RNA) est réalisée pour cet indice, suivie de tests visant à évaluer leurs performances. Ce chapitre présente une application concrète des (RNA) dans le domaine de la stabilité de tension, en comparant également les méthodes conventionnelles d'évaluation de la stabilité de tension aux méthodes basées sur les (RNA). Cela permet d'analyser les avantages et les performances des (RNA) dans ce contexte spécifique.

Enfin, pour clôturer ce travail, une conclusion générale, perspectives, et propositions envisagées pour poursuivre cette recherche sont présentées.

Chapitre 1

Analyse de la stabilité de tension par les méthodes conventionnelles

1.1 Introduction

La stabilité des réseaux électriques a été reconnue comme un problème important pour le fonctionnement sûr des réseaux depuis les années 1920 [1][2]. De nombreuses pannes majeures causées par l'instabilité des réseaux électriques ont illustré l'importance de ce phénomène. Une compréhension claire des différents types d'instabilité et de leur interdépendance est essentielle pour une conception et une exploitation satisfaisantes des réseaux électriques. De plus, une utilisation cohérente de la terminologie est nécessaire pour développer des critères de conception et d'exploitation des systèmes, des outils analytiques standard et des procédures d'étude. Pour mieux comprendre la stabilité du réseau électrique et résoudre le problème, il est indispensable de classer les différents types de stabilité. Généralement trois types de stabilités se distinguent : la stabilité de l'angle de rotor, la stabilité de fréquence et la stabilité de tension [3]. Ces différentes formes de stabilité sont générées par différents facteurs. L'analyse des problèmes de stabilité implique l'identification des facteurs essentiels contribuant à l'instabilité et le développement de méthodes pouvant améliorer la stabilité du réseau.

De plus, la tension et la fréquence sont les deux grandeurs principales qui permettent aux chercheurs de mesurer le degré de stabilité du réseau de façon à pouvoir prendre les précautions nécessaires afin d'éviter un effondrement partiel ou total. Ces deux grandeurs doivent être maintenues dans les limites appropriées pour fournir une énergie de qualité aux besoins des consommateurs et au bon fonctionnement du réseau. Plusieurs événements d'effondrement de tension à travers le monde montrent que les réseaux électriques fonctionnent près de leurs limites de stabilité. Ce problème est d'autant plus aggravé par la libéralisation du marché de l'électricité. En conséquence, les marges de stabilité de la tension sont assignées encore plus loin que leurs limites pour répondre aux besoins du marché [4].

Ce chapitre donne un aperçu général de la stabilité de tension et ses méthodes conventionnelles d'analyse. La première partie de ce chapitre présente les concepts généraux relatifs à la stabilité de la tension. Dans la deuxième partie les différentes définitions liées à la stabilité de tension de plusieurs organismes spécialisés ainsi que les causes qui favorisent l'instabilité de tension et les conséquences seront présentées. A la fin de celui-ci, on trouvera plusieurs méthodes classiques d'analyse de la stabilité de tension. Parmi ces outils d'analyse, nous citerons la courbe PV, la courbe QV et l'écoulement de puissance continue (CPF), présentés en détail, ainsi que leurs applications pour un réseau de 14 noeuds.

1.2 Problème de la stabilité des réseaux électrique

La stabilité d'un système électrique est la capacité, pour une condition de fonctionnement initiale donnée, à retrouver un état d'équilibre de fonctionnement après avoir été soumis à une perturbation physique, la plupart des variables du système étant limitées de sorte que pratiquement tout le système reste intact [3].

L'étude de la stabilité constitue l'un des concepts fondamentaux à considérer par les spécialistes des réseaux électriques, en raison de l'impact nuisible dont l'instabilité peut causer dans les systèmes dynamiques. De nombreuses définitions de stabilité ont été formulées, en établissant plusieurs aspects qui reflètent la manifestation de l'état stable

du système. Selon la nature et l'amplitude de la perturbation, nous pouvons définir trois types de stabilité : la stabilité statique, la stabilité dynamique et la stabilité transitoire [5]. Dans ce travail, nous nous intéresserons en particulier à la stabilité statique.

1.3 Classification de la stabilité de réseau d'énergie électrique

La stabilité est une condition d'équilibre entre des forces opposées. Selon la topologie du réseau, les conditions d'exploitation du système et la forme de la perturbation, différents ensembles de forces opposées peuvent connaître un déséquilibre durable conduisant à différentes formes d'instabilité. Nous fournissons une base systématique pour la classification de la stabilité du système électrique [3].

La stabilité des réseaux électriques est essentiellement un problème unique ; cependant, les diverses formes d'instabilité que peut subir un réseau électrique ne peuvent être correctement comprises et traitées efficacement. En raison de la dimensionnalité et de la complexité des problèmes de stabilité, il est utile de faire des hypothèses simplificatrices pour analyser des types spécifiques de problèmes en utilisant un degré de détail approprié de la représentation du système et des techniques analytiques appropriées [6]. Il est essentiel d'avoir une classification pour pouvoir effectuer une analyse pratique et significative et même la résolution des problèmes de stabilité du système électrique [7].

La classification de la stabilité du système électrique proposée ici est basée sur les considérations suivantes [3] :

- La nature physique du mode d'instabilité qui en résulte.
- La taille de la perturbation considérée,
- Les dispositifs, les processus et la durée.

La figure (1.1) donne une image globale des différentes formes de stabilité électrique , en identifiant les catégories et les sous-catégories de la stabilité [8].

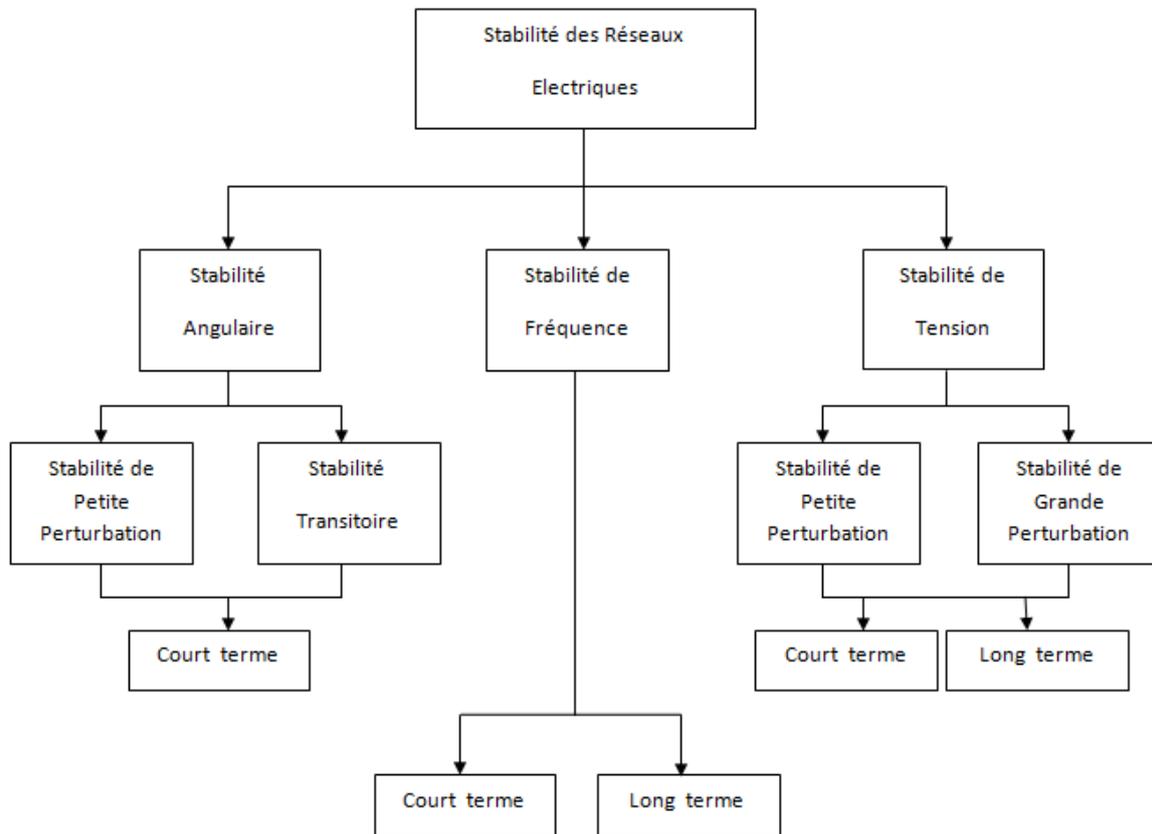


FIGURE 1.1 – Classification des types de stabilité des réseaux électriques [8].

1.3.1 Stabilité angulaire

La stabilité de l'angle du rotor désigne la capacité des machines synchrones d'un système électrique interconnecté à rester en synchronisme après avoir été soumises à une perturbation. Elle dépend de la capacité à maintenir/rétablir l'équilibre entre le couple électromagnétique et le couple mécanique de chaque machine synchrone du système [3]. L'instabilité qui peut en résulter se présente sous la forme d'oscillations angulaires croissantes de certains générateurs entraînant leur perte de synchronisme avec d'autres générateurs ou si l'oscillation transitoire, provoquée par une perturbation, n'est pas suffisamment amortie dans le temps d'évaluation [7].

Le problème de la stabilité de l'angle du rotor implique l'étude des oscillations électromécaniques inhérentes aux systèmes électriques. Un facteur fondamental de ce problème est la manière dont la puissance de sortie des machines synchrones varie en fonction de l'angle de leur rotor. La variation du couple électromagnétique d'une machine synchrone suite à une perturbation peut être décomposée en deux composantes [7] :

- Composante du couple de synchronisation, en phase avec la déviation de l'angle du rotor.
- Composante de couple d'amortissement, en phase avec la déviation de la vitesse.

La stabilité du système dépend de l'existence des deux composantes du couple pour chacune des machines synchrones. L'absence d'un couple de synchronisation suffisante entraîne l'instabilité aperiodique ou non oscillatoire, tandis que l'absence de couple d'amortissement entraîne une instabilité oscillatoire.

Pour faciliter l'analyse et obtenir un aperçu utile de la nature des problèmes de stabilité, il est intéressant de caractériser la stabilité de l'angle du rotor selon les deux sous-catégories suivantes :

- Stabilité angulaire aux petites perturbations (à petits signaux)
- Stabilité angulaire aux grandes perturbations (transitoire)

1.3.2 Stabilité de fréquence

Un réseau électrique est stable en fréquence, si la fréquence est la même en tout point du système après une augmentation de charge. Elle est mesurée et contrôlée avec précision afin de la maintenir dans une zone acceptable suite à une perturbation, entraînant un déséquilibre important entre la production et la charge. L'instabilité de fréquence concerne essentiellement les situations de perte ou de déclenchement des différents ouvrages connectés au réseau tel que les lignes, les transformateurs, les alternateurs, etc, si une partie du réseau se déconnecte du reste du système, elle évoluera vers une fréquence propre et le contrôle de celle-ci peut être difficile en cas de déséquilibre important entre la production et la consommation au sein de ce réseau. Autrement dit, elle dépend de la capacité à maintenir/rétablir l'équilibre global entre la puissance active produite et consommée, avec un minimum de pertes involontaires de charge. L'instabilité qui peut en résulter se présente sous forme des oscillations de fréquence soutenues qui entraînent le déclenchement d'unités de production et/ou de charges [9], [10], [11].

1.3.3 Stabilité de tension

La stabilité de la tension désigne la capacité d'un système électrique à maintenir des tensions stable à tous les noeuds du réseau dans des conditions de fonctionnement normales ou après avoir été soumis à une perturbation. Elle dépend de la capacité à maintenir/rétablir l'équilibre entre la demande de charge et l'offre de charge du système électrique. Plusieurs phénomènes tels qu'une défaillance d'une ligne de transport ou d'un générateur, variations importantes de la charge, modification de la configuration du réseau électrique peuvent engendrer une baisse ou une hausse progressive et incontrôlable des tensions de certains noeuds [12].

L'un des principaux facteurs contribuant à l'instabilité de tension est la chute de tension qui se produit lorsque la puissance active et réactive circule à travers les réactances inductives du réseau de transmission ; cela limite la capacité du réseau de transmission à transférer la puissance et à soutenir la tension. Le transfert de puissance et le maintien de la tension sont encore plus limités lorsque certains générateurs atteignent leurs limites de capacité de surcharge de temps de champ ou de courant d'induit. La stabilité de la tension est menacée lorsqu'une perturbation augmente la demande de puissance réactive au-delà de la capacité durable des ressources de puissance réactive disponibles [3], [12].

Comme dans le cas de la stabilité de l'angle du rotor, il est utile de classer la stabilité de la tension dans les sous-catégories suivantes [13], [14], [15] :

- Stabilité de tension aux grandes perturbations :
La stabilité de la tension aux grandes perturbations fait référence à la capacité du système à maintenir une tension stable à la suite d'une perturbation importante telle que la perte d'un générateur, la perte d'une ligne transport. En effet, cette capacité est déterminée par les caractéristiques du système et de la charge, ainsi que les interactions des éléments continus et discrets, contrôles et protections. La détermination de la stabilité de la tension à grande perturbation nécessite l'examen de la réponse non linéaire du système électrique sur une période de temps suffisant pour capturer la performance et les interactions de dispositifs tels que les moteurs électriques, les changeurs de prise de transformateur et générateur de courant de champ limiteurs. La période d'étude d'intérêt peut s'étendre de quelques secondes à plusieurs dizaines de minutes.
- Stabilité de tension aux petites perturbations : La stabilité de la tension aux petites perturbations fait référence à la capacité du système à maintenir des tensions constantes lorsque est soumis à des petites perturbations telles que des changements incrémentaux dans la charge du système. Cette forme de stabilité est influencée par les caractéristiques des charges, des commandes continues et des commandes discrètes à un instant donné. Ce concept est utile pour déterminer, à tout instant, comment les tensions du système répondront aux petits changements du réseau électrique. En effet, pour ce type de stabilité, les équations mathématiques du système qui décrivent sa dynamique peuvent être linéarisées autour de son point de fonctionnement, ce qui permet d'identifier les facteurs qui influent sur la stabilité.

La période d'intérêt pour les problèmes de stabilité de la tension peut varier de quelques secondes à des dizaines de minutes. Par conséquent, la stabilité de la tension peut être un phénomène à court ou à long terme [6] :

- Stabilité de tension à court terme : La stabilité de tension à court terme concerne la dynamique des composants de charge à action rapide telle que les moteurs à induction les charges à commande électronique et les convertisseurs HVDC, la période d'étude d'intérêt est de l'ordre de quelques secondes.
- Stabilité de tension à long terme : La stabilité de la tension à long terme implique des équipements à action plus lente comme les transformateurs de changement de prise, les charges à commande thermostatique et les limiteurs de courant des générateurs. La période d'étude qui nous intéresse peut s'étendre sur plusieurs minutes.

1.4 Causes d'instabilité de tension

Les risques d'apparition des phénomènes d'écroulement de tension sont liés à la difficulté de régler la tension au-dessus d'une certaine valeur, appelée tension critique compte tenu de la puissance à transiter pour alimenter la charge et la distance électrique sur laquelle cette puissance doit être transitée [16]. Cela peut ainsi correspondre soit à une tension critique basse avec un manque de moyens de compensation empêchant d'amener la tension

de certains postes consommateurs au-dessus de cette valeur, soit une tension trop élevée pour avoir un fonctionnement normal à une tension supérieure [17].

Généralement, l'effondrement de tension peut se produire en tant que conséquence des interactions entre tous les systèmes rapides et lents dans les réseaux électriques en particulier les équipements réactifs de production et les équipements de consommation, une séquence possible à un effondrement, ce dernier touche les réseaux électriques qui sont fortement chargés, court-circuités et/ou ont un manque de la puissance réactive ; Dans cette situation, le réseau électrique ne peut pas assurer la puissance réactive demandée par la charge. Ceci est dû à des limitations sur la production et la transmission de la puissance réactive, de telle sorte que la puissance réactive des générateurs et des systèmes FACTS sont limités par des contraintes physiques [4].

En plus la puissance réactive générée par des bancs de condensateur est relativement réduite à des tensions basses. La limite sur le transport d'énergie réactive est due principalement aux pertes réactives élevées dans les lignes électriques fortement chargées. Ci-dessus sont exposées les principales raisons de l'instabilité de la tension électrique.

1.4.1 Tension trop basse au niveau des unités de production

Une tension élevée à l'extrémité d'une unité de production augmente l'écoulement de puissance, donc le réseau de transport consomme plus de puissance réactive, les générateurs doivent augmenter la puissance réactive générée et le point de fonctionnement du générateur peut être trouvé. Mais en raison du limiteur de surexcitation et du limiteur de courant du stator, la tension ne peut être contrôlée.

1.4.2 Charge appelée trop importante

L'une des causes de l'instabilité de tension correspond à une charge élevée. Ceci est dû à l'augmentation croissante de la demande et à un large transfert d'énergie entre compagnies. Une instabilité de tension peut se produire en particulier lorsque la charge élevée est plus importante que celle prévue et le risque n'est d'autant plus grand que la consommation réactive et également plus grande que prévue.

1.4.3 Production trop éloignée à la consommation

Même si lorsque le système global a des réserves réactives suffisantes nous pouvons faire face à des problèmes locaux de tension, dans la plupart du temps les sources d'énergie électrique se trouvent loin des zones de consommation. Cette situation rend difficile le transport de puissance réactive à travers des longues distances à cause des pertes réactives très élevées.

- Le transport de puissance à travers de longues distances est dû à plusieurs raisons :
- Les indisponibilités des lignes.
 - Difficile d'obtenir des centres de production à proximité des consommateurs.
 - L'interconnexion continue des réseaux électriques.
 - Il peut se produire que les groupes proches d'un point de consommation soient tous arrêtés.

1.4.4 Manque local de la puissance réactive

L’effondrement de tension liée au manque de la puissance réactive demandée pour maintenir le profil de tension dans une marge de fonctionnement permise. L’utilisation croissante des lignes très chargées a résulté en un besoin accru de l’aménagement de la puissance réactive et a augmenté les possibilités d’instabilité et d’effondrement de tension, en effet, l’une des causes principales d’instabilité de tension réside dans la limitation de la production et la consommation de la puissance réactive, le réseau électrique ne satisfait pas la puissance réactive demandée par la charge, lorsqu’elle atteint une certaine limite.

1.5 Blackouts dans le monde

Les systèmes de transport d’énergie électrique sont des grands systèmes complexes qui fonctionnent près de leurs limites de capacité et présentent des défaillances en cascade qui entraînent souvent des coupures de courant [18].

La panne du système électrique dans les différents pays a été causée par différentes raisons : surcharge des lignes, courts-circuits et pertes d’un ouvrage, etc . De ce fait, les conséquences économiques, sociales et humaines d’un blackout peuvent être extrêmement nombreux et grave et sont étroitement liées au degré d’évolution et à l’urbanisation du pays ou de la région. Cependant, si le système électrique peut être amélioré ou si les défaillances en cascade peuvent être prédites, la probabilité d’une panne du système électrique deviendrait plus faible [3]. Le tableau 1.1 résume quelques effondrements de tension dans le monde [19].

Location	Date	Durée
États-Unis	le 9 novembre 1965	13 heures
New York	les 13 et 14 juillet 1977	36 heures
France	le 19 décembre 1978	4 heures
France et Japon	Le 23 juillet 1987	20 minutes
Canada	Le 13 mars 1989	9 heures
France	Fin décembre 1999	19 jours
États-Unis	Le 14 août 2003	24 heures
Algérie	Le 03 février 2003	4 heures
Italie	28 septembre 2003	plusieurs heures
Luxembourg	Le 2 septembre 2004	35 minutes
Suisse	Le 22 juin 2005	11 heures
Europe	Le 4 novembre 2006	30 minutes
États-Unis	Le 26 février 2008	4 heures
Inde	Le 31 juillet 2012	2 jours
Argentine	2013-2014	plusieurs jours
Tunisie	Le 31 août 2014	2 heures
Sénégal	Le 9 septembre 2014	plusieurs heures
Argentine, Paraguay et Uruguay	Le 16 juin 2019	6 heures
Sri Lanka	Le 17 août 2020	7 heures
Texas	La moitié de février 2021	plusieurs jours

TABLE 1.1 – Effondrement de tension dans le monde [19].

1.6 Méthodes conventionnelles

L'analyse de la stabilité de la tension pour un état donné du système implique l'examen de deux aspects :

- Une proximité de l'instabilité de tension : À quel point le système est-il proche de l'instabilité de tension ?

La marge d'instabilité peut être mesurée en termes de quantités physiques, telles que le niveau de charge, l'écoulement de puissance active à travers une interface critique et la réserve de puissance réactive. La mesure la plus appropriée pour une situation donnée dépend du système spécifique et de l'utilisation prévue de la marge [20].

- Mécanisme d'instabilité de tension : Comment et pourquoi cette instabilité se produit-elle ? Quels sont les facteurs clés contribuant à l'instabilité ? Quels sont les points faibles de la tension ? Quelles mesures sont les plus efficaces pour améliorer la stabilité de la tension ?

L'instabilité de tension est un phénomène non linéaire. Il est impossible de capturer le phénomène sous la forme d'une solution fermée. Il y a plusieurs types de dynamiques associées aux problèmes, donc plusieurs aspects du problème peuvent être analysés efficacement en utilisant des techniques d'analyse statiques . Suite à une perturbation, les simulations de puissance fournissent une méthode d'étude d'un problème d'instabilité de tension [21]. Pour étudier l'instabilité de tension , on va utiliser les deux ensemble de graphiques qui sont les courbes P-V et les courbes Q-V , la méthode d'écoulement de puissance continu et les indices de stabilité de tension.

1.6.1 Courbe P-V

C'est l'une des méthodes les plus utilisées pour l'analyse de la stabilité de la tension, elle est formée en augmentant la puissance réelle (P) dans une zone particulière par étapes et la tension (V) est observée à certains noeuds de charges, puis les courbes pour ces noeuds particuliers seront tracées pour déterminer la stabilité de tension d'un système par une approche d'analyse statique.

La courbe PV donne la quantité disponible de marge de puissance active avant le point d'instabilité de la tension, et de tension en utilisant le coude de la courbe comme point de référence. Elle est utilisée dans les centres de contrôle où la complexité de la courbe QV n'est pas pratique [21].

Chapitre 1. Analyse de la stabilité de tension par les méthodes conventionnelles

Pour expliquer l'analyse des courbes PV, supposons un système à deux noeud avec un seul générateur, une seule ligne de transmission et une charge, comme le montre la figure suivante :

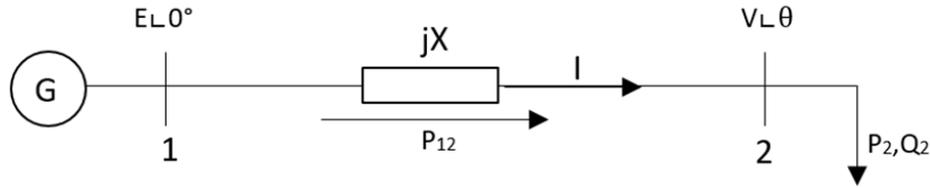


FIGURE 1.2 – Réseau électrique à deux noeuds

D'après cette figure, on peut développer le modèle mathématique qui décrit la variation de la tension en fonction de la charge en exprimant la puissance apparente au noeud 2 suivant l'équation :

$$S = P + jQ = \vec{V}\vec{I}^* \quad (1.1)$$

En considérant la figure 2.1, on peut écrire :

$$\vec{I} = \frac{\vec{E} - \vec{V}}{jX} \quad (1.2)$$

On aura alors :

$$S = \vec{V} \left(\frac{\vec{E} - \vec{V}}{jX} \right)^* = \vec{V} \left(\frac{\vec{E}^* - \vec{V}^*}{jX^*} \right) \quad (1.3)$$

Avec :

$$V^* = (V\angle\theta)^* = V\angle -\theta \quad (1.4)$$

On aura :

$$S = V\angle\theta \frac{(E\angle 0 - V\angle -\theta)}{-jX} = -\frac{EV}{X} \sin\theta + j \left(\frac{EV}{X} \cos\theta - \frac{V^2}{X} \right) \quad (1.5)$$

Les puissances active et réactive qui transitent dans la ligne s'écrivent alors :

$$P = -\frac{EV}{X} \sin\theta \quad (1.6)$$

$$Q = \frac{EV}{X} \cos\theta - \frac{V^2}{X} \quad (1.7)$$

D'après l'équation 1.6 et 1.7, on trouve :

$$\sin\theta = -\frac{PX}{EV} \quad (1.8)$$

$$\cos\theta = \frac{QX + V^2}{EV} \quad (1.9)$$

Chapitre 1. Analyse de la stabilité de tension par les méthodes conventionnelles

On sait que :

$$\sin^2\theta + \cos^2\theta = 1 \quad (1.10)$$

Donc on aura :

$$\left(-\frac{PX}{EV}\right) + \left(\frac{QX + V^2}{EV}\right) = 1 \quad (1.11)$$

L'équation précédente peut s'écrire sous la forme d'une équation quadratique en fonction de V :

$$\frac{V^4}{E^4} + \frac{V^2}{E^4}(2QX - E^2) + \frac{X^2}{E^4}(P^2 + Q^2) = 0 \quad (1.12)$$

$$V_2^2 = \frac{1}{2} \left[V_1^2 - 2QX \pm V_1 \left(V_1^2 - \frac{4P^2X^2}{V_1^2} - 4QX \right)^{\frac{1}{2}} \right] \quad (1.13)$$

Si on pose : $v = \frac{V}{E}$, $p = \frac{PX}{E^2}$, $q = \frac{QX}{E^2}$ et $q = \tan\phi$ avec ϕ est le facteur de puissance de la charge.

L'équation [1.12](#) devient :

$$v^4 + v^2(2p\tan\phi - 1) + p^2(1 + \tan^2\phi) = 0 \quad (1.14)$$

Donc la solution est :

$$v^2 = -(2p\tan\phi - 1) \pm \frac{\sqrt{(2p\tan\phi - 1)^2 - 4p^2(1 + \tan^2\phi)}}{2} \quad (1.15)$$

Cette équation admet deux solutions physiques correspondent à une solution de haute tension et de basse tension. Au point de puissance maximale, le terme à l'intérieur de la racine carré est nulle, sous ces conditions on peut écrire :

$$p_{max} = \frac{\cos\phi}{2(1 + \sin\phi)} \quad (1.16)$$

$$v_{crit} = \frac{1}{\sqrt{2} * \sqrt{1 + \sin\phi}} \quad (1.17)$$

Pour différentes valeurs de facteurs de puissance de la charge, les valeurs normalisées de la puissance active de la charge sont indiquées à la figure suivante :

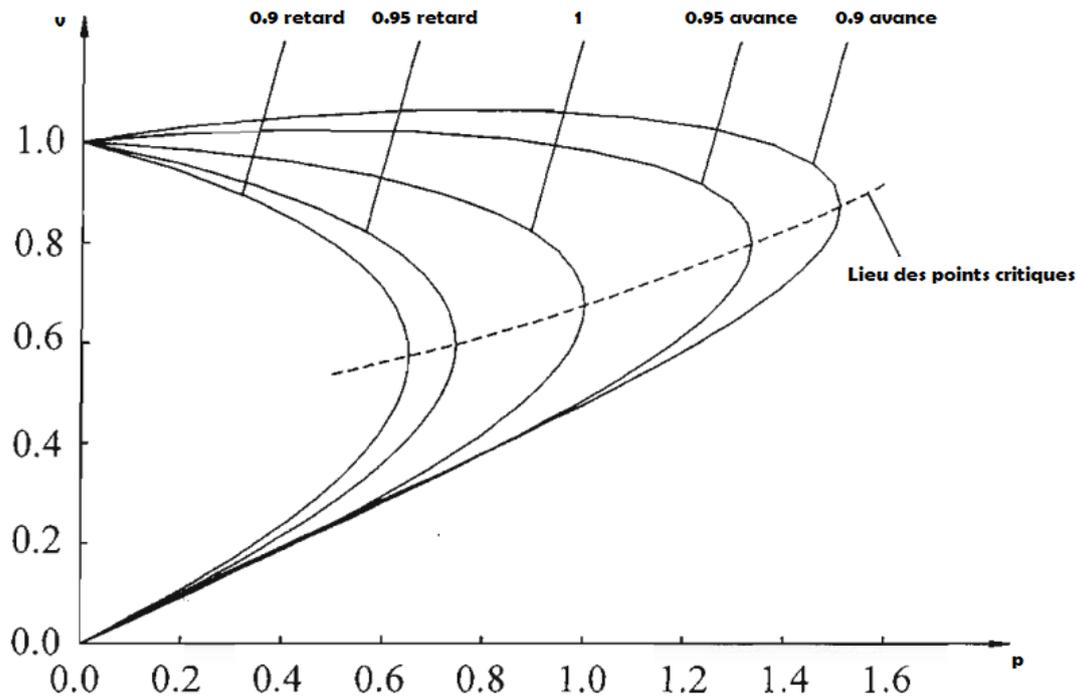


FIGURE 1.3 – Courbe P-V

Chaque courbe correspond à un facteur de puissance donné. On peut remarquer qu'il y a un maximum de puissance qui peut être transférée. Pour toute valeur donnée de P , il existe deux tensions possibles (une tension plus élevée avec un courant plus faible ou une tension plus faible avec un courant plus élevé). Le fonctionnement normal correspond à la tension la plus élevée c'est à dire l'état stable du système. Les points de la courbe (V_{cri} , P_{max}) pour différents facteurs de puissance sont présentés par la ligne pointillée de la figure. Avec une compensation capacitive (facteur de puissance élevé), la puissance maximale augmente. Cependant, la tension critique correspondante augmente également [22].

1.6.2 Courbe Q-V

La méthode de la courbe V-Q est l'une des méthodes les plus populaires qui est utilisée pour étudier les problèmes d'instabilité de tension dans les réseaux électriques à long terme. En plus de caractéristiques PV, une caractéristique plus significative est donnée par la courbe QV, qui met en relief la sensibilité et la variation de tension d'un nœud par rapport à l'injection de puissance réactive [9].

La puissance réactive au niveau du nœud est calculée à partir des solutions d'écoulement de puissance et tracée en fonction de la tension spécifiée pour des différents valeurs de la puissance active P . Le point de fonctionnement correspondant à une puissance réactive nulle représente la condition dans laquelle la source de puissance réactive fictive est retirée du nœud de charge. La sécurité de tension d'un nœud est étroitement liée à la réserve de puissance réactive disponible, qui peut être facilement trouvée à partir de la courbe QV du nœud considéré.

Chapitre 1. Analyse de la stabilité de tension par les méthodes conventionnelles

La marge de puissance réactive est la distance en MVAR entre le point de fonctionnement et le point de bifurcation de la courbe QV [23]. La rigidité du noeud peut être évaluée qualitativement à partir de la pente de la partie droite de la courbe V-Q. Plus la pente est grande, plus la rigidité est faible. Plus la pente est grande, moins le noeud est rigide, et donc plus il est vulnérable à l'effondrement de tension. Les noeuds faibles du système peuvent être déterminés à partir de la pente de la courbe QV.

Pour le système simple à deux noeud illustré précédemment, les équations des courbes V-Q pour des charges de puissance constante peuvent être dérivées comme suit :

$$Q = \frac{EV}{X} \cos\theta - \frac{V^2}{X} \quad (1.18)$$

ou bien :

$$v^2 = \frac{-(2q - 1) \pm \sqrt{(2q - 1)^2 - 4(p^2 + q^2)}}{2} \quad (1.19)$$

Pour une gamme de valeurs de tension et différents niveaux de puissance active, les courbes QV normalisées sont présentées à la figure ci dessous. Le point critique ou point de bifurcation a des caractéristiques correspond au point où $\frac{dQ}{dV}$ devient nul [20]. Si le point minimum de la courbe QV est au-dessus de l'axe horizontal, le système présente un manque de puissance réactive. Des sources de puissance réactive supplémentaires sont nécessaires pour éviter un effondrement de la tension.

Dans la figure 1.4, les courbes pour $p=1,00$ et $p=0,75$ indiquent des noeuds à puissance réactive insuffisante. Les noeud dont les courbes QV sont inférieures à l'axe horizontal ont une marge de puissance réactive positive [23].

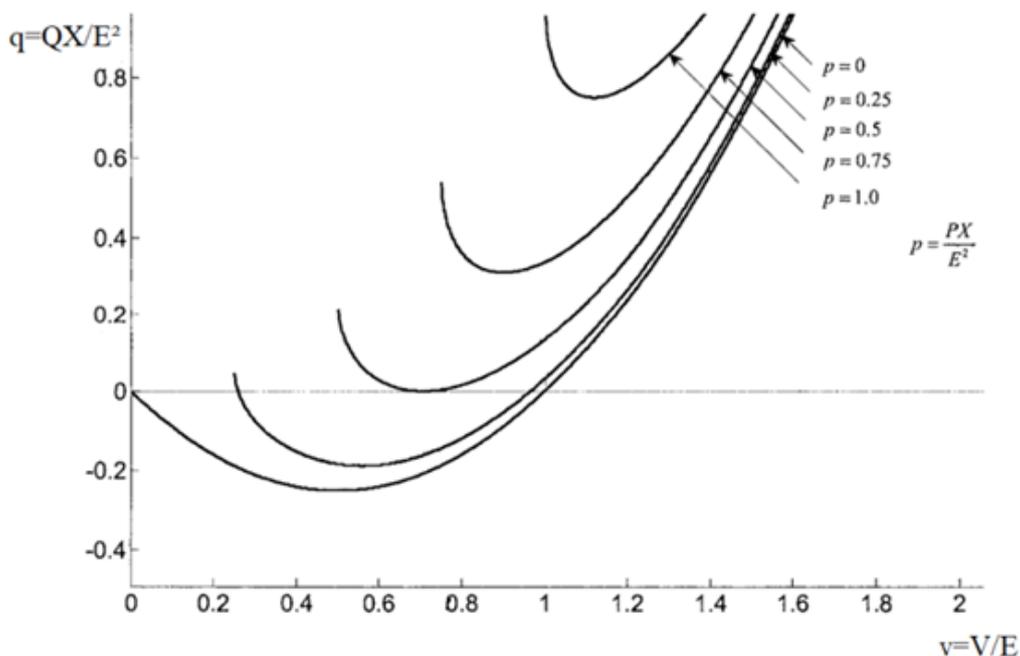


FIGURE 1.4 – Courbe Q-V pour différents niveaux de puissance active

Pour les noeud critiques, les courbes QV peuvent être générées à partir du flux de puissance. La puissance passant par les lignes de transmission introduit une perte de puissance réelle et réactive. Ces pertes dépendent fortement de la quantité de puissance traversant la ligne. Les lignes de transmission sont principalement dominées par les caractéristiques inductives et capacitives de la ligne. À faible charge, elle agit comme un condensateur (elle fournit de la puissance réactive au système). Aux charges élevées, elle agit comme une inductance (absorption de puissance réactive) [22].

1.6.3 Ecoulement de puissance continu

1.6.3.1 Introduction

L'écoulement de puissance continu est une technique très importante qui est utilisée pour obtenir les solutions des équations d'écoulement de puissance et qui surmonte le problème de la singularité de la matrice jacobienne près ou au point d'effondrement de la tension. Elle sert à reformuler les équations d'EP de sorte qu'elles restent bien déterminées dans toutes les conditions de charge possibles. Cela permet de résoudre le problème de l'écoulement de puissance pour les points d'équilibre stables et instables (pour les parties supérieure et inférieure de la courbe PV) [20].

Le CPF est un processus itératif qui consiste à calculer une nouvelle situation à partir d'une situation initiale connue. Comme le montre la figure 1.2 :

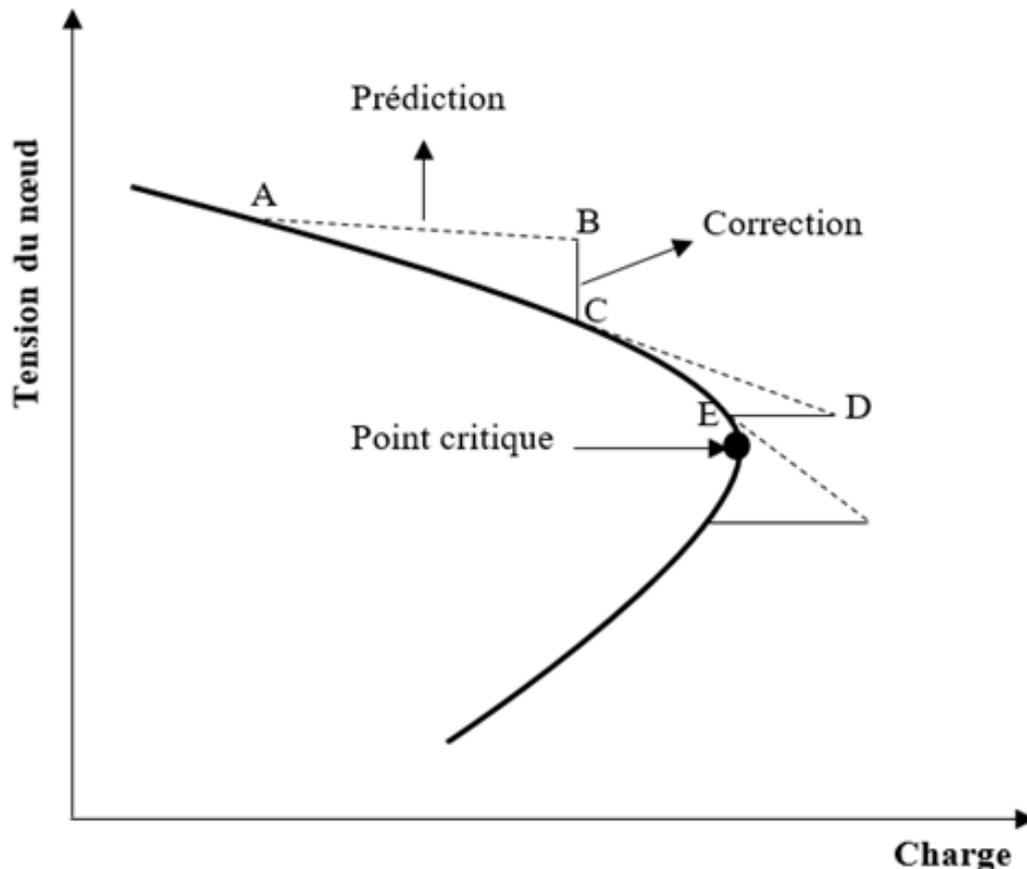


FIGURE 1.5 – La technique prédiction-correction [22]

Une itération est divisée en deux phases : la prédiction et la correction [20]. À partir du point initial A, un prédicteur tangent est utilisé pour estimer la solution B pour un modèle spécifié d'augmentation de la charge. L'étape de correction détermine ensuite la solution exacte C en utilisant la technique Newton-Raphson employée par une analyse d'écoulement de puissance conventionnelle pour une charge supposée fixe. Après cela, une nouvelle prédiction est faite pour une augmentation spécifiée de la charge basée sur le nouveau vecteur tangent au point D. Ensuite, l'étape du correcteur est appliquée (point E).

Ce processus se poursuit jusqu'à ce que le point critique soit atteint. Le point critique est le point où le vecteur tangent est nul [24].

1.6.3.2 Reformulation des équations d'écoulement de puissance

Afin d'appliquer l'écoulement de puissance continu dans la résolution des problèmes, les équations de base d'écoulement de puissance sont reformulées en en insérant un paramètre de charge λ avec $0 \leq \lambda \leq \lambda_{critique}$ dans ces équations. Cette reformulation peut être effectuée en exprimant la charge et la production à un nœud en fonction du paramètre de charge.

Ce paramètre est un élément essentiel de l'analyse CPF. Il désigne la quantité de puissance utilisée par les charges présentes dans le système électrique, et permet d'analyser le comportement du système dans des conditions de charge variables. En outre, il permet de déterminer la capacité maximale de charge que le système peut supporter.

Les formes générales des nouvelles équations pour chaque nœud i se présentent sous les formes générales suivantes :

$$\Delta P_i = P_{G_i}(\lambda) - P_{L_i}(\lambda) - P_{T_i} = 0 \quad (1.20)$$

$$\Delta Q_i = Q_{G_i}(\lambda) - Q_{L_i}(\lambda) - Q_{T_i} = 0 \quad (1.21)$$

avec :

$$P_{T_i} = \sum_{j=1}^n V_i V_j y_{ij} \cos(\delta_i - \delta_j - \gamma_{ij})$$

$$Q_{T_i} = \sum_{j=1}^n V_i V_j y_{ij} \sin(\delta_i - \delta_j - \gamma_{ij})$$

Chaque nœud i parmi n nœuds est associé aux indices L, G, T qui représentent respectivement la puissance consommée, la puissance produite et la puissance injectée. Les tensions aux nœuds i et j sont notées $V_i \angle \delta_i$ et $V_j \angle \delta_j$, respectivement, et l'élément (i,j) de la matrice d'admittance Y_{noeud} est représenté par $Y_{ij} \angle \gamma_{ij}$.

Pour simuler les variations de la charge, les valeurs de P_{L_i} et Q_{L_i} sont divisées en deux composantes : l'une correspond à la charge initiale, tandis que l'autre représente la variation de la charge, ajustée en faisant varier le paramètre de charge λ .

Ces équations peuvent être écrites comme suit :

$$P_{Li} = P_{Li0} + \lambda(\tau_{Li}S_{\Delta base}\cos\psi_i) \quad (1.22)$$

$$Q_{Li} = Q_{Li0} + \lambda(\tau_{Li}S_{\Delta base}\sin\psi_i) \quad (1.23)$$

tel que :

- Les variables P_{Li0} et Q_{Li0} représentent respectivement les puissances active et réactive de la charge de base au nœud consommateur i .
- La constante τ_{Li} est liée au taux de variation de la charge.
- ψ_i représente la phase de la variation de la puissance apparente au nœud i .
- $S_{\Delta base}$ est la puissance apparente qui correspond à une valeur appropriée de λ pour les simulations de changement de charge.

Si l'on considère que $S_{\Delta base}\cos(\psi_i) = P_{Li0}$ et $Q_{Li0} = S_{\Delta base}\sin(\psi_i)$, ainsi que $Q_{Li0} = P_{Li0}\tan(\psi_i)$ alors les équations (1.22) et (1.23) peuvent être réécrites comme suit :

$$P_{Li}(\lambda) = P_{Li0}[1 + \lambda\tau_{Li}] \quad (1.24)$$

$$Q_{Li}(\lambda) = P_{Li0}\tan(\psi_i)[1 + \lambda\tau_{Li}] \quad (1.25)$$

En outre, il est possible d'exprimer la puissance active générée sous la forme suivante :

$$P_{Gi}(\lambda) = P_{Gi0}(1 + \lambda\tau_{Gi}) \quad (1.26)$$

où :

P_{Gi0} : Puissance active de la charge de base produite au nœud i .

τ_{Gi} : Constante liée au taux de variation de production.

L'étape suivante dans la résolution du problème consiste à appliquer l'algorithme de continuation qui commence à partir d'une solution initiale connue. Pour ce faire, on peut utiliser un vecteur F qui contient les équations (1.20) et (1.21). Une fois le vecteur est défini, il est possible d'écrire les équations sous forme d'un ensemble d'équations algébriques non linéaires, qui peuvent être résolues en appliquant la technique de prédiction-correction pour trouver le point critique pour différents nœuds. La correction est effectuée à l'aide d'un algorithme de Newton-Raphson.

Soit F le vecteur qui est défini par :

$$\underline{F}(\underline{\delta}, \underline{V}, \lambda) = 0 \quad (1.27)$$

avec :

δ : Vecteur qui contient les phases des tensions.

V : Vecteur qui contient les modules des tensions.

La solution pour la charge de base (δ_0, V_0, λ) est obtenue en utilisant un calcul d'écoulement de puissance conventionnel pour une gamme de valeurs de λ .

1.6.3.3 Prédiction de la solution suivante

La prédiction est le processus qui consiste à produire une estimation de la solution initiale en utilisant l'équation suivante :

$$\begin{bmatrix} \underline{\delta}^{j+1} \\ \underline{V}^{j+1} \\ \underline{\lambda}^{j+1} \end{bmatrix} = \begin{bmatrix} \underline{\delta}^j \\ \underline{V}^j \\ \underline{\lambda}^{j+1} \end{bmatrix} + \sigma \begin{bmatrix} \underline{d\delta} \\ \underline{dV} \\ \underline{d\lambda} \end{bmatrix} \quad (1.28)$$

où :

- $\underline{t} = [\underline{d\delta} \quad \underline{dV} \quad \underline{d\lambda}]^T$ est le **vecteur tangent**.
- "j" désigne l'itération initiale.
- "j+1" présente l'itération suivante.
- σ : est une constante qui indique la longueur du pas. Le choix de cette variable doit être effectué de manière à ce que la solution anticipée se trouve à l'intérieur du rayon de convergence du correcteur.

Afin d'effectuer cette étape, il est nécessaire de calculer le vecteur tangent qui permet d'obtenir la pente de la courbe qui représente l'évolution de la solution. Il peut être obtenu en prenant la dérivée de l'équation d'écoulement de puissance par rapport à la variable de solution.

Le vecteur tangent peut être calculé à partir de l'équation suivante :

$$\begin{bmatrix} \underline{F}_\delta & \underline{F}_V & \underline{F}_\lambda \end{bmatrix} \begin{bmatrix} \underline{d\delta} \\ \underline{dV} \\ \underline{d\lambda} \end{bmatrix} = 0 \quad (1.29)$$

Dans cette équation, le côté gauche représente la matrice jacobienne conventionnelle de l'écoulement de puissance, augmentée d'une colonne \underline{F}_λ . Lorsqu'on ajoute un nouveau paramètre inconnu λ sans augmenter le nombre d'équations d'écoulement de puissance, il devient nécessaire de trouver une nouvelle équation pour assurer que la Jacobienne augmentée est non singulière au point critique dans la résolution du système. Pour ce faire, on fixe une valeur à l'une des composantes du vecteur tangent et on ajoute une équation qui garantit que le module de ce vecteur ne soit pas nul.

Cette nouvelle équation peut être formulée comme suit :

$$e_k^T \underline{t} = \pm 1 \quad (1.30)$$

avec e_k est un vecteur ligne convenablement dimensionné où tous les éléments sont égaux à zéro excepte le k^{ime} qui est égal à l'unité. Si l'indice k est correctement choisi, le k^{ime} élément impose une norme différente de zéro au vecteur tangent.

Le choix du signe (+) ou (-) dépend de la direction du changement de la k^{ime} variable lors du tracé de la solution. Si cette variable augmente, on choisit le signe (+), tandis que si elle diminue, on choisit le signe (-).

Le vecteur tangent peut être calculé à l'aide de la matrice Jacobienne augmentée représentée par la formule suivante :

$$J_{aug} = \begin{bmatrix} \frac{\partial F}{\partial \delta} & \frac{\partial F}{\partial V} & \frac{\partial F}{\partial \lambda} \\ & & e_k \end{bmatrix} \quad (1.31)$$

$$J_{aug} [t] = \begin{bmatrix} 0 \\ \pm 1 \end{bmatrix} \quad (1.32)$$

Lorsque l'équation (1.32) est résolue et que le vecteur tangent est trouvé, il est alors possible de générer une prédiction pertinente à l'aide de l'équation (1.36).

1.6.3.4 Correction

Après avoir effectué une prédiction, il est essentiel de procéder à une correction de la solution approchée pour garantir une précision suffisante. Chaque technique de continuation adopte une paramétrisation spécifique pour identifier la solution le long de la trajectoire de traçage.

Dans ce système, nous utilisons une paramétrisation locale, qui consiste à ajouter une équation supplémentaire à l'ensemble initial d'équations pour spécifier la valeur d'une variable d'état. Cette méthode permet de contrôler de manière précise l'évolution de la solution en fonction des paramètres choisis.

Dans le cas des équations reformulées, la paramétrisation locale permet de déterminer l'amplitude de la tension V_i pour chaque noeud i , l'angle de phase de la tension nodale δ_i ou le paramètre de charge λ . Cette approche offre plusieurs avantages, tels qu'une meilleure convergence de la solution, une plus grande stabilité numérique et une réduction des coûts de calcul.

Le nouvel ensemble d'équations implique la nouvelle définition de variables d'état. Ceci peut s'exprimer par l'équation suivante :

$$\underline{x} = \begin{bmatrix} \delta \\ V \\ \lambda \end{bmatrix} \quad (1.33)$$

Et aussi :

$$x_k = \eta$$

où x_k représente l'élément k^{ieme} appropriée de \underline{x} , Alors la nouvelle série des équations :

$$\begin{bmatrix} F(x) \\ x_k - \eta \end{bmatrix} = 0 \quad (1.34)$$

Après avoir choisi les valeurs appropriées pour k et η , il est possible d'utiliser une méthode de Newton-Raphson modifiée qui prend en compte la variable d'état ajoutée pour résoudre le système d'équations.

L'indice k utilisé dans la correction est le même que celui utilisé dans la prédiction et η est égal à x_k^* , qui est la valeur prédite à partir de x_k . L'application de la méthode de Newton-Raphson sur le système se traduit par :

$$-J_{aug} * \begin{bmatrix} \Delta\delta \\ \Delta V \\ \Delta\lambda \end{bmatrix} = \begin{bmatrix} \Delta P \\ \Delta Q \\ 0 \end{bmatrix} \quad (1.35)$$

où J_{aug} est la même matrice jacobienne utilisé précédemment et les éléments ΔP et ΔQ sont calculées en remplaçant les valeurs obtenues de la prédiction dans les equations (1.20) et (1.21). Une fois que le x_k est spécifiée dans l'équation (1.34), les valeurs des autres variables sont dépendantes et ils sont résolus par l'application itérative (1.35).

Après avoir obtenu le vecteur $[\Delta\delta \quad \Delta V \quad \Delta\lambda]^T$ en utilisant l'équation (1.35), il convient de vérifier si la condition de convergence pour l'étape de correction est évalué. Si $\max(|\Delta\delta|, |\Delta V|, |\Delta\lambda|) \leq \epsilon$, alors l'étape de correction actuelle a atteint la convergence. Nous pouvons alors utiliser la solution finale convergée comme point de départ pour l'étape de la prédiction et commencer la prochaine étape. Si le critère de convergence de l'étape de correction n'est pas atteint, il faudra procéder à la mise à jour des valeurs de la solution actuelle en utilisant l'équation suivante :

$$\begin{bmatrix} \delta^{nouveau} \\ V^{nouveau} \\ \lambda^{nouveau} \end{bmatrix} = \begin{bmatrix} \delta \\ V \\ \lambda \end{bmatrix} + \begin{bmatrix} \Delta\delta \\ \Delta V \\ \Delta\lambda \end{bmatrix} \quad (1.36)$$

Ensuite, il sera nécessaire de répéter l'itération de correction pour poursuivre le processus de convergence. En effectuant le calcul du vecteur tangent durant l'étape suivante de prédiction, il est possible de vérifier si le système a atteint le point critique. Pour ce faire, il faut savoir que le point critique est atteint lorsque la charge (c'est-à-dire λ) atteint sa valeur maximale et commence à diminuer. À ce moment-là, la composante tangentielle correspondant à λ est nulle, puis devient négative au-delà de ce point.

1.6.3.5 Choix de paramètre de continuation

La variable d'état la plus appropriée est sélectionnée en fonction du composant du vecteur tangent qui présente le taux de variation le plus élevé par rapport à la solution donnée. En général, le paramètre de charge $\lambda = 1$ est le meilleur choix de départ si le cas de base est caractérisé par une charge normale ou faible, car les amplitudes de tension nodale et les angles restent pratiquement constants avec les variations de charge. Toutefois, lorsque le paramètre de charge est augmenté au fil des étapes de continuation, la trajectoire de la solution se rapproche du point critique et les amplitudes de tension et les angles peuvent subir des changements plus importants. À ce stade, le choix initial de λ peut ne plus être le plus approprié par rapport aux autres variables d'état. Une fois que la première sélection a été effectuée, il est important de vérifier la pertinence de la sélection avec la méthode suivante :

$$x_k : |t_k| = \max(|t_1|, |t_2|, \dots, |t_m|)$$

ici, \underline{t} représente le vecteur tangent. Après la sélection du paramètre de continuation, une valeur appropriée de +1 ou -1 doit être attribuée à t_k dans le calcul du vecteur tangent.

La Figure suivante résume les étapes de la méthode de l'écoulement de puissance continu :

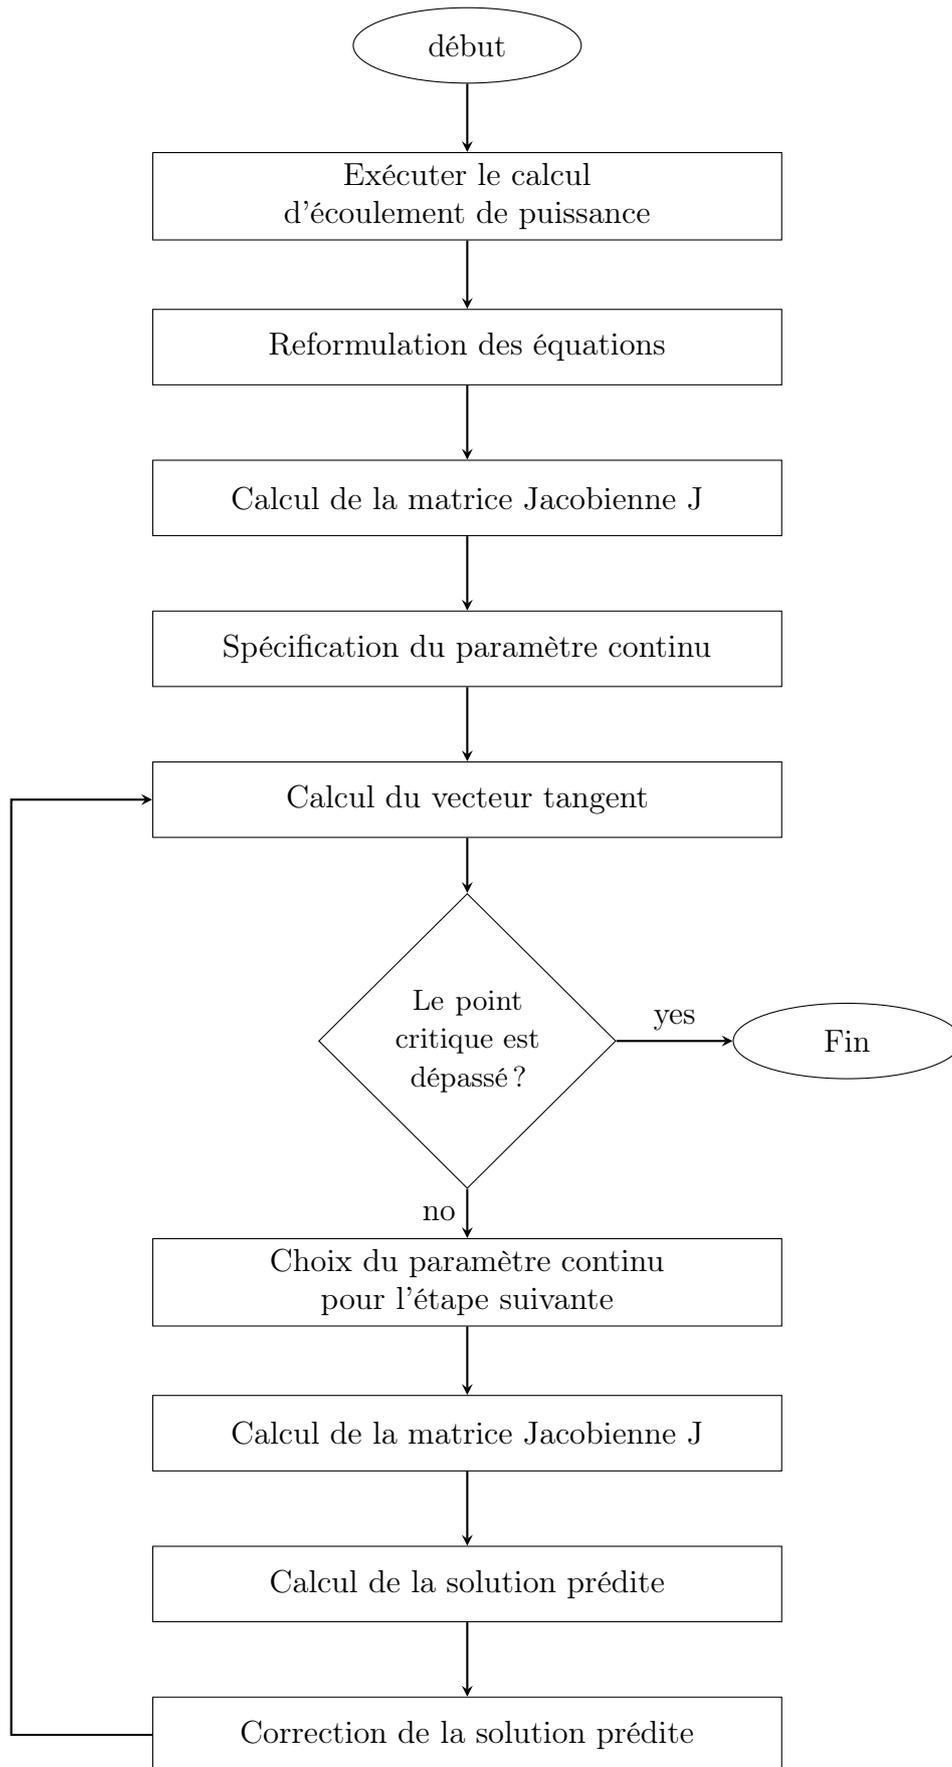


FIGURE 1.6 – Algorithme de l'écoulement de puissance continu

1.7 Exemple d'application

Pour mieux comprendre les parties précédentes, nous avons appliqué les méthodes conventionnelles citées pour analyser la stabilité de tension sur des réseaux électriques standard, en développant un programme propre à l'aide de Matlab. Le réseau 14 nœuds (IEEE 14) a été choisi pour démontrer la validité de ces méthodes pour tout point de fonctionnement et toute topologie de réseau. Les données du système étudié (voir annexe), contiennent des informations sur chaque nœud du réseau ainsi que des données sur les lignes, représentant un point de fonctionnement spécifique du réseau électrique à un moment donné.

1.7.1 Courbe P-V

La marge de stabilité de tension peut être facilement calculée à l'aide des courbes P-V. Ces courbes montrent le niveau de tension du nœud lorsque la charge augmente. La puissance de charge est progressivement augmentée, sur toutes les barres d'alimentation du système, jusqu'à ce que le point de charge maximale soit atteint, en maintenant constant le facteur de puissance.

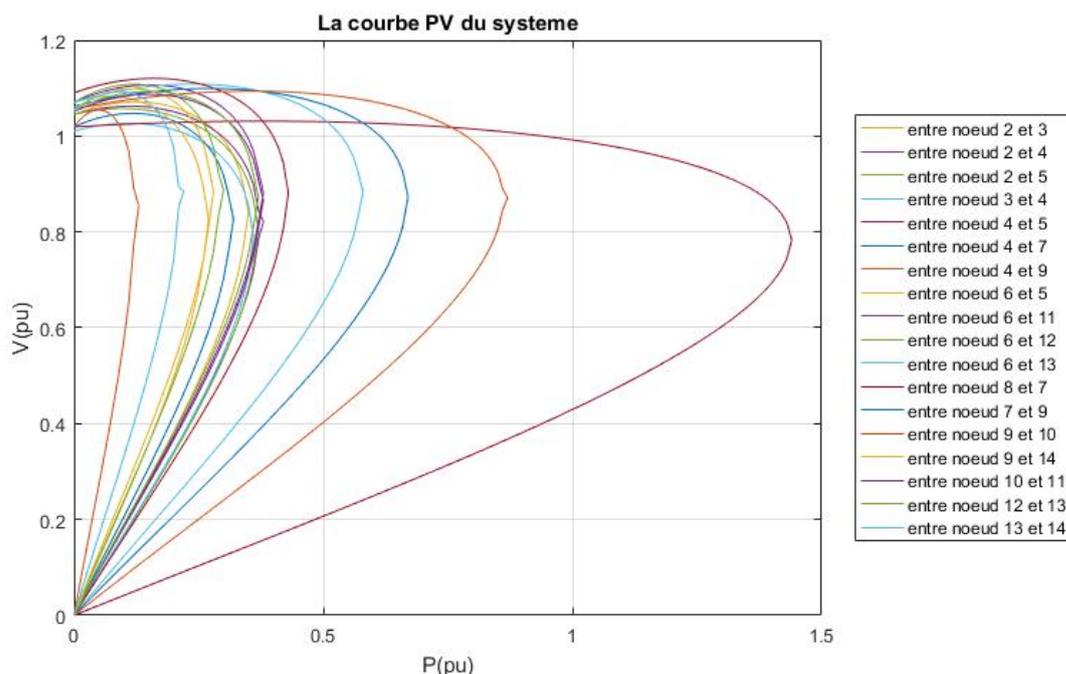


FIGURE 1.7 – Les courbes PV pour chaque ligne du système IEEE 14

En analysant la Figure 1.7, il est observable que l'augmentation graduelle de la charge active du système électrique se traduit par une diminution des tensions dans chaque nœud. On peut observer que la tension chute rapidement au niveau du point de bifurcation, qui est un indicateur d'instabilité. Ce point marque la limite de stabilité du système électrique, et il est important de ne jamais l'exploiter, car cela pourrait entraîner une panne majeure. Pour garantir un fonctionnement fiable du système, il est nécessaire de laisser une marge de puissance suffisante.

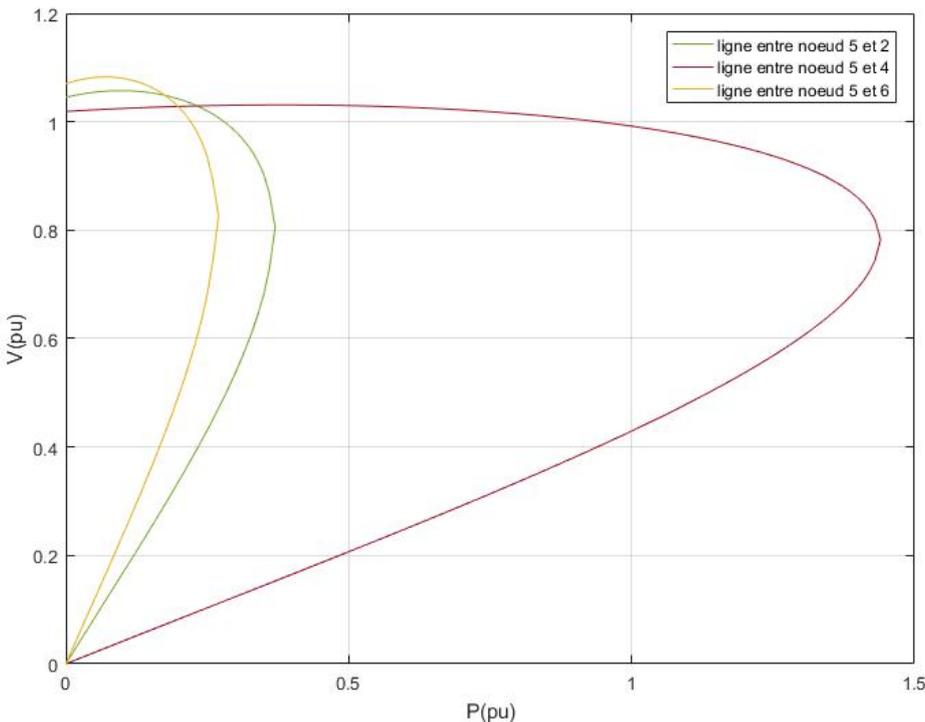


FIGURE 1.8 – Les courbes PV pour chaque ligne du noeud 5

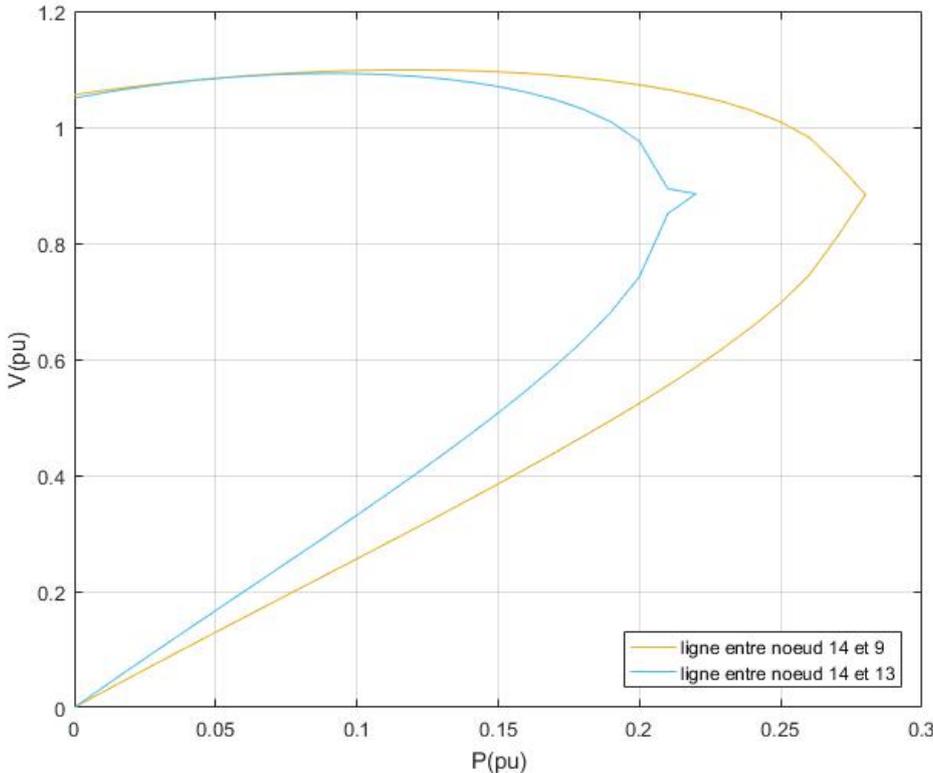


FIGURE 1.9 – Les courbes PV pour chaque ligne du noeud 14

Chapitre 1. Analyse de la stabilité de tension par les méthodes conventionnelles

La figure 1.8 illustre la courbe tracée pour la ligne entre les nœuds 5-2, 5-4 et 5-6, le nœud 5 est considéré comme le nœud le plus fort car il présente la plus grande marge de puissance. En étudiant la figure 1.9, on constate que la tension la plus basse de tous les nœuds se situe au niveau du nœud 14. Cette tension est même inférieure à la tension critique, ce qui indique que le nœud 14 est un nœud faible.

1.7.2 Courbe Q-V

En utilisant l'analyse QV, il est possible de déterminer la tension critique de chaque nœud, une méthode qui se révèle très utile pour identifier les nœuds faibles. Nous savons que dans la courbe QV, la marge de charge doit être plus importante pour éviter l'effondrement de tension du système.

Les courbes Q-V de différents nœuds du réseau 14 nœuds sont représentées dans la figure suivante :

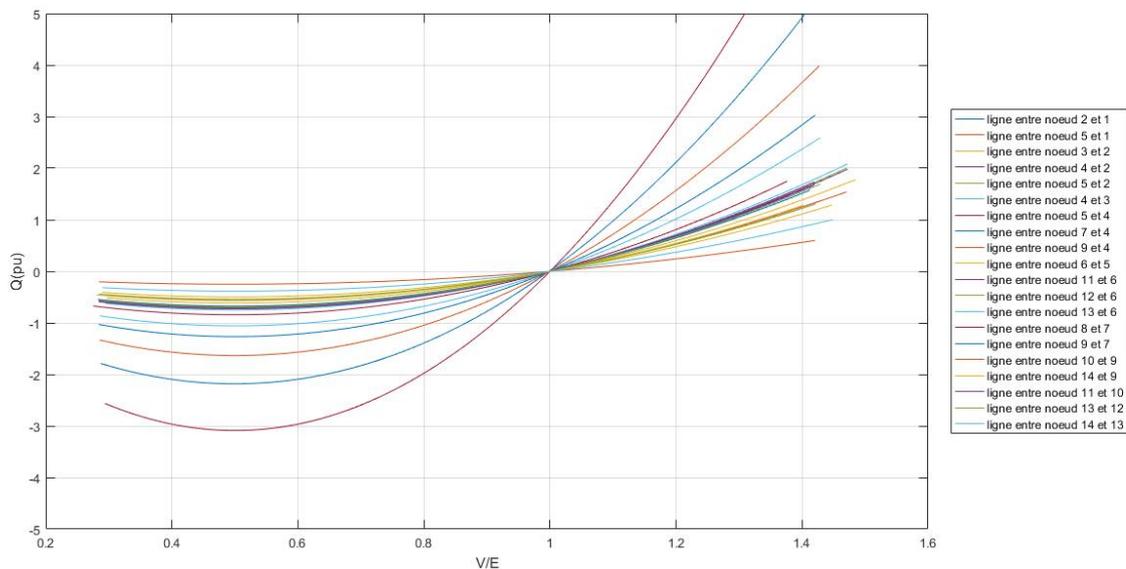


FIGURE 1.10 – Les courbes QV pour un système IEEE 14

Nous allons extraire les courbes des nœuds 5 et 14 à partir de la figure précédente, ce qui nous permettra d'analyser de plus près ces courbes et d'obtenir des données spécifiques à ces derniers.

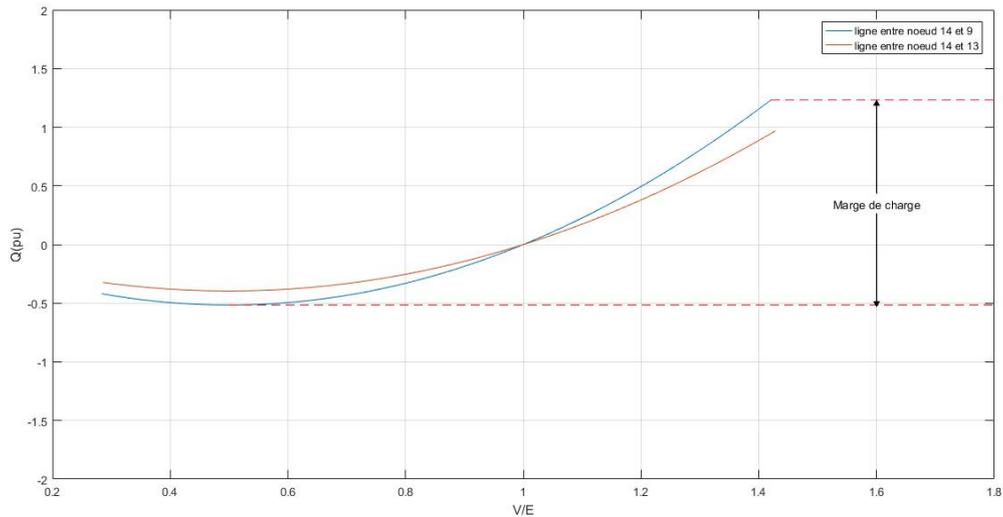


FIGURE 1.11 – Les courbes QV pour chaque ligne du noeud 14

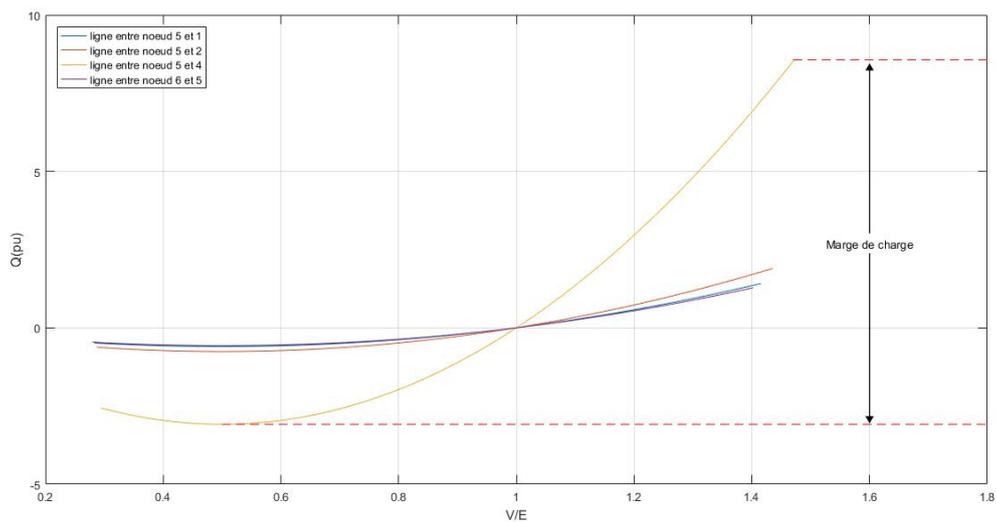


FIGURE 1.12 – Les courbes QV pour chaque ligne du noeud 5

Selon la figure [1.11](#), le noeud 14 a une marge de charge considérablement basse. Ce noeud peut être considéré comme un noeud faible, tandis que les noeuds 4 et 5 ont une marge de charge élevée (comme indiqué sur la figure [1.12](#)), de sorte qu'ils peuvent être classés comme des noeuds forts.

Nous pouvons considérer le noeud 14 comme étant faible, car dans les deux analyses, il présente la plus forte chute de tension. Cette faiblesse se manifeste également dans la courbe QV, où la marge de charge du noeud 14 est faible, ainsi que dans l'analyse PV, où le noeud 14 atteint plus rapidement sa limite de charge que les autres noeuds.

1.7.3 Ecoulement de puissance continu

Pour évaluer la marge de stabilité à l'aide de la méthode CPF (Continuation Power Flow), on augmente progressivement le facteur de charge jusqu'à atteindre le facteur de charge maximal (λ_{max}). λ_{max} représente le facteur de charge maximal qu'un réseau peut supporter sans perdre sa stabilité. Si sa valeur dépasse cette limite, le réseau perd sa stabilité et mathématiquement, il n'y a pas de solution pour l'écoulement de puissance, ce qui signifie qu'il ne peut pas fonctionner physiquement.

La première étape consiste à trouver une solution initiale en effectuant le calcul avec la méthode de Newton-Raphson, puis lancer un processus Prédiction-Correction pour tracer la courbe P-V (en prenant λ comme une image de P), et finalement on détermine le point critique du système. Les résultats de la simulation PSAT sont ensuite analysés.

En appliquant la méthode CPF, le facteur de charge maximal obtenu est $\lambda_{max} = 1,7122$.

noeud	V_i	V_{CPF}	$\Delta V/V$
1	1.06	1.0576	0.2264
2	1.045	0,9469	9.38755
3	1.01	0,8845	12.42574
4	0.99782	0.81789	18.0233
5	1.0029	0.83175	17.065
6	1.07	0.87942	17.811
7	1.036	0.84227	18.6998
8	1.09	0.97488	10.561
9	1.0129	0.7763	23.3527
10	1.0112	0.77028	23.9
11	1.0357	0.81299	21.503
12	1.0462	0.82729	20.924
13	1.0366	0.8066	22.184
14	0.9969	0.72607	27.17

TABLE 1.2 – Résultats du système

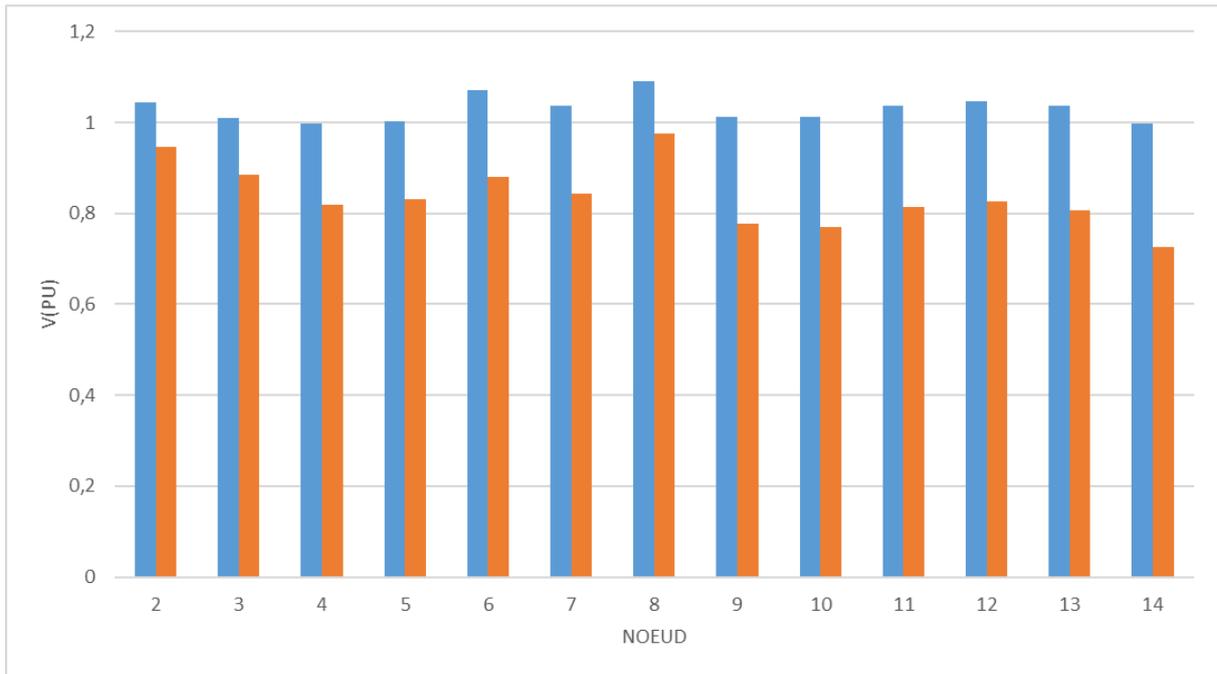


FIGURE 1.13 – Profile du module de tension de l'état initiale et l'état de marge de stabilité pour le réseau 14 noeuds.

Les résultats du tableau 1.2 et la figure 1.13 indiquent clairement que les noeuds 9, 10 et 14 sont considérés comme critiques dans notre système, car le pourcentage de variation de tension y est plus élevé par rapport aux autres noeuds.

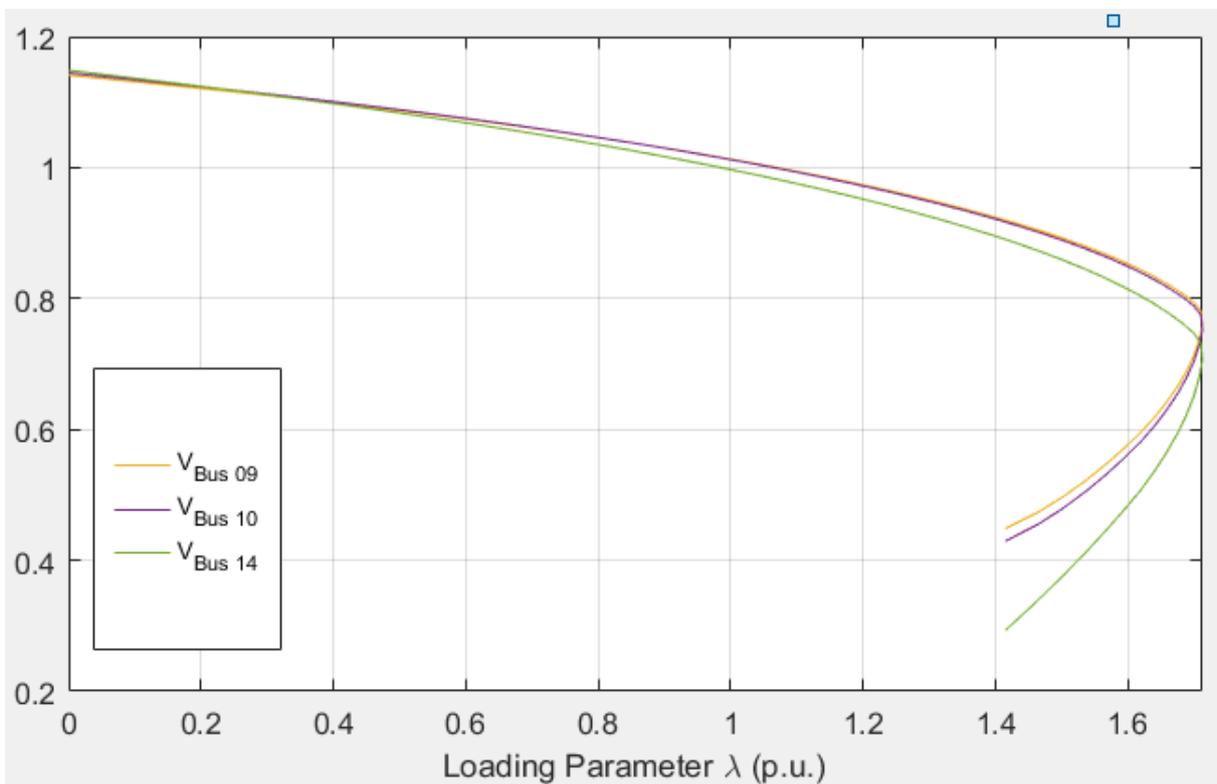


FIGURE 1.14 – Courbe CPF pour les noeuds 9,10 et 14

En examinant la courbe précédente, on constate que le nœud 14 est le premier à tendre vers le point d'effondrement de la tension par rapport aux autres nœuds, car il est le plus sensible à la variation de tension en fonction des puissances réactives.

Il est également observé que les nœuds 2 et 3 ont une chute de tension minimale lorsque la charge est augmentée, ce qui permet de conclure que ces nœuds sont considérés comme étant des nœuds forts. Ces résultats sont importants car ils permettent de déterminer les limites de stabilité du système et de prendre des décisions éclairées pour garantir la fiabilité et la stabilité du système électrique.

1.8 Conclusion

Dans ce chapitre, nous avons classé la stabilité des réseaux électriques pour faciliter l'identification des causes de l'instabilité, l'application de l'instabilité, l'utilisation d'outils d'analyse appropriés et l'élaboration de mesures correctives. Donc, le problème d'instabilité de tension peut être favorisé par plusieurs paramètres à savoir : manque local de la puissance réactive, production trop éloignée de la consommation, ou le cas d'une charge demandée très élevée.

Une analyse efficace de la stabilité de tension reste la solution appropriée pour s'éloigner du point d'effondrement. Ensuite, nous allons présenter, une étude des méthodes d'analyse existantes dans la littérature de la stabilité de la tension, en montrant leurs performances et une comparaison entre eux.

L'application de ces méthodes sur le système de test IEEE 14 nœud a donné des résultats précis. Les simulations présentées indiquent que les courbes PV et QV sont des outils efficaces pour étudier la stabilité de la tension et la marge de puissance. Il s'avère que la compensation de la puissance réactive est le moyen le plus efficace d'améliorer le profil de tension et la marge de puissance.

Également la méthode d'écoulement de puissance en continu est une méthode simple pour construire la courbe P-V complète. Le tracé de cette dernière aide à analyser la limite de la stabilité de la tension d'un réseau d'énergie électrique. L'objectif de la méthode est d'améliorer le conditionnement de la matrice jacobienne autour du point d'effondrement pour obtenir la courbe PV complète et exacte en se basant sur l'écoulement de puissance classique. Cette amélioration est accomplie en modifiant les conditions initiales d'écoulement de puissance au point de bifurcation.

Chapitre 2

Indices de stabilité de tension électrique

2.1 Introduction

Dans le chapitre précédent, nous avons vu que les méthodes P-V, Q-V et CPF sont des outils couramment utilisés pour évaluer la limite de stabilité de tension statique d'un système électrique. Ces méthodes reposent sur une analyse numérique approfondie du système électrique. En outre, il existe d'autres approches pour évaluer la stabilité de tension, notamment les indices de stabilité.

Dans ce chapitre, nous présentons l'approche ou les approches basées sur les indices de stabilité électrique, utilisés pour détecter les zones du système électrique présentant des risques d'instabilité de tension. Les indices de stabilité de tension sont des indicateurs qui permettent d'évaluer la stabilité de la tension dans le système, en fournissant des informations sur les niveaux de tension et en identifiant les noeuds ou les lignes faibles. Ces indices sont classés en fonction d'hypothèses, de modélisation du réseau, de valeurs critiques, d'analyse de stabilité régionale ou globale, et peuvent être définis pour une ligne ou un noeud.

Notre objectif dans ce chapitre est de présenter l'analyse théorique de quelques uns de ces indices et de comparer leurs performances en les appliquant sur le réseau standard IEEE 14 noeuds. Nous présenterons les résultats de la simulation de l'application des différents indices développés.

2.2 Classification des indices de stabilité

Depuis les années 1920, la stabilité de tension est connue comme un facteur essentiel pour garantir un système électrique sécurisé et fiable. Les indices de stabilité de tension sont utilisés pour évaluer la marge de stabilité de tension d'un système, déterminer le point d'effondrement de tension et identifier les zones les plus sensibles et les plus faibles du système. Une classification de ces indices peut être effectuée en fonction de leur approche de formulation, notamment les indices qui s'appuient sur la matrice jacobienne, les indices qui utilisent les variables système et ceux qui se basent sur les mesures PMU (Phasor Measurement Unit).

Les indices basés sur **la matrice jacobienne** sont dérivés à partir de l'analyse d'écoulement de puissance et de la matrice jacobienne [25]. Ces indices démontrent la capacité de charge maximale et déterminent la marge de stabilité de la tension. Toutefois, le calcul de la matrice jacobienne est plus complexe, ce qui limite son utilisation pour une évaluation en ligne de la stabilité de tension.

Les indices PMU sont basés sur **Les synchrophaseurs**. Cette technologie est utilisée pour surveiller la stabilité de tension plutôt que pour prédire l'instabilité [26]. Les techniques de surveillance de la stabilité de tension PMU sont classées en deux grandes catégories : les mesures locales basées sur l'impédance de Thévenin et les mesures globales à large échelle. Toutefois, la méthode de Thévenin présente des lacunes en raison de la variation des paramètres lors des deux mesures.

Enfin, les indices basés sur **les variables systèmes** sont dérivés des éléments du système tels que l'évaluation des noeuds faibles ou des zones faibles en tension et la limite de charge de ligne en considérant la matrice admittance du réseau [25] [27]. Ces indices sont classés en deux catégories : les indices des noeuds et les indices de ligne. Ils sont souvent utilisés pour une évaluation en ligne de la stabilité de tension des éléments critiques d'un système électrique.

La figure ci-dessous présente une synthèse de la classification des indices de stabilité de tension, ainsi que la relation entre ces indices :

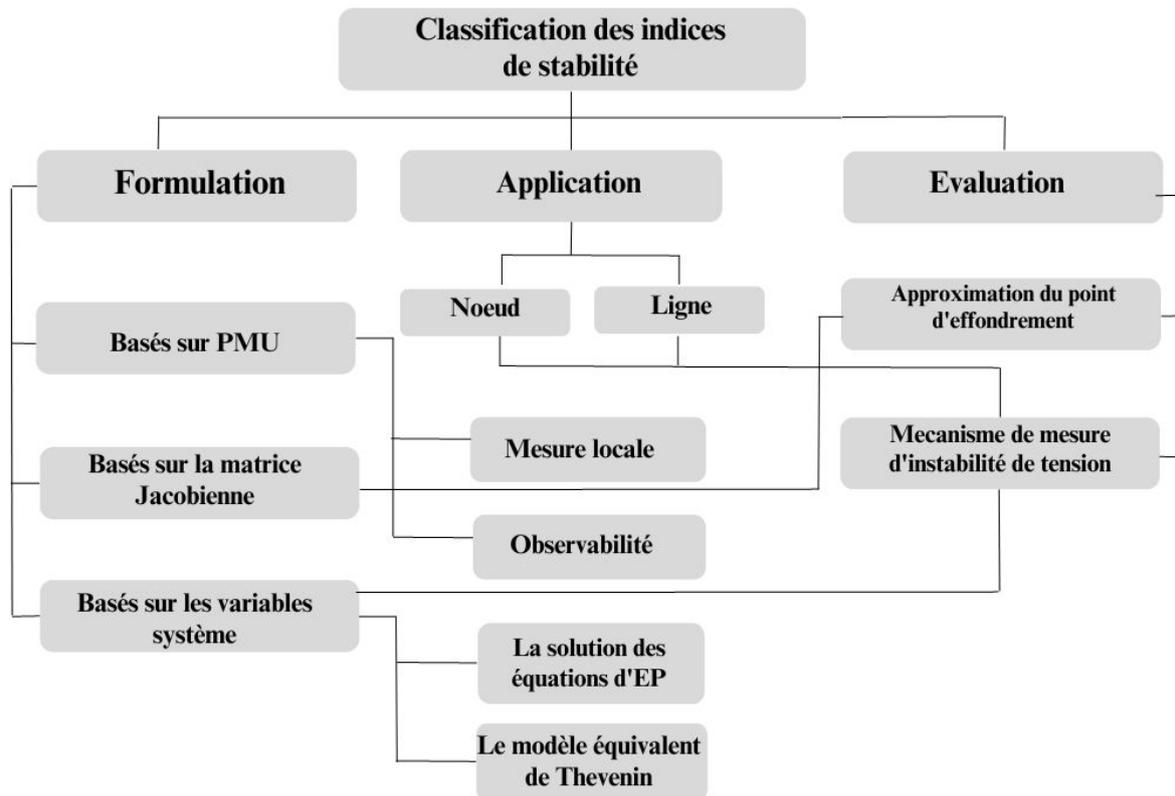


FIGURE 2.1 – Classification des indices de stabilité de tension et la relation entre eux.

La suite du chapitre est consacrée à la présentation de quelques indices basés sur les variables système pour évaluer la stabilité de tension des lignes et des noeuds.

2.3 Indices de stabilité basés sur l'écoulement de puissance

Le calcul d'écoulement de puissance est une étude en régime permanent du réseau électrique qui consiste à déterminer, en premier lieu, à chaque extrémité de ligne, l'amplitude et la phase de tension ainsi que les puissances active et réactive injectées. Connaissant les tensions (amplitude et phase) aux noeuds ainsi que les puissances injectées (active et réactive), nous pouvons calculer, en deuxième lieu, les courants et les puissances dans les lignes et ceux fournis par les sources.

Cette section présente l'implémentation de plusieurs types d'indices de stabilité de tension dérivés d'un même modèle de ligne. Ces indices sont formulés en se basant sur le concept de transmission de puissance sur une seule ligne, comme illustré dans la figure ci-dessous :

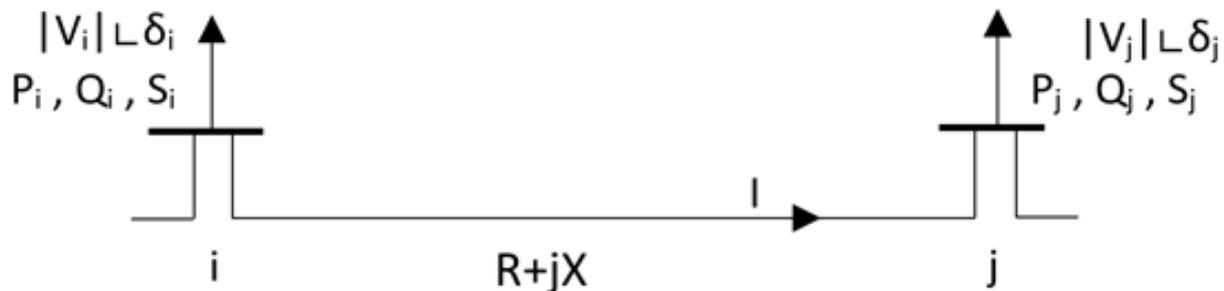


FIGURE 2.2 – Circuit équivalent d'une seule branche dans un réseau interconnecté.

avec :

V_i, V_j : tension sur les nœuds de production (associés aux centrales) et de consommation (associés aux charges).

P_i, Q_i : puissance active et réactive sur le nœud de production.

P_j, Q_j : puissance active et réactive sur le nœud de consommation.

S_i, S_j : puissance apparente sur les nœuds de productions et de consommations.

$Z=R+ jX$: impédance de ligne.

2.3.1 Facteur de stabilité de ligne (LQP)

L'indice LQP dérivé par A. Mohamed et al. [28] est obtenu en utilisant l'analyse de l'écoulement de puissance effectuée dans le modèle de système électrique équivalent à deux nœuds présenté dans la figure 2.2. En prenant le nœud i comme nœud de référence et en laissant Q_j être la puissance réactive entrant dans le nœud j depuis le nœud i, on obtient :

$$Q_j = Q_i - \frac{X}{V_i^2}(Q_i^2 + P_i^2) \quad (2.1)$$

Ce qui est équivalent a :

$$\frac{X}{V_i^2}Q_i^2 - Q_i + \frac{X}{V_i^2}P_i^2 + Q_j = 0 \quad (2.2)$$

Ainsi, en appliquant le critère de stabilité où le déterminant de Q_i^2 doit être supérieur ou égal à zéro, cela se forme :

$$\Delta = 1 - 4\frac{X}{V_i^2} \left(\frac{X}{V_i^2}P_i^2 + Q_j \right) \geq 0 \quad (2.3)$$

Finalement, la formule de la LQP est obtenue comme suit :

$$LQP = 4\frac{X}{V_i^2} \left(\frac{X}{V_i^2}P_i^2 + Q_j \right) \quad (2.4)$$

Pour maintenir une condition sécurisée, la valeur de l'indice LQP doit être maintenue inférieure à 1.

Le calcul du facteur de stabilité de ligne est appliqué à toutes les lignes du système afin de déterminer celle qui présente la valeur la plus élevée (c'est-à-dire la plus proche de 1,0). Cette ligne est considérée comme étant la plus susceptible de causer un effondrement de tension, et donc le facteur de stabilité de la ligne peut être utilisé comme indicateur statique d'effondrement de tension.

2.3.2 Indice L

Le calcul de l'indice L, introduit par Kessel et Glavtsh [29], repose sur une analyse analytique d'un système à deux nœuds, composé d'un nœud générateur et d'un nœud de charge reliés par une ligne de transmission (tel qu'illustré dans la figure (2.2)). L'indice L est dérivé à partir de cette analyse et permet de quantifier la distance entre l'état actuel du système et sa limite de stabilité, fournissant ainsi une mesure de la stabilité globale du système. En représentant le système par sa matrice d'admittance Y , le circuit équivalent d'une ligne est représenté comme par le modèle π :

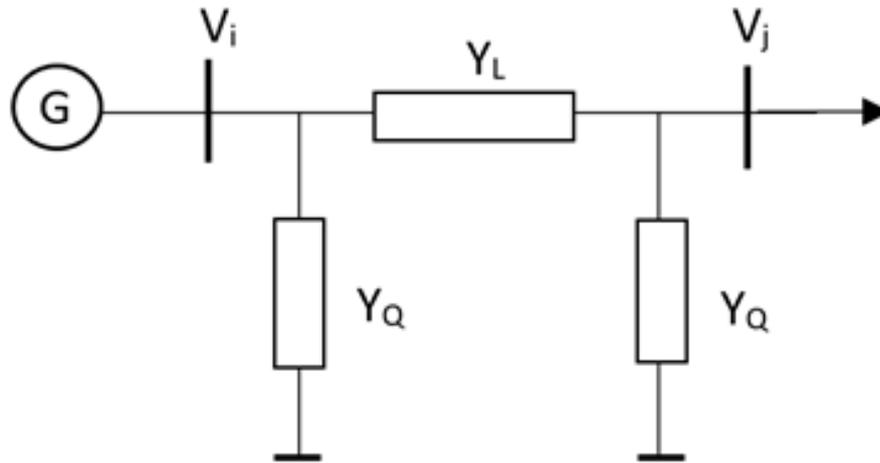


FIGURE 2.3 – Circuit équivalent d'une seule ligne de transmission

L'équation de son fonctionnement peut être décrite en termes de matrice d'admittance du système comme suit :

$$Y_{jj}V_j + Y_{ji}V_i = I = \frac{S_j^*}{V_j^*} \quad (2.5)$$

Où Y_{jj} et Y_{ji} sont les éléments diagonaux et non diagonaux de la matrice admittance $[Y]$. On peut exprimer l'équation (2.5) de la manière suivante :

$$V_j^2 + \frac{Y_{ji}}{Y_{jj}}V_iV_j^* = \frac{S_j^*}{Y_j} = A + jB \quad (2.6)$$

Dans ce cas, les variables A et B correspondent respectivement aux composantes réelle et imaginaire.

Posons :

$$V_0 = \frac{Y_{ji}}{Y_{jj}}V_i = \frac{-Y_L}{Y_L + Y_Q}V_i$$

avec : Y_L et Y_Q représentant respectivement l'admittance série et l'admittance shunt de la modélisation en π de la ligne (2.3).

Alors on obtient :

$$V_j^2 + V_0 V_j^* = \frac{S_j^*}{Y_j} \quad (2.7)$$

L'équation (2.7) peut se présenter sous la forme complexe suivante :

$$V_j^2 + |V_0||V_j|e^{j\alpha} = A + jB \quad (2.8)$$

avec : $\alpha = \delta_0 - \delta_j$.

Les deux composantes réelles et imaginaires sont respectivement :

$$A = V_j^2 + |V_0||V_j|\cos\alpha = f(V_j, \alpha) \quad (2.9)$$

$$B = |V_0||V_j|\sin\alpha = g(V_j, \alpha) \quad (2.10)$$

De ce système d'équation on peut tirer la matrice jacobienne :

$$J = \begin{pmatrix} 2V_j + V_0\cos\alpha & -V_0V_j\sin\alpha \\ V_0\sin\alpha & V_0V_2\cos\alpha \end{pmatrix} \quad (2.11)$$

Si la tension chute au niveau du noeud j, les équations (2.9) et (2.10) ne pourront pas être résolues, ce qui entraînera que la matrice J sera singulière (son déterminant sera nul).

$$Det(J) = 2V_j^2V_0\cos\alpha + V_jV_0^2 = 0 \quad (2.12)$$

En effectuant une division de l'expression (2.12) par $V_jV_0^2$ on obtient :

$$\frac{V_j\cos\alpha}{V_0} = Re\left\{\frac{\bar{V}_j}{V_0}\right\} = -\frac{1}{2} \quad (2.13)$$

Si on divise l'équation (2.6) par V_j^2 , On aura donc :

$$\left|1 + \frac{V_0}{V_j}\right| = \left|\frac{S_j^*}{Y_{jj}V_j^2}\right| \quad (2.14)$$

En utilisant l'équation (2.9) et (2.10), on peut montrer que :

$$\left|\frac{S_j^*}{Y_{jj}}\right| = \sqrt{A^2 + B^2} = \sqrt{(V_j^2 + |V_0||V_j|\cos\alpha)^2 + (|V_0||V_j|\sin\alpha)^2} = V_j^2 \quad (2.15)$$

D'où :

$$\left|1 + \frac{V_0}{V_j}\right| = 1 \quad (2.16)$$

Par conséquent, on peut définir l'indicateur L de la manière suivante :

$$L = \left|1 + \frac{V_0}{V_j}\right| = \left|\frac{S_j^*}{Y_{jj}V_j^2}\right| = 1 \quad (2.17)$$

L'indicateur (L) peut être employé pour aborder la problématique de la stabilité de la tension dans les systèmes électriques, ainsi que pour évaluer le niveau de risque d'un effondrement de la tension. Sa valeur varie entre 0 et 1 : si aucun chargement n'est présent au niveau du noeud, l'indicateur sera égal à **zéro**. Dans le cas où le système est totalement instable, l'indicateur prendra la valeur de **un**.

2.3.2.1 Généralisation à un Système de n noeuds :

Pour que l'indicateur L devienne utile, il doit être étendu au système multi-noeuds. Cet indicateur permet de mesurer quantitativement la distance entre l'état actuel et la limite de stabilité. Deux catégories de noeuds doivent être distinguées. La première est caractérisée par le comportement du noeud PQ qui représente un type de noeud consommateur, tandis que l'autre comprend les noeuds générateurs qui peuvent être représentés par des noeuds PV ou par un noeud de référence.

Le système de transmission en lui-même est linéaire et peut être représenté en termes d'une matrice hybride (H) :

$$\begin{pmatrix} V_L \\ I_G \end{pmatrix} = H \begin{pmatrix} I_L \\ V_G \end{pmatrix} = \begin{pmatrix} Z_{LL} & F_{LG} \\ K_{GL} & Y_{GG} \end{pmatrix} \begin{pmatrix} I_L \\ V_G \end{pmatrix} \quad (2.18)$$

Avec :

V_L, I_L : vecteurs des tensions et courants aux noeuds de charge.

V_G, I_G : vecteurs des tensions et courants aux noeuds générateurs.

$Z_{LL}, F_{LG}, K_{GL}, Y_{GG}$: sous-matrices de H.

La matrice H est générée à partir de la matrice Y par une inversion partielle (les tensions V_L des noeuds consommateurs dans le vecteur des inconnues sont échangées contre leurs courants I_L). Pour un noeud de charge i, on a :

$$V_i = \sum_{j=1}^n Z_{ij} I_j + \sum_{j=1}^m F_{ij} V_j \quad (2.19)$$

Où n représente le nombre de noeuds de charge et m représente le nombre de noeuds générateurs. En effectuant la multiplication de cette équation par V_i^* , on aura :

$$V_i V_i^* = \sum_{j=1}^n Z_{ij} I_j V_i^* + \sum_{j=1}^m F_{ij} V_j V_i^* \quad (2.20)$$

D'un autre côté, il est possible de modifier le terme de droite de l'équation de la manière suivante :

$$\sum_{j=1}^n Z_{ij} I_j V_i^* = \sum_{j=1}^n \frac{Z_{ij}}{Z_{ii}} Z_{ii} \frac{V_j^*}{V_j^*} I_j V_i^* = \sum_{j=1}^n \frac{Z_{ij}}{Z_{ii}} \frac{1}{Y_{ii}} \frac{S_j^*}{V_j^*} V_i^* = \frac{S_i'^*}{Y_{ii}} \quad (2.21)$$

Avec :

$$S_i'^* = \sum_{j=1}^n \frac{Z_{ij}}{Z_{ii}} \frac{S_j^*}{V_j^*} V_i^* \quad (2.22)$$

On peut poser :

$$V_{0i} = - \sum_{j=1}^m F_{ij} V_j \quad (2.23)$$

Alors, l'équation (2.20) peut être écrite sous la forme suivante :

$$V_i^2 + V_{0i} V_i^* = \frac{S_i'^*}{Y_{ii}} \quad (2.24)$$

L'équation (2.7) découverte pour le système simple à deux nœuds est exactement la même que la dernière équation.

Par conséquent, cela nous donne :

$$L_i = \left| 1 + \frac{V_{0i}}{V_i} \right| = \left| \frac{S_i'^*}{Y_{ii}V_i^2} \right| \quad (2.25)$$

D'après (2.22), on a :

$$\frac{S_i'^*}{Y_{ii}V_i^2} = \frac{V_i^*}{V_i^2} \sum_{j=1}^n Z_{ij}I_j = \frac{1}{V_i} \sum_{j=1}^n Z_{ij}I_j \quad (2.26)$$

En utilisant l'équation (2.25) pour extraire cette expression, on obtiendra :

$$L_i = \left| \frac{1}{V_i} \sum_{j=1}^n Z_{ij}I_j \right| = \left| 1 - \frac{\sum_{j=1}^m F_{ij}V_j}{V_i} \right| \quad (2.27)$$

Pour des situations stables, la condition $L_i < 1$ ne doit être violée pour aucun des nœuds i .

Ainsi, un indicateur global L décrivant la stabilité du système complet est donné par :

$$L = \max_{i \in n} \{L_i\} \quad (2.28)$$

On obtient :

$$L = \max_{i \in n} \left| 1 - \frac{\sum_{j=1}^m F_{ij}V_j}{V_i} \right| \quad (2.29)$$

Par conséquent, le résultat important de la théorie présentée pour garantir la stabilité est :

$$L < 1 \quad (2.30)$$

2.3.3 Indice de stabilité de tension (VSI)

Le VSI est contrôlé en se basant sur les paramètres variables du système, tels que la tension du nœud et les amplitudes du courant, pour évaluer la distance entre le point de fonctionnement actuel et le point d'effondrement de tension. L'indice est établi à partir des équations de l'écoulement de puissance [30]. Prenons par exemple un nœud de charge locale i dans un système électrique général. L'amplitude de la puissance apparente du nœud i peut être représentée comme suit :

$$S_i = V_i I_i \quad (2.31)$$

Lorsque la puissance apparente de charge S_i change, V_i et I_i sont tous deux modifiés pour satisfaire (2.31). Il est important de noter que même pour une impédance de charge donnée, V_i et I_i peuvent également varier lorsque le réseau modifie sa configuration. Dans ce cas, S_i change également en raison de la modification de V_i et I_i .

En utilisant le théorème de Taylor, il est possible d'écrire la relation entre les variations de V_i et I_i résultant d'une variation de S_i comme suit :

$$\Delta S_i = \frac{\partial S_i}{\partial I_i} \Delta I_i + \frac{\partial S_i}{\partial V_i} \Delta V_i + \sigma \quad (2.32)$$

avec σ un terme d'ordre supérieur négligeable. En utilisant l'équation (2.31), l'équation (2.32) peut être écrite sous la forme suivante :

$$\Delta S_i = V_i \Delta I_i + I_i \Delta V_i \quad (2.33)$$

En général, lorsque la charge d'un noeud est augmentée, le courant de charge augmente mais la tension de charge diminue. En d'autres termes, pour une valeur positive de ΔS_i , ΔI_i est positif et ΔV_i est négatif. Cependant, lorsque la charge d'un noeud approche de la valeur critique ou du point d'effondrement de tension, l'augmentation de la charge au noeud peut ne pas augmenter la puissance apparente de charge S_i en raison d'une réduction rapide de la tension par rapport à l'augmentation du courant, ce qui peut être vérifié par (2.31). Dans ce cas, ΔS_i de l'équation (2.33) approche de zéro. Cependant, dans la limite de stabilité de tension ou lorsque la charge réelle est inférieure à la valeur critique, l'augmentation de la charge fournira toujours une valeur positive de ΔS_i .

Ainsi, dans la limite de stabilité de tension, l'équation (2.33) peut être réécrit (après avoir divisé les deux côtés par $V_i \Delta I_i$) comme suit :

$$1 + \left(\frac{I_i}{V_i} \right) \left(\frac{\Delta V_i}{\Delta I_i} \right) \geq 0 \quad (2.34)$$

La valeur de l'expression du côté droit de l'équation (2.34) peut être considérée comme une mesure de la distance de l'effondrement de tension. À vide, $I_i = 0$ et donc le côté droit de l'équation (2.34) devient unité. À mesure que la charge augmente, cette équation diminue et finit par atteindre une valeur nulle au point d'effondrement de tension. Notez que ΔV_i et ΔI_i ont généralement un signe opposé et que V_i et I_i sont tous deux positifs.

D'un autre côté, la caractéristique présentée précédemment est fortement non linéaire, ce qui peut conduire à des résultats erronés lorsqu'elle est utilisée pour estimer la charge critique du système au point d'effondrement de tension. Toutefois, en élevant les deux côtés de l'équation (2.34) à une puissance $\alpha > 1$, il est possible d'obtenir une caractéristique plus ou moins linéaire.

Ainsi, l'indice de stabilité de tension (VSI) du noeud i peut être considéré comme suit :

$$VSI_i = \left[1 + \left(\frac{I_i}{V_i} \right) \left(\frac{\Delta V_i}{\Delta I_i} \right) \right]^\alpha \quad (2.35)$$

2.3.4 Indice de stabilité de la tension (SI)

Ranjan et Venkatesh [31] ont développé une technique d'analyse de la sensibilité de la tension, appelée indice de stabilité de la tension (SI), qui permet de calculer l'indice pour chaque nœud d'un réseau électrique et d'identifier le nœud le plus vulnérable à l'effondrement de la tension et prendre les mesures appropriées pour éviter l'effondrement de la tension. L'expression mathématique de cet indice est très simple et facile à utiliser.

L'indice de stabilité de la tension (SI) proposée compte tenu la figure (2.2), en peut écrire l'équation quadratique qui est principalement utilisée pour calculer des tensions de fin d'émission de la ligne à partir d'analyse d'écoulement de puissance .

le courant de branche I est donné par :

$$I = \frac{|V_i|\angle\delta_i - |V_j|\angle\delta_j}{Z} \quad (2.36)$$

Pour la puissance apparente à la fin de la branche.

$$S_j^* = P_j - jQ_j = V_j^* * I \quad (2.37)$$

En utilisant l'équation (2.36) et (2.37) on peut écrire :

$$P_j - jQ_j = |V_j|\angle\delta_j \left(\frac{|V_i|\angle\delta_i - |V_j|\angle\delta_j}{R + jX} \right) \quad (2.38)$$

En développant l'expression (2.38) on aura :

$$RP_j - jRQ_j + jXP_j + XQ_j = |V_iV_j|(\cos(\delta_i - \delta_j) + j \sin(\delta_i - \delta_j)) - |V_j|^2 \quad (2.39)$$

Qui, en séparant la partie réelle de la partie imaginaire, donne :

$$RP_j + XQ_j + |V_j|^2 = |V_iV_j| \cos(\delta_i - \delta_j) \quad (2.40)$$

$$XP_j + RQ_j = |V_iV_j| \sin(\delta_i - \delta_j)$$

L'élévation au carré de chacune des deux équations de (2.40) et leur sommation donne après réarrangement une équation quadratique en $|V_j|$

$$|V_j|^4 + 2|V_j|^2[(P_jR + Q_jX) - \frac{V_i^2}{2}] + (RP_j + XQ_j)^2 + (RP_j - XQ_j)^2 = 0 \quad (2.41)$$

La solution de l'équation quadratique conduit à :

$$|V_j|^2 = -A + (A^2 - |Z|^2(P_j^2 + Q_j^2))^{\frac{1}{2}} = B - A \quad (2.42)$$

Avec

$$A = RP_j + XQ_j - 0.5|V_i|^2 \quad (2.43)$$

$$B = (A^2 - |Z|^2(P_j^2 + Q_j^2))^{\frac{1}{2}} \quad (2.44)$$

Nous obtenons enfin

$$|V_j| = (B - A)^{\frac{1}{2}} \quad (2.45)$$

A partir de l'équation (2.45) on constate que la tension $|V_j|^2$ n'admet de solution que si :

$$B - A \geq 0 \quad (2.46)$$

$$(B - A)^2 \geq 0 \quad (2.47)$$

Où :

$$(B^2 - A^2) + 2A^2 - 2BA \geq 0 \quad (2.48)$$

$$(B^2 - A^2) \geq 2A(B - A) \quad (2.49)$$

Le côté gauche de l'équation (2.49) peut être écrit en fonction de l'impédance de la ligne et des puissance actives et réactives transitant par le nœud j comme il suit :

$$B^2 - A^2 = A^2 - |Z|^2(P_j^2 + Q_j^2) - A^2 = -|Z|^2(P_j^2 + Q_j^2) \quad (2.50)$$

La substitution du premier membre de (2.49) par son expression (2.51) donne :

$$|Z|^2(P_j^2 + Q_j^2) \leq -2A(B - A) \quad (2.51)$$

comme $|Z|^2(P_j^2 + Q_j^2)$ ne peut pas être négatif et $(B - A)$ est supérieure à zéro alors, pour que la tension puisse exister, est supérieur à zéro. Alors, pour que l'expression (2.51) soit vérifiée, on doit nécessairement avoir :

$$A < 0 \quad (2.52)$$

Ou en remplaçant A par son expression (2.43)

$$RP_j + XQ_j - 0.5|V_i|^2 < 0 \quad (2.53)$$

$$0.5|V_i|^2 - RP_j - XQ_j > 0 \quad (2.54)$$

L'indice de stabilité du nœud j est alors défini comme étant égale à :

$$SI = 0.5|V_i|^2 - RP_j - XQ_j \quad (2.55)$$

Dans cette étude, le critère de stabilité simple mentionné dans l'équation (2.55) est utilisé pour trouver l'indice de stabilité de chaque nœud de réception de ligne. Après l'étude de l'écoulement de puissance, les tensions de tous les nœuds et les courants de branche sont connus. Par conséquent, les puissances active et réactive à l'extrémité de réception de chaque ligne peuvent être facilement calculées, et ainsi, en utilisant l'équation (2.55), l'indice de stabilité de tension de chaque nœud peut être facilement calculé. Le nœud pour lequel la valeur de l'indice de stabilité est minimale est le plus sensible à l'effondrement de la tension. Pour un fonctionnement sûr et stable il faut que $SI > 0$ pour tous les jeux de barres

2.3.5 Indice de capacité de charge (Li)

Le Li (Loadability Index), ou l'indice de capacité de charge. Il est défini comme la charge maximale admissible sur une ligne de transmission sans provoquer de chute de tension excessive ou d'effondrement de tension, Cet indice est développé par Jasmon et autres [32]. Partant d'un schéma identifié à celui de la figure (2.2) et que nous reproduisons ici, on peut tirer les équations suivantes :

Pour le courant circulant dans la branche.

$$|I|^2 = \frac{P_i^2 + Q_i^2}{|V_i|^2} \quad (2.56)$$

$$|I|^2 = \frac{P_j^2 + Q_j^2}{|V_j|^2} \quad (2.57)$$

Où P_i et Q_i sont les puissances active et réactive au début de la branche , et sont données par la somme des puissances active et réactive à la fin de la branche de transmission et des pertes de puissance active et réactive qui se produisent dans la branche elle-même.

$$\begin{cases} P_i = P_j + P_{loss} \\ Q_i = Q_j + Q_{loss} \end{cases} \quad (2.58)$$

Les pertes de puissance active et réactive s'obtiennent par :

$$\begin{cases} P_{loss} = \left(\frac{P_j^2 + Q_j^2}{|V_j|^2} \right) R \\ Q_{loss} = \left(\frac{P_j^2 + Q_j^2}{|V_j|^2} \right) X \end{cases} \quad (2.59)$$

En substituant l'équation (2.58) dans l'équation (2.56), on peut obtenir une nouvelle équation exprimant le courant de branche.

$$|I|^2 = \frac{\left[P_j + \left(\frac{P_j^2 + Q_j^2}{|V_j|^2} \right) R \right]^2 + \left[Q_j + \left(\frac{P_j^2 + Q_j^2}{|V_j|^2} \right) X \right]^2}{|V_i|^2} \quad (2.60)$$

En prenant (2.57)=(2.60), et après développement et simplification on obtient l'équation quadratique en $|V_j|^2$:

$$|V_j|^4 + 2|V_j|^2(P_j R + Q_j X) - |V_i V_j|^2 + (P_j^2 + Q_j^2)(R^2 + X^2) = 0 \quad (2.61)$$

Le discriminant de l'équation (2.61) est alors égal à :

$$\Delta = 8P_j Q_j R X - 4|V_i|^2(P_j R + Q_j X) + |V_i|^4 - 4(P_j^2 X^2 + Q_j^2 R^2) \quad (2.62)$$

L'équation quadratique en $|V_j|^2$, elle aura des racines réelles si et seulement si le discriminant de l'équation (2.61)est supérieur ou égal à zéro, C'est-à-dire :

$$8P_j Q_j R X - 4|V_i|^2(P_j R + Q_j X) + |V_i|^4 - 4(P_j^2 X^2 + Q_j^2 R^2) \geq 0 \quad (2.63)$$

après simplification et réarrangement on obtient :

$$\frac{4[|V_i|^2(P_j R + Q_j X) + (P_j X + Q_j R)]}{|V_i|^4} \leq 1 \quad (2.64)$$

Le premier membre de l'inégalité (2.64) est alors employé comme indice de stabilité de la tension au nœud j , et on le note alors :

$$Li = \frac{4[|V_i|^2(P_j R + Q_j X) + (P_j X + Q_j R)]}{|V_i|^4} \quad (2.65)$$

Les lignes critiques seront identifiés lorsque leurs indices de stabilité (Li) approchent de 1. Cela permettra ensuite de prendre les mesures appropriées pour maintenir la stabilité du système et ainsi éviter toute incidence d'effondrement de tension.

2.3.6 Indice de stabilité de tension rapide (FVSI)

Le FVSI (Fast Voltage Stability Index), ou indice de stabilité de tension rapide proposé par Ismail Musirin dans [33], est en train d'être simplifié à partir d'une ligne de l'équation quadratique de tension au niveau de la fin de la ligne de transmission d'un système à deux nœuds figure (2.2). Cette simplification utilise le même concept d'écoulement de puissance pour déterminer la puissance maximale transportée. Le (FVSI) est important pour assurer une tension stable dans les systèmes électriques et peut être utilisé pour évaluer et améliorer les performances du système au fil du temps.

Cependant, l'équation pour le courant à travers une ligne reliant les nœuds i et j est obtenue à partir de l'équation suivante :

$$I = \frac{|V_i| \angle \delta_i - |V_j| \angle \delta_j}{Z} \quad (2.66)$$

Pour la puissance apparente à la fin de la branche.

$$S_j^* = P_j - jQ_j = V_j^* * I \quad (2.67)$$

Donc le courant en fonction de la puissance apparente et du courant de branche.

$$I = \left(\frac{S_j}{V_j} \right)^* = \frac{P_j - jQ_j}{|V_j| \angle \delta} \quad (2.68)$$

En prenant (2.66) = (2.68), et on considère $\delta_i = 0$ (référence des phases) et on prend $\delta = \delta_j$, on peut tirer les équations suivantes :

$$P_j - jQ_j = \frac{-|V_j|^2 + |V_i V_j| \angle \delta}{R + jX} \quad (2.69)$$

Le développement de (2.69) conduit à trouver l'équation quadratique pour le nœud j :

$$|V_j|^2 - (|V_i V_j| \cos \delta - RP_j - XQ_j) + j(|V_i V_j| \sin \delta - RQ_j + XP_j) = 0 \quad (2.70)$$

Cette dernière expression est égale à zéro si les parties réelles et imaginaires sont égales à zéro c'est à dire :

$$|V_j|^2 - (|V_i V_j| \cos \delta - RP_j - XQ_j) = 0 \quad (2.71)$$

et

$$(|V_i V_j| \sin \delta - RQ_j + XP_j) = 0 \quad (2.72)$$

En divisant l'équation (2.72) par X , nous pouvons obtenir une expression de P_j , ensuite remplacer cette expression dans l'équation (2.71) pour obtenir une nouvelle expression pour la puissance réactive .

$$|V_j|^2 - |V_i V_j| \left(\frac{R}{X} \sin \delta + \cos \delta \right) + Q_j \left(\frac{R^2}{X} + X \right) = 0 \quad (2.73)$$

Le discriminant de (2.73) est alors égale à :

$$\Delta = \left[|V_i| \left(\frac{R}{X} \sin \delta + \cos \delta \right) \right]^2 - 4 \left[Q_j \left(\frac{R^2}{X} + X \right) \right] \quad (2.74)$$

L'équation quadratique de degré 2 en $|V_j|$, elle aura des racines réelles si et seulement si le discriminant de l'équation (2.73) est supérieur ou égal à zéro, C'est-à-dire :

$$\frac{4|Z|^2 Q_j X}{|V_i|^2 (R \sin \delta + X \cos \delta)^2} \leq 1 \quad (2.75)$$

Puisque la différence d'angle est normalement petite et peut être négligée $\delta \approx 0$, nous avons alors $R \sin \delta \approx 0$ et $X \cos \delta \approx 0$, l'expression précédente nous mène à la forme suivante :

$$\frac{4|Z|^2 Q_j}{|V_i|^2 X} \leq 1 \quad (2.76)$$

Enfin, l'indice de stabilité de ligne FVSI est formulé comme suit :

$$FVSI = \frac{4|Z|^2 Q_j}{|V_i|^2 X} \quad (2.77)$$

Cette équation est utilisée pour évaluer la stabilité de la tension dans les systèmes électrique, en particulier dans les situations où la charge électrique varie rapidement. La ligne dont l'indice se rapproche le plus de 1 est considérée comme la plus critique du réseau électrique et peut entraîner l'instabilité de l'ensemble du système. Le (FVSI) calculé peut également être utilisé pour déterminer le nœud le plus faible du système. La détermination du nœud le plus faible est basée sur la charge maximale autorisée sur un nœud de charge. Le nœud le plus critique du système correspond au la plus petite charge maximale permise.

2.4 Etude de cas

L'analyse des indices de stabilité de tension a été effectuée sur le réseau standard IEEE 14 nœuds avec simulation à l'aide de MATLAB. Les résultats de la simulation ont été étudiés afin de documenter l'analyse théorique et indiquent la performance du code de script programmé. Le système étudié est composé de 04 nœuds de générateur (PV), 09 nœuds de charge (PQ), 01 nœud slack bus et 20 lignes de transmission.

Les indices (FVSI) et (LQP) ont été calculés en faisant varier la puissance réactive de la charge de tous les nœuds de charge du système étudié. Une analyse a été menée pour identifier les lignes critiques pour chaque nœud de charge individuellement. L'algorithme de calcul des indices de stabilité de tension a été utilisé pour mener à bien cette analyse.

Les résultats, présentés dans les graphiques ci-dessous, montrent le classement des contingences des lignes uniquement pour les indices de stabilité (FVSI) et (LQP).

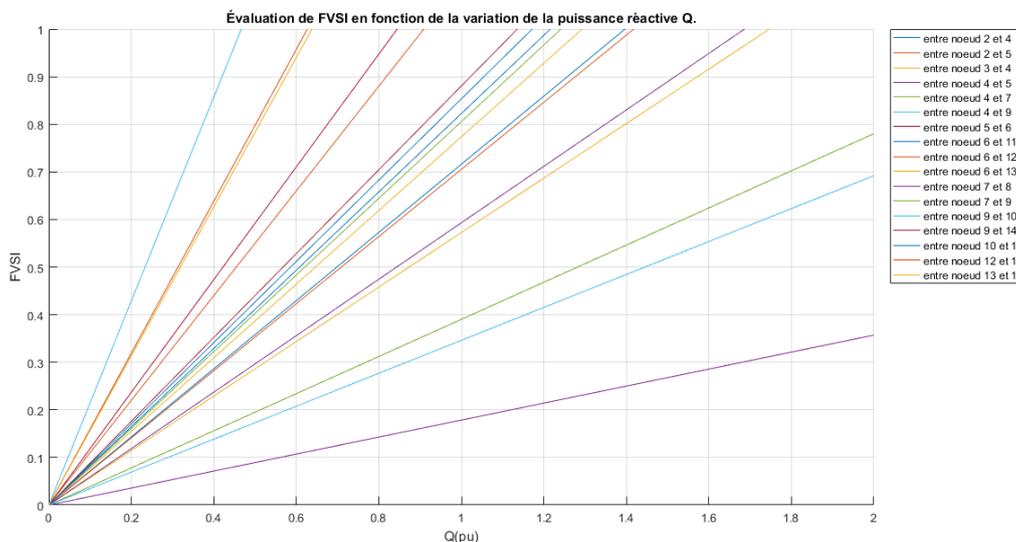


FIGURE 2.4 – L'évaluation des indices FVSI en fonction de la variation de la puissance réactive Q .

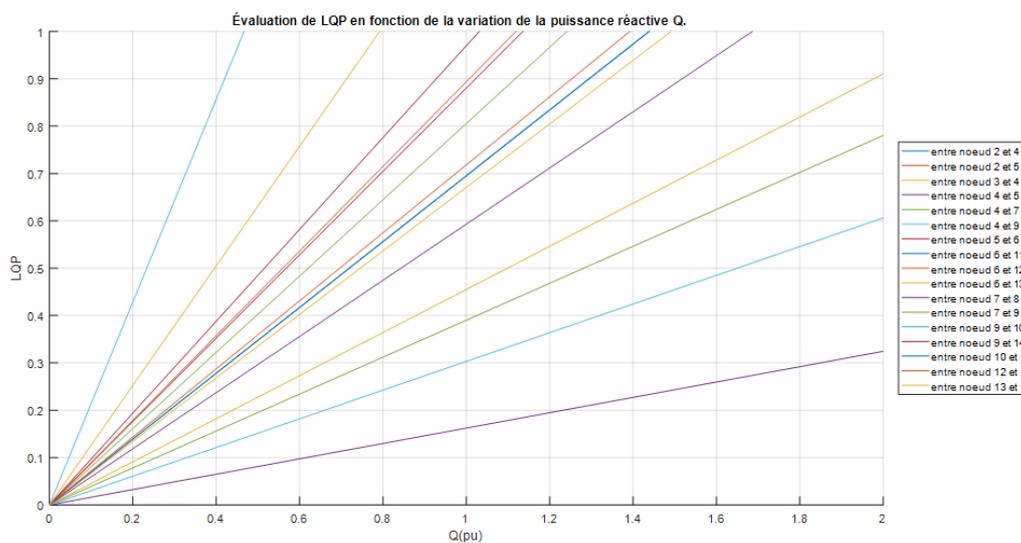


FIGURE 2.5 – L'évaluation des indices LQP en fonction de la variation de la puissance réactive Q .

La ligne qui fournit la plus grande valeur d'indice par rapport à l'augmentation de la charge est considérée comme la ligne la plus critique. Les figures (2.4) et (2.5) mettent en évidence que la ligne entre le nœud 4 et le nœud 9 présente les indices (FVSI) et (LQP) les plus élevés, ce qui indique qu'il s'agit de la ligne la plus vulnérable du système en termes de risque de défaillance. Les lignes voisines indiquent également des valeurs (FVSI) et (LQP) élevées.

Les lignes 6-13 et 3-4 ont été choisies au hasard pour comparer certains indices de stabilité de ligne.

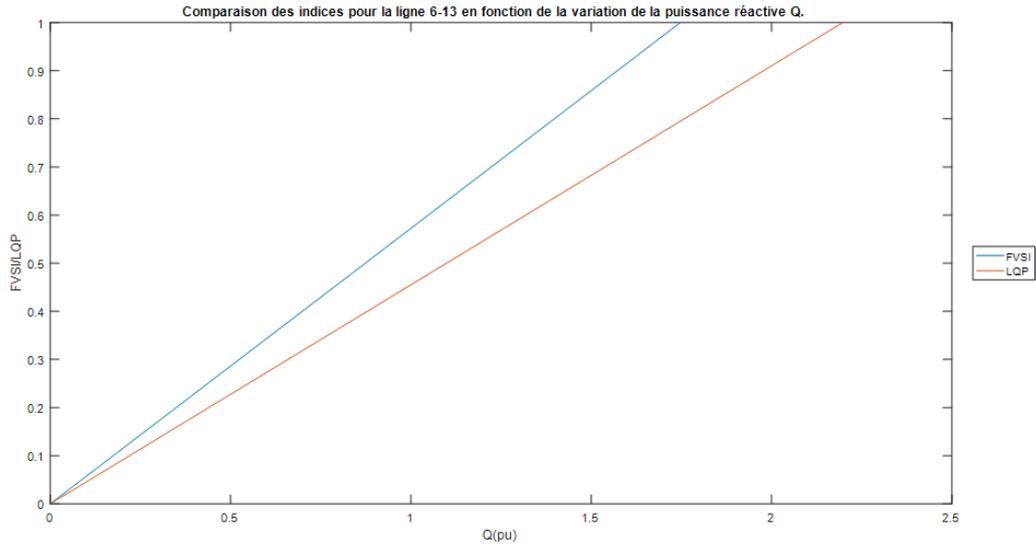


FIGURE 2.6 – Comparaison des indices pour la ligne 6-13 en fonction de la variation de la puissance réactive Q .

Les résultats tirés de l'analyse de la figure (2.6) indiquent que les indices (FVSI) et (LQP) donnent des résultats proches, avec une précision propre à chaque méthode. En d'autres termes, les données obtenues à partir de l'indice (FVSI) confirment les résultats obtenus à partir de l'indice (LQP), et vice versa. Cette constatation renforce la fiabilité des deux indices. En outre, cette corroboration mutuelle renforce également la validité des méthodes de mesure utilisées pour calculer les indices.

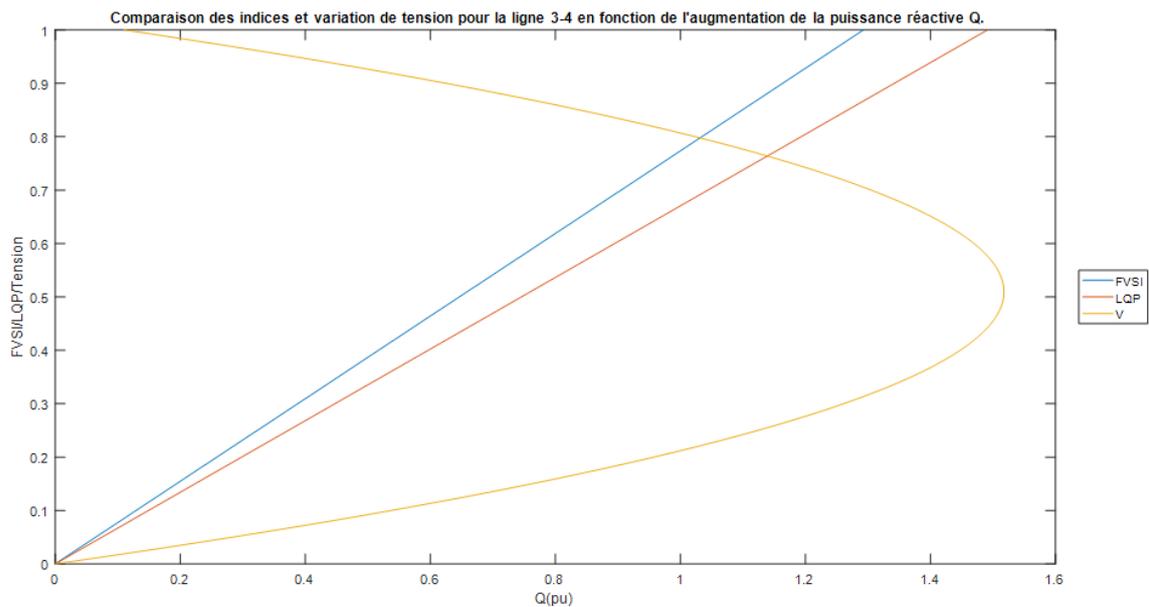


FIGURE 2.7 – Comparaison des indices et variation de tension pour la ligne 3-4 en fonction de l'augmentation de la puissance réactive Q .

La variation du (FVSI) et (LQP) pour la ligne critique entre le nœud 3 et le nœud 4 par l'augmentation de la puissance réactive au niveau du nœud 4 est illustrée dans la Figure (2.7). En outre, la figure présente la tension du nœud 4, et on peut constater que lorsque le (LQP) atteint l'unité, la tension du nœud diminue soudainement. Ce point est connu sous le nom de "point d'effondrement".

2.5 Conclusion

Les indices de stabilité de tension sont des outils essentiels pour les opérateurs du réseau électrique afin de surveiller et améliorer la stabilité de la tension. Ils permettent d'évaluer ou de détecter le point d'effondrement de la tension d'un système et localiser les nœuds vulnérables nécessitant une injection de puissance réactive pour prévenir tout effondrement de la tension en améliorant son profil. Plusieurs indices de stabilité de tension ont été développés pour atteindre cet objectif. Dans ce chapitre, nous avons présenté six indices de stabilité de tension dérivés du concept de ligne de transmission à deux nœuds. Ensuite, nous avons procédé à une comparaison et à une analyse de certains de ces indices à l'aide de l'environnement MATLAB. Les indices (FVSI) et (LQP) que nous avons développés ont une structure simple et peuvent être facilement calculés à partir des paramètres de la ligne et de la solution de l'écoulement de charge. En se basant sur les analyses effectuées, nous pouvons conclure que (FVSI) et (LQP) convergent vers la solution selon des approches différentes pour ce système pendant les changements de la charge.

Chapitre 3

Réseaux de neurones artificiels

3.1 Introduction

Dans ce chapitre, nous présentons les concepts fondamentaux des réseaux de neurones, tels que les fonctions d'activation, les couches, les architectures et les algorithmes d'apprentissage. Nous examinons également les différents types de réseaux de neurones, tels que les réseaux de neurones feedforward, les réseaux de neurones récurrents et les réseaux de neurones convolutifs. Ensuite, nous nous concentrons sur l'une des techniques les plus utilisées en apprentissage supervisé, la méthode de rétropropagation, qui permet d'ajuster les poids des connexions entre les neurones. Nous décrivons en détail notre approche pour entraîner et évaluer le réseau de neurones à l'aide de la méthode de rétropropagation.

3.2 Définition

Les Réseaux de Neurones Artificiels sont des modèles statistiques adaptatifs qui tirent leur inspiration du fonctionnement du cerveau humain. La structure de base d'un Réseau de Neurones Artificiels est composée d'un ensemble d'unités simples appelées neurones, qui sont interconnectées à l'aide d'un ensemble de connexions pondérées. Chaque unité correspond à une caractéristique d'une forme à analyser. L'apprentissage consiste à ajuster les valeurs des connexions entre les neurones pour entraîner le réseau à effectuer une tâche spécifique.

Les neurones biologiques sont complexes et leurs différentes fonctions de neurones, y compris celles de la mémoire, sont stockées au niveau des connexions (synapses) entre les neurones. Les architectures de Réseaux de Neurones Artificiels sont inspirées par ces théories du fonctionnement des neurones biologiques. Les spécialistes des neurones biologiques ont commencé à comprendre certains de leurs mécanismes internes, mais les mécanismes de stockage de la mémoire ne sont pas encore bien compris [34].

3.3 Historique

Les réseaux de neurones artificiels (RNA) ont une longue histoire qui remonte aux années 1940, lorsque les premiers modèles de neurones artificiels ont été proposés. Les travaux du neurophysiologiste Warren McCulloch et du logicien Walter Pitts en 1943, de Hebb en 1949, et de Rosenblatt en 1958 ont introduit les premiers modèles de réseaux neuronaux en tant que "machines de calcul", le modèle de base d'auto-organisation du réseau, et le modèle d'apprentissage supervisé, respectivement.

Les réseaux de neurones artificiels sont une tentative de modélisation mathématique du cerveau humain et sont conçus pour reproduire certaines de ses caractéristiques telles que la capacité d'apprentissage, la capacité de mémorisation de l'information, et la capacité de traitement des informations incomplètes.

En 1948, plusieurs disciplines ont uni leurs forces pour former le domaine actuel de la recherche sur les réseaux neuronaux. Ce domaine est maintenant axé sur les idées de calcul parallèle et distribué, avec une attention particulière portée à l'apprentissage dans les réseaux neuronaux. Les notions d'information et de mécanique statistique défendues par Wiener ont également ressurgi comme un courant fort dans l'étude des réseaux neuronaux

aujourd'hui. En 1957, Frank Rosenblatt a conçu le Perceptron, le premier modèle artificiel qui a connu un succès significatif. Ce réseau de neurones s'est inspiré du système visuel et comprend deux couches de neurones : une couche de perception et une couche de décision. Le Perceptron a été le premier système artificiel capable d'apprendre par expérience et de corriger les erreurs de son instructeur.

Bien que les réseaux de neurones aient une histoire relativement courte, ce n'est qu'à partir des années 1970, grâce aux progrès de l'informatique, que des applications intéressantes ont vu le jour. L'algorithme de rétropropagation a permis de relancer la recherche sur les réseaux de neurones artificiels en rendant possible l'entraînement de réseaux multicouches. Cependant, à cette époque, les réseaux de neurones artificiels étaient encore limités en termes de taille et de complexité.

En 1980, les RNA ont continué de progresser avec l'introduction de nouveaux algorithmes d'apprentissage, tels que l'apprentissage par renforcement et l'apprentissage non supervisé.

Depuis les années 2000, l'intérêt pour les RNA a connu une nouvelle croissance grâce à l'introduction de l'apprentissage en profondeur et des réseaux de neurones convolutifs profonds. Ces avancées ont permis d'obtenir des améliorations significatives dans de nombreux domaines tels que la vision par ordinateur, la reconnaissance de la parole, et la traduction automatique.

Actuellement, les réseaux de neurones artificiels sont utilisés dans une grande variété d'applications, comme la reconnaissance d'images et de voix, la prédiction de séries chronologiques, la recommandation de contenu et l'analyse de données [35].

3.4 Neurone biologique et artificiel

Le concept de réseau de neurones artificiels tire son inspiration du traitement de l'information par les neurones biologiques, et il est utilisé pour mettre en œuvre des simulations informatiques massivement parallèles impliquant des éléments de traitement interconnectés dans une architecture en réseau. Dans le cerveau humain, l'apprentissage se fait à travers un réseau de neurones interconnectés par l'axone, les synapses et les dendrites. Bien que le cerveau humain et l'ordinateur soient tous deux dédiés au traitement de l'information, leur structure diffère.

Le neurone est une cellule composée d'un corps cellulaire et d'un noyau, avec des dendrites qui se ramifient à partir du corps cellulaire pour acheminer l'information de l'extérieur vers le soma, le centre du neurone [36]. L'information est ensuite transmise le long de l'axone, qui est unique, pour être reliée à d'autres neurones. La transmission entre deux neurones se fait par l'intermédiaire de synapses, où un espace intercellulaire sépare l'axone du neurone afférent des dendrites du neurone efférent.

Les réseaux de neurones biologiques sont capables d'accomplir diverses tâches, comme la reconnaissance de formes, le traitement du signal, l'apprentissage, la mémorisation et la généralisation. Malgré les avancées en algorithmique et en intelligence

artificielle, ces applications restent cependant limitées par les capacités actuelles. C'est pourquoi les réseaux de neurones artificiels ont été développés pour tenter de modéliser mathématiquement la structure et le comportement du cerveau humain. Un neurone artificiel peut être considéré comme une fonction mathématique non linéaire, paramétrée et bornée, inspirée du modèle de neurones biologiques.

Les premiers travaux remontent à 1943 et ont été réalisés par McCulloch et Pitts [37], qui ont modélisé cette cellule nerveuse comme une simple porte logique avec des sorties binaires. De multiples signaux arrivent aux dendrites, sont ensuite intégrés dans le corps cellulaire, et si la somme des signaux accumulés dépasse un certain seuil, un signal de sortie est généré, qui sera transmis par l'axone.

Soit un vecteur \vec{x} de dimension m , de coordonnées x_1, x_2, \dots, x_m et \hat{y} un scalaire. Le vecteur \vec{x} constitue l'entrée du neurone artificiel et le scalaire \hat{y} la sortie.

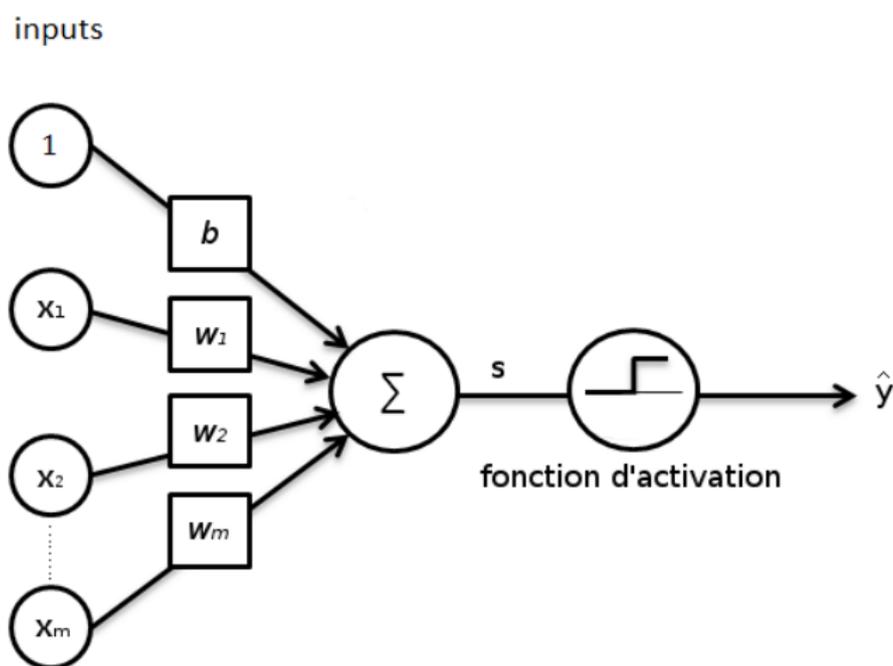


FIGURE 3.1 – Modèle de McCulloch-Pitts

Un neurone artificiel est constitué de deux parties :

- Une partie linéaire telle que $s = \vec{w}^T \cdot \vec{x} + b$ avec \vec{w} est le vecteur de poids synaptiques et b le biais ;
- Une partie « non linéaire » où l'on applique une fonction d'activation telle que $\hat{y} = f(s)$. Historiquement cette fonction d'activation était la fonction «échelle» ($H(x) = 0$ si $x \leq 0$ et $H(x) = 1$ si $x > 0$).

Ce modèle a été étendu de plusieurs manières, dont une généralisation évidente est l'utilisation d'autres fonctions d'activation que la fonction à seuil, comme illustré dans la figure 3.2. Le choix de la fonction d'activation dépend des besoins de la simulation. La fonction sigmoïde est largement utilisée dans les réseaux de neurones artificiels, car elle possède une propriété asymptotique distinctive [38].

nom	valeur	représentation
seuil	$F(x) = 0$ si $x < 0$ $F(x) = 1$ si $x > 0$	
linéaire	$F(x) = x$	
linéaire saturée	$F(x) = 0$ si $x < 0$ $F(x) = x$ si $0 \leq x \leq 1$ $F(x) = 1$ si $x > 1$	
sigmoïde	$F(x) = (1 + e^{-x})^{-1}$	
tangente hyperbolique	$F(x) = (e^x - e^{-x}) \cdot (e^x + e^{-x})^{-1}$	

FIGURE 3.2 – Différents types de fonctions d'activation de RNA

La comparaison entre un neurone biologique et un neurone artificiel est illustrée dans la figure ci-dessous. Les poids de connexion représentent les connexions synaptiques, la fonction de transfert correspond au corps cellulaire qui traite les signaux d'entrée et génère une réponse, et l'élément de sortie du neurone artificiel agit comme l'axone, permettant la transmission de la réponse à l'unité suivante du réseau. Cette analogie facilite la compréhension du fonctionnement d'un réseau de neurones artificiels en le comparant aux processus biologiques du cerveau [39].

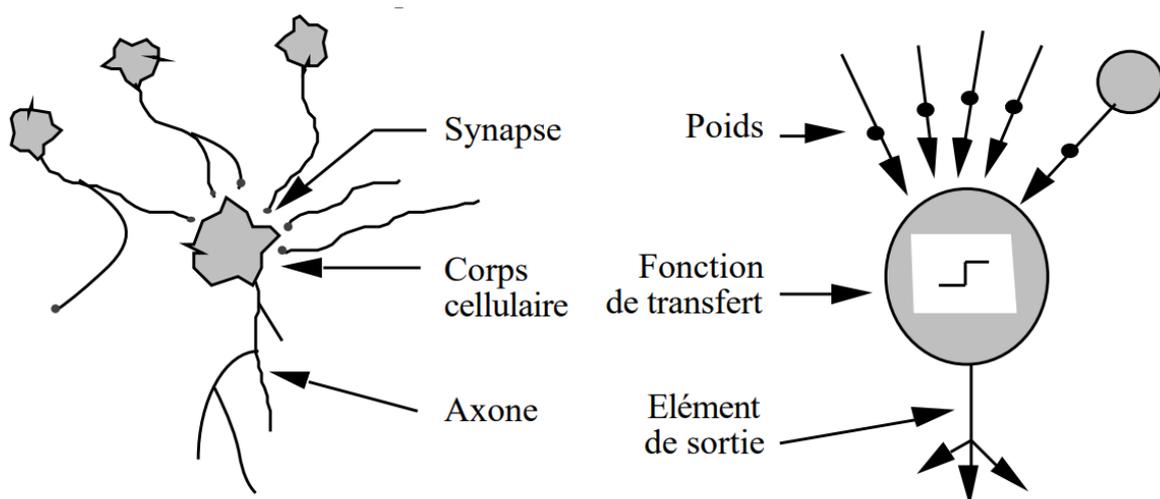


FIGURE 3.3 – Mise en correspondance neurone biologique / neurone artificiel [39].

3.5 Structure du RNA

Un réseau de neurones artificiels (RNA) est un modèle mathématique qui simule le fonctionnement du cerveau humain en utilisant des milliers, voire des millions de neurones interconnectés et organisés en couches. La dynamique globale de ces neurones est déterminée par les connexions établies entre les différents éléments de traitement et les paramètres connexes de la structure du réseau de neurones. Chaque connexion reliant les neurones de couches consécutives est pondérée par un poids w_{ij} représentant la force de la connexion entre le nœud i de la couche actuelle et le nœud j de la couche suivante. Ces poids sont initialement attribués de manière aléatoire et ajustés lors de l'apprentissage pour améliorer la performance du réseau. La structure d'un RNA se compose d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie [40].

Les couches d'entrée sont responsables de la réception des données d'entrée, chaque neurone dans cette couche correspondant à une variable d'entrée différente. Les neurones de cette couche n'effectuent pas d'opérations mathématiques, mais transmettent simplement les informations aux neurones de la couche suivante.

Les couches cachées sont responsables de la transformation des données d'entrée en sorties, les neurones qu'elles contiennent captent les relations complexes entre les entrées et les sorties.

Le nombre de couches cachées dans un RNA est déterminé par la complexité du problème à résoudre, une seule couche pouvant suffire pour résoudre un problème théorique, tandis que plusieurs couches peuvent faciliter la résolution d'un problème complexe.

Dans un RNA, les données sont reçues par les neurones de la couche d'entrée, puis transformées par les connexions pondérées établies entre la couche d'entrée et la première couche cachée. Les données de chaque couche sont traitées mathématiquement avant d'être transmises à la couche suivante. Les couches de sortie sont responsables de la production des résultats finaux du réseau, tels qu'une classification ou une prédiction.

Chaque couche du réseau de neurones est également caractérisée par un terme de biais, qui est un paramètre supplémentaire ajouté à chaque neurone du réseau. Les biais sont utilisés pour régler le seuil d'activation des neurones et ajuster la sortie en fonction des entrées. Ils jouent un rôle clé dans l'apprentissage et l'optimisation des réseaux de neurones, permettant de compenser les valeurs de poids excessivement grandes ou petites.

La figure suivante illustre une structure typique d'un RNA comportant deux couches cachées.

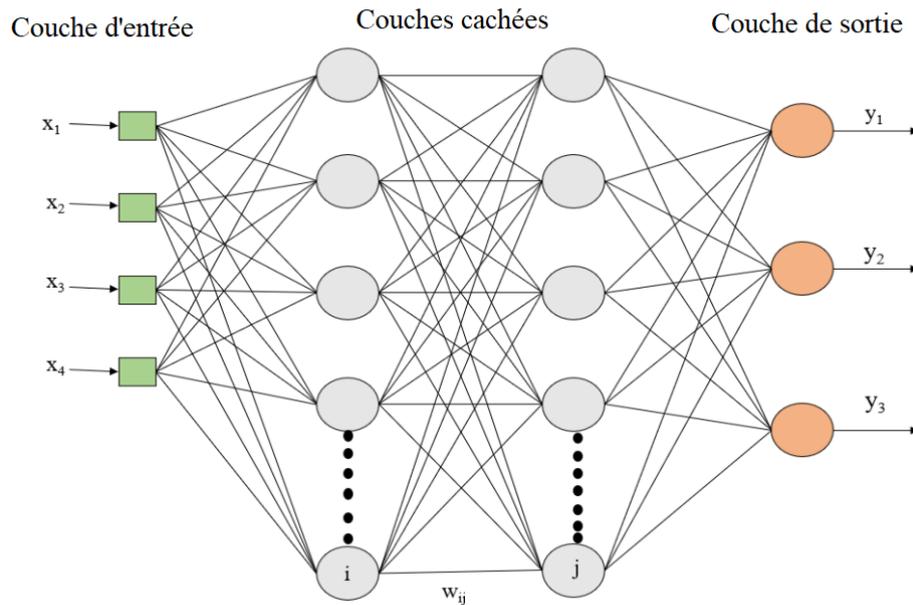


FIGURE 3.4 – Structure générale d'un RNA avec deux couches cachées. [40]

3.5.1 Sélection des couches cachées

Si les données sont linéairement séparables, alors aucune couche cachée n'est nécessaire. Si les données sont moins complexes et ont moins de dimensions ou de caractéristiques, un réseau de neurones avec 1 à 2 couches cachées conviendrait. Si les données ont un grand nombre de dimensions ou de caractéristiques, l'utilisation de 3 à 5 couches cachées peut permettre d'obtenir une solution optimale. Il convient de noter que l'augmentation du nombre de couches cachées augmenterait également la complexité du modèle, et le choix de couches cachées telles que 8, 9 ou à deux chiffres peut parfois conduire à un surapprentissage.

3.5.2 Sélection des nœuds dans les couches cachées

Le choix du nombre de neurones dans les couches cachées d'un réseau de neurones revêt une importance particulière pour garantir des performances optimales. En général, le nombre de neurones dans les couches cachées doit être choisi en fonction de la taille de la couche d'entrée et de la couche de sortie. Une des méthodes couramment utilisées consiste à suivre la règle de la pyramide géométrique, qui stipule que le nombre de neurones pour chaque couche cachée forme une pyramide, avec un nombre décroissant de neurones de la couche d'entrée à la couche de sortie.

Selon les travaux de Master [41], il n'y a pas de raisons théoriques ou pratiques d'utiliser plus de deux couches cachées. Pour un réseau de neurones à une seule couche cachée, le nombre de neurones est :

$$N_h = \sqrt{n \cdot m}$$

Où n est le nombre de caractéristiques d'entrée et m est le nombre de sorties.

Cependant, il est important de noter qu'il n'existe pas de règle absolue pour le choix du nombre de neurones dans les couches cachées, car cela dépend fortement du cas d'utilisation et des données d'entrée. Le choix doit être guidé par une évaluation empirique pour assurer une bonne généralisation du modèle. En outre, l'utilisation d'un nombre excessif de neurones cachés peut considérablement augmenter le temps de formation du réseau, il est donc préférable d'utiliser le nombre minimum de neurones nécessaires pour obtenir une performance adéquate.

3.6 Architecture d'un RNA

Dans le domaine des réseaux de neurones, l'architecture est un concept clé qui joue un rôle crucial dans la classification des RNA. Le terme "structure" est souvent utilisé de manière interchangeable avec le terme "architecture" dans la littérature, car la structure du réseau est une caractéristique essentielle pour la classification des RNA [42]. Il est important de dire que la définition de l'architecture d'un RNA consiste à sélectionner judicieusement sa taille (c'est-à-dire le nombre total de couches et de neurones) et sa structure. Bien que l'utilisateur ait la responsabilité de choisir la taille du réseau, il n'existe pas de méthode objective pour déterminer le nombre optimal de neurones nécessaires pour résoudre un problème donné [43]. La définition de la taille et de la structure du réseau est une étape difficile dans la construction d'un RNA, mais choisir l'architecture du réseau est relativement plus simple, car il n'y a que deux formes principales : les réseaux faiblement connectés que l'on appelle des réseaux directs (feedforward) et les réseaux fortement connectés que l'on appelle des réseaux récurrents avec (feedback), dans ces deux configurations, on retrouve des connexions totales ou partielles entre les couches [38]. Chaque architecture possède des particularités propres et peut servir à des applications spécifiques. Cependant, ces différences topologiques n'impliquent pas nécessairement l'utilisation d'algorithmes différents [43]. La figure (3.5) illustre une classification possible des architectures de réseaux.

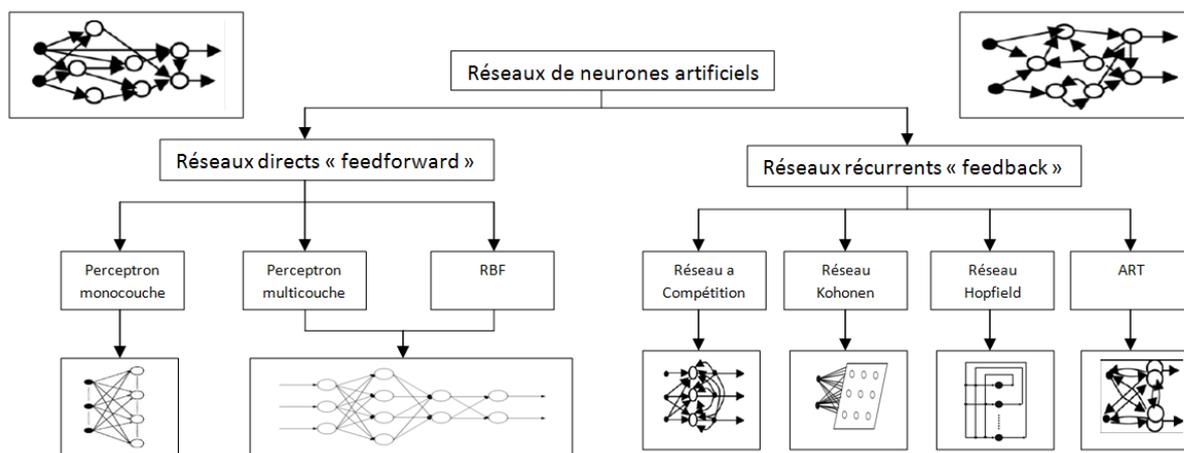


FIGURE 3.5 – Topologies des réseaux de neurones artificiels.

3.6.1 Réseaux récurrents Feed-back

Les réseaux récurrents, également connus sous le nom de réseaux bouclés ou dynamiques, permettent à l'information de circuler récursivement de manière partielle ou totale. Ils ont des connexions entre les sorties du réseau et les neurones dans des couches précédentes, permettant à la sortie d'un neurone d'être influencée par elle-même, prenant ainsi en compte la notion de temps. Ces réseaux ont des retards attachés à chaque connexion de neurone bouclé, qui sont des multiples entiers de l'unité de temps choisie. Les cartes auto-organisatrices de Kohonen, Les réseaux de Hopfield et Les ART sont les architectures les plus couramment utilisées pour les réseaux récurrents, qui sont largement utilisés dans des domaines tels que la reconnaissance de la parole, la traduction automatique et la génération de texte.

- **Les cartes auto-organisatrices de Kohonen :** La carte de Kohonen [44] est un réseau de neurones avec une seule couche cachée organisée en grilles rectangulaires bidimensionnelles. Chaque nœud dans la couche cachée est connecté à tous les nœuds d'entrée. Elle utilise l'apprentissage non supervisé avec la règle du gagnant qui prend tout, mettant à jour uniquement le nœud qui a la réponse la plus élevée et ses voisins. La carte de Kohonen est utilisée pour projeter des données multidimensionnelles dans un espace bidimensionnel, pour la classification de données, etc.
- **Les réseaux de Hopfield :** Les réseaux de Hopfield [45] sont des réseaux de neurones récurrents qui utilisent l'apprentissage non-supervisé et sont souvent utilisés pour résoudre des problèmes d'optimisation. Ils sont considérés comme étant totalement connectés et chaque nœud est connecté à tous les autres nœuds, mais pas à lui-même, sans distinction entre les neurones d'entrée et de sortie. Le réseau de Hopfield fonctionne comme une mémoire associative non linéaire qui peut reconnaître des objets stockés dans un ensemble de données. En appliquant une entrée, le réseau de Hopfield met à jour son état jusqu'à atteindre un état attracteur stable. Le réseau peut être utilisé comme mémoire associative pour récupérer des motifs partiellement corrompus et résoudre des problèmes tels que le voyageur de commerce.
- **Les ART :** Les réseaux ART sont des outils basés sur la théorie de la résonance adaptative, utilisés pour trier des motifs dans un système en se basant uniquement sur leur description interne. Ils sont capables d'acquérir de nouvelles connaissances sans perdre celles accumulées antérieurement, ce qui les rend adaptés pour des entraînements continus avec l'ajout de nouvelles données [46].

3.6.2 Réseaux propagation vers l'avant Feed-forward

Un réseau de neurones (FEED-FORWARD) est un type de réseau de neurones où les neurones sont connectés dans une direction unique, de l'entrée vers la sortie, sans boucles de rétroaction. Il peut être à une seule couche (comme le Perceptron) ou multicouches (avec une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées), et chaque neurone est connecté à tous les neurones de la couche précédente. Ce type de réseau utilise principalement un apprentissage supervisé, où les erreurs sont corrigées en rétro-propageant le signal d'erreur vers les entrées pour mettre à jour les poids des neurones [47].

- **Perceptron monocouche (SPL)** : Le perceptron est un réseau de neurones simple qui ne comporte qu'une couche d'entrée et une couche de sortie, sans couche cachée. Les neurones dans la couche d'entrée sont connectés à chaque neurone dans la couche de sortie via des poids. Le perceptron utilise généralement un apprentissage supervisé avec la règle de correction d'erreur ou la règle de Hebb [48].
- **Le perceptron multicouche (PMC)** : Le perceptron multicouche (PMC) est un type de réseau de neurones (FEED-FORWARD), qui contient une ou plusieurs couches cachées placées entre les couches d'entrée et de sortie. Les neurones dans une couche sont connectés à tous les neurones de la couche précédente et suivante, à l'exception des couches d'entrée et de sortie. Il n'y a pas de connexions entre les neurones d'une même couche ou entre deux couches non successives. Les fonctions d'activation couramment utilisées dans les PMC sont des fonctions sigmoïdes. Le nombre de couches cachées choisi dépend de la complexité du problème à résoudre. En théorie, une seule couche cachée peut suffire pour résoudre un problème donné, mais plusieurs couches cachées peuvent faciliter la résolution d'un problème complexe [48].
- **Réseaux à fonction radiale (RBF)** : Les réseaux à fonction radiale RBF sont très semblables à celle des (PMC) mais leur particularité est qu'ils sont caractérisés par l'utilisation des fonctions Gaussiennes comme fonctions de base. Les (RBF) sont donc utilisés dans les mêmes genres de problèmes que les (PMC) à savoir, en classification et en prédiction. Parmi les types d'apprentissage utilisés pour les (RBF) on peut citer le mode hybride avec les règles de correction de l'erreur [49].

Dans notre étude, le type du réseau qui nous intéresse est le réseau multicouche.

3.7 Apprentissage

Les réseaux de neurones peuvent apprendre, mais ils ont besoin d'être entraînés avec des exemples pour acquérir cette compétence. La phase d'apprentissage est une étape de développement où les paramètres des neurones sont ajustés pour que le réseau puisse accomplir sa tâche de manière optimale. Pendant cette phase, le comportement du réseau est modifié jusqu'à ce qu'il fonctionne correctement.

3.7.1 Règles d'apprentissage :

Les règles d'apprentissage sont utilisées pour déterminer la quantité de modification à apporter à chaque poids du réseau, en fonction des exemples d'entrée et/ou des sorties désirées associées :

$$W_{ij}(t + 1) = W_{ij}(t) + \Delta W_{ij}$$

où :

t : représente un moment avant la modification des poids.

$t + 1$: représente un moment après la modification des poids.

Il existe de nombreuses règles d'apprentissage différentes, Les règles d'apprentissage les plus couramment utilisées comprennent les suivantes [50] :

- **Règle de correction d'erreur** : Un réseau de neurones se voit attribuer une sortie désirée pour chaque motif d'entrée. Pendant le processus d'apprentissage, la sortie réelle générée par le réseau peut ne pas correspondre à la sortie désirée. Le principe de base des règles d'apprentissage par correction d'erreur consiste à utiliser le signal d'erreur (différence entre la sortie désirée et la sortie obtenue) pour ajuster les poids de connexion. Le but est d'obtenir une sortie produite qui se rapproche le plus possible de la sortie désirée pour chaque entrée. Ce processus se répète jusqu'à ce que l'erreur soit suffisamment faible pour que le réseau produise des sorties précises et cohérentes pour chaque entrée donnée.

$$\Delta W_{ij} = \alpha x_i (y_j^d - y_j)$$

avec :

α : taux d'apprentissage.

x_i : entrées.

$e_j = y_j^d - y_j$: erreur de sortie.

- **Règle d'apprentissage du perceptron** : Le perceptron est un algorithme de classification qui traite les éléments d'un ensemble d'entraînement un par un. Il est similaire à un neurone linéaire, mais effectue une classification plutôt qu'une régression. Le perceptron ajuste ses poids pour séparer les exemples d'entraînement dans leurs classes respectives. L'algorithme du perceptron est appelé perceptron à une couche et est le réseau de neurones FEED-FORWARD le plus simple.

$$\Delta W_{ij} = x_i (y_j^d - y_j)$$

- **Règle d'apprentissage de Boltzmann** : L'apprentissage de Boltzmann est dérivé de principes thermodynamiques et d'information. L'objectif de l'apprentissage de Boltzmann est d'ajuster les poids de connexion de sorte que les états des unités visibles satisfont une distribution de probabilité désirée particulière. L'apprentissage de Boltzmann peut être considéré comme un cas particulier de l'apprentissage par correction d'erreur dans lequel l'erreur n'est pas mesurée comme la différence directe entre les sorties désirées et réelles, mais comme la différence entre les corrélations entre les sorties de deux neurones dans des conditions de fonctionnement claquées et libres.
- **Règle de Hebb** : La règle de Hebb peut être résumée par l'expression "Les cellules qui tirent ensemble, se lient ensemble." Cette règle est utilisée pour déterminer comment modifier les poids entre les neurones d'un modèle. Les poids entre deux neurones augmentent s'ils s'activent simultanément et diminuent s'ils s'activent séparément. Les nœuds qui ont tendance à être tous deux positifs ou tous deux négatifs en même temps ont des poids positifs forts, tandis que ceux qui ont tendance à être opposés ont des poids négatifs forts.

$$\Delta W_{ij} = \alpha x_i y_j^d$$

avec :

y_j^d : est la sortie désirée du neurone j.

- **Règle d'apprentissage compétitif** : L'apprentissage compétitif est un type d'apprentissage où les unités de sortie se concurrencent pour l'activation, aboutissant à un phénomène de (gagnant prend tout). Cet apprentissage a été trouvé dans les réseaux neuronaux biologiques et est souvent utilisé pour regrouper ou catégoriser les données d'entrée en fonction de leurs corrélations. Un système d'apprentissage est stable si les motifs dans les données d'entraînement ne changent pas de catégorie après un nombre fini d'itérations. Cependant, forcer le taux d'apprentissage à diminuer progressivement peut entraîner une perte de plasticité, c'est-à-dire la capacité à s'adapter à de nouvelles données, ce qui est connu sous le nom de dilemme de stabilité-plasticité de Grossberg en apprentissage compétitif.

$$\Delta W_{ij} = \alpha(x_i - W_{ij})y_j^d$$

avec :

W_{ij} : poids de la connexion entre les neurones i et j .

- **Rétro-propagation du gradient** : La rétro-propagation est l'algorithme le plus couramment utilisé en prévision et est largement utilisée dans le domaine des réseaux de neurones. Bien que découverte indépendamment par différents auteurs sous différents noms, elle est maintenant utilisée dans différents types de réseaux de neurones, Initialement développée pour l'apprentissage des perceptrons multicouches, elle a été étendue à d'autres types de réseaux de neurones. La rétro-propagation utilise une technique de calcul des dérivées qui peut être appliquée à n'importe quelle structure de fonctions dérivables.

$$\Delta W_{ij} = \alpha \delta_j y_j$$

avec :

δ_j : est un paramètre qui dépend de la dérivée de fonction d'activation et des poids des couches en aval.

3.7.2 Types d'apprentissage

L'apprentissage est une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information . Il existe plusieurs règles d'apprentissage qui peuvent être regroupées en trois catégories : les règles d'apprentissage supervisé, non supervisé, et renforcé. Mais l'objectif fondamental de l'apprentissage reste le même : soit la classification, l'approximation de fonction ou encore la prédiction [43], [51], [52].

- **Apprentissage supervisé** : La procédure usuelle dans le cadre de la classification ou la prédiction est l'apprentissage supervisé, C'est actuellement le mode d'apprentissage le plus couramment utilisé qui consiste à associer une réponse spécifique désirée à chaque signal d'entrée (on soumet au réseau à un grand nombre d'exemples). La mise à jour des poids s'effectue progressivement jusqu'à ce que l'erreur entre les sorties du réseau et les résultats désirés soit minimisée. Le plus répandu des algorithmes d'apprentissage supervisé est l'algorithme de rétropropagation du gradient d'erreur qui appliqué aux réseaux Multi Couches. Des exemples d'utilisations de différentes règles d'apprentissage, architectures et algorithmes qui sont relié à ce type supervisé sont illustrés dans le tableau (3.1) [43], [53], [42].

Paradigme	Architecture	Règle d'apprentissage	Algorithme	Taches
Supervisé	Perceptron simple ou Multi-couches	Correction d'erreur	Perceptron, Rétro-propagation, Adaline, Madaline	Classification, Approximation de fonctions, Prédiction, Contrôle
	Récurrente	Bolzman	Apprentissage de Boltzmanh	Classification
	Multi-Couches non bouclés	Hebb	Analyse de discriminants linéaires	Analyse de données, Classification
	à compétition	Par compétition	LVQ	Catégorisation au sein d'une classe, Compression de données
	ART	-	ARTMap	Classification, Catégorisation au sein d'une classe

TABLE 3.1 – Exemple de différents types d'apprentissages en mode supervisé [42].

- **Apprentissage semi-supervisé (Apprentissage renforcé) :** L'apprentissage renforcé est une technique similaire à l'apprentissage supervisé à la différence qu'au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade qui est une mesure du degré de performance du réseau après quelques itérations. Les algorithmes utilisant la procédure d'apprentissage renforcé sont surtout utilisés dans le domaine des systèmes du contrôle [51], [43].
- **Apprentissage non supervisé :** Contrairement aux modes supervisés, l'apprentissage non supervisé ne nécessite pas de résultats désirés fournis au réseau, mais consiste plutôt à ajuster les poids à partir d'un ensemble d'apprentissage de données. Le but est de détecter les similarités et les différences dans les données, en convergeant théoriquement vers des représentations qui capturent les régularités statistiques des données. Ce type d'apprentissage est compétitif et coopératif, et est reconnu pour sa grande capacité d'auto-organisation. Il est principalement utilisé pour la reconnaissance des patrons, le traitement du signal et l'analyse factorielle. Le tableau (3.2) [43], [42], [53] illustre différents exemples de règles d'apprentissage, d'architectures et d'algorithmes utilisés dans ce type d'apprentissage.

Paradigme	Architecture	Règle d'apprentissage	Algorithme	Taches
Non supervisé	Multi-couches non bouclé	Correction d'erreur	Projection de Sammon	Analyse de données
	Non bouclé ou à compétition	Hebb	Analyse en composantes	Analyse de données
	à compétition	Par compétition	VQ	Catégorisation, Compression de données
	Carte de Kohonen	-	SOM	Catégorisation, Analyse de données
	ART	-	ART-1, ART-2	Catégorisation

TABLE 3.2 – Exemple de différents types d'apprentissages en mode non supervisé [42].

3.8 Rétro-propagation du gradient d'un PMC

3.8.1 Principe

La rétropropagation est simplement une méthode de descente de gradient utilisée pour minimiser l'erreur quadratique totale de la sortie calculée par le réseau. Elle fonctionne en faisant circuler les données d'entrée à travers le réseau jusqu'à l'obtention d'une sortie calculée par le réseau, puis en comparant cette sortie à la sortie réelle connue. Les poids sont ajustés de manière à minimiser l'erreur lors de la prochaine itération en prenant en compte la présence de couches cachées. L'erreur est rétro propagée à travers le réseau jusqu'à la couche d'entrée, et les poids sont modifiés en utilisant l'erreur quadratique (le carré de la différence entre ce qu'on obtient et ce qu'on désire). En calculant la dérive partielle de l'erreur quadratique par rapport aux poids de connexion (gradient), on peut déterminer leur contribution à l'erreur globale et les corriger en conséquence. Le processus est répété pour tous les exemples d'apprentissage jusqu'à ce que l'erreur de sortie soit considérée comme négligeable. Cependant, la rétropropagation peut être piégée dans un minimum local et est sensible aux conditions initiales, à la taille de l'ensemble d'apprentissage et au phase d'apprentissage. Des modifications ont été proposées pour surmonter ces limitations [54].

3.8.2 Algorithme

Le choix d'utiliser le Perceptron multicouches (PMC) et l'algorithme rétro-propagation est dû principalement à la popularité de ces deux derniers dans la gestion des relations non linéaire entre les variables.

3.8.2.1 Définition du réseau

Soit un réseau multicouche défini par :

- Une couche d'entrée à N cellules d'entrées (x_i).
- Une couche de sortie à S neurones d'activation (y_j).
- Une couche cachée à K neurones d'activation (u_k).
- $K * N$ connexions entre la couche d'entrée et la couche cachée, chacune pondérée par W_{ij} .
- $K * S$ connexions entre la couche cachée et la couche de sortie, chacune pondérée par W_{ij} .

3.8.2.2 Propagation

Lorsque le réseau de neurones artificiels est construit, il passe par une étape appelée (phase de propagation) qui permet de prédire la sortie finale en utilisant les poids et les fonctions d'activation des différents neurones pour combiner les entrées et produire des sorties. Cette phase consiste en une série de calculs qui sont effectués de la couche d'entrée à la couche de sortie du réseau de neurones. La propagation depuis la couche d'entrée vers la couche cachée [55], [53] :

$$u_k^{in} = \sum_{i=1}^N w_{ik} x_i \quad (3.1)$$

Après activation avec une fonction f :

$$u_k^{out} = f(u_k^{in}) \quad (3.2)$$

Au niveau de la couche de sortie :

$$y_j^{in} = \sum_{k=1}^K v_{kj} u_k^{out} \quad (3.3)$$

Une fois la sortie sera activée par une fonction f , on aura :

$$y_j^{out} = f(y_j^{in}) \quad (3.4)$$

3.8.2.3 Erreur quadratique moyenne

Pour évaluer la performance et la validité d'un réseau de neurones, on compare la sortie prédite par le réseau à la sortie attendue d'un ensemble de données. Si l'erreur entre les deux est minimale, cela signifie que le réseau s'adapte bien et donne de bons résultats. L'erreur quadratique moyenne est l'une des formes d'erreur les plus couramment utilisées pour évaluer l'adaptation du réseau à un problème donné. Elle se base sur la théorie de la régression par la méthode des moindres carrés et vise à minimiser la somme des carrés des différences entre les sorties désirées et les sorties calculées. L'objectif est de trouver une droite de régression qui minimise cette somme de carrés, ce qui conduit à une convergence de l'erreur vers zéro et indique que le réseau est capable de prédire les sorties attendues avec précision [55], [56].

L'expression de l'erreur quadratique moyenne associée à tous les neurones de sortie est donnée par :

$$E = \frac{1}{2} \sum_{j=1}^S (y_j^d - y_j^{out})^2 \quad (3.5)$$

3.8.2.4 Rétro-propagation

La rétropropagation est un algorithme utilisé pour entraîner les réseaux de neurones en ajustant les poids et les biais entre les neurones. L'algorithme utilise les sorties des couches de neurones pour calculer les gradients, qui indiquent comment les poids doivent être ajustés pour minimiser les erreurs. En ajustant les poids et les biais de manière itérative, le réseau de neurones peut apprendre à reconnaître des modèles dans les données et à effectuer des tâches spécifiques. L'algorithme de rétropropagation est défini par une suite d'instructions qui se succèdent de la manière suivante [55], [53] :

- **Correction des poids v_{kj} entre la couche de sortie et la couche cachée précédente**

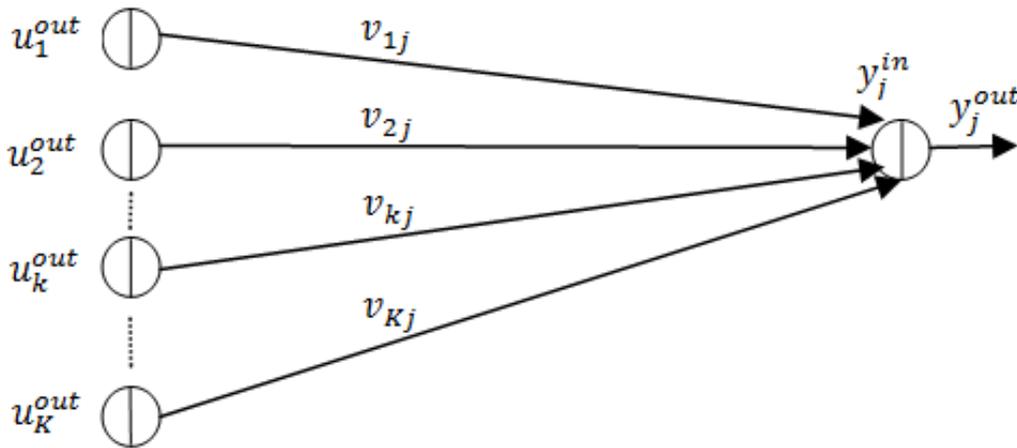


FIGURE 3.6 – Cas de neurone entre la couche de sortie et la couche cachée précédente [53].

En commençant à partir de la couche de sortie vers la couche cachée (couche précédente), la correction des pondérations va obéir à la règle du gradient :

$$v_{kj} = v_{kj} + \Delta v_{kj} = v_{kj} - \alpha \frac{\partial E}{\partial v_{kj}} \quad (3.6)$$

Où α est un paramètre de déplacement dit : pas d'apprentissage. Il faudra donc déterminer $(\partial E / \partial v_{kj})$, or E est une fonction ou expression composée, c'est-à-dire que E dépend de y_j^{out} qui dépend de y_j^{in} qui dépend à son tour de v_{kj} , ce qui permet d'écrire :

$$\frac{\partial E}{\partial v_{kj}} = \frac{\partial E}{\partial y_j^{out}} \frac{\partial y_j^{out}}{\partial y_j^{in}} \frac{\partial y_j^{in}}{\partial v_{kj}} \quad (3.7)$$

Avec

$$\frac{\partial E}{\partial y_j^{out}} = -(y_j^d - y_j^{out}) = -(y_j^d - f(y_j^{in})) \quad (3.8)$$

$$\frac{\partial y_j^{out}}{\partial y_j^{in}} = \frac{\partial f(y_j^{in})}{\partial y_j^{in}} = f'(y_j^{in}) \quad (3.9)$$

$$\frac{\partial y_j^{in}}{\partial v_{kj}} = u_k^{out} \quad (3.10)$$

Si par exemple la fonction d'activation est une sigmoïde de type :

$$y_j^{out} = f(y_j^{in}) = \frac{1}{1 + \exp -y_j^{in}} \quad (3.11)$$

Sa dérivée est :

$$\frac{\partial y_j^{out}}{\partial y_j^{in}} = f'(y_j^{in}) = f(y_j^{in})(1 - f(y_j^{in})) \quad (3.12)$$

Alors

$$\frac{\partial E}{\partial y_j^{out}} = -(y_j^d - y_j^{out}) = -(y_j^d - f(y_j^{in})) \quad (3.13)$$

$$\frac{\partial y_j^{out}}{\partial y_j^{in}} = \frac{\partial f(y_j^{in})}{\partial y_j^{in}} = f'(y_j^{in}) = f(y_j^{in})(1 - f(y_j^{in})) \quad (3.14)$$

$$\frac{\partial y_j^{in}}{\partial v_{kj}} = u_k^{out} \quad (3.15)$$

D'où

$$\frac{\partial E}{\partial v_{kj}} = \frac{\partial E}{\partial y_j^{out}} \frac{\partial y_j^{out}}{\partial y_j^{in}} \frac{\partial y_j^{in}}{\partial v_{kj}} = -(y_j^d - y_j^{out}) f'(y_j^{in}) u_k^{out} \quad (3.16)$$

Ou encoure

$$\frac{\partial E}{\partial v_{kj}} = -(y_j^d - y_j^{out}) f'(y_j^{in}) (1 - f(y_j^{in})) u_k^{out} \quad (3.17)$$

Comme

$$\Delta v_{kj} = -\alpha \frac{\partial E}{\partial v_{kj}} \quad (3.18)$$

Alors

$$v_{kj} = v_{kj} + \Delta v_{kj} = v_{kj} + \alpha (y_j^d - y_j^{out}) f'(y_j^{in}) u_k^{out} \quad (3.19)$$

La définition du gradient local δ_j traduit l'expression suivante :

$$\frac{\partial E}{\partial v_{kj}} = -\delta_j u_k^{out} \quad (3.20)$$

En posant

$$\delta_j = (y_j^d - y_j^{out}) f'(y_j^{in}) = (y_j^d - y_j^{out}) f(y_j^{in}) (1 - f(y_j^{in})) \quad (3.21)$$

Cela donne

$$v_{kj} = v_{kj} + \alpha \delta_j u_k^{out} \quad (3.22)$$

- Correction des poids w_{ik} entre la couche cachée et la couche d'entrée

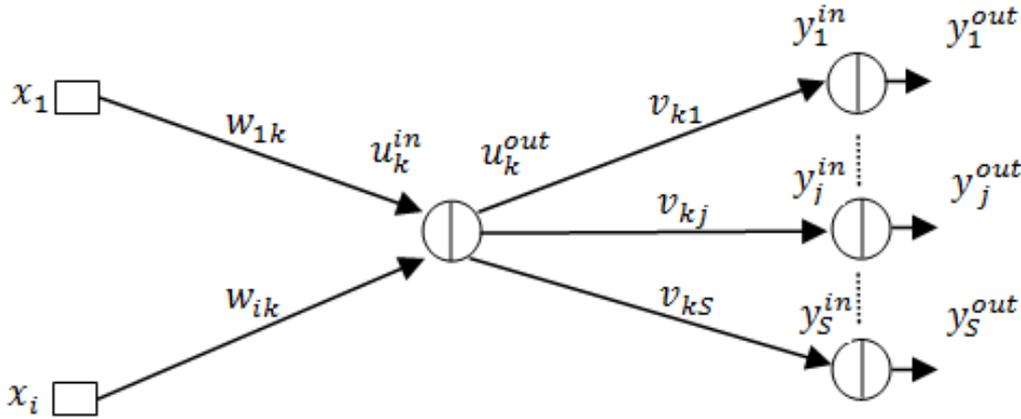


FIGURE 3.7 – Cas de neurone entre la couche cachée et la couche d'entrée [53].

Nous devons ensuite corriger les pondérations entre la couche cachée et la couche d'entrée (couche précédente) par le biais de la formulation ci – dessous :

$$w_{ik} = w_{ik} + \Delta w_{ik} = w_{ik} - \alpha \frac{\partial E}{\partial w_{ik}} \quad (3.23)$$

Il faudra donc déterminer $\frac{\partial E}{\partial w_{ik}}$ en utilisant l'erreur quadratique (3.5). Dans ce cas, il faut dériver E par rapport aux poids de la couche cachée précédente w_{ik} (au lieu des poids de la couche de sortie v_{kj}), à travers une décomposition reliant u_k^{out} à u_k^{in} qui dépend à son tour de w_{ik} , ce qui permet d'écrire :

$$\frac{\partial E}{\partial w_{ik}} = \frac{\partial E}{\partial u_k^{out}} \frac{\partial u_k^{out}}{\partial u_k^{in}} \frac{\partial u_k^{in}}{\partial w_{ik}} \quad (3.24)$$

calcul de $\frac{\partial E}{\partial u_k^{out}}$:

Pour un neurone de cette couche cachée, le calcul est le même que le cas d'un neurone de sortie, jusqu'à :

$$\frac{\partial E}{\partial u_{kout}} = \frac{1}{2} \sum_{j=1}^S \frac{\partial e_j^2}{\partial u_k^{out}} = \sum_j e_j \frac{\partial e_j}{\partial u_k^{out}} \quad (3.25)$$

La dépendance entre e_j et u_k^{out} est à deux niveaux, ce qui nous amène à faire la décomposition utile suivante :

$$\frac{\partial E}{\partial u_{kout}} = \sum_j e_j \frac{\partial e_j}{\partial y_j^{in}} \frac{\partial y_j^{in}}{\partial u_k^{out}} \quad (3.26)$$

Avec

$$\frac{\partial e_j}{\partial y_j^{in}} = \frac{\partial(y_j^d - y_j^{out})}{\partial y_j^{in}} = \frac{\partial(y_j^d - f(y_j^{in}))}{\partial y_j^{in}} = f'(y_j^{in}) = -f(y_j^{in})(1-f(y_j^{in})) = -y_j^{out}(1-y_j^{out}) \quad (3.27)$$

Et

$$\frac{\partial y_j^{in}}{\partial u_k^{out}} = \frac{v_{kj} \partial(\sum u_k^{out})}{\partial u_k^{out}} = v_{kj} \quad (3.28)$$

D'ou

$$\frac{\partial E}{\partial u_k^{out}} = - \sum_j e_j (y_j^{out}(1-y_j^{out})v_{kj}) = - \sum_j e_j f'(y_j^{in})v_{kj} \quad (3.29)$$

calcul de $\frac{\partial u_k^{out}}{\partial u_k^{in}}$:

A partir de l'équation (3.2), nous avons :

$$\frac{\partial u_k^{out}}{\partial u_k^{in}} = f'(u_k^{in}) = f(u_k^{in})(1-f(u_k^{in})) \quad (3.30)$$

calcul de $\frac{\partial u_k^{out}}{\partial u_k^{in}}$:

Depuis l'équation de propagation (3.1)

$$\frac{\partial u_k^{out}}{\partial u_k^{in}} = x_i \quad (3.31)$$

Et donc

$$\frac{\partial E}{\partial w_{ik}} = \frac{\partial E}{\partial u_k^{out}} \frac{\partial u_k^{out}}{\partial u_k^{in}} \frac{\partial u_k^{in}}{\partial w_{ik}} = - \left[\sum_j f'(y_j^{in})v_{jk} \right] f'(u_k^{in})x_i \quad (3.32)$$

On remarque que le gradient local δ_j apparaît aussi dans cette expression. Nous avons déjà précédemment posé : $\delta_j = (y_j^d - y_j^{out})f'(y_j^{in})$

On peut alors écrire

$$\frac{\partial E}{\partial u_k^{out}} = - \sum_j e_j f'(y_j^{in})v_{kj} = - \sum_j \delta_j v_{kj} \quad (3.33)$$

Et

$$\frac{\partial E}{\partial w_{ik}} = -f'(u_k^{in}) \left[\sum_j \delta_j v_{jk} \right] x_i \quad (3.34)$$

La définition du gradient local pour ce deuxième cas est donc valable en posant

$$\delta_k = f'(u_k^{in}) \sum_j \delta_j v_{kj} \quad (3.35)$$

Ce qui donne bien

$$\frac{\partial E}{\partial w_{ik}} = -\delta_k x_i \quad (3.36)$$

Finalement la correction des poids entre la couche de sortie et la couche cachée précédente est :

$$w_{ik} = w_{ik} + \Delta w_{ik} = w_{ik} + \alpha \delta_k x_i = w_{ik} + \alpha \left[f'(u_k^{in}) \sum_j \delta_j v_{kj} \right] x_i \quad (3.37)$$

On retrouvera cette récursivité entre les autres couches, et donc la méthode permet d'adapter les poids de n'importe quelle couche du PMC, menant à une diminution progressive de l'erreur de sortie.

3.8.3 Résumé de l'algorithme de rétro-propagation

L'algorithme de rétro-propagation standard se résume donc à la série des étapes suivante

57 :

Etape01

- les entrées d'un exemple sont injectées dans les cellules d'entrée du RNA.
- le RNA calcule sa sortie en propageant ces entrées vers l'avant à travers les différentes couches du réseau. Ce calcul prend en compte les états internes des neurones ainsi que les poids synaptiques des connexions entre les neurones.

Etape02

- Après le calcul de sa sortie, le RNA compare cette sortie à la sortie désirée pour l'exemple. Cette comparaison donne lieu à une mesure d'erreur qui permet d'évaluer la performance du RNA.
- Au début de l'apprentissage, cette erreur peut être importante car le RNA ne dispose pas encore des bons poids synaptiques pour produire une réponse précise.

Etape03

- Ajuster les poids en rétro-propageant l'erreur calculée.

Etape04

- On répète ces étapes pour chaque exemple de la base d'apprentissage, jusqu'à ce que le RNA converge vers une configuration qui lui permette de résoudre le problème à traiter.

3.9 Avantages et inconvénients des réseaux de neurones

3.9.1 Avantages

Maintenant que nous avons compris les principes de base des réseaux neuronaux et leur mode de fonctionnement, nous allons nous pencher sur les avantages des réseaux neuronaux **58** **38** **59**.

- **Une analyse visuelle efficace** : Le tout premier avantage des réseaux neuronaux est qu'ils permettent une analyse visuelle efficace. Étant donné qu'un réseau de neurones artificiel est similaire au réseau de neurones d'un être humain, il est capable d'effectuer des tâches et des activités plus complexes que d'autres machines. Il s'agit notamment d'analyser les informations visuelles et de les classer en différentes catégories.

- **Filtrage efficace du bruit dans les données :**
Cette propriété se retrouve dans les réseaux de neurones artificiels. Après la formation, ils sont capables d'isoler uniquement les informations dont ils ont besoin à partir d'un énorme flux continu de données, en ignorant tout bruit parasite. Il s'agit d'une fonctionnalité très utile si vous avez besoin de rechercher des modèles dans d'énormes quantités de données.
- **Traitement des données non organisées :** Le troisième avantage des réseaux neuronaux est qu'ils sont capables de traiter, séparer et catégoriser des données non organisées. Avec l'arrivée des réseaux neuronaux artificiels, la tâche d'organiser des données non structurées est devenue beaucoup plus facile. Contrairement à l'époque traditionnelle où des équipes d'humains qualifiés devaient consacrer leurs journées à catégoriser des données non organisées, les ordinateurs peuvent aujourd'hui accomplir la même fonction en quelques minutes, voire quelques secondes.
- **Structure adaptative :** L'un des principaux avantages des réseaux neuronaux est que leur structure est de nature adaptative, qui leur permet de s'ajuster en fonction de l'objectif spécifique qu'ils doivent atteindre. Contrairement à de nombreux algorithmes et applications d'apprentissage automatique, les réseaux neuronaux peuvent se transformer et se modifier rapidement pour s'adapter à de nouveaux environnements et situations. De plus, cela rend l'entraînement de ces réseaux plus flexible et moins contraignant en termes de type de formation nécessaire. En somme, les réseaux neuronaux offrent une grande souplesse et une capacité d'adaptation rapide, contrairement aux structures rigides des méthodes d'apprentissage automatique traditionnelles.
- **Auto-apprentissage :** C'est la principale caractéristique et l'avantage des réseaux de neurones artificiels. Vous créez simplement un algorithme de base, puis lui donnez des exemples à former et regardez les résultats dans le même temps, l'algorithme lui-même décide comment atteindre l'objectif souhaité, trouvant souvent des solutions qui ne sont pas évidentes. De plus, le réseau de neurones n'est pas seulement un auto-apprentissage, il est conçu pour s'auto-apprendre en permanence et améliorer ses résultats. Une fois le système formé, le programme ou l'application devient plus convivial au fur et à mesure de son utilisation.
- **Tolérance aux pannes :** Les solutions basées sur les réseaux de neurones restent opérationnelles même après la défaillance d'une partie des neurones. Cela peut affecter la précision et/ou la vitesse de l'algorithme, mais ses réponses seront toujours logiques, rationnelles et correctes.
- **Interface conviviale :** Le dernier avantage parmi d'autres est qu'ils présentent une interface conviviale. Avec une interface conviviale, les réseaux de neurones peuvent être formés sans trop de complexité.

3.9.2 Inconvénients

Même si les avantages des réseaux de neurones l'emportent sur leurs inconvénients, il est important de les considérer et même d'approfondir leur nature. Voici quelques-uns des inconvénients bien connus des réseaux de neurones [58] [38] [59].

- **Problème de la boîte noire** : L'un des principaux défauts des réseaux de neurones est leur opacité, c'est-à-dire qu'il est difficile de comprendre comment et pourquoi ils produisent un certain résultat. Le fonctionnement interne de ces "cerveaux" artificiels reste largement mystérieux, ce qui constitue un obstacle majeur à leur apprentissage et à leur utilisation dans divers domaines d'activité.
- **Quantité de données** : Le prochain inconvénient des réseaux de neurones est que leur formation nécessite généralement beaucoup plus de données que les algorithmes d'apprentissage automatique traditionnels. Et comme nous l'avons déjà dit, s'il s'agit de données uniques ou difficiles à collecter, cela peut être un sérieux défi pour les développeurs. Et souvent bien plus que d'écrire le code d'un réseau de neurones artificiels.
- **Problème du sur-apprentissage** (apprentissage au détriment de la généralisation).
- **Choix des valeurs initiales des poids du réseau et le réglage du pas d'apprentissage** : qui jouent un rôle important dans la vitesse de convergence.
- **L'absence de méthode systématique permettant de définir la meilleure topologie du réseau et le nombre de neurones à placer dans la (ou les) couche(s) cachée(s)** .

3.10 Conclusion

Ce chapitre met en évidence l'importance de la rétropropagation dans les réseaux de neurones artificiels pour apprendre les caractéristiques d'un système et classer des objets avec une partie de leurs propriétés. La rétropropagation peut être améliorée en ajustant les paramètres tels que le nombre de neurones ou le taux d'apprentissage. Contrairement aux méthodes classiques, les réseaux de neurones ont montré leur capacité à s'adapter à des problèmes complexes grâce à leur puissance de calcul et d'apprentissage, et sont utilisés dans de nombreux domaines. Le prochain chapitre traitera de l'application des réseaux de neurones pour la stabilité de tension.

Chapitre 4

Application du RNA dans le calcul des indices de stabilité de tension

4.1 Introduction

Ce chapitre présente l'utilisation des RNAs pour calculer l'indice de stabilité de tension, en se concentrant spécifiquement sur l'indice FVSI (le choix de cet indice est arbitraire). Nous utilisons le perceptron multicouche (PMC) comme modèle de RNA, entraîné à l'aide de la rétropropagation. Le PMC est choisi en raison de sa capacité à résoudre des problèmes complexes et non linéaires, tels que l'évaluation de la stabilité de tension dans les systèmes électriques. Nous discutons de l'architecture du PMC, des données d'entrée requises et de la méthodologie employée pour obtenir des prédictions précises de l'indice FVSI.

4.2 Architecture du PMC

L'introduction du perceptron multicouche dans le contexte du calcul de l'indice de stabilité de tension vise à créer une boîte noire capable de recevoir des données d'entrée et de produire des sorties représentant la solution de stabilité de tension pour un réseau électrique donné. Cette approche permet d'obtenir une méthode efficace et rapide pour le traitement en ligne de l'indice de stabilité de tension (on-line stability assessment) une fois que le modèle a été préalablement entraîné hors ligne (off-line) sur le réseau électrique. En utilisant le perceptron multicouche comme modèle de réseaux de neurones, on peut exploiter la puissance du calcul parallèle pour obtenir des prédictions en temps réel et fournir des évaluations précises de la stabilité de tension du réseau électrique.

Le modèle utilisé est un perceptron multicouche à propagation directe avec une seule couche cachée, conçu pour représenter le système électrique étudié et reconnaître les non-linéarités présentes. Les données d'entrée du perceptron multicouche sont choisies en utilisant les paramètres de l'indice FVSI, ce qui inclut les informations de puissance réactive, de tension des nœuds de charge et de génération, ainsi que les impédances des lignes du réseau. L'indice de stabilité de tension est déduit en tant que sortie du modèle.

La taille de la couche cachée est déterminée de manière empirique en utilisant la loi de Masters [41], afin d'obtenir une représentation optimale des non-linéarités du système électrique simulé. L'algorithme d'apprentissage utilisé est la rétropropagation, qui ajuste les poids des connexions du perceptron en fonction de l'erreur entre la sortie obtenue et le résultat attendu en utilisant la descente du gradient.

Pour la réalisation de ce travail, un programme MATLAB a été développé. Le réseau PMC considéré comprend une couche d'entrée, une couche de sortie et une couche cachée.

La sélection des paramètres d'entrée revêt une importance primordiale pour les performances du réseau de neurones. Les paramètres utilisés visent à identifier la meilleure caractéristique d'entrée qui fournira le maximum d'informations essentielles sur le fonctionnement du système électrique.

4.3 Analyse du modèle PMC proposé pour le calcul d'indice de stabilité de tension (FVSI)

4.3.1 Base de données

Dû à l'absence d'une base de données préexistante, tant théorique que pratique fournie par les fournisseurs d'énergie électrique, nous avons développé des critères spécifiques pour générer une base de données aléatoire. Cette base de données a ensuite été divisée en deux parties : une grande partie (environ 70% à 80% des données globales) utilisée pour la phase d'apprentissage, et le reste réservé à la phase de test. Nous avons choisi de travailler avec le réseau 14 nœuds, afin de valider notre modèle de perceptron multicouche.

Notre objectif était de générer une courbe de charge respectant des limites prédéfinies, en se basant sur un calcul d'écoulement de puissance optimale et en utilisant le point de fonctionnement standard du réseau électrique 14 nœuds. Voici les étapes du processus :

- Pour déterminer les limites spécifiques à respecter, nous avons extrait les valeurs minimales et maximales de la puissance active de charge $(P_L)_{\min}$ et $(P_L)_{\max}$ à partir d'un calcul d'écoulement de puissance optimale. Ces limites nous ont permis d'établir les bornes à ne pas dépasser lors de la génération de la courbe de charge. En respectant ces limites, nous avons assuré que la puissance active de charge reste dans une plage acceptable, garantissant ainsi un équilibre adéquat entre l'offre et la demande d'électricité.
- Nous avons utilisé le point de fonctionnement basique du réseau électrique 14 nœuds comme point de départ. À partir de là, nous avons calculé le pourcentage de la puissance totale de charge qui correspond à la puissance active de charge (P_L) dans chaque nœud. En utilisant ce pourcentage et en effectuant un choix aléatoire de la puissance active totale (P_L) totale dans les plages données, nous avons pu calculer la valeur de (P_L) pour chaque point de fonctionnement. Ensuite, en utilisant cette valeur de (P_L) , nous avons appliqué la relation du facteur de puissance pour calculer la puissance réactive de charge (Q_L) , nous nous sommes basés sur le critère de garder le facteur de puissance des charges constant 0.8 dans le but d'assurer un bon fonctionnement des charges et de ne pas avoir des anomalies. Ce processus nous a permis de déterminer les niveaux appropriés de puissance active et réactive de charge, garantissant ainsi un équilibre adéquat dans le système électrique.
- Nous avons déterminé la puissance active totale de génération $(P_g)_{\text{tot}}$ en prenant la valeur totale de la puissance de charge et en ajoutant 5% de cette valeur, ce pourcentage correspond en général aux pertes totales. Pour chaque point de fonctionnement, le calcul de (P_g) suit le même principe que celui utilisé pour (P_L) .
- Par la suite, nous avons procédé à un calcul d'écoulement de puissance pour ajuster les tensions, les angles et la puissance réactive de génération. Cette étape nous a permis d'optimiser les paramètres du système électrique et d'assurer un fonctionnement stable et équilibré.

Ce processus nous a conduit à la création de notre base de données, où chaque échantillon représente un point de fonctionnement à un moment précis. Afin d'obtenir de bons résultats d'apprentissage pour notre modèle de prévision de stabilité de tension, il est essentiel d'extraire les points de fonctionnement à partir d'une prévision de charge pour chaque instant dans une période de temps spécifiée. Cela nous permet de générer une courbe de charge qui respecte les contraintes imposées et assure un équilibre entre l'offre et la demande d'électricité.

4.3.2 Procédure d'apprentissage

Le perceptron multicouche est utilisé pour résoudre le problème de la stabilité de tension en utilisant l'algorithme de rétropropagation. Pendant le processus d'apprentissage, à la fois le modèle de réseau de neurones et la méthode conventionnelle d'indice de stabilité de tension reçoivent des valeurs d'entrée. Les sorties des deux systèmes sont ensuite comparées pour générer des signaux d'erreur. Ces signaux sont rétro-propagés aux couches de sortie et cachées afin d'ajuster les poids du réseau [60]. La figure suivante présente le schéma fonctionnel qui représente cette procédure :

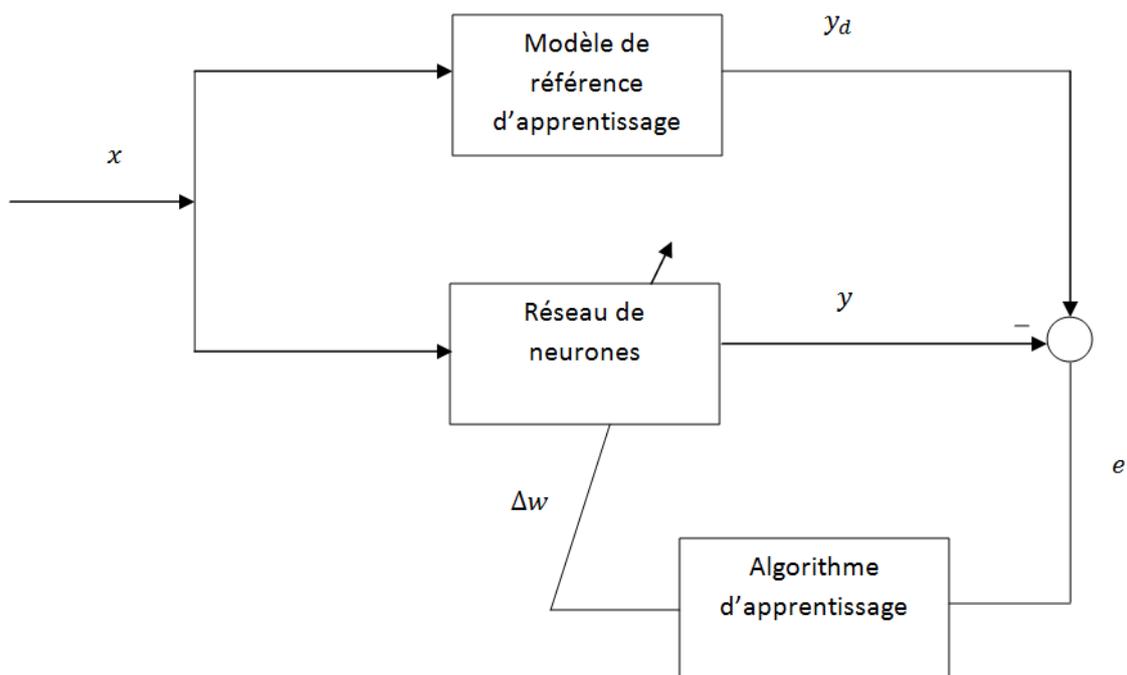


FIGURE 4.1 – Procédure d'apprentissage du réseau de neurones du système électrique [60].

où

x : Données d'entrée.

y_d : Sortie désirée.

y : Sortie prédite.

e : Erreur entre la sortie prédite et la sortie désirée.

Δw : Correction des poids.

Une fois que l'entraînement est terminé et que le modèle est correctement entraîné, nous passons à la phase de test qui calcule l'indice de stabilité (FVSI) en effectuant une propagation directe sur la base des poids et des biais finaux calculés lors de l'apprentissage. Pour chaque point de fonctionnement, la valeur de l'indice peut être déterminée en une seule itération, ce qui est plus rapide que les méthodes conventionnelles. Cela offre un avantage notable à notre approche basée sur l'intelligence artificielle, notamment lorsqu'il s'agit de traitement en ligne et du concept de boîte noire. Notons que nous avons ajouté le point de fonctionnement basique de réseau 14 nœuds lors de la phase de test puisque la donnée n'était pas utilisée pour faire entraîner le (PMC).

4.3.3 Réseau 14 nœuds

Pour résoudre le problème de stabilité de tension à l'aide d'un (PMC), il est important de sélectionner une architecture adaptée aux caractéristiques spécifiques du réseau électrique considéré. Dans ce cas précis, le réseau standard est constitué de 14 nœuds, comprenant 4 nœuds de génération (PV), 9 nœuds de charge (PQ) avec un nœud balancier, et 20 branches. Cela implique que nous disposons de 48 entrées, tandis que le nombre de neurones en sortie est de 1. De plus, nous avons choisi d'utiliser 7 neurones dans la couche cachée (selon la loi de Masters).

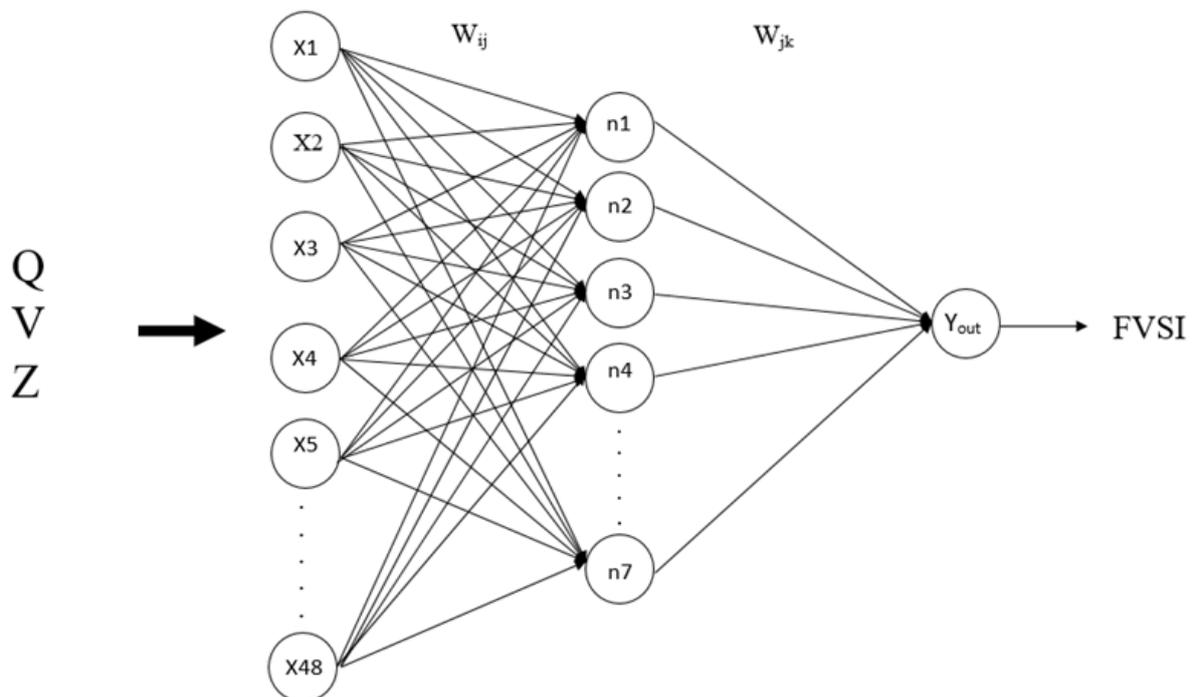


FIGURE 4.2 – Architecture du (PMC) proposée pour le calcul d'indice de stabilité de tension (FVSI).

Pour générer une base de données d'entrées et de sorties, nous avons développé un programme en utilisant le logiciel MATLAB, en suivant le processus que nous avons déjà décrit. Grâce à ce programme, nous avons pu créer 400 ensembles de données. Parmi ces 400 échantillons, 87% (350 échantillons) ont été réservés à l'apprentissage, tandis que les 13% restants (50 échantillons) ont été dédiés aux tests.

Chapitre 4. Application du RNA dans le calcul des indices de stabilité de tension

Après avoir réalisé plusieurs essais en ajustant différents paramètres, nous avons finalement trouvé une combinaison de paramètres qui est considérée comme optimale pour obtenir un calcul précis de l'indice recherché :

Taux d'apprentissage α	Neurones cachées	Tolérance	points d'entraînement
0.2	7	0.01	350

TABLE 4.1 – Paramètres optimaux pour le réseau 14 noeuds.

4.3.3.1 Résultats des tests

Le réseau de neurones qui a été entraîné sur 350 échantillons avec l'erreur la plus faible est considéré comme le meilleur modèle pour les tests. Lors de l'évaluation des performances du réseau de neurones avec 50 points de fonctionnement, les résultats obtenus, tels que ceux présentés dans le tableau (4.2), ont montré que 96%(48 échantillons) de ces points de fonctionnement ont présenté des performances similaires entre la méthode d'indice FVSI et la méthode de PMC , avec une différence d'erreur inférieure à 0.1. Cette faible marge d'erreur pour l'indice de stabilité démontre la capacité du réseau de neurones à prédire de manière précise cet indice pour la majorité des points de tests. Cette précision remarquable est nécessaire pour évaluer la stabilité d'un système et permet de prendre des décisions éclairées en se basant sur les prédictions du modèle.

Chapitre 4. Application du RNA dans le calcul des indices de stabilité de tension

Numéro	FVSI	PMC	Erreur
1	0.4187	0.4184	0.0003
2	0.3729	0.4195	0.0465
3	0.3729	0.4193	0.0464
4	0.3729	0.4188	0.0458
5	0.3729	0.4195	0.0465
6	0.3729	0.4193	0.0464
7	0.4726	0.4184	0.0542
8	0.4936	0.4184	0.0753
9	0.4431	0.4213	0.0218
10	0.4756	0.4184	0.0572
11	0.5322	0.4183	0.1138
12	0.3729	0.4188	0.0459
13	0.3729	0.4206	0.0476
14	0.4674	0.4193	0.0464
15	0.3877	0.4184	0.0490
16	0.3729	0.4184	0.0307
17	0.4273	0.4185	0.0456
18	0.4818	0.4212	0.0061
19	0.3729	0.4184	0.0634
20	0.3729	0.4204	0.0474
21	0.3729	0.4192	0.0463
22	0.3843	0.4184	0.0341
23	0.4672	0.4184	0.0488
24	0.3729	0.4184	0.0455
25	0.3729	0.4186	0.0457
26	0.4967	0.4184	0.0783
27	0.3729	0.4190	0.0460
28	0.4520	0.4184	0.0336
29	0.3804	0.4184	0.0380
30	0.3729	0.4189	0.0460
31	0.4408	0.4184	0.0224
32	0.4236	0.4184	0.0052
33	0.3729	0.4191	0.0461
34	0.4348	0.4184	0.0164
35	0.3729	0.4202	0.0472
36	0.4283	0.4212	0.0070
37	0.3729	0.4196	0.0467
38	0.3993	0.4184	0.0191
39	0.3729	0.4189	0.0460
40	0.5019	0.4184	0.0836
41	0.3729	0.4207	0.0478
42	0.3729	0.4205	0.0476
43	0.3729	0.4201	0.0472
44	0.4368	0.4184	0.0184
45	0.3729	0.4190	0.0460
46	0.5361	0.4183	0.1178
47	0.3729	0.4184	0.0455
48	0.4136	0.4184	0.00448
49	0.4796	0.4184	0.0613
50	0.4723	0.4184	0.0540

Chapitre 4. Application du RNA dans le calcul des indices de stabilité de tension

De plus, l'analyse visuelle des graphes tracés dans la figure (4.2) nous permettent de confirmer la fiabilité du PMC en évaluant à quel point les valeurs calculées correspondent aux valeurs désirées. Cela nous aide à prendre des décisions informées quant à l'efficacité du modèle et aux ajustements éventuels nécessaires pour améliorer ses performances.

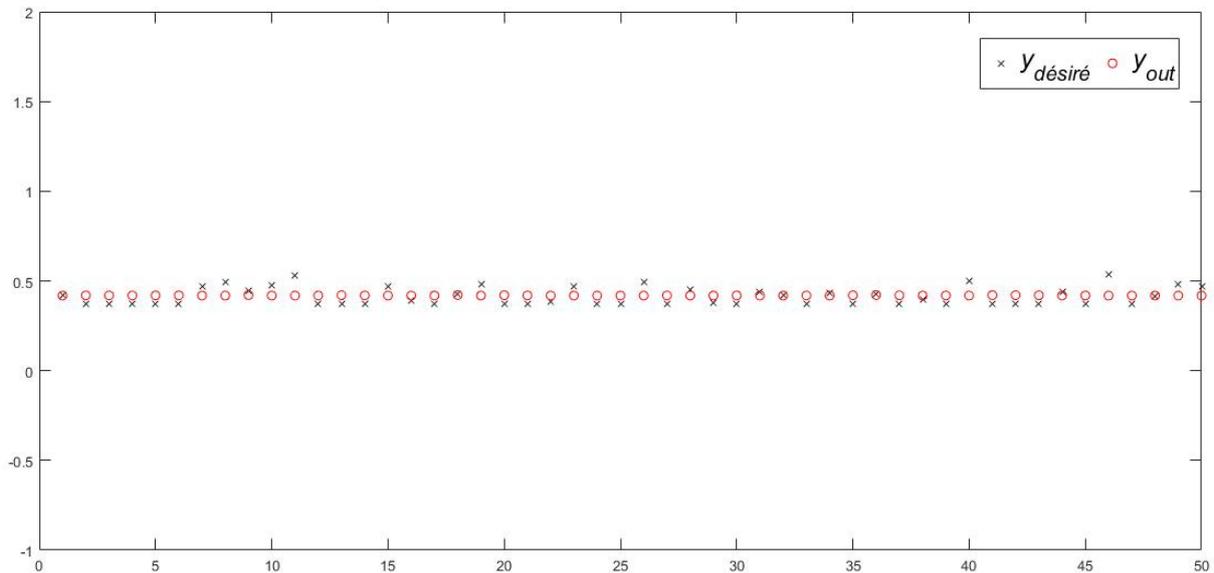


FIGURE 4.3 – Comparaison entre valeurs désirées de l'indice FVSI et valeurs calculées durant la phase de test.

Cependant, il est important de souligner que ces résultats pourraient être améliorés en optimisant davantage notre réseau de neurones. Pour cela, plusieurs aspects peuvent être pris en compte pour ajuster les paramètres du modèle, tels que la tolérance, le nombre de couches cachées, le taux d'apprentissage et la fonction d'activation. De plus, l'utilisation d'autres règles d'apprentissage ou l'exploration de différentes architectures de réseaux neuronaux peuvent également être bénéfiques.

Un autre aspect à considérer est la base de données utilisée pour l'entraînement du réseau. Il est possible que la base de données actuelle ne soit pas entièrement représentative de la réalité, ce qui peut limiter les performances du réseau de neurones. En effet, certaines variations ou scénarios spécifiques présents dans la réalité pourraient ne pas être correctement capturés par la base de données. Dans ce cas, il est essentiel de prendre en compte ces limites et de chercher des moyens d'améliorer la représentativité des données. Cela pourrait inclure l'augmentation de la taille de l'ensemble de données ou l'obtention de données plus diversifiées et représentatives.

En prenant en compte ces considérations et en réalisant des efforts supplémentaires pour optimiser le réseau de neurones, il est possible d'atteindre une meilleure précision et une plus grande fiabilité dans les prédictions de stabilité du système.

Après avoir appliqué l'algorithme de stabilité de tension du PMC au point de test de base du réseau 14 nœuds, nous avons obtenu des résultats significatifs qui sont présentés dans le tableau (4.3). Ce tableau met en évidence les prédictions de stabilité de tension

Chapitre 4. Application du RNA dans le calcul des indices de stabilité de tension

fournies par le modèle PMC pour ce point de fonctionnement standard, ainsi que les valeurs d'indice FVSI et les erreurs associées.

FVSI	PMC	L'erreur	L'état
0.3557	0.4167	0.061	Stable

TABLE 4.3 – Le résultat de test pour le réseau 14 noeuds standard.

Nous observons que l'erreur de prédiction obtenue est de seulement 0.061 bien en dessous de la tolérance 0.1. Ces résultats démontrent que le modèle du PMC établi pour le réseau 14 noeuds fonctionne de manière satisfaisante pour prédire la stabilité de tension du réseau, ce qui est essentiel pour assurer un fonctionnement fiable du système d'énergie.

4.4 Comparaison entre PV et indices

Dans le cadre de la validation de notre outil basé sur le RNA, nous avons sélectionné trois points spécifiques pour effectuer une comparaison avec les courbes PV afin de déterminer leur stabilité. Nous traçons d'abord la courbe PV pour chacun de ces points de fonctionnement. Ensuite, nous déterminons la tension critique pour l'extrémité de chaque ligne et estimons également la tension obtenue par la projection de P sur chaque courbe. En comparant ces valeurs, si la tension obtenue ($V_{tirée}$) est supérieure à la tension critique ($V_{critique}$), cela indique que le point est stable. Dans le cas contraire, s'il est inférieur, cela suggère que le point est instable. Nous pourrions confirmer cette conclusion en effectuant des calculs d'indice appropriés.

point 1		point 2		point 3	
$V_{critique}$	V_{tire}	$V_{critique}$	V_{tire}	$V_{critique}$	V_{tire}
0.7842	1.0474	0.8829	1.0800	1.9995	0.4333
0.7862	1.0465	0.8491	1.0606	1.9492	0.1516
0.7806	1.0455	0.8409	1.0478	1.9176	0.1245
0.7287	0.9640	0.7823	0.9782	1.9198	0.1501
0.7317	1.0009	0.7574	0.9648	1.8907	0.00654
0.7663	1.0008	0.8206	0.9641	1.9941	0
0.8185	1.0042	0.8711	1.0053	2.0499	0.2263
0.7942	1.0416	0.8470	1.0449	2.0073	0.1453
0.7993	1.0415	0.9026	1.0437	2.1418	0.1256
0.8013	1.0417	0.9137	1.0467	2.1470	0.1844
0.7840	1.0418	0.9072	1.0474	2.1453	0.1950
0.7636	1.0132	0.8555	1.0132	2.0495	0
0.7722	1.0257	0.8281	0.9828	2.0176	0
0.7760	1.0322	0.8482	0.9856	2.0489	0.2221
0.7901	1.0247	0.8423	0.9835	2.0488	0.2931
0.7855	1.0317	0.8522	0.9855	2.0522	0.1233
0.7887	1.0318	0.8824	1.0076	2.0549	0.1643
0.7930	1.0240	0.8561	0.9750	2.0539	0.2779

TABLE 4.4 – Résultats de comparaison.

Chapitre 4. Application du RNA dans le calcul des indices de stabilité de tension

Point	FVSI	PMC	L'erreur	L'état
1	0.4187	0.4181	0.0003	Stable
2	0.4283	0.4212	0.007	Stable
3	1.4106	1.4281	0.0175	Instable

TABLE 4.5 – Comparaison d'indices FVSI et PMC

4.4.1 Discussions

Une analyse comparative approfondie entre l'indice de stabilité et les courbes PV permet de mettre en évidence des observations encore plus significatives, renforçant ainsi la crédibilité des résultats obtenus lors du test. En examinant les valeurs de tension obtenues par projection ($V_{tirée}$) par rapport au seuil critique (V_{crit}) pour les différents points étudiés dans le tableau 4.4, une tendance claire émerge. Pour les points 1 et 2 spécifiques, les valeurs de tension dépassent le seuil critique, ce qui indique une stabilité du système à ces emplacements précis. Cette constatation est étayée par l'indice de stabilité présenté dans le tableau 4.5, qui confirme également la stabilité de ces points. Cette corroboration entre les mesures de tension et l'indice de stabilité renforce la validité des résultats obtenus et souligne l'importance cruciale de maintenir la stabilité des points de fonctionnement dans les systèmes électriques.

Cependant, le troisième point étudié présente un comportement opposé, révélant une instabilité. Les valeurs de tension obtenues par projection sont inférieures au seuil critique, ce qui indique clairement une instabilité du système à ce point particulier. Encore une fois, ces résultats sont cohérents avec les données de l'indice de stabilité qui mettent en évidence cette instabilité.

Il est toutefois essentiel de noter que ces conclusions spécifiques ne peuvent être généralisées à l'ensemble du système sans une analyse plus approfondie. Une évaluation complète de la stabilité globale du système nécessite la prise en compte d'autres facteurs et points de fonctionnement.

Conclusion générale

Ce mémoire présente l'application des méthodes conventionnelles telles que les courbes PV, QV, CPF et les indices de stabilité, ainsi que l'utilisation des réseaux de neurones artificiels avec un perceptron multicouche à une couche cachée pour le calcul d'indices de stabilité de tension. Une étude comparative a été réalisée pour évaluer les performances de ces différentes méthodes.

Dans la première partie du mémoire, une compréhension approfondie des méthodes conventionnelles d'analyse de la stabilité de tension a été développée et elles ont été implémentées en utilisant MATLAB. Les programmes développés ont été soumis à des tests et validés sur plusieurs réseaux standards tels que IEEE 14 bus, IEEE 30 bus, IEEE 9 bus. Toutefois, dans le cadre de ce mémoire, nous nous sommes concentrés exclusivement sur le réseau IEEE 14 nœuds, dont les résultats ont été présentés en détails.

Les résultats obtenus pour divers réseaux standards, notamment le réseau IEEE 14 bus, ont révélé des informations cohérentes concernant les nœuds forts et faibles du réseau, ainsi que la marge de stabilité de chaque nœud. Ces résultats ont permis de mieux comprendre la dynamique de la stabilité de tension dans ce réseau et ont fourni des indications précieuses pour l'identification des nœuds critiques.

La dernière partie du mémoire concerne l'application du perceptron multicouche au calcul de l'indice de stabilité FVSI pour un réseau électrique. En général, cette approche est utilisée pour résoudre des problèmes de régression, et les résultats ont montré que le perceptron multicouche peut prédire avec précision les valeurs des indices analytiques, même sans connaître la formulation mathématique sous-jacente.

Une architecture de réseau de neurones a été choisie en fonction des caractéristiques du réseau électrique, et un algorithme d'entraînement basé sur la rétropropagation des erreurs a été utilisé. Les résultats obtenus pour le réseau à 14 nœuds (IEEE 14 bus) ont montré que le perceptron multicouche peut produire des résultats proches de ceux des méthodes conventionnelles, en particulier du calcul analytique de l'indice FVSI. De plus, le perceptron multicouche s'est avéré intéressant et plus rapide, pour traiter le problème d'analyse de stabilité de tension d'un système donné, évitant ainsi les problèmes de complexité des méthodes conventionnelles et les risques de blocage ou de divergence. Cette technique pourrait être développée pour des réseaux de plus grande dimension, offrant ainsi une alternative supplémentaire pour une utilisation pratique.

En conclusion, ce mémoire démontre que les méthodes conventionnelles telles que les courbes PV, QV, CPF et les indices de stabilité, ainsi que l'utilisation de réseaux de neurones artificiels avec un perceptron multicouche, sont des outils efficaces pour analyser la stabilité de tension dans les réseaux électriques. Le perceptron multicouche présente des avantages en termes de rapidité, d'efficacité et de capacité d'apprentissage, et peut être une alternative pratique pour l'analyse de stabilité de tension, en particulier pour les réseaux de plus grande dimension.

Perspectives

Nous proposons comme éventuelles perspectives l'exploration de différentes configurations d'architecture pour améliorer les résultats de l'analyse de la stabilité de tension par les RNA. Cela comprendrait l'ajustement du nombre de couches cachées, du nombre d'entrées, ainsi que d'autres aspects architecturaux.

En ajustant le nombre de couches cachées, il est possible d'explorer différentes profondeurs du modèle pour déterminer celle qui offre les meilleures performances de prédiction. Une architecture avec un nombre approprié de couches cachées peut permettre au réseau de capturer des relations complexes entre les entrées et les sorties, conduisant à des résultats améliorés.

De même, l'ajustement du nombre d'entrées et de sorties peut être bénéfique pour adapter le modèle aux caractéristiques spécifiques de l'analyse de la stabilité de tension. Il peut être intéressant d'explorer si l'inclusion de certaines variables ou l'exclusion d'autres peut conduire à de meilleurs résultats.

En plus de ces ajustements architecturaux, il est important de souligner que l'optimisation des autres paramètres du modèle, tels que la tolérance, le taux d'apprentissage et la fonction d'activation, reste essentielle pour améliorer les performances du réseau de neurones. L'expérimentation avec différentes valeurs de ces paramètres peut aider à trouver la combinaison optimale pour la tâche spécifique d'analyse de la stabilité de tension.

Bibliographie

1. STEINMETZ, C. P. Electric Generating Stations the American Institute of Electrical Engineers,(July 1920).
2. AIEE COMMITTEES. First Report Of Power System Stability Committee Report 282.p. 21 (fév. 1937).
3. P.KUNDIR. Definition and Classification of Power System Stability IEEE/CIGRE Joint Task Force on Stability Terms and Definitions. en. *IEEE Transactions on Power Systems* **19**, 1387-1401. ISSN : 0885-8950. <http://ieeexplore.ieee.org/document/1318675/> (2023) (août 2004).
4. KAZEMI, A. & BADRZADEH, B. Modeling and simulation of SVC and TCSC to study their limits on maximum loadability point. *International Journal of Electrical Power & Energy Systems* **26**, 381-388. ISSN : 01420615. <https://linkinghub.elsevier.com/retrieve/pii/S0142061503001364> (2023) (juin 2004).
5. K.VALERIJS. Stability of Power Systems with Large Amounts of Distributed Generation. en. *Doctoral Thesis Stockholm, Sweden*, 172 (2004).
6. BOURZAMI, A. Contribution à l'étude de la stabilité des grands réseaux électriques dans un marché de l'électricité dérégulé en présence des sources d'énergie renouvelable par la logique floue. *Thèse de doctorat, Univ.Ferhat Abbas-Setif 1*.
7. J.PASERBA. Control of Power System Oscillations. en. *IFAC Proceedings Volumes* **30**, 75-83. ISSN : 14746670. <https://linkinghub.elsevier.com/retrieve/pii/S1474667017463890> (2023) (août 1997).
8. BENASLA, M. Apport du SMES comme stockage d'énergie aux performances de l'HVDC pour améliorer la stabilité d'un réseau électrique. fr. Publisher : Unpublished. <http://rgdoi.net/10.13140/RG.2.2.35802.34245> (2023) (2011).
9. HELLAL, A. Analyse de la stabilité de tension. fr. *Polycopié du cours,Ecole Nationale Polytechnique,Alger* (2022).
10. VAN CUTSEM, T. & VOURNAS, C. D. *Emergency Voltage Stability Controls : an Overview* en. in *2007 IEEE Power Engineering Society General Meeting* ISSN : 1932-5517 (IEEE, Tampa, FL, USA, juin 2007), 1-10. ISBN : 978-1-4244-1296-9 978-1-4244-1298-3. <http://ieeexplore.ieee.org/document/4275855/> (2023).
11. D.LEBLANC. Contribution a l'étude de la stabilité et à la stabilisation des reseaux electriques industriels. fr. *Docteur de l'Université de Lorraine Spécialité : Génie Electrique* (juill. 2014).
12. CUTSEM, T. & VOURNAS, C. *Voltage Stability of Electric Power Systems* en. ISBN : 978-0-387-75535-9 978-0-387-75536-6. <http://link.springer.com/10.1007/978-0-387-75536-6> (2023) (Springer US, Boston, MA, 1998).

13. PRAING, C. Stabilité d'un réseau de transport avec pôles de production et de consommation éloignés en période de forte croissance. fr, 179 (oct. 2000).
14. MEKHNANE ET AL, M. *Etude de la Stabilité de Tension*. Master (Université 8Mai 1945,Guelma, 2022). 55 p.
15. A.GACEM. Commande Robuste d'un Dispositif FACTS par les Méthodes Métaheuristiques pour la Stabilité de Tension d'un Réseau Electrique. *Doctorat Université Mohamed Khider Biskra*, 144 (avr. 2019).
16. LAIFA, A. Evaluation de la Stabilité de Tension d'un Réseau d'énergie électrique Développement et Application Des Indices De Stabilité. *thèse de Magister, Ecole Nationale polytechnique* (juin 1995).
17. R.BENABID. Optimisation Multiobjective De La Synthèse Des Facts Par Les Particules En ESSAIM Pour Le Controle De La Stabilité De Tension Des Réseaux Electriques, Magister(Université Amar Thelidji LAGHOUAT - 2007).
18. DOBSON, I., DEPARTMENT, E., CARRERAS, B. A., LYNCH, V. E. & NEWMAN, D. E. An initial model for complex dynamics in electric power system blackouts, Hawaii International Conference on System Sciences, (January 2001), Maui, Hawaii. en.
19. LU, W., BÉSANGER, Y., ZAMAĪ, E. & RADU, D. Blackouts : Description, Analysis and Classification September 2006 Lisbon, Portugal. 434 p. en.
20. PRABHA, K. *Power-System-Stability-and-Control* 1199 p. (McGraw-Hill, 1994).
21. KHAN, A. A. A Simple Method for Tracing PV Curve of a Radial Transmission Line, World academy of science, Engineering and Technology (2008).
22. *Computational Techniques for Voltage Stability Assessment and Control* (éd. AJJARAPU, V.) (Springer US, Boston, MA, 2007). ISBN : 978-0-387-26080-8. <http://link.springer.com/10.1007/978-0-387-32935-2> (2023).
23. CHAKRABARTI, S. Notes on Power System Voltage Stability, Dept of EE, IIT, Kanpur.
24. KESKIN, M. B. *Continuation power flow and voltage stability in power systems* Master degree in electrical and electronic engineering (Middle east technical university, sept. 2007).
25. KARBALAEI, F., SOLEYMANI, H. & AFSHARNIA, S. *A comparison of voltage collapse proximity indicators in 2010 Conference Proceedings IPEC Energy Conference (IPEC 2010)* (IEEE, Singapore, Singapore, oct. 2010), 429-432. ISBN : 978-1-4244-7399-1. <http://ieeexplore.ieee.org/document/5697034/> (2023).
26. KWATNY, H., PASRIJA, A. & BAHAR, L. Static bifurcations in electric power networks : Loss of steady-state stability and voltage collapse. *IEEE Transactions on Circuits and Systems* **33**, 981-991. ISSN : 0098-4094. <http://ieeexplore.ieee.org/document/1085856/> (2023) (oct. 1986).
27. NAGESWA RAO, A., VIJAYA, P. & KOWSALYA, M. Voltage stability indices for stability assessment : a review. *International Journal of Ambient Energy* **42**, 829-845. ISSN : 0143-0750, 2162-8246. <https://www.tandfonline.com/doi/full/10.1080/01430750.2018.1525585> (2023) (19 mai 2021).
28. A.MOHAMED, G.B.JASMON & S.YUSOF. A static voltage collapse indicator using line stability factors. *Journal of industrial technology* (1998).

29. KESSEL, P. & GLAVITSCH, H. Estimating the Voltage Stability of a Power System, IEEE Trans. on Power Delivery vol. 1, pp. 346–352, 1986.
30. M.H.HAQUE. Use of Local Information to Determine the Distance to Voltage Collapse. *International Journal of Emerging Electric Power Systems*. ISSN : 21945756, 1553779X (2008).
31. RANJAN, R. & DAS, D. Voltage Stability Analysis of Radial Distribution Networks. *Electric Power Components and Systems* **31**, 501-511. ISSN : 1532-5008, 1532-5016. <http://www.tandfonline.com/doi/abs/10.1080/15325000390127011> (2023) (mai 2003).
32. RAHMAN, T. & JASMON, G. A new technique for voltage stability analysis in a power system and improved loadflow algorithm for distribution network in *Proceedings 1995 International Conference on Energy Management and Power Delivery EMPD '95* 1995 International Conference on Energy Management and Power Delivery EMPD '95. **2** (IEEE, Singapore, 1995), 714-719. ISBN : 978-0-7803-2981-2. <http://ieeexplore.ieee.org/document/500816/> (2023).
33. MUSIRIN, I. & ABDUL RAHMAN, T. Novel fast voltage stability index (FVSI) for voltage stability analysis in power transmission system in *Student Conference on Research and Development 2002* Student Conference on Research and Development. SCOReD2002.. Global Research and Development in Electrical and Electronics Engineering (IEEE, Shah Alam, Malaysia, 2002), 265-268. ISBN : 978-0-7803-7565-9. <http://ieeexplore.ieee.org/document/1033108/> (2023).
34. GÉRARD DREYFUS *et al.* in *Réseaux de neurones - Méthodologie et applications* 2002^e éd. ().
35. *The handbook of brain theory and neural networks* (éd. ARBIB, M. A.) 2nd ed (MIT Press, Cambridge, Mass, 2003). 1290 p. ISBN : 978-0-262-01197-6.
36. LIU, T. Implémentation de méthodes d'intelligence artificielle pour le contrôle du procédé de projection thermique.(Université de Belfort-Montbeliard,2013).
37. MCCULLOCH, W. S. & PITTS, W. A Logical Calculus Of The Ideas Immanent In Nervous Activity (University of Chicago, Chicago, USA).
38. B.HABIBOULLAH, B. Utilisation des réseaux de neurones artificiels pour la prédiction de la vitesse de vent Université Mohamed Boudiaf M'Sila 61.p. *Master* (2017).
39. TOUZET, C. Les Reseaux De Neurones Artificiels-Introduction Au Connexionnisme (juill. 1992).
40. SATHELLY, B. An Artificial Neural Network Approach to Predict Liver Failure Likelihood. (Master of Science Degree in Engineering Computer Science The University of Toledo 2018).
41. MASTERS, T. *Practical neural network recipes in C++* 493 p. ISBN : 978-0-12-479040-7 (Academic Press, Boston, 1993).
42. BRAKNI, E. M. Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire infiniTEM l'université du Quebec à Chicoutimi (Mai 2011) 96.p. fr.
43. COULIBALY, P. Préviation hydrologique par réseaux de neurones artificiels : état de l'art CNRC Canada. fr. **26** (le 31 octobre 1999).

44. KOHONEN, T. *Self-Organization and Associative Memory* en (éd. HUANG, T. S. & SCHROEDER, M. R.) ISBN : 978-3-540-18314-3 978-3-662-00784-6. <http://link.springer.com/10.1007/978-3-662-00784-6> (2023) (Springer Berlin Heidelberg, Berlin, Heidelberg, 1988).
45. HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. en. *Proc Nat Acad Sci* **79** :2554–2558.
46. CHATTERJEE, A. Art in an age of artificial intelligence. en. *Frontiers in Psychology* **13**, 1024449. ISSN : 1664-1078. <https://www.frontiersin.org/articles/10.3389/fpsyg.2022.1024449/full> (2023) (nov. 2022).
47. BENARDOS, P. & VOSNIAKOS, G.-C. Optimizing feedforward artificial neural network architecture National Technical University of Athens, Greece. en. *Engineering Applications of Artificial Intelligence* **20**, 365-382. ISSN : 09521976. <https://linkinghub.elsevier.com/retrieve/pii/S0952197606001072> (2023) (avr. 2007).
48. H.SALHI. A Brief Review Of Feed-Forward Neural Networks Ankara University, TURKEY (27 Jun 2006).
49. THANH NGUYEN, T., NGO, T.-Q., DUONG, T. L. & NGUYEN, T. T. Finding Radial Network Configuration of Distribution System Based on Modified Symbiotic Organisms Search. en. *Complexity* **2021** (éd. ALEXANDRIDIS, A.) 1-23. ISSN : 1099-0526, 1076-2787. <https://www.hindawi.com/journals/complexity/2021/7135318/> (2023) (fév. 2021).
50. MOMOH, J., DIAS, L. & ADAPA, R. *Investigation of artificial neural networks for voltage stability assessment in 1995 IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century* 1995 IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century. **3** (IEEE, Vancouver, BC, Canada, 1995), 2188-2192. ISBN : 978-0-7803-2559-3. <http://ieeexplore.ieee.org/document/538105/> (2023).
51. GUPTA, N. Artificial Neural Network Institute of Engineerinf and Technology,DAVV,Indore (2013) 28.p. en.
52. Artificial Neural Networks. *Steven Walczak University of Colorado, Denver Narciso Cerpa University of Talca, Chile.*
53. A.HELLAL. Réseaux de Neurones Artificiels. *Polycopié du cours,Ecole Nationale Polytechnique,Alger* (2021).
54. KROGH, A. What are artificial neural networks? en. *Nature Biotechnology* **26**, 195-197. ISSN : 1087-0156, 1546-1696. <https://www.nature.com/articles/nbt1386> (2023) (fév. 2008).
55. BISHOP, C. M. Neural networks and their applications .Aston University, Birmingham, B4 7EI; United Kingdom. en. *Neural networks* **65** (1 March 1994).
56. A.A. EL-KEIB & X.MA. *Application of artificial neural networks in voltage stability assessment ,IEEE Transactions on power systems*, Alabama, Tuscaloosa, nov. 1995.
57. AL-SAMMARRAIE, N. A., AL-MAYALI, Y. M. H. & BAKER EL-EBIARY, Y. A. *Classification and diagnosis using back propagation Artificial Neural Networks (ANN)* en. in *2018 International Conference on Smart Computing and Electronic Enterprise (ICSC EE)* (IEEE, Shah Alam, juill. 2018), 1-5. ISBN : 978-1-5386-4836-0 978-1-5386-4838-4. <https://ieeexplore.ieee.org/document/8538383/> (2023).

58. TU, J. V. Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. en. *Journal of Clinical Epidemiology* **49**, 1225-1231. ISSN : 08954356. <https://linkinghub.elsevier.com/retrieve/pii/S0895435696000029> (2023) (nov. 1996).
59. M.DAOUDI, Y. Prédiction de la tension de claquage d'une configuration pointe-barrière-plan polluée par l'approche basée sur l'intelligence artificielle Université Mohamed Boudiaf M'sila. *Master* (2019).
60. RIVALS, I., PERSONNAZ, L., DREYFUS, G. & PLOIX, J. L. Modélisation, Classification Et Commande Par Réseaux De Neurones : Principes Fondamentaux, Méthodologie de Conception Et Illustrations Industrielle Ecole Supérieure de Physique et de Chimie Industrielles de la Ville de Paris (January 1995) 42.p. fr.

Annexe

Annexe A

Données du système de test

A.1 Données du réseau 14 nœuds (point de fonctionnement standard)

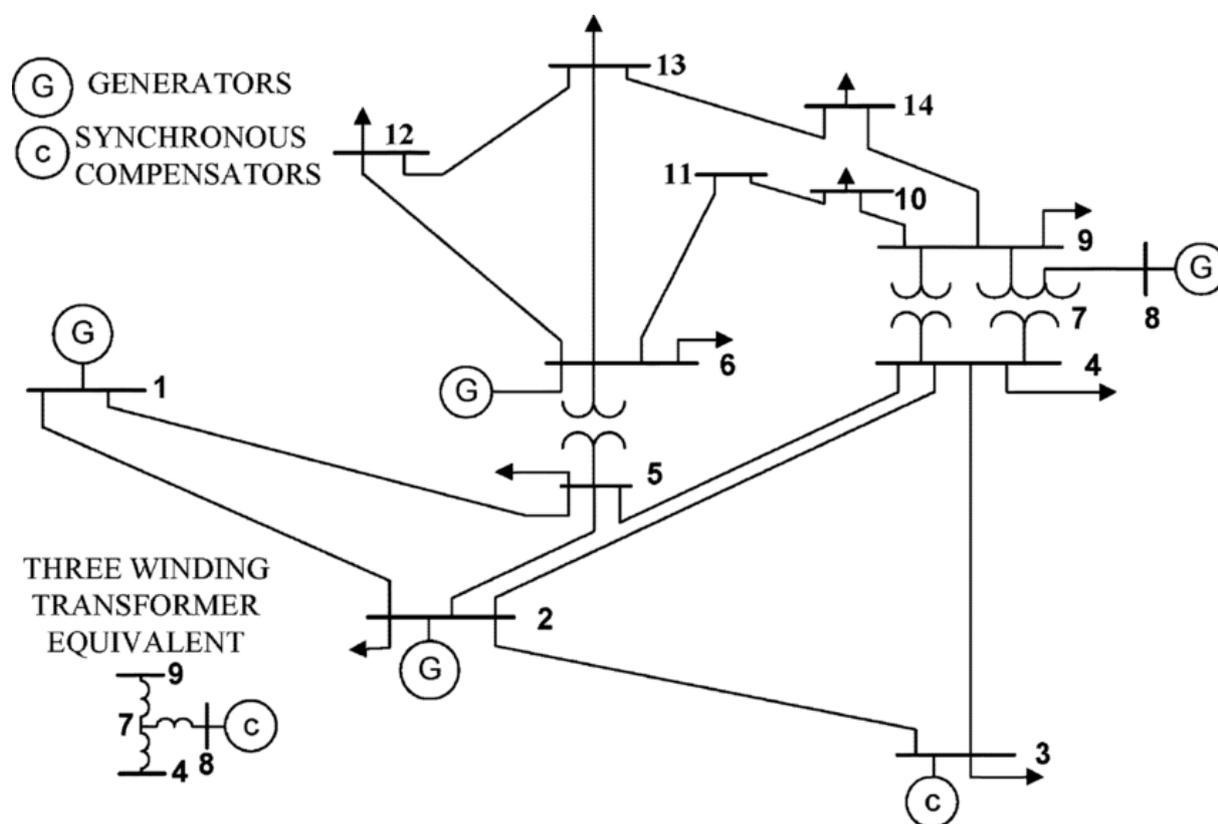


FIGURE A.1 – Schéma unifilaire pour un réseau électrique standard à 14 nœuds.

A.2 Données des nœuds

Numéro de nœud	Type	V [p.u]	Ang [Deg]	Pi [MW]	Qi [MVAR]	Pgen [MW]	Qgen [MVAR]
1	3	1.060	0.00	0.0	00.0	232.4	-16.9
2	2	1.045	-4.98	21.7	12.7	40.0	42.4
3	2	1.010	-12.72	94.2	19.0	0.0	23.4
4	0	1.019	-10.33	47.8	-3.9	0.0	0.0
5	0	1.020	-8.78	7.6	1.6	0.0	0.0
6	2	1.070	-14.22	11.2	7.5	0.0	12.2
7	0	1.062	-13.37	0.0	0.0	0.0	0.0
8	2	1.090	-13.36	0.0	0.0	0.0	17.4
9	0	1.056	-14.94	29.5	166	0.0	0.0
10	0	1.051	-15.10	9.0	5.8	0.0	0.0
11	0	1.057	-14.79	3.5	1.8	0.0	0.0
12	0	1.055	-15.07	6.1	1.6	0.0	0.0
13	0	1.050	-15.16	13.5	5.8	0.0	0.0
14	0	1.036	-16.04	14.9	5.0	0.0	0.0

TABLE A.1 – Données des nœuds.

A.3 Données des lignes

Numéro de ligne	R[p.u]	X[p.u]	B[p.u]
1-2	0.01938	0.05917	0.0528
1-5	0.05403	0.22304	0.0492
2-3	0.04699	0.19797	0.0438
2-4	0.05811	0.17632	0.0340
2-5	0.05695	0.17388	0.0346
3-4	0.06701	0.17103	0.0128
4-5	0.01335	0.04211	0.0
4-7	0.0	0.20912	0.0
4-9	0.0	0.55618	0.0
5-6	0.0	0.25202	0.0
6-11	0.09498	0.19890	0.0
6-12	0.12291	0.25581	0.0
6-13	0.06615	0.13027	0.0
7-8	0.0	0.17605	0.0
7-9	0.0	0.11001	0.0
9-10	0.03181	0.08450	0.0
9-14	0.12711	0.27038	0.0
10-11	0.08205	0.19207	0.0
12-13	0.22092	0.19988	0.0
13-14	0.17093	0.34802	0.0

TABLE A.2 – Données des lignes.