

UNIVERSITE SAAD DAHLEB DE BLIDA

Faculté de Technologie

Département de Génie Civil

MEMOIRE DE MASTER EN GENIE CIVIL

Spécialité : Structure et Matériaux

**EVALUATION DE L'EXCENTRICITE ACCIDENTELLE PAR
LES RNAs A PARTIR D'UNE REponse DYNAMIQUE**

Présenté par :

Ismail DERBAL

Proposé par :

Professeur N.BOURAHLA

Blida, Septembre 2013



RÉSUMÉ

الملخص

تدرج القوانين المضادة للزلازل البعد اللاتمركزي الارتياحي كنسبة مئوية (5% أو 10%) من البعد العمودي على محور الاهتزاز الزلزالي للأخذ بعين الاعتبار كل الارتياحات و الأخطاء في الخصائص الهندسية و الميكانيكية للبنية الأساسية للبناء، كذا نتيجة التكسر العشوائي للعناصر التي لا تنتمي للبنية، وكذلك عدم توازن توزيع حملات الاستعمال.

نظرا لهذه الطبيعة العشوائية للعوامل المتسببة في البعد اللاتمركزي الارتياحي والتي من الصعب معرفتها بالتدقيق ومعرفة تأثيراتها. فان مشروع هذا البحث يهدف إلى وضع إمكانية و طريقة لحساب تأثير الفتل العرضي الناتج عن البعد اللاتمركزي الارتياحي على تصرف البناية باستخدام طريقة الشبكات العصبية الاصطناعية. بحيث يستخدم الانتقال على جانبي الأرضية كمدخل لنماذج الشبكات العصبية الاصطناعية، وانتقال مركز الكتلة ومركز صلابة كمخرج لها. وبواسطة عملية حسابية هندسية بسيطة يمكن الحصول على البعد اللاتمركزي الحقيقي واستنتاج البعد اللاتمركزي الارتياحي.

ABSTRACT

The seismic codes specify the accidental eccentricity as a percentage (5% or 10%) of the building dimension perpendicular to the direction of excitation, to account all uncertainties and errors of evaluation of the geometrical and mechanical characteristics of the structural elements, the random rupture of the nonstructural elements, or space variability of the permanent loads, and with an unfavorable distribution of the live loads.

Because of the random and uncertain nature of the factors responsible for the accidental eccentricity, it is very difficult to evaluate explicitly and with precision its effect on the total seismic response of constructions. In this context, this research project attempts to develop a procedure for the quantification of the effect of torsion induced by accidental eccentricity using artificial neural networks method. The displacements of rigid and flexible sides are used as INPUT of neural network models and the displacements of the mass and rigidity centers as OUTPUT. Thus by a simple geometric calculation can obtain real eccentricity and deduct the accidental eccentricity.

RÉSUMÉ

Les règlements parasismiques spécifient l'excentricité accidentelle en pourcentage (5% ou 10%) de la dimension du bâtiment perpendiculaire à la direction de l'excitation, pour tenir compte toutes les incertitudes et les erreurs d'évaluation des caractéristiques géométriques et mécaniques des éléments structuraux et la rupture aléatoire des éléments non structuraux, ou encore à la variabilité spatiale des charges permanentes ou à une distribution défavorable des charges d'exploitation.

Eu égard, à la nature aléatoire et incertaine des facteurs responsables de l'excentricité accidentelle, il s'avère très difficile d'évaluer explicitement et avec précision son effet sur la réponse sismique globale des constructions. Dans cette optique, le présent projet consiste à développer une procédure pour la quantification de l'excentricité à partir d'une réponse dynamique de la structure en utilisant la méthode des réseaux de neurones artificiels. Les déplacements sur les deux côtés du plancher sont utilisés comme entrée pour les modèles de RNAs, et les déplacements du centre de masse et du centre de rigidité comme sortie. Ainsi par un simple calcul géométrique on peut obtenir l'excentricité réelle et déduire l'excentricité accidentelle.

REMERCIEMENTS

Tout d'abord, je tiens à remercier Allah, le clément et le miséricordieux de m'avoir donné la force et le courage de mener à bien ce modeste travail.

Je souhaite exprimer, tout particulièrement, mes vifs remerciements et ma profonde reconnaissance à mon directeur de mémoire Prof. N. BOURAHLA de m'avoir fait confiance et d'avoir accepté de diriger ce mémoire et qui, malgré ses multiples obligations, n'a jamais ménagé aucun effort pour suivre cette étude de près pendant toute la durée du travail, et pour son soutien moral qui n'a pas cessé même dans les moments difficiles.

Je tiens également à remercier les membres de jury pour l'honneur qu'ils m'ont accordé en acceptant de juger ce travail.

Mes sincères remerciements sont réservés à l'ensemble des enseignants du département de génie civil de l'USDB qui ont contribué de près ou de loin à ma formation.

Je remercie également tous ceux qui ont aidé de près ou de loin à élaborer ce modeste travail.

LISTE DES SYMBOLES ET DES ABREVIATIONS

RNAs:	Réseau de neurones artificiel
UBC:	Uniform building code
IBC:	International Building Code
NBCC:	National Building Code of Canada
EC8 :	European code n°8
CM :	Centre de masse
CR :	Centre de rigidité
eD :	Excentricité de conception (m)
ed :	Excentricité dynamique (m)
ea = β xb :	Excentricité accidentelle (m)
eo :	Excentricité statique (m)
X _{CM} , Y _{CM} :	Cordonnées du centre de masse (m)
X _{CR} , Y _{CR} :	Cordonnées du centre de rigidité (m)
Ω :	Rapport de fréquence
Mt :	Moment de torsion à la base de la structure (KN.m)
Θ :	L'angle de rotation du bâtiment (Rad)
T :	Effort tranchant à la base de la structure (KN)
FL :	Effort tranchant latéral (KN)
Ft :	Effort dû au moment de torsion (KN)
ft, fi :	Fréquence de rotation et de translation (HZ)

ξ_t, ξ_l :	Amortissement structurel de rotation et translation (%)
L :	Dimension du bâtiment (m)
b :	Dimension du bâtiment perpendiculaire à l'excitation sismique (m)
ρ_k :	Coefficient adimensionnel de rigidité
K :	Rigidité de translation (KN/m)
K_θ :	Rigidité de rotation (KN.m)
X_r, X_f :	Déplacement des bords rigides et flexibles (m)
MLPs :	Perceptron multicouches
RPG :	Rétropropagation

TABLE DES MATIERES

Résumé	
Remerciements	
Liste des Symboles et des Abréviations	
Table des matières	
Listes des Illustrations, Graphiques et Tableaux	
Introduction générale.....	1
CHAPITRE 1: LA TORSION DES BATIMENTS	4
1.1. Introduction	4
1.2. Origines du phénomène de torsion	5
1.3. Constructions susceptibles à des endommagements de torsion	6
1.3.1. Bâtiments à angles rentrants	6
1.3.2. Variation de la rigidité et la résistance du périmètre du bâtiment	7
1.3.3. Bâtiment à systèmes résistants non parallèles.....	7
1.4. Sources de la torsion accidentelle	7
1.4.1. Mouvement rotationnel de la base de la structure	7
1.4.2. Incertitude dans la rigidité des éléments	7
1.4.3. Incertitude dans la localisation du centre de masse.....	8
1.4.4. Incertitude dans l'évaluation du seuil de la résistance des éléments.....	8
1.5. Couplage et amplification dynamique des vibrations de torsion.....	8
1.6. Considération de la torsion accidentelle dans les règlements parasismiques	9
1.7. Revue des travaux récents sur l'évaluation de l'excentricité accidentelle.....	11
1.8. Conclusion	14
CHAPITRE 2: LES RESEAUX DE NEURONES ARTIFICIELS	15
2.1. Introduction	15
2.2. Modèle d'un neurone.....	15

2.3.	Fonctions de transfert	16
2.4.	Architecture de réseau	18
2.5.	L'apprentissage des réseaux de neurones	19
2.5.1.	Définition	20
2.5.2.	Les types d'apprentissage	20
2.5.3.	L'apprentissage des réseaux de neurones formels	21
2.6.	Les différents types de réseaux de neurones	22
2.7.	Principe de rétropropagation	23
2.8.	Choix de l'architecture	23
2.9.	Propriétés des réseaux de neurones	24
2.10.	Les applications des réseaux de neurones en génie civil.....	25
2.11.	Conclusion.....	27
CHAPITRE 3: EVALUATION DE L'EXCENTRICITE ACCIDENTELLE PAR LES RNAs A PARTIR D'UNE REponse DYNAMIQUE		28
3.1.	Introduction	28
3.2.	Principe et méthodologie	28
3.3.	Etablissement du modèle de réseau de neurones	32
3.4.	Choix du réseau.....	34
3.5.	Facteurs influents sur la conception du RNAs	35
3.6.	L'architecture du réseau	35
3.6.1.	Modèle de RN pour la prédiction du déplacement du centre de masse	37
3.6.2.	Modèle de RN pour la prédiction du déplacement du centre de rigidité	37
3.7.	Apprentissage des modèles de réseau de neurones	38
3.7.1.	La base de données d'apprentissage du RNAs	38
3.7.2.	La stratégie d'apprentissage du réseau de neurones	40
3.7.3.	L'apprentissage	41
3.8.	Test et validation	43
3.8.1.	Base de données de validation	44
3.8.2.	Description des modèles numériques utilisés pour le test des réseaux	44

3.8.3. Performance des Résultats	46
3.9. Etude de sensibilité du réseau.....	49
3.10. Champs d'application de la méthode.....	54
3.11. Calcul des excentricités par les RNAs	55
3.12. Conclusion.....	56
CONCLUSION GENERALE	57
Références bibliographiques.....	59
Appendice A - Les résultats de validation des réseaux de prédiction des déplacements de centre de masse et de centre de rigidité	62
Appendice B - Article.....	91

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure 1.1: Déplacement de torsion.....	5
Figure 1.2: Dommages dans les angles rentrants.....	6
Figure 2.1: Modèle d'un neurone artificiel.....	15
Figure 2.2: Fonction de transfert : (a) neurone «seuil» ; (b) neurone «linéaire», et (c) neurone «sigmoïde».....	17
Figure 2.3: Architecture d'un réseau de neurones (avec deux couches cachées).....	18
Figure 3.1: Modèle structurel excentré dans un seul sens.....	29
Figure 3.2: Le déplacement du centre de masse et de rigidité lors d'une réponse couplée.....	30
Figure 3.3: Le déplacement du centre de masse et de rigidité lors d'une réponse couplée.....	30
Figure 3.4: Principe de fonctionnement du premier modèle de réseau de neurones.....	33
Figure 3.5: Principe de fonctionnement du deuxième modèle de réseau de neurones.....	33
Figure 3.6: La structure de RNA d'Elman.....	34
Figure 3.7: Le modèle de RN utilisé pour la détection de déplacement du centre de masse.....	37
Figure 3.8: Le modèle de RN utilisé pour la détection de déplacement du centre de rigidité.....	37
Figure 3.9 : Modèle structurel.....	38
Figure 3.10 : Les signaux input.....	39
Figure 3.11: Signal désiré de déplacement du centre de masse.....	40
Figure 3.12: Signal désiré de déplacement du centre de rigidité.....	40
Figure 3.13: Evaluation de l'erreur pour la prédiction de déplacement du centre de masse.....	42
Figure 3.14: Evaluation de l'erreur pour la prédiction de déplacement du centre de rigidité.....	43
Figure 3.15 : Modèle 2.....	45
Figure 3.16 : Modèle 6.....	45
Figure 3.17 : Modèle 9.....	46
Figure 3.18 : Modèle 10.....	46
Figure 3.19: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 2.....	47
Figure 3.20: La déférence entre le signal x_{CM} cible et le signal output du modèle 2.....	47
Figure 3.21: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 2.....	48
Figure 3.22: La déférence entre le signal x_{CR} cible et le signal output du modèle 2.....	48
Figure 3.23: L'erreur sur le déplacement du centre de masse en fonction de la position du centre de masse.....	50

Figure 3.24: L'erreur sur le déplacement du centre de rigidité en fonction de la position du centre de rigidité.	52
Figure 3.25: L'erreur sur le déplacement du centre de masse.	53
Figure 3.26: L'erreur sur le déplacement du centre de rigidité.	54
Tableau 1.1: Excentricités de conception dans les règlements parasismiques.	10
Tableau 2.1: Fonctions de transfert $a = f(n)$	17
Tableau 3.1: Des excentricités calculées par RNAs.	55

INTRODUCTION GÉNÉRALE

Généralités

Les effets de la torsion sont considérés comme un facteur majeur responsable de sévères endommagements et même de ruines de plusieurs structures lors des séismes. Dans le but de tenir compte de ces effets, les règlements parasismiques préconisent deux moments supplémentaires aux charges latérales et proportionnels aux excentricités dynamiques de conception primaire et secondaire en fonction de l'excentricité calculée et accidentelle.

L'introduction d'une excentricité accidentelle a pour but la considération de toutes les incertitudes et les erreurs d'évaluation des caractéristiques géométriques et mécaniques des éléments structuraux et la rupture aléatoire des éléments non structuraux, ou encore à la variabilité spatiale des charges permanentes ou à une distribution défavorable des charges d'exploitation. Selon le code sismique, cette excentricité accidentelle est forfaitairement prise égale à 5% ou 10% de la dimension en plan perpendiculaire à l'axe d'excitation pour tous les types de structures.

Eu égard, à la nature aléatoire et incertaine des facteurs responsables de l'excentricité accidentelle, il s'avère très difficile d'évaluer explicitement et avec précision son effet sur la réponse sismique globale des constructions. Dans cette optique, le présent projet consiste à développer une procédure pour la quantification de l'excentricité à partir d'une réponse dynamique de la structure en utilisant la méthode des réseaux de neurones artificiels. Le modèle adapté est un réseau de neurones multicouches à rétropropagation qui permet les aspects appropriés suivants :

- établissement des relations entre les inputs et les outputs, basé sur des données historiques prédéfinis, sans déclaration de modèle explicite.
- tolérer des erreurs dans la base d'apprentissage.
- Peut être mis à jour par de nouvelles données.

Motifs et objectifs

Les règlements parasismiques préconisent une excentricité accidentelle forfaitaire égale à 5% ou 10% de la dimension en plan perpendiculaire à l'axe d'excitation pour tous les types de structures.

Quelle est la valeur réelle de l'excentricité accidentelle ?

Est-ce-que les valeurs forfaitaires sont sous-estimées ou surestimées ?

Cette étude propose une méthode basée sur les réseaux de neurones artificiels capable d'évaluer la valeur de l'excentricité accidentelle à partir d'une réponse dynamique.

A cet effet, nous définissons une architecture adéquate du réseau de neurones et nous constituons des bases de données d'apprentissage à partir des modèles numériques pour différents types de structures. Le réseau de neurones ainsi établi sera capable de localiser le centre de masse et le centre de rigidité d'un plancher ce qui permettra de déduire l'excentricité accidentelle à partir des réponses structurelles réelles enregistrées lors des essais de vibrations ambiantes. Le même principe peut être éventuellement appliqué dans le cas d'enregistrements sur des constructions instrumentées.

La méthodologie de l'étude

L'approche consiste à déterminer la valeur de l'excentricité d'un plancher d'un bâtiment à partir de la rotation du plancher et les déplacements du centre de masse et du centre de rigidité.

La rotation Θ du plancher est calculée directement en fonction des déplacements de deux points l'un sur le côté rigide et l'autre sur le côté flexible.

Par contre les déplacements du centre de masse et du centre de rigidité seront obtenus par le réseau de neurones ayant subi l'apprentissage à partir des déplacements des points sur les deux côtés rigide et flexible.

Par ailleurs, deux modèles de réseau de neurones seront établis, le premier pour prédire le déplacement du centre de masse et l'autre pour la prédiction du déplacement du centre de rigidité.

Les déplacements sur les deux côtés rigide et flexible sont utilisés comme des entrées (INPUT) dans les deux modèles de réseau de neurones, et les déplacements du centre de masse et du centre de rigidité comme des sorties (OUTPUT) des réseaux.

Plan de travail

Notre projet de recherche est organisé comme suit :

Dans l'introduction générale, nous avons présenté des généralités sur le problème posé, les motifs et les objectifs de la recherche, la méthodologie ainsi qu'un plan de travail de l'étude.

Le premier chapitre est axé essentiellement sur la torsion des bâtiments, les origines du phénomène de torsion, quelques constructions susceptibles à des endommagements de torsion sont exposées, les sources de la torsion accidentelle, le couplage et l'amplification dynamique des vibrations de torsion, la considération de la torsion accidentelle dans les règlements parasismiques ainsi qu'une revue des travaux récents sur l'évaluation de l'excentricité accidentelle.

Le deuxième chapitre présente les réseaux de neurones artificiels : un modèle de neurone, les fonctions de transfert, l'architecture de réseau de neurones, l'apprentissage des réseaux de neurones, les différents types de réseaux de neurones, le principe de rétropropagation, le choix de l'architecture du réseau de neurones, les propriétés des réseaux de neurones et en fin des exemples d'applications des réseaux de neurones en génie civil et en génie sismique.

Dans le troisième chapitre, nous avons illustré la méthodologie utilisée pour l'évaluation de l'excentricité accidentelle par les RNAs à partir d'une réponse dynamique. On énonce d'abord l'explication du principe de l'approche, avant de passer à l'établissement du modèle de réseau de neurones et le problème du choix de type du réseau ainsi que les facteurs influents sur sa conception. Après on sélectionne l'architecture du réseau qui détecte le déplacement du centre de masse et celui qui détecte le déplacement du centre de rigidité. On constitue par la suite la base de données qui servira à l'apprentissage des modèles de réseau de neurones tout en soulignant la stratégie adoptée pour l'apprentissage et le niveau de la performance des résultats d'apprentissage. Enfin on présente la phase de test et de la validation avec une description des modèles numériques des structures utilisées pour la constitution des réponses structurelle. Pour terminer, on présente l'étude de sensibilité du réseau, le champ d'application de la méthode et le calcul des excentricités par les RNAs.

CHAPITRE 1: LA TORSION DES BATIMENTS

1.1. Introduction

Dans le contexte de l'action sismique, plusieurs faits sont à l'origine de la torsion des bâtiments. Il y a d'abord l'existence d'excentricités structurales entre les centres de gravité CM_i et les centre de rigidité CR_i (ou centre de torsion) à chaque niveau i :

- Les composantes horizontales de l'action sismique induisent dans une structure, outre la flexion et le cisaillement, de la torsion, car le centre de gravité CM_i , point de passage de la force d'inertie engendrée par le tremblement de terre à un niveau i donné, n'est pas confondu généralement avec le centre de torsion CR_i de cet étage. Il résulte les moments de torsion $M_t = V_y \cdot (CM_i CR_i)_x$ ou $M_t = V_x \cdot (CM_i CR_i)_y$.
- Dans une construction à plusieurs niveaux, les centres de masses CM_i des différents niveaux i ne sont pas nécessairement sur une même verticale, pas plus que les centres de torsion CR_i . Un niveau j dont le centre de masse CM_j serait confondu avec le centre de torsion CR_j peut donc être soumis à une torsion résultante des décalages entre CM et CR aux niveaux supérieurs.
- La position du centre de masse CM_i de chaque niveau n'est pas connue avec précision, car elle dépend de l'utilisation : position du mobilier, affectation des locaux en archives, salle de réunion, etc.
- La position du centre de raideur CR_i de chaque niveau n'est pas connue avec précision, car elle dépend de la flexibilité réelle des diverses unités de contreventement, qui est forcément une estimation, en particulier dans les constructions en béton.

Enfin, il existe des phénomènes additionnels engendrant de la torsion, tels que :

- La possibilité de couplage des réponses longitudinale et torsionnelle.
- Des mouvements horizontaux différentiels du sol correspondant à la propagation des ondes de cisaillement en surface, qui appliquent aux constructions des rotations alternées faisant appel à leur inertie torsionnelle, cet effet existe toujours, il est significatif pour les constructions dont la longueur est comparable à la longueur des ondes de cisaillement.

On tient compte des phénomènes décrits en considérant deux contributions à la torsion :

- La torsion résultante de la non-coïncidence des centres de gravité CM avec les centres de torsion CR , qu'on appelle dans la suite **la torsion "naturelle"**, cependant la distance entre CM et CR est appelée **excentricité structurale e_0** .

- La torsion résultante des incertitudes et phénomènes additionnels divers, qu'on appelle dans la suite **torsion "accidentelle"** et qui est traduite dans une **excentricité accidentelle** e_a additionnelle à l'excentricité structurale e_0 .

Dans certains codes y compris le RPA99v2003 et l'Eurocode 8, «l'excentricité accidentelle » additionnelle à l'excentricité naturelle vaut:

- $e_{ai} = \pm 0,05 L_i$ où e_{ai} est l'excentricité accidentelle de la masse du niveau i par rapport à sa position nominale, appliquée dans la même direction à tous les niveaux et L_i est la dimension du plancher perpendiculaire à la direction de l'action sismique.

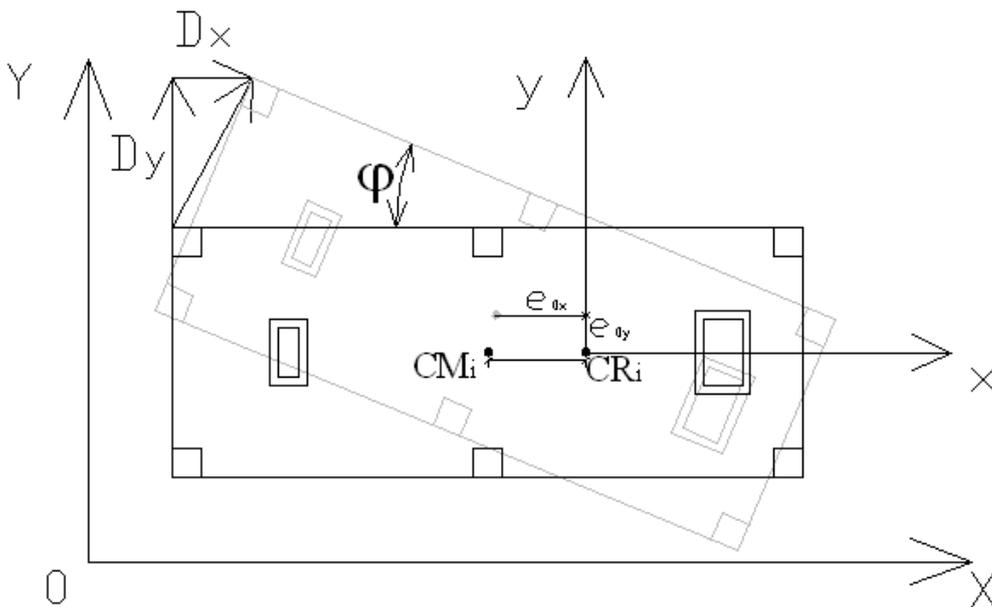


Figure 1.1: Déplacement de torsion.

1.2. Origines du phénomène de torsion

Trois causes principales peuvent être à l'origine de la torsion :

- C'est l'existence d'excentricité entre les centres de gravité (CM) et les centres de rigidité (CR). Les composantes horizontales de l'action sismique induisent dans une structure, outre la flexion et le cisaillement, de la torsion. En effet, le centre de gravité, point de passage de la force d'inertie engendrée par le tremblement de terre, n'est généralement pas confondu avec le centre de rigidité de l'étage considéré. Pour un bâtiment multi-étages, les centres de gravité et les centres de rigidité des différents niveaux ne sont pas nécessairement sur des lignes verticales.
- Ensuite, les incertitudes diverses sur les positions des centres de gravité et des centres de rigidité à chaque étage sont des facteurs importants. La position du centre de masse de chaque niveau n'est pas connue de façon précise car elle dépend de l'utilisation de l'étage.

En effet, l'affectation des locaux a une incidence importante sur la distribution des masses (archives, salle de réunion, etc...). La position des centres de rigidité de chaque niveau dépend de la flexibilité réelle des diverses unités de contreventement, cette dernière n'est connue que par une estimation.

- Enfin, il y a des phénomènes additionnels qui sont aussi à l'origine de la torsion, tels que les mouvements horizontaux différentiels du sol correspondant à la propagation des ondes de cisaillement en surface et la possibilité de couplage des réponses longitudinale et torsionnelle [1].

1.3. Constructions susceptibles à des endommagements de torsion

Lors des séismes majeurs, plusieurs cas d'endommagements étaient dus principalement aux effets de la torsion induite par le couplage des modes de torsion avec les modes latéraux.

On cite ici certains types de constructions susceptibles à des endommagements de torsion :

1.3.1. Bâtiments à angles rentrants

L'angle rentrant est une caractéristique de la majorité des constructions qui ont la forme en plan: L, T, ..., où une combinaison de ces formes.

Deux problèmes liés sont créés par ces formes. Le premier tend à produire des variations de rigidité, et par conséquent des mouvements entre les différentes parties du bâtiment, résultant en une concentration locale de contrainte au niveau de la partie rentrante de l'angle. Le second problème est la torsion, elle est due au fait que le CM et le CR dans ces formes ne coïncident pas géométriquement, le résultat est une rotation qui s'ajoute aux efforts tranchants des éléments les plus éloignés du CR. De graves endommagements attribués à ce facteur ont été identifiés lors des séismes de 1932 à Kantô (JAPON), 1925 à Santa Barbara, 1964 en Alaska et de 1985 à Mexico City.

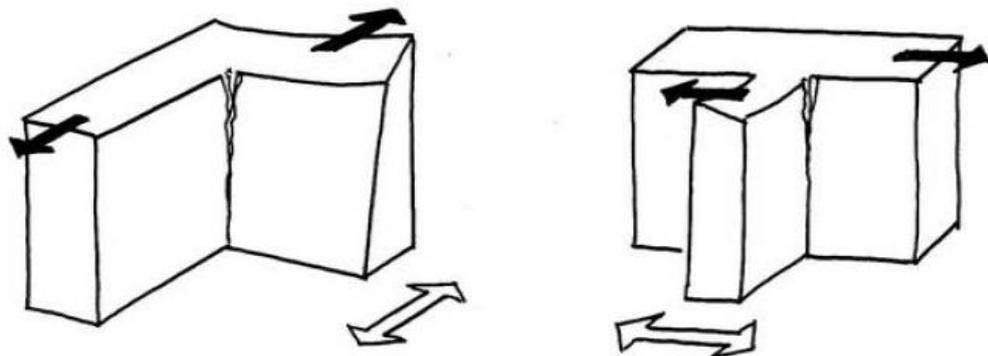


Figure 1.2: Dommages dans les angles rentrants.

1.3.2. Variation de la rigidité et la résistance du périmètre du bâtiment

On considère ici les efforts de la variation de la rigidité et la résistance autour du périmètre du bâtiment qui fournit la résistance latérale. Le problème peut surgir dans les bâtiments ayant des configurations symétriques mais qui du point de vue rigidité sont asymétriques. Dans ce cas le bâtiment tourne autour du CR sous une excitation sismique.

En 1969, lors du séisme d'Anchorage (Alaska), un cas représentatif a été identifié dans un magasin du T.C.Penny. Ce dernier comportait des voiles sur son pourtour au RDC. Et au premier étage supérieur les voiles étaient disposés suivant trois directions uniquement.

1.3.3. Bâtiment à systèmes résistants non parallèles

Les éléments résistants verticaux dans certains cas sont asymétriques par rapport aux axes principaux orthogonaux de la structure. Les parties étroites du bâtiment ont tendance à devenir plus flexible par rapport aux parties larges. Ce qui augmente le risque de torsion.

Beaucoup de bâtiments de ce genre ont subi de sévères dommages lors du séisme de 1985 à Mexico City. [2]

1.4. Sources de la torsion accidentelle

1.4.1. Mouvement rotationnel de la base de la structure

Le mouvement de terre lors d'un séisme peut causer une rotation autour de l'axe vertical de la base de la structure même si celle-ci est parfaitement symétrique.

Une étude analytique est faite sur une structure nominale symétrique ou les mouvements ont été enregistrés durant les séismes de wéittier (1987), Loma Prieta (1989, 1990) et Sierra Madre (1992). Une comparaison montre que la réponse à l'excitation rotationnelle en terme d'accélération est d'un ordre de magnitude plus petit que celui de l'excitation translationnelle. D'autre part, les valeurs maximales de la réponse de torsion se produisent à des périodes plus petites, comparées à celles de la réponse latérale. Cette observation suggère que l'excitation rotationnelle est supposée causer une augmentation plus importante dans la réponse des systèmes à courte période de vibrations.

1.4.2. Incertitude dans la rigidité des éléments

La valeur réelle de la rigidité des éléments structuraux d'un bâtiment, d'un voile ou d'un poteau diffère en général de sa valeur initiale à cause de l'incertitude dans les propriétés des matériaux, des dimensions des éléments de la structure, de la qualité du contrôle, du chargement historique de l'élément et des modèles théoriques utilisés pour prévoir la rigidité des éléments qui ne sont pas très

exacts, cela implique qu'une structure nominale symétrique est en réalité asymétrique à un certain degré.

1.4.3. Incertitude dans la localisation du centre de masse

La variabilité non prévue dans la distribution du poids propre et de la charge d'exploitation dans la structure implique que le centre de masse réel est éloigné de sa position nominale prévue dans l'analyse. Le manque de données statistiques sur la variabilité en plan du poids propre et de la charge d'exploitation ne nous permet pas de donner une bonne approximation de la loi de variation de la localisation du centre de masse (CM).

1.4.4. Incertitude dans l'évaluation du seuil de la résistance des éléments

Le niveau de la résistance des éléments varie à cause de la nature propre du matériau lui-même, les tolérances et les erreurs géométriques durant le processus de la construction et de l'assemblage des éléments résistants entre eux.

La torsion accidentelle peut apparaître même dans les structures symétriques résultant de diverses sources, tel que le mouvement rotationnel de la base de la structure non spécifié explicitement, l'incertitude dans la rigidité des éléments, dans la localisation du centre de masse et dans l'évaluation du seuil de la résistance des éléments.

Les effets de ces sources sur la torsion accidentelle font l'objet de plusieurs recherches intensives dont les résultats peuvent être résumés par:

- Toutes les sources de l'excentricité accidentelle causent une amplification de la réponse de la structure, cette amplification est plus importante pour les systèmes à plans nominale symétriques.
- L'amplification de la réponse résultante d'une torsion accidentelle est très sensible aux valeurs du rapport de fréquence Ω et par conséquent l'excentricité accidentelle l'est aussi.

1.5. Couplage et amplification dynamique des vibrations de torsion

L'amplification et le couplage des vibrations de torsion sont affirmés dans les structures soumises à des actions sismiques. Elles subissent simultanément des mouvements latéraux et de torsion si l'irrégularité dans la distribution des masses, de la rigidité des éléments dans leurs plans structuraux ou dont les formes architecturales sont telles que la distinction entre le centre de masse et le centre de rigidité est plus ou moins prononcée. D'autres causes imprévisibles peuvent être la source d'initiation des vibrations de torsion dans des structures géométriquement symétriques soumises aux actions sismiques. Nous citerons :

La propagation des ondes sismiques (onde à propagation inclinée - onde love - dont la longueur de fond est inférieure aux dimensions de la fondation).

Le couplage des modes latéraux et de torsion a pour effet d'amplifier la réponse de certains éléments. Autrement dit, les forces latérales reprises par ces éléments diffèrent de celles qu'ils auraient reprises s'ils n'étaient soumis qu'aux vibrations planes. Cette amplification peut causer des dommages excessifs aux éléments structuraux et non structuraux.

Les causes citées ci-dessus étant difficiles à prévenir et à quantifier. Les codes de protection parasismique s'intéressent au facteur d'asymétrie qui peut s'exprimer par la valeur de l'excentricité statique (la distance entre le centre de masse et le centre de rigidité en plan) et introduisent comme coefficients de sécurité, des excentricités supplémentaires (additionnelles, accidentelles) pour tenir compte de ces phénomènes.

Il y a certains facteurs structuraux qui influent sur le couplage des modes de torsion et latéraux. Les paramètres les plus importants sont:

- L'excentricité statique e_0 .
- Le rapport des fréquences de torsion et latérale $\Omega = f_t / f_l$.
- L'intensité d'excitation.
- L'amortissement structurel de torsion et latéral (ξ_t, ξ_l).
- Le contenu fréquentiel de la secousse sismique.
- Le rapport d'interaction sol-structure.

1.6. Considération de la torsion accidentelle dans les règlements parasismiques

La plupart des codes du bâtiment donnent pour l'évaluation des effets de torsion résultant de charges sismiques dans la conception parasismique des structures. Dans certains codes de conception, ils amplifient les excentricités statiques par un multiplicateur pour tenir compte de l'amplification dynamique possible de la torsion. Les excentricités de conception comprennent également un complément pour tenir compte la torsion accidentelle. Une telle torsion est supposée être induite par la composante rotationnelle du mouvement du sol et par déviation possible des centres de rigidité et de masse à partir de leurs positions calculées. Les formules de l'excentricité de conception donnée dans les codes du bâtiment peuvent être écrites sous la forme suivante :

Excentricité de conception primaire : $e_{D1} = e_{d1} + e_a$

Excentricité de conception secondaire : $e_{D2} = e_{d2} - e_a$

$e_{d1} = \alpha \cdot e$, $e_{d2} = \gamma \cdot e$, $e_a = \beta \cdot L$ où :

e = l'excentricité de structure définie comme la distance entre le centre de masse et le centre de rigidité (L'excentricité statique).

L = dimension du bâtiment en plan perpendiculaire à la direction du mouvement sismique du sol.

α et Υ = des coefficients d'amplification.

β = coefficient de l'excentricité accidentelle.

ed1 = excentricité dynamique primaire.

ed2 = excentricité dynamique secondaire.

ea = excentricité supplémentaire ou accidentelle.

Les premiers termes ed1 et ed2 prennent en compte l'amplification dynamique de torsion, ses derniers sont définis par la répartition connue de la masse et de l'architecture du bâtiment.

Le second terme ea représente l'excentricité accidentelle qui est destiné pour tenir compte la torsion supplémentaire possible causée par une variation imprévue de la rigidité relative des éléments résistants, l'incertitude sur la distribution de la masse, les différentes dispositions des panneaux muraux et des cloisons amovibles, la variation de la rigidité en fonction du temps et les actions inélastiques ou plastiques. En outre l'excentricité accidentelle prend en compte également l'influence du mouvement rotationnel du sol.

Les recommandations de ces règlements concernant l'effet de torsion dans les constructions sont basées essentiellement sur :

- Les résultats de nombreuses études paramétriques.
- Observation des comportements des structures dans le cas des séismes majeurs.
- Études de constructions soumises à des vibrations forcées.

L'excentricité de conception pour différents codes du bâtiment est énumérée dans le tableau ci-dessous :

Tableau 1.1: Excentricités de conception dans les règlements parasismiques.

Règlement parasismique	Excentricité primaire	Excentricité secondaire
IBC (2003)	1.0 e + 0.05 L	1.0 e – 0.05 L
Canada (NBCC 95)	1.5 e + 0.1 L	0.5 e – 0.1 L
Europe (EC8)	1.0 e + 0.05 L	1.0 e – 0.05 L
Bulgarie	1.0 e + 0.02 L	1.0 e – 0.02 L
Grèce	1.0 e + 0.05 L	1.0 e – 0.05 L
Mexico 1995	1.5 e + 0.1 L	1.0 e – 0.1 L
Romania	1.0 e + 0.05 L	1.0 e – 0.05 L
New Zeland 1992	1.0 e + 0.05 L	1.0 e – 0.05 L
Indian Standards 2002	1.5 e + 0.05 L	1.0 e – 0.05 L
RPA1999 (version2003)	1.0 e si e > 0.05L 0.05 L si e < 0.05L	0.0 si e > 0.05L - 0.05 L si e < 0.05L

1.7. Revue des travaux récents sur l'évaluation de l'excentricité accidentelle

La torsion des bâtiments est un paramètre très important dans la conception parasismique. Dans les codes parasismiques, l'excentricité d'un bâtiment prend en compte à la fois l'excentricité statique et accidentelle, cette dernière est introduite pour tenir compte des oscillations aléatoires et des origines inconnus de torsion.

En raison de la nature aléatoire des systèmes structuraux, il est très difficile d'évaluer l'excentricité accidentelle et de spécifier son effet sur la réponse sismique des structures, et pour ce fait, plusieurs études ont été menées dans le but de déterminer sa valeur exacte.

En 1988 O.a. Pekau et R. Guimond [3] examinent l'adéquation des provisions pour l'excentricité accidentelle du code national du bâtiment du Canada 1980 et 1985 pour tenir compte la torsion induite dans les structures nominalelement symétriques en raison de la variation imprévue dans la force élasto-plastique dans les éléments résistants. Sur la base des résultats présentés dans cette étude, la variation de la force des éléments résistants aux charges latérales peut entraîner une torsion accidentelle considérable. Par rapport à la réponse symétrique, il peut entraîner des facteurs d'amplification importants de déplacement maximum des bords.

En 1991 A.K. Chopra et R.K. Goel [4] ont étudié les effets d'asymétrie en plan sur la réponse sismique dans les codes, des systèmes à un seul étage et à déterminer dans quelle mesure ces effets sont représentés par les dispositions de torsion dans les codes du bâtiment. Ils ont d'abord déterminé la façon dont les dispositions de conception dans les divers codes influencent les forces des éléments de conception. Par la suite, les exigences de déformation et de ductilité des éléments résistants des systèmes asymétriques en plan sont comparées à leurs valeurs si le système est symétrique en plan. Sur la base de ces résultats, des lacunes dans les dispositions du code sont identifiées et des améliorations ont été suggérées.

En 1992 J.C. De La Llera et A.K. Chopra [5] présentent une procédure pour l'évaluation des provisions de la torsion accidentelle dans les codes sismiques à partir de l'analyse des mouvements enregistrés des bâtiments nominalelement symétriques pendant les tremblements de terre. Cette procédure est utilisée pour analyser les mouvements de trois bâtiments enregistrés au cours des tremblements de terre en Californie. Leurs résultats démontrent que la torsion accidentelle spécifiée par l'Uniform Building Code est suffisante pour représenter la torsion dans les mouvements enregistrés de ces trois bâtiments.

En 1994 J.C. De La Llera et A.k. Chopra [6] ont évalué les différences de la réponse du bâtiment résultante de l'utilisation du code spécifié l'excentricité accidentelle dans l'analyse

dynamique et statique du bâtiment, et ils ont identifié les contradictions possibles entre les deux procédures d'analyse alternatives du code pour incorporer les effets de torsion accidentelle.

Dans l'étude de H. Shakib et R.Z. Tohidi [7] en 2002, et dans le cadre de l'excentricité de conception, les effets de la composante rotationnelle du tremblement de terre sur l'excentricité accidentelle ont été évalués par l'application d'une procédure d'analyse aléatoire dans le domaine fréquentiel pour calculer la variation de la réponse de la structure sous l'effet de la composante de rotation de l'accélération de tremblement de terre, et la détermination de l'efficacité ou de l'inefficacité de l'excentricité accidentelle proposée par les codes de construction parasismique en tenant compte les effets de la composante de rotation du séisme.

En 2003 J.L. Almazan et J.C. De la Llera [8] cherchent les variables qui contrôlent la torsion accidentelle due au renversement, ils ont évalué l'augmentation attendue de la réponse que l'on attribue à la torsion accidentelle et sa dépendance avec les paramètres de construction et l'efficacité du système de pendule de frottement des isolateurs (FPS) pour contrôler la torsion accidentelle par opposition aux structures classiques, et proposer des limites fiables pour rendre en compte la torsion accidentelle dans la conception des bâtiments.

En 2003 S.L. Dimova et I. Alashki [9] estiment analytiquement les effets dynamiques causés par le déplacement du centre de masse dans des structures symétriques. La solution analytique prouve que même dans le cas des petites excentricités accidentelles, les structures symétriques présentent un comportement irrégulier et les effets de torsion accidentelle ne peuvent être décrits correctement dans l'application statique des moments de torsion. Ils ont prouvé par des simulations numériques de la réponse dynamique des modèles des structures symétriques en 3D que le coefficient de correction proposé donne des résultats précis.

En 2004 H. Shakib [10] a proposé une équation simple pour l'excentricité de conception sur la base des analyses stochastiques de l'interaction sol-structure des bâtiments asymétriques, cette équation considère les effets de l'interaction sol-structure en définissant la vitesse des ondes de cisaillement de l'état du sol et il a comparé l'excentricité dynamique calculée d'après la méthode d'analyse avec l'excentricité dynamique de l'UBC-97 et EC-8.

En 2005 N. Bourahla et T. Boukhemacha [11] présentent une méthode globale basée sur les réseaux de neurones artificiels pour estimer le niveau de l'excentricité accidentelle dans un bâtiment nominalelement symétrique. Un ensemble d'enregistrements de vibrations ambiantes du nouvel aéroport d'Alger sont utilisés pour l'apprentissage du réseau de neurones de type Elman à rétropropagation, puis une fonction linéaire est entrée dans le réseau afin d'estimer le niveau de l'excentricité à divers gammes d'amplitudes de réponse.

Une estimation de la réponse maximale de rotation des systèmes asymétriques à un seul étage sous une excitation sismique est obtenue et développée concernant des différentes applications à

partir d'une formulation de forme proche identifiée dans des recherches par G. Gasparini, S. Silvestri et T. Trombetti [12] en 2008, les résultats fournissent des indications utiles sur la compréhension du comportement en torsion des systèmes asymétriques et peuvent directement utilisés pour la conception préliminaire et / ou vérifier des résultats obtenus par la modélisation en éléments finis de système structural à trois dimensions.

En 2008 O.M.O. Ramadan, S.S.F. Mehanny et A. Mostafa [13] étudient l'effet de la variation de la position du centre de masse et revoient la disposition de l'excentricité accidentelle afin d'évaluer la pertinence de sa valeur de 5% (supposée dans les codes parasismiques pour les bâtiments à plusieurs étages).

Ils ont trouvés que cette valeur peut être conservée pour les bâtiments de faible hauteur (ne dépassant pas les 5 étages). Cependant, pour des bâtiments plus élevés, il est initialement proposé d'opter pour une excentricité accidentelle de 5% au quart supérieur du bâtiment, 3% à la moitié médiane et 2% pour le quart inférieur.

En 2010 C.J. Jose, T.P. Somasundaran et V. Mustafa [14] débutent leur étude par la quantification des ressemblances et différences de la méthode statique équivalente et la méthode d'analyse modale spectrale sur la réponse d'un bâtiment régulier de grande hauteur, sous la période fondamentale et la période de torsion basée sur le code sismique indien. Les moments de conception des poteaux et les déplacements des planchers sont pris comme des paramètres de l'étude.

Ils ont constaté que les excitations de la période de torsion sont importantes que celles de la période fondamentale, et ces effets ont commencé à partir des bâtiments de faible hauteur même pour les structures régulières.

Une insuffisance dans les dispositions du code sismique indien a été constatée.

En 2010 M. Badaoui et all [15] ont développé une procédure d'évaluation de l'excentricité accidentelle en utilisant les techniques de réseaux de neurones couplées à des simulations de Monte Carlo. Ils ont utilisé un réseau de feed-forward multi-couches où la couche d'entrée correspond aux réponses maximales (des déplacements ou des accélérations) et des fréquences naturelles et la couche de sortie correspond à l'excentricité de chaque étage. Cette méthode donne des résultats très intéressants pour les structures à un seul étage.

En 2011 M.D. Bensalah et all [16] ont étudié l'influence des effets de la torsion induite sur le comportement d'une structure asymétrique. Ils ont considéré deux types de structures, symétriques et asymétriques, afin de voir les effets de certains paramètres précédemment cités. Leur étude porte spécifiquement sur les paramètres suivants: la ductilité et le facteur de réduction. Pour cela, la ductilité et le facteur de réduction sont calculés dans les deux structures. Ces

paramètres sont comparés pour les différents séismes utilisés en termes d'intensité Arias et de la période moyenne.

1.8. Conclusion

Parmi les sujets de recherches les plus importants et les plus actuels dans le domaine de génie parasismique, on retrouve le phénomène de torsion qui est dû aux différentes incertitudes dans les caractéristiques géométriques et mécaniques des structures. Ce dernier présente un facteur important caractérisant le comportement global de la construction. Les conséquences causées par ce phénomène ont fait l'objet de plusieurs études et observations lors des séismes majeurs. Certaines causes de la torsion accidentelle ont été discutées théoriquement et analytiquement dans la littérature. En conséquence, les codes parasismiques préconisent une valeur sous forme d'une excentricité additionnelle ajoutée algébriquement à l'excentricité dynamique. Dans notre étude la contribution essentielle consiste à proposer un modèle de réseaux de neurones artificiels pour évaluer l'excentricité accidentelle à partir d'une réponse dynamique.

CHAPITRE 2: LES RESEAUX DE NEURONES ARTIFICIELS

2.1. Introduction

Les réseaux de neurones formels, ou plus simplement réseaux de neurones, constituent aujourd'hui une technique de traitement de données bien comprise et maîtrisée qui permet à l'ingénieur d'extraire dans de nombreuses situations le maximum d'informations pertinentes des données qu'il possède : commande de procédés, prédiction de propriétés, modélisation de fonctions, reconnaissance de formes, etc.

Définition

Un réseau de neurones artificiel est une structure composée d'entités capables de calcul et interconnectées entre elles. Il permet de traiter, par le biais de l'informatique, des problèmes de différentes natures que les outils classiques ont du mal à résoudre. En effet, son fonctionnement s'inspire de celui des cellules neuronales humaines, et est donc différent des méthodes de calcul analytiques que l'on utilise ordinairement. Il s'avère très puissant dans des problèmes de reconnaissance, classification, approximation ou prévision.

2.2. Modèle d'un neurone

Le modèle mathématique d'un neurone artificiel est illustré à la figure 2.1. Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformée par une fonction de transfert f qui produit la sortie a du neurone.

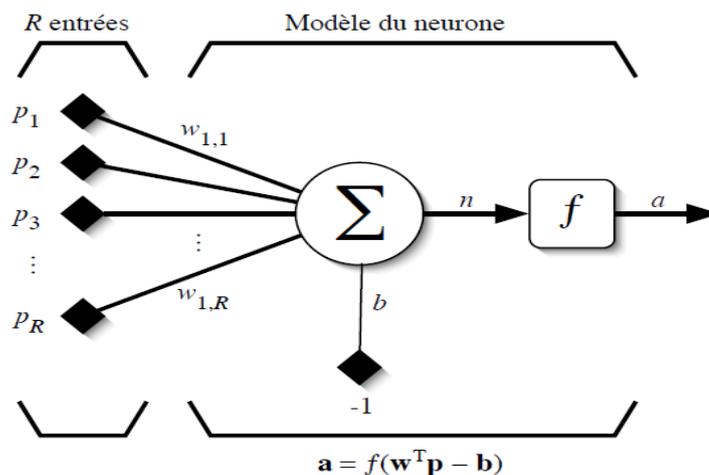


Figure 2.1: Modèle d'un neurone artificiel.

Les R entrées du neurone correspondent au vecteur $p = [p_1 p_2 \dots p_R]^T$, alors que $w = [w_{1,1} w_{1,2} \dots w_{1,R}]^T$ représente le vecteur des poids du neurone. La sortie n de l'intégrateur est donnée par l'équation suivante :

$$\begin{aligned} n &= (\sum_{j=1}^R w_{1,j} p_j) - b \\ &= w_{1,1} p_1 + w_{1,2} p_2 + \dots + w_{1,R} p_R - b \end{aligned}$$

Que l'on peut aussi écrire sous forme matricielle :

$$n = w^T p - b.$$

Cette sortie correspond à une somme pondérée des poids et des entrées moins ce qu'on nomme le biais b du neurone. Le résultat n de la somme pondérée s'appelle le niveau d'activation du neurone.

Le biais b s'appelle aussi le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient positif (ou nul). Sinon, il est négatif [17].

2.3. Fonctions de transfert

Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone sont énumérées au tableau 2.1. Les trois les plus utilisées sont les fonctions «seuil» (en anglais «hard limit»), «linéaire» et «sigmoïde».

Comme son nom l'indique, la fonction seuil applique un seuil sur son entrée. Plus précisément, une entrée négative ne dépasse pas le seuil, la fonction retourne alors la valeur 0 (on peut interpréter ce 0 comme signifiant faux), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne 1 (vrai). Utilisée dans le contexte d'un neurone, cette fonction est illustrée à la figure 2.2a. On remarque alors que le biais b dans l'expression de $a = \text{hardlim}(w^T p - b)$ détermine l'emplacement du seuil sur l'axe $w^T p$, où la fonction passe de 0 à 1. Nous verrons plus loin que cette fonction permet de prendre des décisions binaires.

La fonction linéaire est très simple, elle affecte directement son entrée à sa sortie :

$$a = n.$$

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à la figure 2.2b. Dans ce cas, la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $w^T p = b$.

La fonction de transfert sigmoïde est quant à elle illustrée à la figure 2.2c. Son équation est donnée par :

$$a = \frac{1}{1 + \exp(-n)}$$

Tableau 2.1: Fonctions de transfert $a = f(n)$.

Nom de la fonction	Relation d'entrée/sortie	Icône	Nom Matlab
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlim
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$		hardlins
linéaire	$a = n$		purelin
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$		satlin
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$		satlins
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$		poslin
sigmoïde	$a = \frac{1}{1 + \exp(-n)}$		logsig
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
compétitive	$a = 1$ si n maximum $a = 0$ autrement		compet

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que l'on est loin ou près de b , respectivement. La fonction seuil est très non-linéaire car il y a une discontinuité lorsque $w^T p = b$.

De son côté, la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement, que la fonction «tangente hyperbolique» est une version symétrique de la sigmoïde [17].

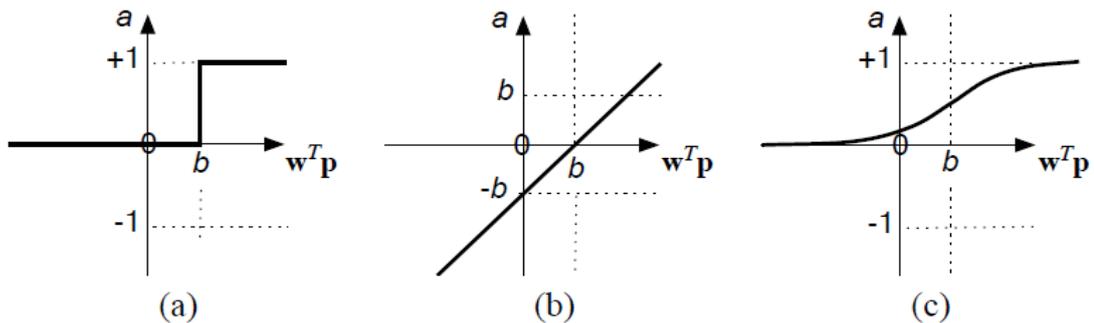


Figure 2.2: Fonction de transfert : (a) neurone «seuil» ; (b) neurone «linéaire», et (c) neurone «sigmoïde».

2.4. Architecture de réseau

Un réseau de neurones, comme son nom l'indique, est un ensemble de neurones en réseau, de sorte que les signaux sortant (outputs) des neurones deviennent des signaux entrant (inputs) dans d'autres neurones. L'architecture générale des réseaux de neurones consiste à la représentation des neurones en couches (layers) successives, la première représentant la couche d'intrants (input layer), la dernière étant la couche de sortie (output layer), les couches intermédiaires étant les couches cachées (hidden layers) du réseau. Ces couches sont dites cachées car de l'extérieur du réseau, on ne peut analyser clairement leur fonctionnement. On ne connaît vraiment que les signaux intrants et extrants du réseau. Les neurones de la couche d'intrants ne sont pas vraiment des neurones traitants (computing neurons), mais ont pour seule utilité de normaliser les entrées des signaux ainsi que la distribution des signaux intrants. Dans cette architecture normalisée, les couches de neurones sont totalement interconnectées, c'est-à-dire que les neurones d'une couche sont tous reliés à tous les neurones des couches adjacentes. Cette architecture normalisée peut sembler rigide, mais elle permet une représentation correcte de la plupart des réseaux de neurones, tout en permettant l'utilisation d'algorithmes d'entraînement plus généraux.

D'une manière générale, un réseau de neurones se comporte, d'un point de vue extérieur, comme une fonction S qui traite des données (inputs) et produit une réponse correspondante (output). Les données entrées peuvent être de n'importe quel type représentable de manière binaire ou numérique. Ces données peuvent également être vues comme des vecteurs, et le réseau de neurones une application vectorielle.

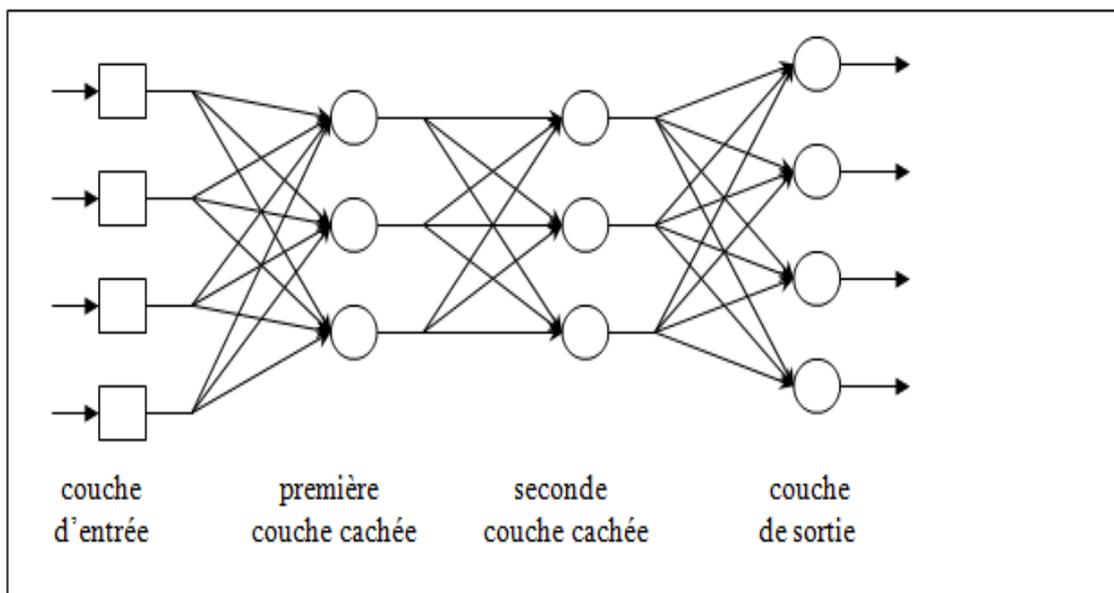


Figure 2.3: Architecture d'un réseau de neurones (avec deux couches cachées).

2.5. L'apprentissage des réseaux de neurones

La notion d'apprentissage est claire et intuitive pour les humaines ou les animaux : c'est une procédure cognitive qui doit faire en sorte que l'individu réalise de manière autonome une tâche donnée.

Typiquement, cette procédure s'effectue à partir des exemples : ainsi, pour apprendre à lire à un enfant, on lui présente des exemples de lettres et de chiffres, écrits avec des écritures et des fontes différentes.

A la fin de l'apprentissage, on attend de l'enfant qu'il soit capable de lire non seulement tous les chiffres et lettres de son livre de lecture, mais également tous les chiffres et lettres qu'il est susceptible de voir : en d'autres termes, on attend de lui qu'il ait une capacité de généralisation à partir des exemples qui lui ont été présentés, sans qu'il soit jamais nécessaire de lui fournir une description analytique de la forme et de la topologie des chiffres et des lettres.

L'apprentissage numérique poursuit exactement le même objectif : il s'agit de faire en sorte, à l'aide d'une procédure numérique programmée et exécutée sur un ordinateur, d'inférer un modèle d'un processus que l'on observe et sur lequel on peut effectuer des mesures, c'est-à-dire un ensemble d'équations qui décrivent le processus observé et qui permettent de faire des prédictions concernant le comportement de celui-ci.

A cette ...fin, on fait l'hypothèse que le processus peut être décrit avec la précision désirée par une ou plusieurs fonctions qui contiennent des paramètres, et l'on ajuste ces derniers pour que cette ou ces fonctions s'ajustent aux données. L'apprentissage est un algorithme qui permet d'ajuster ces paramètres.

En ce sens, l'apprentissage est semblable, en apparence, aux méthodes statistiques de modélisation; nous verrons d'ailleurs que l'apprentissage emprunte aux statistiques un grand nombre de techniques.

Une méthode bien connue, dite " méthode des moindres carrés " permet de résoudre ce problème; d'autres techniques permettent également d'estimer la confiance que l'on peut avoir dans la valeur E ainsi obtenue, compte tenu du bruit du présent dans les données.

En revanche, dans le contexte de l'apprentissage, on n'a aucune idée a priori sur le modèle, on choisit une forme d'équation aussi générale que possible, et on ajuste les paramètres de cette équation de manière à lui conférer la meilleure capacité de généralisation possible.

On ne s'intéresse pas particulièrement aux valeurs de ces paramètres. Car ceux-ci, contrairement à l'énergie d'activation mentionnée plus haut, n'ont pas de signification physique particulière.

En revanche, on s'intéresse à la capacité de généralisation du modèle : on cherche à estimer la qualité des prédictions que le modèle peut effectuer, dans des situations qu'il n'a pas rencontrées dans l'apprentissage.

L'objectif de l'apprentissage est donc différent de celui des statistiques. Nous verrons néanmoins que les techniques développées par les statisticiens sont précieuses pour l'apprentissage.

Avant de fixer ce cadre général, nous allons à présent introduire les concepts fondamentaux de la modélisation par réseaux de neurones, et de l'apprentissage de ceux-ci.

2.5.1. Définition

On appelle <<apprentissage>> des réseaux de neurones la procédure qui consiste à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse la tâche qui lui est affectée.

Dans le cadre de cette définition, on peut distinguer deux types d'apprentissage : l'apprentissage "supervisé" et l'apprentissage "non supervisé".

2.5.2. Les types d'apprentissage

a. L'apprentissage supervisé

Un réseau non bouclé réalise une relation algébrique entre ses entrées et ses sorties. On peut donc effectuer à un tel réseau la tâche qui consiste à réaliser une fonction algébrique non linéaire, celle-ci peut être :

- Connue analytiquement : le réseau réalise alors une tâche d'approximation de fonction.
- Inconnue analytiquement : mais pour laquelle on dispose de valeurs, en nombre...fini, qui sont entachées de bruit si ces valeurs résultent de mesures effectuées sur un processus physique, chimique, économique, biologique, etc. : le réseau a alors une tâche de modélisation statique ou une régression.

C'est essentiellement pour ce dernier type d'application que sont mis en œuvre les réseaux de neurones à apprentissage supervisé.

On connaît donc, en tout point ou seulement en certains points, les valeurs que doit avoir la sortie du réseau en fonction des entrées correspondantes : c'est en ce sens que l'apprentissage est "supervisé", métaphore qui signifie qu'un "professeur" peut fournir au réseau des "exemples" de ce que celui-ci doit faire.

b. L'apprentissage semi supervisé

Dans ce type d'apprentissage, l'utilisateur possède seulement des indications floues sur le comportement...final du réseau, mais en revanche, il est possible d'obtenir des indications qualitatives.

c. L'apprentissage non supervisé

Un réseau de neurones non bouclé peut également être utilisé dans un but de visualisation ou d'analyse de données : on dispose un ensemble de données, représentées par des vecteurs de grande dimension, et on cherche à les regrouper, selon des critères de ressemblance qui sont inconnus a priori.

Ce type de tâche est connu en statistique sous le nom de méthodes "d'agrégation". On peut utiliser les réseaux de neurones non bouclés pour réaliser une tâche assez voisine : à partir de données décrites par des vecteurs de grandes dimensions trouver une représentation de ces données dans un espace de dimension beaucoup plus faible (typiquement de dimension 2) tout en conservant les "proximités" ou "ressemblances" entre ces données. Il n'y a pas là de "professeur", puisque c'est au réseau de découvrir les ressemblances entre les éléments de la base de données, et de les traduire par une proximité dans le "carte" de dimension 2 qu'il doit produire.

Les réseaux à apprentissage non supervisé les plus étudiés et utilisés sont les "cartes auto-organisatrices" ou "cartes de Kohonen".

2.5.3. L'apprentissage des réseaux de neurones formels

Comme nous l'avons indiqué plus haut, l'apprentissage "supervisé", pour les réseaux de neurones formels, consiste à calculer les coefficients de telle manière que les sorties du réseau de neurones soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties "désirées", qui peuvent être la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander. La plupart des algorithmes d'apprentissage des réseaux de neurones formels sont des algorithmes d'optimisation : ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées.

Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût : le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite méthode de rétropropagation, puis il est utilisé par l'algorithme d'optimisation proprement dit :

Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement jusqu'à obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de validation disjoint du précédent.

Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent : il existe des algorithmes d'optimisation non linéaire extrêmement rapides qui permettent de faire des développements industriels. L'apprentissage des

réseaux de neurones bouclés (pour réaliser des modèles dynamiques) est très semblable à celui des réseaux non bouclés [18].

2.6. Les différents types de réseaux de neurones

a. Le perceptron

Le perceptron peut être vu comme le type de réseau de neurones le plus simple. C'est un classificateur linéaire. Ce type de réseau neuronal ne contient aucun cycle.

b. Le perceptron multicouche

Dans le Perceptron multicouche à rétropropagation, les neurones d'une couche sont reliés à la totalité des neurones des couches adjacentes. Ces liaisons sont soumises à un coefficient altérant l'effet de l'information sur le neurone de destination. Ainsi, le poids de chacune de ces liaisons est l'élément clef du fonctionnement du réseau : la mise en place d'un Perceptron multicouche pour résoudre un problème passe donc par la détermination des meilleurs poids applicables à chacune des connexions inter-neuronales. Ici, cette détermination s'effectue au travers d'un algorithme de rétropropagation.

c. Les réseaux de neurones à fonctions radiales de base (Radial Basis Network)

- Les réseaux de neurones à régression généralisée (Generalized Regression Networks)

Ces réseaux sont aussi utilisés en tant qu'approximation de fonction, mais sont plus lourds d'utilisation que les perceptrons multicouches.

- Les réseaux de neurones probabilistes (Probabilistic Neural Networks)

Ces réseaux sont généralement utilisés pour des problèmes de classification. La première couche qui est un réseau à base radiale, donne une information sur la ressemblance entre la donnée d'entrée et le jeu de données utilisé lors de l'apprentissage. La deuxième couche produit comme sortie un vecteur de probabilité. Finalement, une fonction de transfert compétitive produit 1 ou 0.

d. Les réseaux de neurones compétitifs ou cartes auto organisatrices

Ces réseaux peuvent détecter des régularités et des corrélations dans les données d'entrées et peuvent adapter leurs réponses en fonction de ces entrées. Les neurones de ces réseaux peuvent reconnaître des groupes dans les vecteurs d'entrée. Les cartes auto organisatrices peuvent apprendre à reconnaître des groupes de vecteurs similaires, ce qui entraîne que les neurones physiquement proches les uns des autres dans la couche de neurones à répondre à ces vecteurs d'entrée similaires.

- Réseaux de neurone compétitif ou réseaux de Kohonen (loi d'apprentissage de Kohonen).
- Les cartes auto organisatrices.
- Les LVQ réseaux de neurones.

e. Les réseaux récurrents

- **Réseaux d'Elman**

Le réseau d'Elman a des neurones tanh dans sa couche cachée récurrente et un neurone linéaire dans sa couche de sortie. Ce type de réseau peut aussi approximer n'importe quel type de fonction pourvu que la couche cachée ait assez de neurones. Puisque ce réseau peut enregistrer de l'information pour une référence future, il est capable d'apprendre des associations aussi bien temporelles que spatiales.

- **Réseaux de Hopfield**

Ces réseaux sont des réseaux récurrents, un peu plus complexes que les perceptrons multicouches. Chaque cellule est connectée à toutes les autres et les changements de valeurs de cellules s'enchaînent en cascade jusqu'à un état stable. Ces réseaux sont bien adaptés à la reconnaissance de formes.

2.7. Principe de rétropropagation

Le réseau de neurones multicouche de rétropropagation est l'un des paradigmes le plus largement répandu des réseaux de neurones artificiels. Le réseau se compose de couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Les neurones des couches adjacentes sont reliés entre eux par les poids qui indiquent la force de la connectivité. Les neurones de la couche d'entrée n'exécutent aucun calcul, et ils reçoivent juste des signaux de l'environnement extérieur. La présence d'une série de couches cachées et l'adoption de la fonction non linéaire de transfert permettent au réseau d'apprendre le tracé fonctionnel non linéaire complexe entre les quantités d'entrée et les quantités de sortie. Le réseau doit être formé en présentant un ensemble de paires d'entrée-sortie d'apprentissage. Ceci est réalisé par l'optimisation de la mise en œuvre afin d'essayer de réduire au minimum l'erreur d'apprentissage par des mises à jour de poids. Lors du fonctionnement du réseau, les données du flux de la couche d'entrée expédient des informations à la couche de résultat. Chaque neurone calcule la somme pesée de ses entrées et soustrait un seuil. Le résultat passe par une fonction non linéaire de transfert et le résultat du neurone est produit. Alors la sortie de neurone est envoyée aux neurones de la couche suivante. Ce processus est répété pour chaque couche suivante de neurones, et les sorties des neurones de la dernière couche servent de prévisions au réseau.

2.8. Choix de l'architecture

Le choix d'une architecture d'un réseau de neurones artificiels pour résoudre un problème donné pose un problème majeur. Le nombre de neurones, le pas d'apprentissage, la fonction d'activation, les poids initiaux..., influencent fortement la performance des réseaux de neurones artificiels.

Le choix de l'architecture d'un réseau détermine la classe des fonctions calculables par celui-ci, ou encore sa complexité potentielle. C'est évidemment le premier paramètre sur lequel les

utilisateurs de réseaux ont joué pour contrôler les performances d'un système. La démarche la plus évidente pour choisir la meilleure architecture est bien entendu de tester plusieurs modèles différents, changeants les types de neurones, le nombre de couches, le nombre de neurones cachés. Cependant, l'évaluation comparative des réseaux ainsi créé pose problème, de nombreuses méthodes existant mais étant beaucoup trop lourdes en calculs. Pour cette raison, la communauté de réseaux de neurones a adopté des procédures sous-optimales. La plus courante consiste en l'utilisation d'un ensemble de validation, le réseau offrant les erreurs les moindres sur cet ensemble étant considéré le meilleur. Cette méthode est également coûteuse en temps de calcul et soumise à de nombreux aléas.

2.9. Propriétés des réseaux de neurones

Les réseaux de neurones peuvent être assimilés dans certaines conditions à des approximateurs universels. Ce fait explique pourquoi les réseaux de neurones peuvent prédire un comportement décisionnel et peuvent résoudre de problèmes de type "Binary Choice Model": les réseaux de neurones artificiels peuvent approximer la relation entre les caractéristiques d'un individu et son comportement décisionnel. En résumé, ceci est possible à cause de ces sept propriétés des réseaux de neurones:

- **Non-linéarité:** la relation recherchée ne doit pas être linéaire, les dépendances non-linéaires sont même mieux approximées.
- **Le parallélisme:** C'est l'exécution de plusieurs tâches (données numériques et non pas symboliques) en même temps, c'est un point essentiel que présente le réseau de neurones à grande rapidité de calcul.
- **Capacité d'apprentissage:** Il faut faire aucune hypothèse à propos de la forme de la dépendance, celle-ci va être déterminée à partir des données exemple.
- **La mémoire distribuée:** La mémoire est répartie sur tout le réseau, l'intérêt de cette distribution de la mémoire sur plusieurs entités est la résistance au bruit.
- **Capacité de généralisation:** Même si les données d'apprentissage sont bruitées, le réseau peut apprendre le processus initial.
- **Classificateur de modèle:** la nécessité d'un classement des données est un problème très commun dans le traitement de l'apprentissage. Nous la retrouvons dans le contrôle de qualité, les prévisions financières, la recherche de laboratoire, le marketing visé, la prévision de faillite, la reconnaissance optique des caractères, etc. RNAs du type de rétropropagation, normalement appelés les perceptions multicouche (MLPs) ont été appliqués dans ces secteurs parce qu'ils sont d'excellents cartographes fonctionnels (ces problèmes peuvent être formulés en tant que conclusion d'une bonne carte d'entrée-sortie).

- **Nombre de variables:** Le nombre de variables d'entrée n'est pas limité comme pour d'autres procédés d'interpolation, par exemple l'interpolation spline.

Il y a aussi des propriétés moins souhaitables, comme par exemple le fait que la fonction reste inconnue à l'utilisateur, qui a accès seulement aux sorties qui correspondent à des entrées données [19].

2.10. Les applications des réseaux de neurones en génie civil

Au cours des dernières années ou plus, l'utilisation de réseaux de neurones artificiels (RNA) a augmenté dans de nombreux domaines de l'ingénierie. En particulier, les RNAs ont été appliqués à de nombreux problèmes de génie civil et ont démontré un certain succès. Un examen de la littérature révèle que les réseaux de neurones artificiels ont été utilisés dans des différentes disciplines de génie civil.

En dynamique :

N. Bourahla et T. Boukhemacha [11] présentent une méthode globale basée sur les réseaux de neurones artificiels pour estimer le niveau de l'excentricité accidentelle dans un bâtiment nominale ment symétrique. Un ensemble d'enregistrements de vibrations ambiantes du nouvel aéroport d'Alger sont utilisés pour l'apprentissage du réseau de neurones de type Elman à rétropropagation, puis une fonction linéaire est entrée dans le réseau afin d'estimer le niveau de l'excentricité à divers gammes d'amplitudes de réponse.

M. Badaoui et al. [15] ont développé une procédure d'évaluation de l'excentricité accidentelle en utilisant les techniques de réseaux de neurones couplées à des simulations de Monte Carlo. Ils ont utilisé un réseau de feed-forward multi-couches où la couche d'entrée correspond aux réponses maximales (des déplacements ou des accélérations) et des fréquences naturelles et la couche de sortie correspond à l'excentricité de chaque étage. Cette méthode donne des résultats très intéressants pour les structures à un seul étage.

K. Kuzniar, E. Maciag, R. Obiata et Z. Waszczyszyn [20] traitent une application de réseaux de neurones pour la détection des périodes propres des vibrations de bâtiments préfabriqués de moyenne hauteur. La technique de réseau de neurones est également utilisée pour simuler la réponse dynamique à l'étage sélectionné de l'un des bâtiments analysés soumis à des charges sismiques induites par des explosifs dans une carrière voisine.

N. Bourahla, R. Taleb et T. Boukhemacha [21] présentent une technique basée sur l'analyse des réseaux de neurones pour extraire des informations spécifiques à partir du signal enregistré, ils ont utilisé le réseau d'Elman avec une base de données composée de signaux sonores enregistrés comme entrée et les variations de l'accélération dans le domaine temporel calculées numériquement à un point spécifique du spécimen comme des signaux cibles.

S. Saadata et al. [22] présentent une nouvelle approche d'identification du système, la méthode de paramètre variable intelligent qui est utilisée pour identifier le comportement non-linéaire des structures soumises à des excitations sismiques et ils ont adapté les réseaux de neurones artificiels pour la modélisation non paramétrique et l'identification de système à cause de leurs capacités propres d'approximation d'une fonction non linéaire.

J. Zhang et R.O. Foschi [23] ont étudié la conception des expériences informatiques et les réseaux de neurones pour la représentation du comportement structural. Une méthode de calcul pour l'estimation de la fiabilité sismique est présentée, avec une stratégie basée sur la performance pour la conception en utilisant plusieurs critères de performance.

N. Djarfour et al. [24] ont choisi un RNA de type Elman (connexion récurrente) pour le filtrage des données sismiques. Ce type possède une couche spéciale appelée «couche de contexte» qui copie l'activité des neurones de la couche cachée, les sorties des neurones de la «couche de contexte» sont utilisées en entrée de la couche cachée. Il y a alors conservation de la trace des activités internes du réseau sur un pas de temps. L'intérêt de ces modèles réside dans leurs capacités d'apprendre des relations complexes à partir des données numériques.

Dans la vulnérabilité sismique:

H. Noura, M. Abed et H. Bouarfa [25] exposent une approche utilisant les Réseaux de Neurones comme outil pour évaluer la vulnérabilité de structures en béton armé. Un système de RNs associé à un ensemble de 130 constructions expertisées est mis en place pour constituer d'abord une phase d'apprentissage. Dans une seconde phase dite de simulation, un autre ensemble de constructions est utilisé pour prédire la vulnérabilité. Une étude de validation a permis de qualifier de satisfaisants les résultats estimés par le système de RNs par rapport à ceux figurants dans les fiches d'expertise réelles.

T. Aokia et al. [26] ont utilisé des simulations par éléments finis pour créer un ensemble d'apprentissage qui a été utilisé pour l'apprentissage d'un système de réseau de neurones probabiliste qui estime la vulnérabilité sismique des éléments structuraux typiques des usines de produits chimiques.

Diagnostic des bâtiments :

J.L. Zapico, M.P. Gonzalez et K. Worden [27] proposent une méthode d'évaluation des dégâts dans une structure basés sur les réseaux de neurones. Un réseau de neurones est utilisé pour calibrer la structure initiale en bon état, et un autre pour prédire les dommages, les données utilisées pour l'apprentissage des réseaux de neurones ont été obtenus grâce à un modèle élément finis et les fréquences propres de la structure sont utilisées comme des entrées du réseau.

K. Tsuchimoto, N. Wada et Y. Kitagawa [28] ont développé un système de diagnostic des dommages structurels et de la dégradation. Ce système utilise une stratégie d'identification des dégâts en deux étapes dans lequel le dommage est identifié globalement basé sur les réseaux de neurones (le taux de diminution de la fréquence propre est sélectionné comme entrée, et le taux de réduction de la rigidité est sélectionné en tant que sortie) et puis localement en fonction des variations de l'excentricité entre le centre de rigidité et le centre de masse le long de chaque axe.

En géotechnique :

Dans l'étude de B. Siyahi, B. Akbas et N.D. Onder, un modèle du réseau de neurones a été développé pour étudier la liquéfaction induite par la diffusion latérale au cours d'un mouvement du sol lors d'un séisme. Un lien est établi entre la diffusion latérale et le sol et les paramètres des mouvements du sol en développant et en testant un modèle de réseau de neurones multicouches feed-forward en utilisant l'algorithme de rétro-propagation pour l'apprentissage.

T.R. Mehrzad et H.M. Reza [30] déterminent la période dynamique et le facteur d'amplification du sol pour micro zonage en zone urbaine en utilisant les réseaux de neurones artificiels.

2.11. Conclusion

Nous avons exposé les éléments essentiels qui permettent de comprendre le principe de fonctionnement des réseaux de neurones artificiels et leur utilisation et la puissance de cette technique dans les différents domaines de l'ingénierie.

Les réseaux de neurones ont de puissantes fonctionnalités comme approximateurs universels de fonctions de cartographie non linéaires avec une complexité arbitraire. Vu la performance et le développement des RNA, leur utilisation est très répandue dans différents domaines et notamment en génie civil et génie sismique.

CHAPITRE 3: EVALUATION DE L'EXCENTRICITE ACCIDENTELLE PAR LES RNAS A PARTIR D'UNE REPONSE DYNAMIQUE

3.1. Introduction

Dans l'analyse sismique des structures, l'excentricité additionnelle est introduite pour tenir compte des oscillations aléatoires et des origines inconnus. En raison de la nature aléatoire des systèmes structuraux, il est très difficile d'évaluer l'excentricité accidentelle d'une manière déterministe et de préciser son effet sur la réponse sismique globale des structures.

Ce chapitre étudie la possibilité de déterminer l'excentricité accidentelle causée par les incertitudes structurelles de rigidité et de masse à partir d'une réponse dynamique du bâtiment au niveau d'un plancher (les déplacements).

Pour atteindre cet objectif, nous procédons par une approche basée sur les réseaux de neurones artificiels dont l'architecture, la base de données et la validation sont exposés ci-après.

3.2. Principe et méthodologie

L'excentricité accidentelle est le terme utilisé dans les codes parasismique pour tenir compte les incertitudes dans plusieurs facteurs qui contrôlent la symétrie structurale de la construction et du chargement. Les sources d'incertitudes communément connus sont : la masse, la distribution de rigidité et de résistance et de la composante de rotation du mouvement du sol, qui ne sont pas exprimés explicitement dans l'analyse dynamique. Aujourd'hui, et plus encore à l'avenir, avec les progrès technologiques, la conception parasismique tend à être plus précise en utilisant des principes et des critères de conception plus précis. Pour préparer les changements nécessaires dans les codes de conception, de nombreux facteurs approximatifs doivent être affinés. Cela est possible grâce à l'utilisation de techniques innovantes disponibles numériques et expérimentales. Dans ce cas, une tentative en vue de réduire les incertitudes de l'excentricité est obtenue par l'estimation de la valeur de l'excentricité accidentelle.

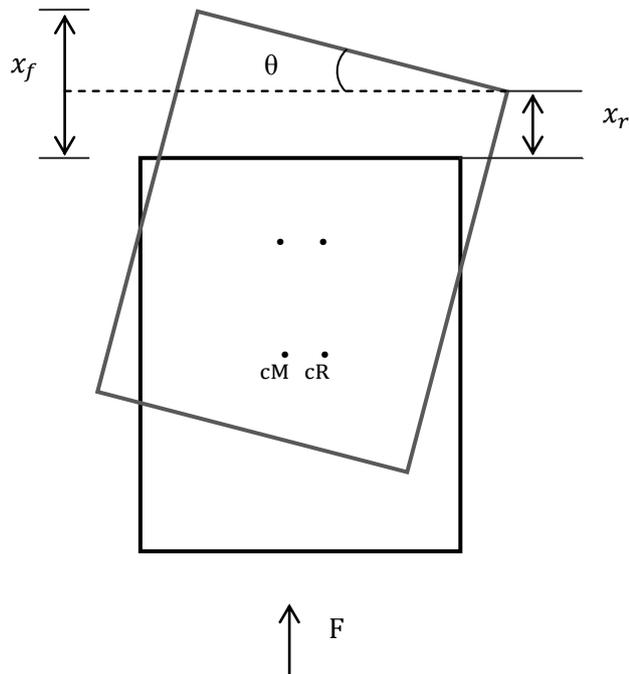


Figure 3.1: *Modèle structurel excentré dans un seul sens.*

Si on considère un bâtiment asymétrique représenté dans la figure 3.1, sous une excitation sismique F appliquée au centre de masse, le système subira une rotation (supposée petite) qui peut être exprimée comme suit:

$$\theta = \frac{x_f - x_r}{b} \quad (1)$$

θ : le signal de variation de l'angle de rotation du plancher.

x_r et x_f : sont les signaux de déplacements de deux points situés sur le côté rigide et flexible du plancher, respectivement.

Le côté rigide : c'est le côté du plancher le plus proche du centre de rigidité.

Le côté flexible : c'est le côté du plancher le plus loin du centre de rigidité

b : est la dimension du bâtiment perpendiculaire au sens de l'excitation.

Lorsqu'on découple les modes de la réponse on constate que :

- Lors du mode de translation, le centre de masse et le centre de rigidité se déplacent de la même manière (même déplacement) car le plancher est infiniment rigide.
- Lors du mode de rotation, le centre de rigidité ne se déplace pas (reste fixe), par contre le centre de masse se déplace et tourne autour du centre de rigidité avec un angle θ définie dans la formule (1). Tous les points du plancher tournent avec un angle θ autour du centre de rigidité (centre de torsion).

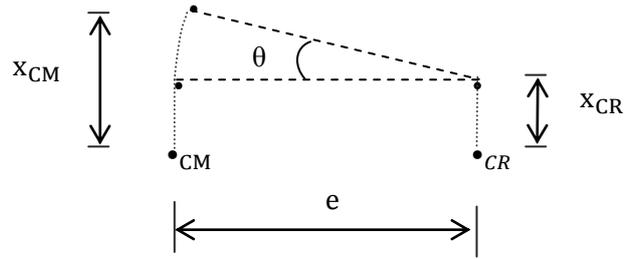


Figure 3.2: Le déplacement du centre de masse et de rigidité lors d'une réponse couplée.

D'après la figure 3.2, on peut écrire :

$$e = \frac{x_{CM} - x_{CR}}{\theta} \quad (2)$$

Avec :

θ : le signal de variation de l'angle de rotation du plancher dans le domaine temporel défini dans l'équation (1).

x_{CM} : le signal de déplacement du centre de masse.

x_{CR} : le signal de déplacement du centre de rigidité.

e : la distance entre le centre de masse et le centre de rigidité (l'excentricité).

- **Le cas des excentricités dans les deux sens**

C'est le cas général, la plupart des bâtiments en réalité ont des excentricités dans les deux sens (e_x et e_y).

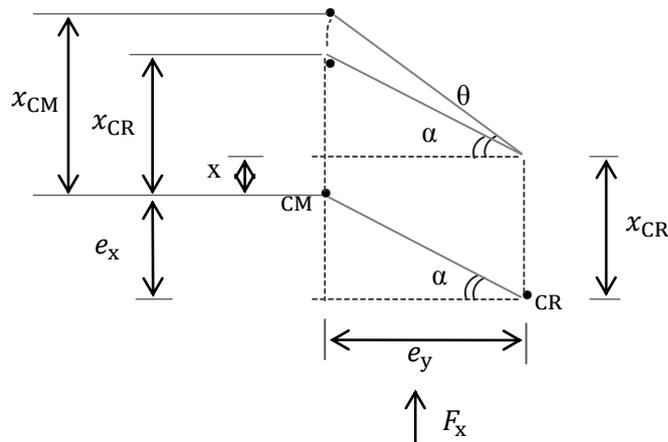


Figure 3.3: Le déplacement du centre de masse et de rigidité lors d'une réponse couplée.

D'après la figure 3.3, on a :

α : L'angle entre l'horizontale et la droite qui relie le centre de masse avec le centre de rigidité.

Θ : L'angle de rotation du plancher.

e_x : L'excentricité dans le sens x.

e_y : L'excentricité dans le sens y.

x_{CM} : Le déplacement du centre de masse.

x_{CR} : Le déplacement du centre de rigidité.

x : La distance entre la position initiale du centre de masse et la position du centre de rigidité après déplacement.

On peut écrire :

$$\alpha = \frac{x_{CR} - X}{e} \quad (3)$$

$$(\alpha + \Theta) = \frac{x_{CM} - X}{e} \quad (4)$$

On remplace (3) dans (4) et on obtient :

$$e = \frac{x_{CM} - x_{CR}}{\Theta} \quad (5)$$

Alors cette formule est valable pour la détermination de la valeur de l'excentricité de n'importe quel plancher.

Pour déterminer la valeur de l'excentricité e à partir de cette formule il faut connaître :

L'angle de rotation Θ , le déplacement du centre de masse et le déplacement du centre de rigidité.

La détermination de l'angle Θ à partir de la formule (1) est très simple car il est en fonction de x_f et x_r et la dimension du plancher b .

x_f , x_r sont des réponses structurales qui peuvent être mesurées directement sur un étage du bâtiment dans les essais de vibrations ambiantes ou un enregistrement pendant une excitation sismique réelle.

Par contre la détermination du déplacement du centre de masse et le déplacement du centre de rigidité est très difficile ou impossible, parce qu'en réalité on ne peut pas localiser à priori les positions exactes des centres de masse et de rigidité.

Pour la résolution de ce problème on va utiliser la technique des réseaux de neurone artificiels qui a démontré un certain succès dans le domaine de génie parasismique et notamment dans la prédiction et l'approximation des fonctions.

3.3. Etablissement du modèle de réseau de neurones

On doit construire deux modèles de réseaux de neurones, un pour la prédiction de déplacement du centre de masse, et le deuxième qui doit prédire le déplacement du centre de rigidité.

Les étapes suivies pour constituer le réseau de neurones sont les suivantes :

La première étape consiste à identifier les grandeurs à employer pour le modèle de réseau de neurones. Deux ensembles de données ont été produits. Un pour la phase d'apprentissage et l'autre pour la phase de test ou de validation. En se basant sur le type et la taille des données d'entrée, le nombre de neurones en entrée et dans les couches cachées, les configurations (architecture) du réseau de neurones, le réseau est rodé en présentant les données d'entrée au réseau autant de fois que nécessaire jusqu'à satisfaction du critère de l'erreur maximale permise.

Une fois que la phase d'apprentissage est accomplie, le réseau qualifié et testé devrait maintenant prévoir les propriétés requises. Pour examiner la capacité du réseau à généraliser les exemples d'apprentissage, les données prévues pour le test sont présentées et la sortie réelle du réseau est comparée avec la sortie désirée.

Une question récurrente dans le développement des modèles de réseaux de neurones est le choix des entrées à employer pendant le processus d'apprentissage. Etant donné que le réseau de neurones ne peut pas être exploité pour extrapoler des valeurs, le modèle d'apprentissage devrait donc englober toutes les valeurs.

Dans notre étude pour l'extraction des deux signaux des déplacements du centre de masse et de centre de rigidité à partir des réponses structurales, la situation idéale serait de former le modèle de réseau de neurones à partir des deux signaux de déplacements des deux côtés extrêmes du plancher (flexible et rigide) donnés par le calcul numérique, on a utilisé comme entrée de réseau le signal de différence des déplacements des deux côtés rigide et flexible, mais nous avons obtenu des mauvais résultats (le réseau n'a pas trouvé une bonne correspondance entre les données de l'entrée et celles de sortie).

Le résultat du réseau de neurones étant le signal de déplacement du centre de masse ou le déplacement du centre de rigidité.

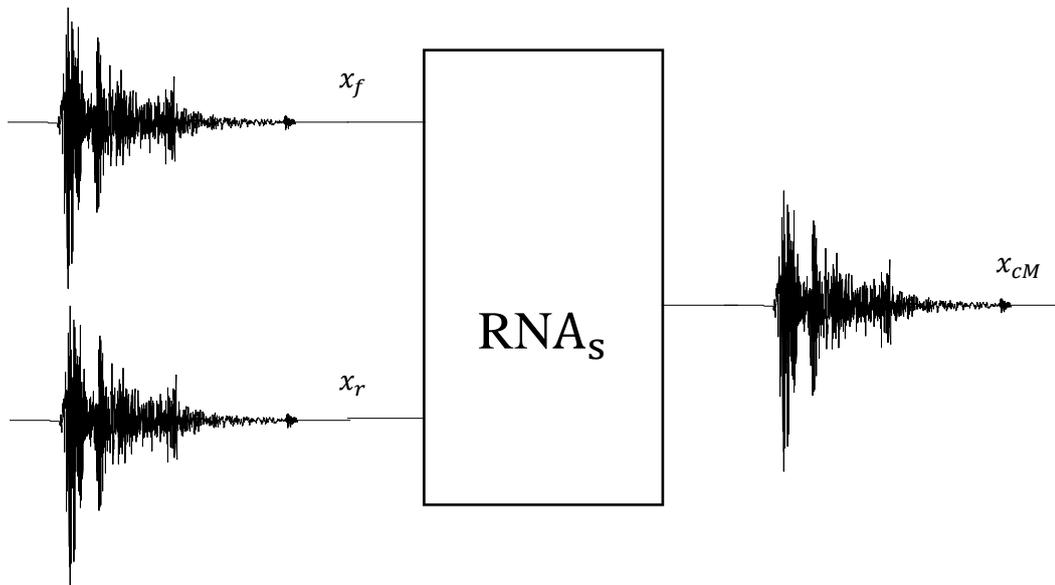


Figure 3.4: Principe de fonctionnement du premier modèle de réseau de neurones.

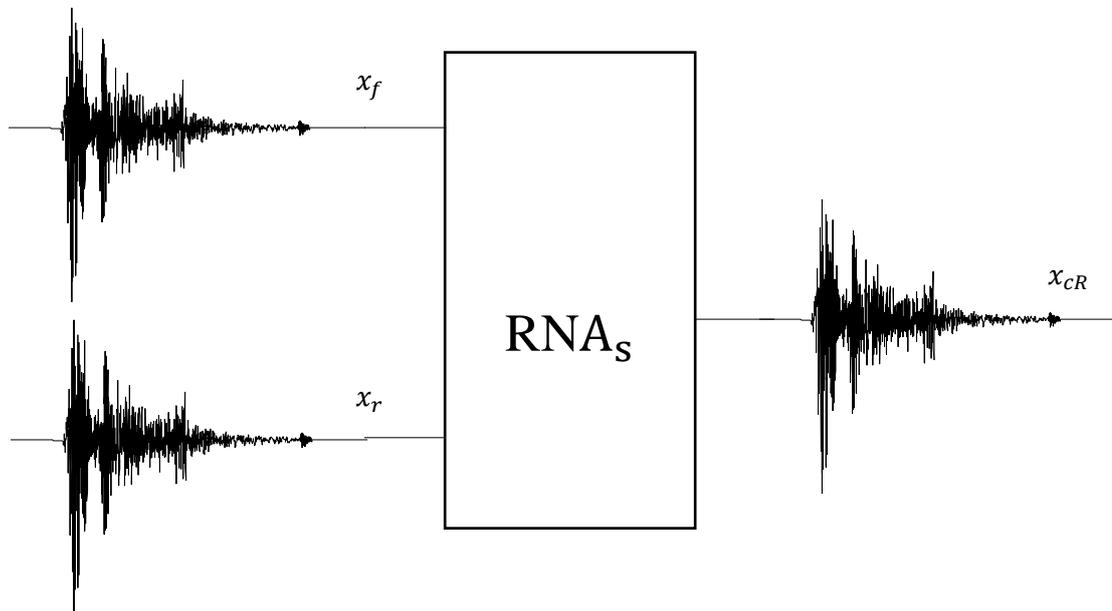


Figure 3.5: Principe de fonctionnement du deuxième modèle de réseau de neurones.

3.4. Choix du réseau

Pour une prédiction précise des deux signaux de déplacement du centre de masse et du centre de rigidité, le réseau d'Elman est le plus approprié pour ce travail [15].

Le réseau d'Elman est un réseau à deux couches raccordées entre elles. Ce raccordement récurrent permet au réseau de détecter et produire des modèles qui varient en fonction du temps.

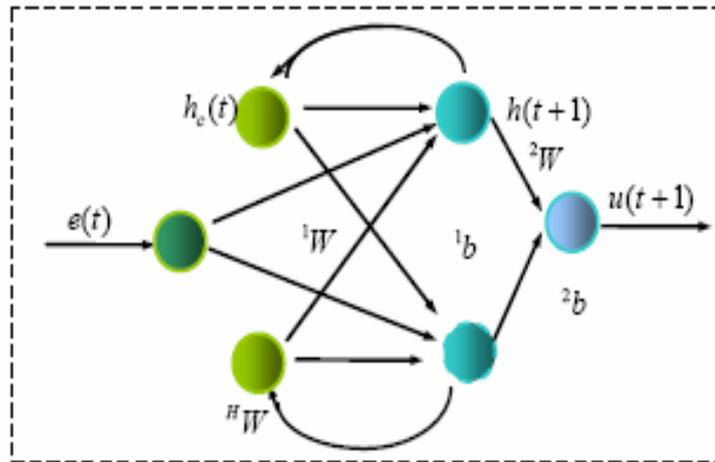


Figure 3.6: La structure de RNA d'Elman.

Un diagramme représentant le réseau d'Elman est montré sur la figure 3.6. Il a des fonctions sigmoïdes tangentielles de transfert dans les neurones de sa couche (récurrente) cachée, et la fonction linéaire pure de transfert dans les neurones de sa couche de sortie.

Cette combinaison est spéciale du fait que les réseaux de deux couches avec ces fonctions de transfert peuvent simuler n'importe quelle fonction (avec un nombre fini de discontinuités) avec l'exactitude voulue. La seule condition est que la couche cachée doit avoir assez de neurones. Plus de neurones cachés sont nécessaires quand la fonction comporte plus de complexités. Notez que le réseau d'Elman diffère des réseaux conventionnels de deux couches car la première couche a un raccordement récurrent. Ainsi, même si deux réseaux d'Elman, avec les mêmes poids et polarisations, sont donnés l'étape identique d'entrées à un moment donné, leurs sorties peuvent être différentes dues aux différents états de rétroaction.

Comme indiqué précédemment, le choix du type du réseau de neurones est dicté par la nature des thèmes.

3.5. Facteurs influents sur la conception du RNAs

Dans cette étude le nombre de couches cachées a été choisi afin de rendre le réseau aussi simple que possible, et d'éviter de prolonger le temps d'apprentissage. Cependant, le nombre de neurones dans la couche cachée varie en fonction de la taille de la couche d'entrée, sachant que le temps d'apprentissage augmente sensiblement avec le nombre de couches cachées, et que le nombre de neurones dans la couche d'entrée est fonction de la taille du modèle.

L'architecture des réseaux considérés dans cette étude a seulement deux couches cachées. Cependant, le nombre de neurones dans chaque couche cachée a été optimisé.

3.6. L'architecture du réseau

L'architecture du réseau de neurones doit être déterminée avant l'apprentissage. Le nombre de variables d'entrée (notre cas, les signaux des déplacements des cotés rigide et flexible) et le nombre de variables de sortie (notre cas, signal de déplacement du centre de masse pour le premier modèle et le signal de déplacement du centre de rigidité pour le deuxième modèle) sont déterminés par les caractéristiques du problème. Avant de définir l'architecture du réseau de neurones, le nombre de couches cachées et le nombre de neurones dans chaque couche doivent être définis. Alors un ensemble d'échantillons d'apprentissage sont utilisés pour adapter le réseau de sorte qu'il apprenne le rapport fonctionnel entre les variables d'entrée et les variables de sortie. Au début de l'apprentissage, les poids sont aléatoirement assimilés à des petits nombres réels. Puis les exemples sont présentés au réseau et une opération de passage vers l'avant est effectuée. Chaque neurone calcule la somme pesée de ses entrées et transmet le résultat par une fonction de transfert à partir de laquelle le résultat de neurone (output) est obtenu. La fonction typique de transfert est la fonction sigmoïde. Les données flux évoluent couche par couche. Les résultats des neurones de sortie servent d'évaluations au réseau. Les anomalies entre les sorties réelles et les sorties prévues mesurent l'erreur de l'apprentissage, afin de la réduire à un minimum acceptable, les poids des réseaux doivent être ajustés.

Bien qu'il y ait des théorèmes qui garantissent que les réseaux de neurones de rétro-propagation avec (au moins) deux couches cachées sont capables de rapprocher n'importe quelle fonction non linéaire avec une exactitude désirée. Aucune directives générales ne sont disponibles pour choisir la topologie appropriée des réseaux.

En générale, une approche d'essai/erreur est suivie pour trouver la structure la plus adaptée au réseau. Plusieurs réseaux avec différentes architectures sont formés et examinés, mais seulement les réseaux qui comprennent le moins d'erreurs sont employées pour l'application.

Cette phase est réalisée par un passage en arrière de l'erreur nommé rétropropagation d'erreur. L'erreur du réseau est rétrocédée de la couche de résultat vers la couche d'entrée, et les poids sont ajustés selon des stratégies étudiées afin de ramener l'erreur de réseau à un niveau acceptable.

Après cette phase de rodage et d'ajustement systématique, tous les poids sont figés et le réseau peut être appliqué pour la prévision.

La couche cachée joue un rôle crucial dans l'exécution de réseau de neurones. Elle permet au réseau de modéliser des rapports non linéaires compliqués et de capturer les dispositifs sous tendant entre les entrées et les sorties. Un nombre optimal de neurones dans la couche cachée est exigé. Un réseau avec peu de neurones peut ne pas pouvoir capturer le rapport fondamental complexe entre les données de l'entrée et les données de sortie, ainsi il ne peut pas généraliser bien aux données inaudibles. D'autre part, trop de neurones tendent à avoir comme conséquence un mauvais ajustage de précision des données d'apprentissage, c.à.d. le modèle est trop compliqué pour être sûrement impliqué d'une quantité limitée de données d'apprentissage, par conséquent la prévision de réseau sera pauvre malgré une erreur très basse d'apprentissage. Il n'y a aucune règle générale pour choisir le nombre optimal de neurones dans la couche cachée, ce dernier doit être assez grand pour pouvoir modéliser le tracé non linéaire compliqué, tandis qu'assez petit pour assurer une bonne généralisation. En outre, le nombre de neurones doit être inférieure au nombre d'exemples d'apprentissage.

Il y a deux algorithmes disponibles: algorithme de descente et algorithme de taille. Dans l'algorithme de descente, on commence par une architecture simple avec seulement quelques neurones cachés, et on calcule l'erreur du réseau. Si l'erreur d'apprentissage est grande, on ajoute plus de neurones cachés. Le processus est répété jusqu'à ce que l'erreur d'essai commence à diminuer.

Dans l'algorithme de taille, on commence par une architecture complexe avec beaucoup de neurones cachés, et on évalue l'exécution du réseau par l'apprentissage et l'essai parallèle. Si l'ajustage de précision se produit, les neurones dans la couche cachée sont réduits jusqu'à ce que l'erreur d'apprentissage soit réduite à un niveau acceptable.

Dans ce travail, deux couches cachées sont adoptées et le nombre de neurones dans les couches cachées est déterminé par l'algorithme de descente.

Le nombre de neurones dans la couche cachée, est déterminé par des expériences. Avec deux couches cachées de 21 neurones chacune pour le modèle qui détecte le déplacement du centre de masse et avec deux couches cachées de 17 neurones chacune pour le modèle qui détecte le déplacement du centre de rigidité, le réseau a atteint son limite optimale de convergence.

Les neurones additionnels n'ont pas diminué l'erreur pour la plupart des cas.

3.6.1. Modèle de RN pour la prédiction du déplacement du centre de masse

Pour la prédiction de déplacement du centre de masse on a utilisé un réseau de neurones de type Elman avec une couche d'entrée et deux couches cachées de 21 neurones chacune avec des fonctions sigmoïdes tangentielles comme fonctions de transfert et une couche de sortie avec la fonction linéaire pure comme fonction de transfert.

Les deux signaux de déplacement des cotés rigide et flexible sont utilisés comme une entrée de réseau, et le signal de déplacement du centre de masse comme sa sortie.

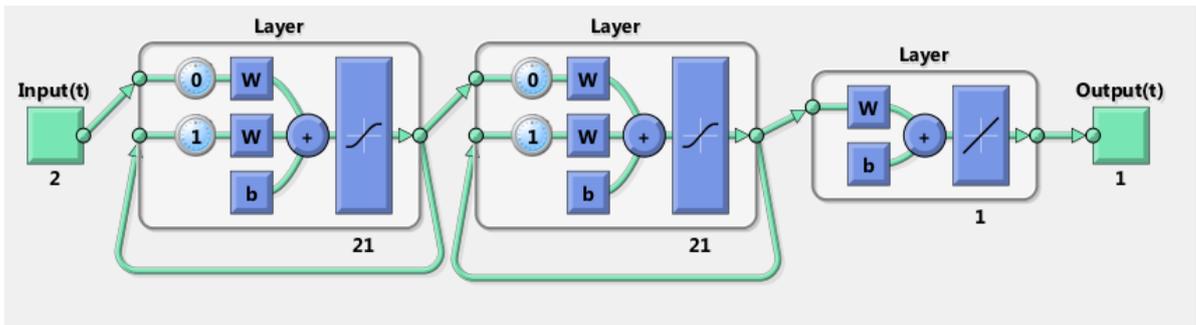


Figure 3.7: Le modèle de RN utilisé pour la détection de déplacement du centre de masse.

3.6.2. Modèle de RN pour la prédiction du déplacement du centre de rigidité

Pour la prédiction du déplacement du centre de rigidité on a utilisé un réseau de neurones de type Elman qui est approprié pour ce travail avec une couche d'entrée et deux couches cachées de 17 neurones chacune avec des fonctions sigmoïdes tangentielles comme des fonctions de transfert et une couche de sortie avec la fonction linéaire pure comme une fonction de transfert.

Les deux signaux de déplacement des cotés rigide et flexible sont utilisés comme une entrée de réseau, et le signal de déplacement du centre de mase comme sa sortie.

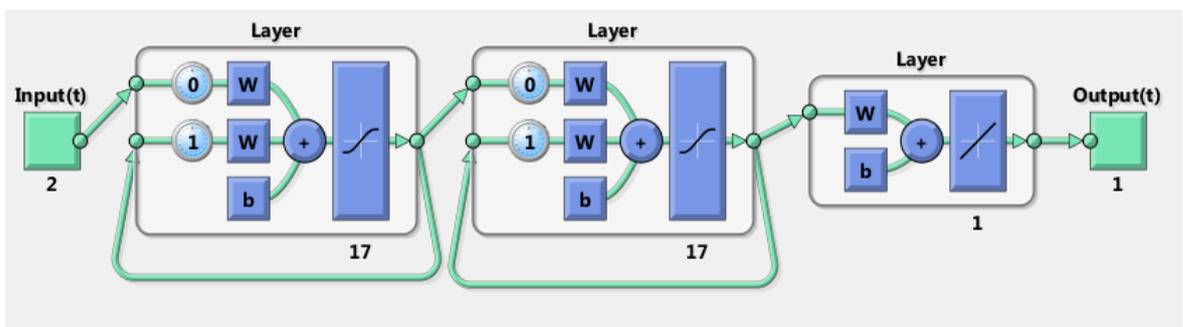


Figure 3.8: Le modèle de RN utilisé pour la détection de déplacement du centre de rigidité.

3.7. Apprentissage des modèles de réseau de neurones

3.7.1. La base de données d'apprentissage du RNAs

Notre base de donnée est divisée en deux partie une pour l'apprentissage et l'autre pour le test et la validation, dans cette section nous exposons la description et la définition de la base de données d'apprentissage pour l'application aux modèles de réseau de neurones, choisis pour la détermination des déplacements du centre de masse et du centre de rigidité.

Le réseau de neurones utilise la technique d'apprentissage supervisé, chaque donnée d'entrée doit être associée à un résultat désiré pour que l'apprentissage du réseau de neurones soit achevé. Après que l'apprentissage ait été accompli, le réseau a été testé pour déterminer sa capacité de généralisation.

Un modèle numérique en éléments finis est utilisé pour la création de la base de données d'apprentissage des deux modèles de réseau de neurones.

- Description du modèle numérique

C'est un modèle à un seul niveau en béton armé de dimension 6x6 m formé par quatre poteaux de section carrée 30x30 cm et des poutres de section rectangulaire 25x35 cm.

Le module de Young $E=32000000$ KN/m, le poids volumique $\rho=25$ KN/ m³.

En affectant aux 2 nœuds du côté flexible des masses ponctuelles de 30 KN chacune, et aux 2 nœuds du côté rigide des masses ponctuelles 10 KN chacune, on obtient Une excentricité dans le sens y égale à 79.73 cm, soit 13.29% de la dimension totale du plancher. Il n'y a pas d'excentricité dans le sens x.

L'accélérogramme de Petrolia est utilisé comme une excitation suivant la direction x.

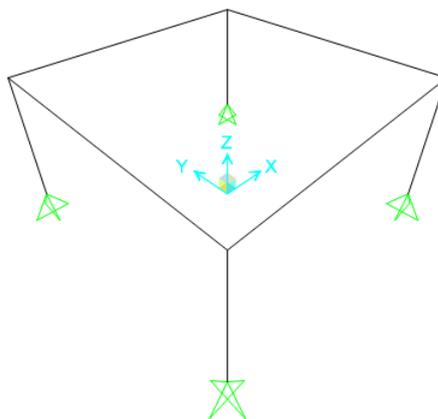
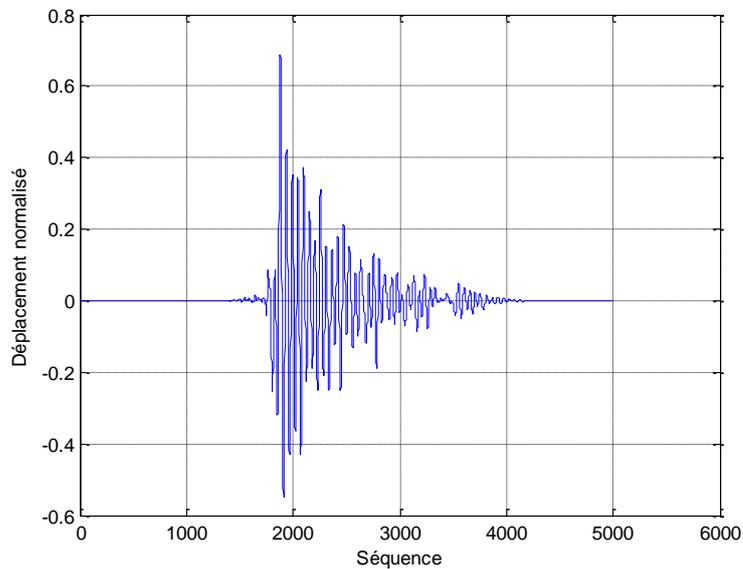


Figure 3.9 : Modèle structurel.

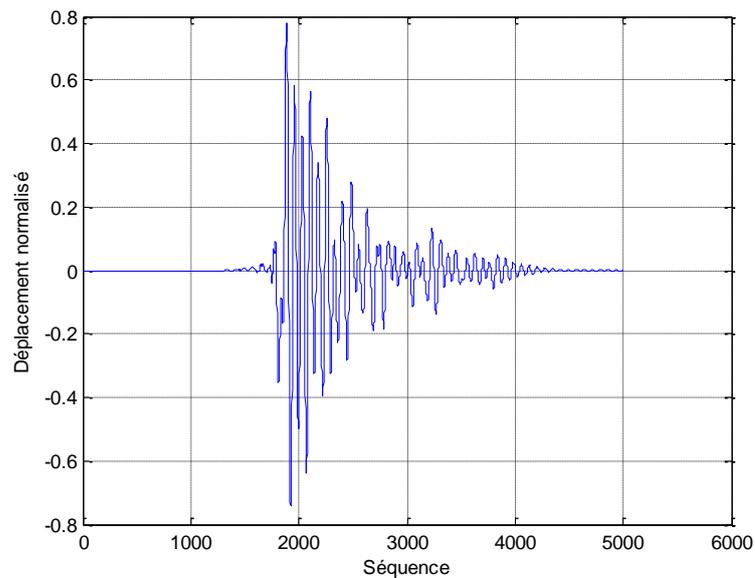
Les signaux de déplacements des cotés flexible et rigide (figure 3.10) sont utilisés comme des entrées dans les deux modèles de RN.

Le signal de déplacement du centre de masse (figure 3.11) est utilisé comme une sortie désirée de modèle de RN qui prédit le déplacement du centre de masse.

Le signal de déplacement du centre de rigidité (figure 3.12) est utilisé comme une sortie désirée de modèle de RN qui prédit le déplacement du centre de rigidité.



(a) Signal input de déplacement du côté rigide.



(b) Signal input de déplacement du côté flexible.

Figure 3.10: Les signaux input.

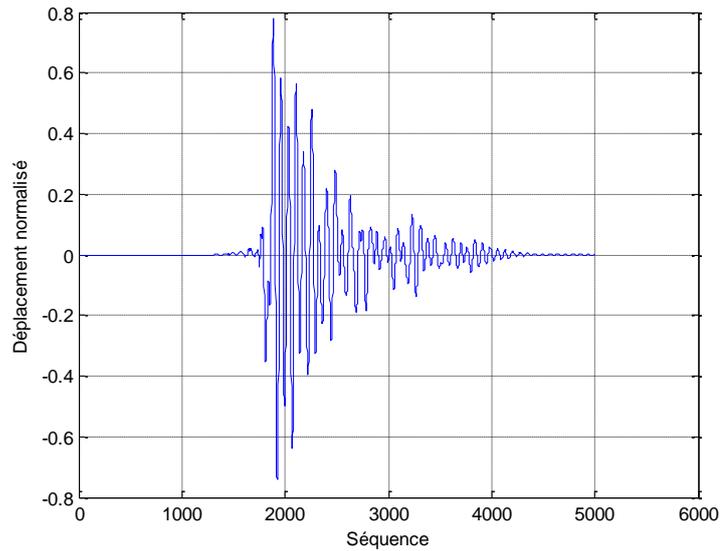


Figure 3.11: Signal désiré de déplacement du centre de masse.

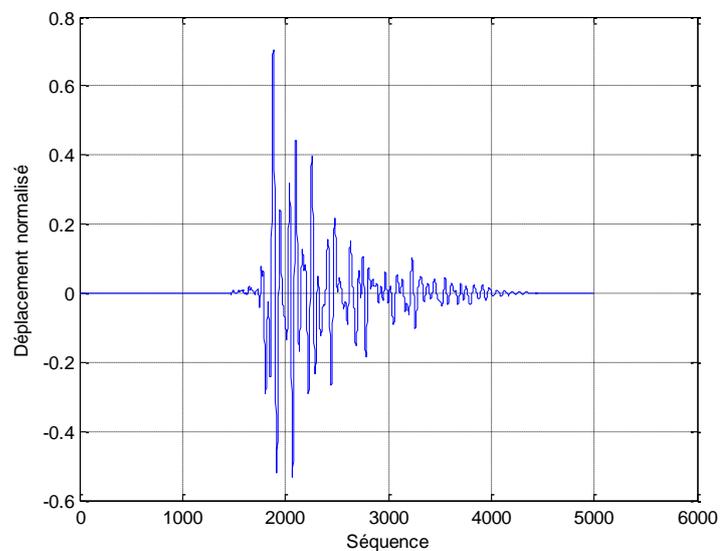


Figure 3.12: Signal désiré de déplacement du centre de rigidité.

Chacun de ces signaux contient 5000 points qui sont suffisants pour l'apprentissage du réseau de neurones.

3.7.2. La stratégie d'apprentissage du réseau de neurones

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré.

L'apprentissage neuronal fait appel à des exemples de comportement. Les méthodes d'optimisation utilisées pour l'apprentissage des RNAs peuvent être classées par catégorie dans deux classes: la méthode déterministe et la méthode stochastique.

La classe déterministe comporte des méthodes de premier ordre telles que la descente de gradient et des méthodes de second ordre telles que la méthode de Newton. La méthode stochastique est basée sur la recherche aléatoire, telle que l'algorithme évolutionnaire.

Si les données ne sont pas représentatives du processus, on ne pourra l'apprendre que partiellement. Le choix des données est crucial pour un bon apprentissage. Il faut bien choisir :

- le type des données
- leur nature
- leur pertinence/importance
- la quantité
- l'ordre dans lequel elles sont prises en compte.

3.7.3. L'apprentissage

Deux modes d'apprentissage sont utilisés : l'exploitation par lots, et l'autre par échantillon. En exploitant par lots, tout le jeu de données est présenté au réseau de neurones en un seul coup lors de la phase d'apprentissage, le résultat et l'erreur moyenne du réseau pour chaque vecteur d'entrée sont calculés, et les poids de réseau sont ajustés vers l'arrière en utilisant le principe de rétropropagation d'erreur.

Dans le deuxième mode, chaque exemple est présenté au réseau seul, l'erreur correspondante de réseau est calculée, les poids du réseau sont ajustés vers l'arrière en se basant sur l'erreur de cet exemple seul.

Généralement l'exploitation par lots est préférée, qui a été adoptée dans cette étude.

Le procédé suivant a été utilisé pour l'apprentissage final.

- Formez l'ensemble de données d'apprentissage (deux signaux de déplacement des deux nœuds d'extrémités rigides et flexibles comme entrée, et le signal de déplacement du centre de masse ou le déplacement du centre de rigidité comme sortie désirée).
- Formez le réseau de neurones, en utilisant l'ensemble de la base de données d'apprentissage et évaluez son exécution avec l'ensemble de données d'essai.
- Si l'erreur pour un certain cas d'essai est plus grande que le seuil prédéfini, il est mis dans l'ensemble de données d'apprentissage. En attendant, le cas où l'erreur est plus petite dans l'ensemble de données d'apprentissage est mis dans l'ensemble de données d'essai.
- Répétez le processus d'apprentissage jusqu'à l'erreur moyenne d'apprentissage R est réduite à la limite acceptable, ou le nombre d'itération est épuisé.

D'autre part, il est difficile de savoir quel algorithme d'apprentissage sera le plus rapide pour un problème donné. Il dépendra de beaucoup de facteurs, y compris la complexité du problème, du

nombre de points de repères dans l'ensemble d'apprentissage, du nombre de poids et de polarisations dans le réseau, et de l'erreur. Pour cette application où l'apprentissage précise est exigé, plusieurs essais ont été faits par les différents algorithmes disponibles dans MATLAB [31], et on constate que l'algorithme de Levenberg-Marquardt a la convergence la plus rapide.

La fonction de performance utilisée pour l'apprentissage de réseau de neurones est l'erreur quadratique moyenne (MSE) donnée par:

$$MSE = \frac{1}{N} \left(\sum_k (X_{CM_{RN_k}} - X_{CM_{D_k}})^2 \right)$$

Où X_{CMD} est le déplacement du centre de masse désiré, X_{CMRN} est le déplacement du centre de masse calculé par le réseau de neurones, N égal au nombre d'exemples de la base d'apprentissage et k est le numéro de l'échantillon. Les données sont saisies simultanément en mode groupe. Pour éviter le sur apprentissage du réseau, le procédé de l'arrêt précoce est utilisé.

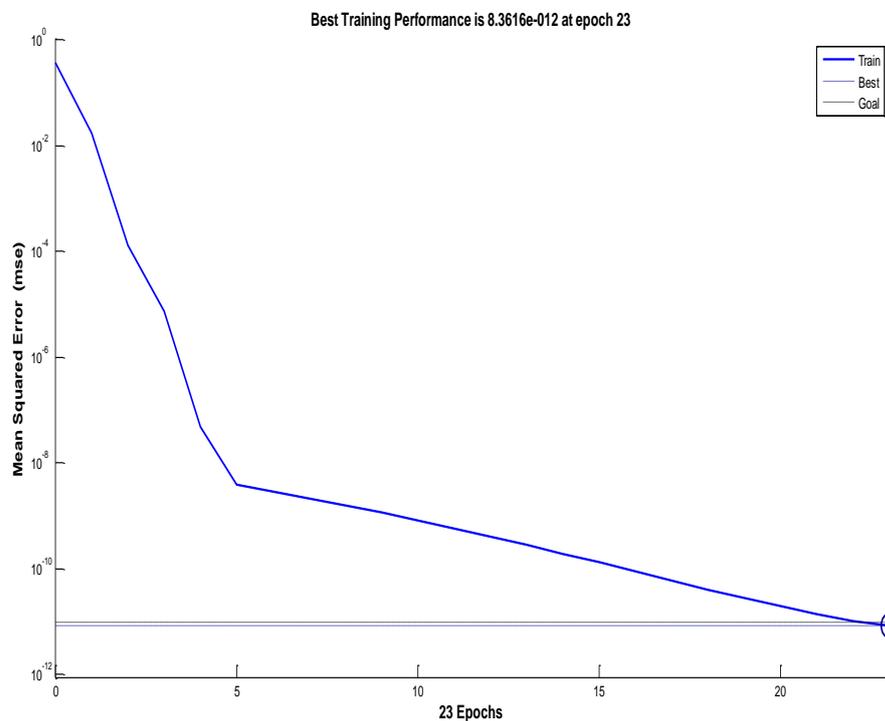


Figure 3.13: Evaluation de l'erreur pour la prédiction de déplacement du centre de masse.

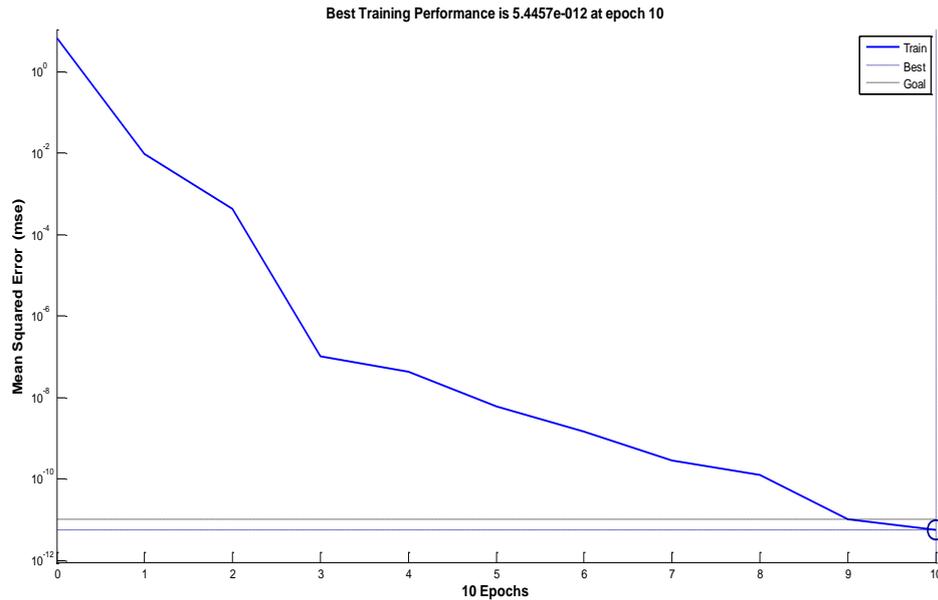


Figure 3.14: Evaluation de l'erreur pour la prédiction de déplacement du centre de rigidité.

Les erreurs sur les ensembles d'apprentissage sont conduites aux valeurs relativement petites avec une attention particulière faite pour éviter l'ajustage de précision fini. L'ordre d'entrée entier est présenté au réseau, et ses sorties sont calculées et comparées à l'ordre de cible pour produire l'ordre d'erreur. Pour chaque fois l'erreur est rétropropagée pour trouver des gradients des erreurs pour chaque poids et polarisation. Ce gradient est réellement une approximation puisque les contributions des poids et des polarisations aux erreurs par l'intermédiaire du raccordement récurrent retardé sont ignorées. Ce gradient est alors employé pour mettre à jour les poids avec la fonction d'apprentissage de rétropropagation. La courbe d'apprentissage d'exemple est représentée sur les figures 3.13 et 3.14.

3.8. Test et validation

L'efficacité des modèles proposés de réseau de neurones est évaluée sur la base des possibilités du réseau de simuler exactement la corrélation entre les signaux d'entrée de déplacement des cotés flexible et rigide, et le signal ciblé de déplacement du centre de masse du plancher ou le déplacement du centre de rigidité. Après que le réseau de neurones soit entièrement formé pour un ensemble donné de paires d'entrée-sortie, il est examiné en utilisant un signal qui n'appartient pas à l'ensemble d'apprentissage.

3.8.1. Base de données de validation

Pour le test de l'efficacité des deux modèles de réseau de neurones on construit une base de données en variant plusieurs paramètres dans des modèles numériques en éléments finis, ces paramètres sont les suivants :

- **L'excentricité** : création des différentes excentricités dans les modèles numériques utilisés dans le test des réseaux ce qui donne aussi un changement dans la position du centre de masse, on va tester aussi le cas des excentricités dans les deux sens (e_x et e_y).
- **L'excitation** : l'utilisation des différents accélérogrammes c.à.d. la variation de la durée, la forme des signaux des déplacements, les amplitudes et le contenu fréquentiel.
- **Les dimensions** : des changements dans les dimensions des modèles numériques et le nombre de travées et même dans les dimensions des éléments (poteaux, poutres).
- **La position du centre de rigidité** : création d'une excentricité du centre de rigidité du plancher.
- **Le nombre des niveaux** : établissement des modèles numériques à plusieurs niveaux.

3.8.2. Description des modèles numériques utilisés pour le test des réseaux

Modèle 1 : c'est un modèle à un seul niveau de dimensions de 4x4 m formé par cinq poteaux de section 30x30 cm et des poutres de section rectangulaire 25x35 cm. $E=32000000$ KN/m, le poids volumique $\rho=25$ KN/ m³. Une excentricité de 24,35 cm a été créée dans le sens y, soit 6.09% de la dimension totale du plancher. L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

Modèle 2: c'est un modèle à un seul niveau de forme rectangulaire et de dimensions de 3x5 m formé par quatre poteaux de section 30x30 cm et des poutres de section 25x35 cm.

$E= 24855578$ KN/m, le poids volumique $\rho=25$ KN/ m³. Une excentricité de 75,19 cm a été créée dans le sens y, soit 15.04% de la dimension totale du plancher. L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

Modèle 3 : c'est un modèle à un seul niveau de dimensions de 4x4 m formé par quatre poteaux de section 30x30 cm et des poutres de section rectangulaire 25x35 cm.

$E=32000000$ KN/m, le poids volumique $\rho=25$ KN/ m³. Une excentricité de 19,42 cm a été créée dans le sens y, soit 4.86% de la dimension totale du plancher. L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

Modèle 4: c'est un modèle symétrique à un seul niveau de dimensions de 4x4 m formé par quatre poteaux de section 30x30 cm et des poutres de section 25x35 cm. $E=32000000$ KN/m, le

poids volumique $\rho=25 \text{ KN/ m}^3$. L'accélérogramme de Petrolia est utilisé comme une excitation suivant la direction x.

Modèle 5: c'est le modèle utilisé pour l'apprentissage.

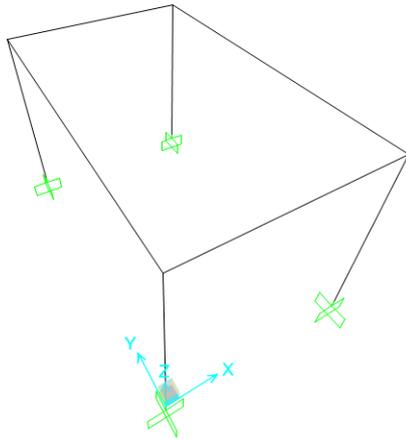


Figure 3.15 : Modèle 2.

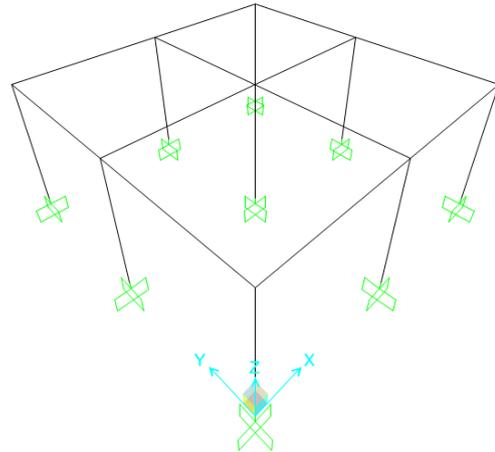


Figure 3.16 : Modèle 6.

Modèle 6 : c'est un modèle à un seul niveau formé par trois fils de poteaux de section 30x40 cm dans le sens x et 3 fils dans le sens y espacés de 3,5m et des poutres de section 25x35 cm.

$E= 24855578 \text{ KN/m}$, le poids volumique $\rho=25 \text{ KN/ m}^3$. Une excentricité de 83,21 cm a été créée dans le sens y, soit 11.89% de la dimension totale du plancher. L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

Modèle 7 : c'est un modèle à un seul niveau de dimensions de 5x5m formé par quatre poteaux de section 45x45 cm et des poutres de section 30x45 cm. $E=32000000 \text{ KN/m}$, le poids volumique $\rho=25 \text{ KN/ m}^3$. Une excentricité de 16,91 cm a été créée dans le sens y, soit 3.38% de la dimension totale du plancher. L'accélérogramme de Petrolia est utilisé comme une excitation suivant la direction x.

Modèle 8: c'est un modèle à un seul niveau de dimensions de 4x4 m formé par quatre poteaux de section 30x30 cm et des poutres de section 25x35 cm. $E=32000000 \text{ KN/m}$, le poids volumique $\rho=25 \text{ KN/ m}^3$. On a créé des excentricités dans les deux sens ($e_x= 48,78\text{cm}$, soit 12.20% de la dimension totale du plancher, $e_y= 16,26 \text{ cm}$, soit 4.07% de la dimension totale du plancher). L'accélérogramme de Petrolia est utilisé comme une excitation suivant la direction x.

Modèle 9: c'est un modèle à trois niveaux chaque niveau est formé par trois fils de poteaux de section 30x30 cm dans le sens x et 3 fils dans le sens y espacés de 3,5m et des poutres de section 25x35 cm. $E=24855578 \text{ KN/m}$, le poids volumique $\rho=25 \text{ KN/m}^3$. Des excentricités ont été créées dans le sens y ($e_{y1}=e_{y2}=43,23\text{cm}$, soit 6.18% de la dimension totale du plancher. $e_{y3}=83,21$, soit

11.89% de la dimension totale du plancher). L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

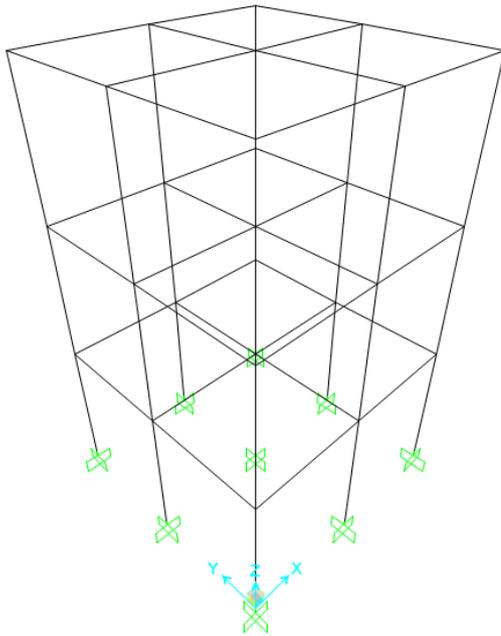


Figure 3.17 : Modèle 9.

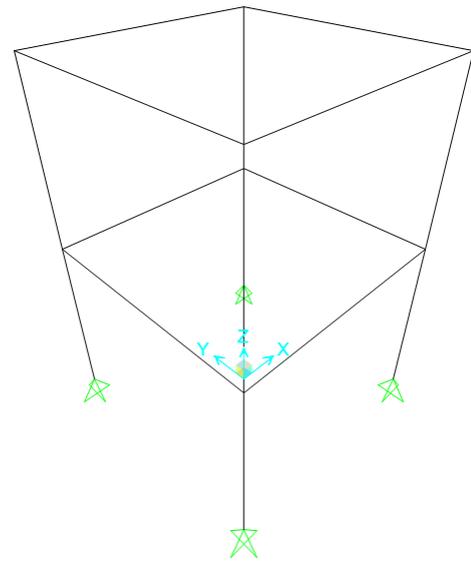


Figure 3.18: Modèle 10.

Modèle 10: c'est un modèle à deux niveaux de dimensions de 4x4 m, chaque niveau est formé par quatre poteaux de section 35x35 cm et des poutres de section 25x35 cm.

$E=32000000$ KN/m, le poids volumique $\rho=25$ KN/ m³. Des excentricités ont été créées dans le sens y ($e_{y1}= 16,42$ cm, soit 4.11% de la dimension totale du plancher. $e_{y2}= 59,98$ cm, soit 15% de la dimension totale du plancher). L'accélérogramme d'El Centro est utilisé comme une excitation suivant la direction x.

Modèle 11 : C'est un modèle similaire au modèle 1 avec une différence de l'excentricité $e_{y1}=1,128$ m, soit 28.2% de la dimension totale du plancher.

3.8.3. Performance des Résultats

Afin de vérifier le bon fonctionnement des réseaux de neurones, l'ensemble des données utilisées pour le test et la validation a été passé à travers le réseau pour effectuer une régression linéaire entre les sorties du réseau Y et les cibles correspondantes T (target). Le coefficient de corrélation R nous a permis de mesurer la qualité de la prédiction du réseau, une prédiction parfaite suggère que tous les points sont alignés le long de la diagonale $Y = T$ et le coefficient de corrélation est $R = 1$.

Pour les résultats de validation des réseaux de prédiction des déplacements du centre de masse et du centre de rigidité (figures 3.19 et 3.21), les lignes d'adaptation sont pratiquement superposées

à la diagonale, et le coefficient de corrélation est très proche de l'unité, ce qui signifie que les réseaux de neurones donnent des prédictions très précises des déplacements du centre de masse et du centre de rigidité.

Pour voir tous les résultats de validation des réseaux de prédiction des déplacements du centre de masse et du centre de rigidité, on se réfère à l'appendice A.

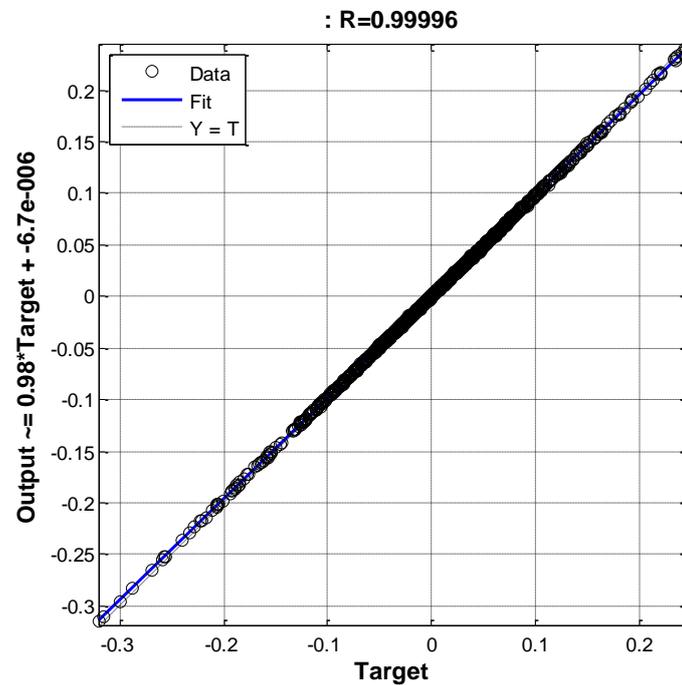


Figure 3.19 : La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 2.

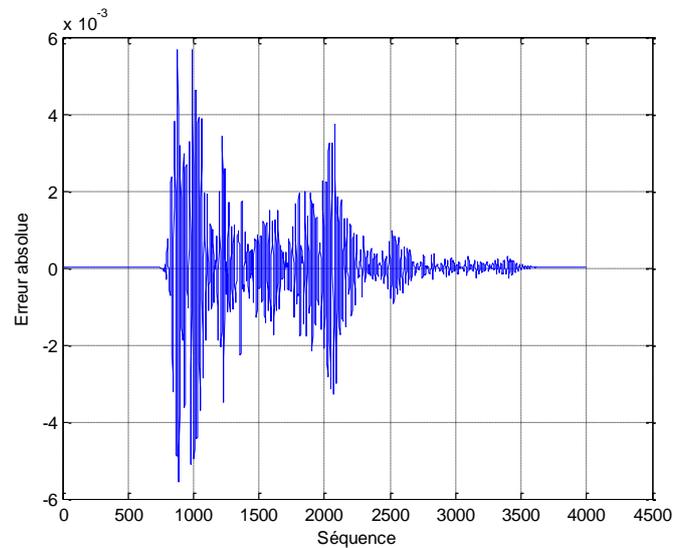


Figure 3.20: La différence entre le signal x_{CM} cible et le signal output du modèle 2.

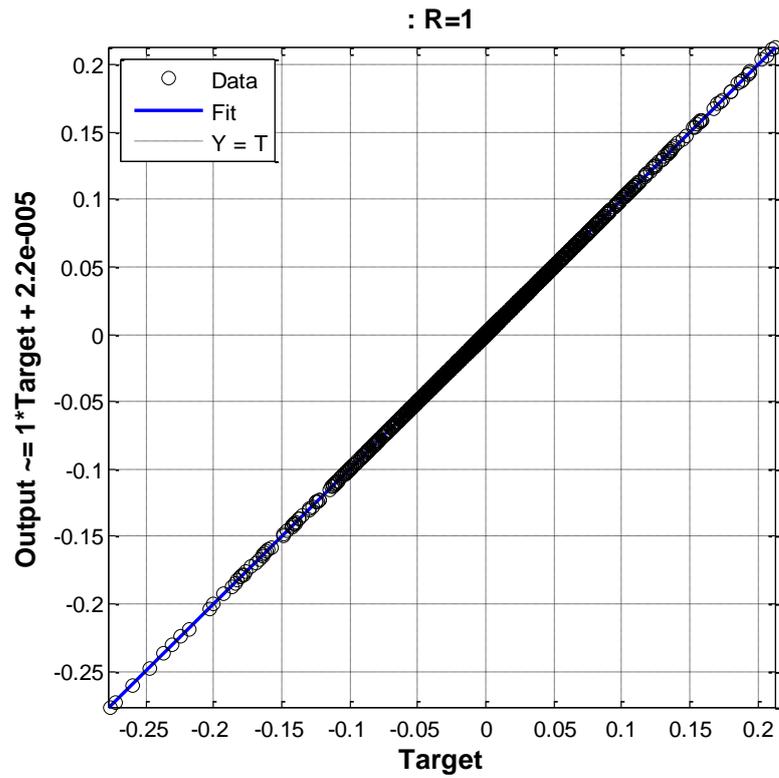


Figure 3.21: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 2.

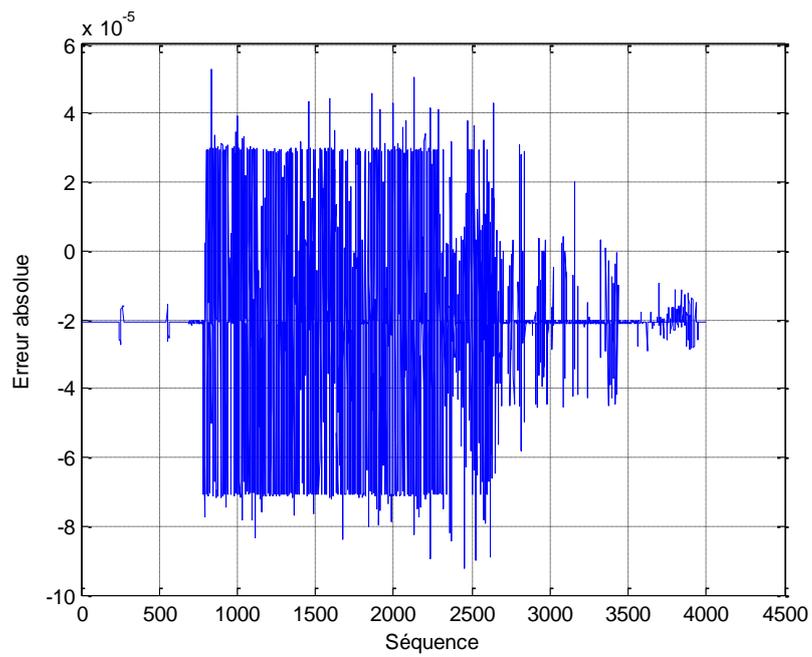


Figure 3.22: La déférence entre le signal x_{CR} cible et le signal output du modèle 2.

3.9. Etude de sensibilité du réseau

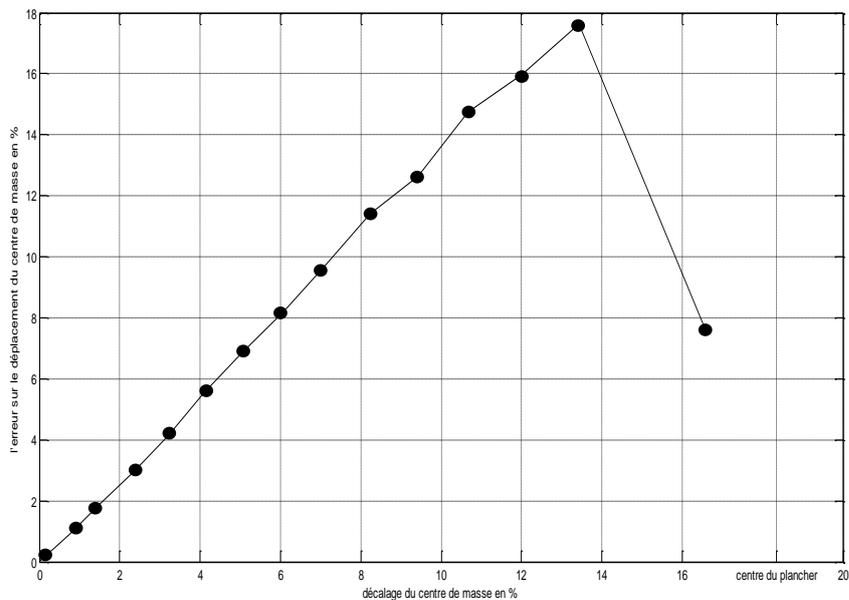
D'après le test des réseaux, nous remarquons qu'il y a un seul paramètre qui influe sur la précision des résultats des réseaux :

Dans le cas de la prédiction du déplacement du centre de masse : c'est la position du centre de masse dans l'apprentissage (par rapport au milieu du plancher), de tel sorte que plus la position du centre de masse dans la simulation est proche de sa position dans l'apprentissage plus la précision du réseau augmente.

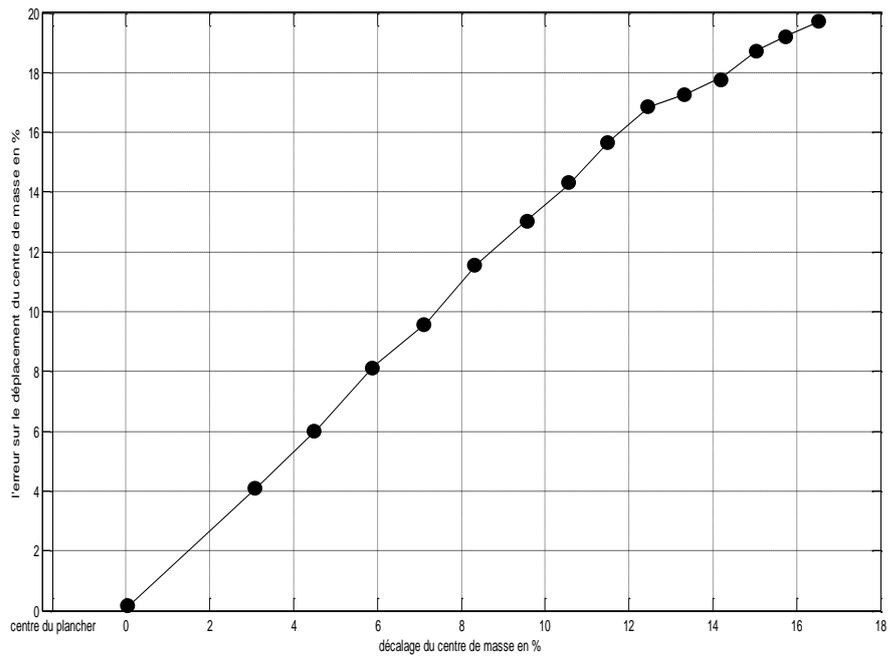
Dans le cas de prédiction du déplacement du centre de rigidité : c'est la position du centre de rigidité dans l'apprentissage (par rapport au milieu du plancher), de tel sorte que plus la position du centre de rigidité dans la simulation est proche de sa position dans l'apprentissage plus la précision du réseau augmente.

La position du centre de masse a été variée tout en gardant fixe la position de centre de rigidité. La simulation se fait par des modèles qui ont des centres de masse décalés par rapport à la position du centre de masse du modèle utilisé pour l'apprentissage.

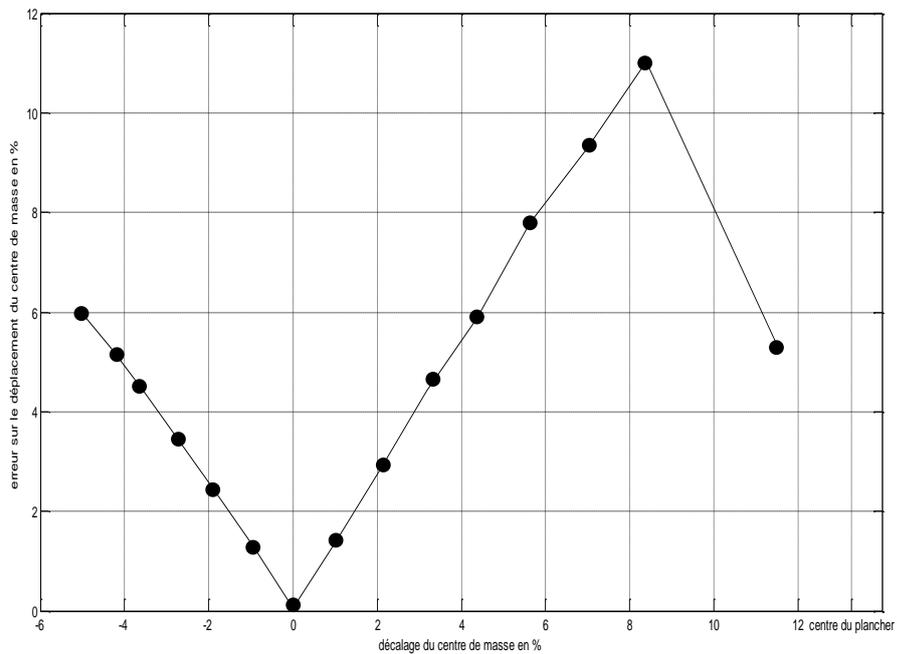
Les résultats montrés sur la figure 3.23 représentent la variation de l'erreur relative sur le déplacement du centre de masse en fonction du rapport entre la distance décalée du centre de masse et la dimension du plancher perpendiculaire à l'excitation, c.à.d. un décalage du centre de masse égale à 0% correspond à la position du centre de masse lors de l'apprentissage qui est utilisée comme une référence.



(A) Le centre de masse est décalé de 18.34% par rapport au centre du plancher lors de l'apprentissage.



(B) Le centre de masse est décalé de 1.75% par rapport au centre du plancher lors de l'apprentissage.

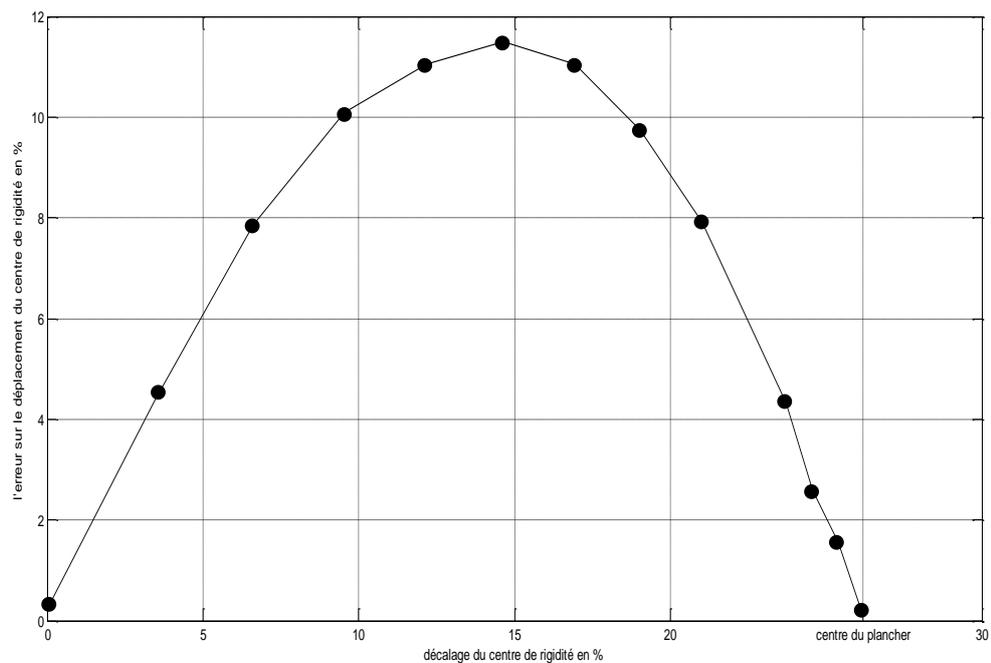


(C) Le centre de masse est décalé de 13.28% par rapport au centre du plancher lors de l'apprentissage.

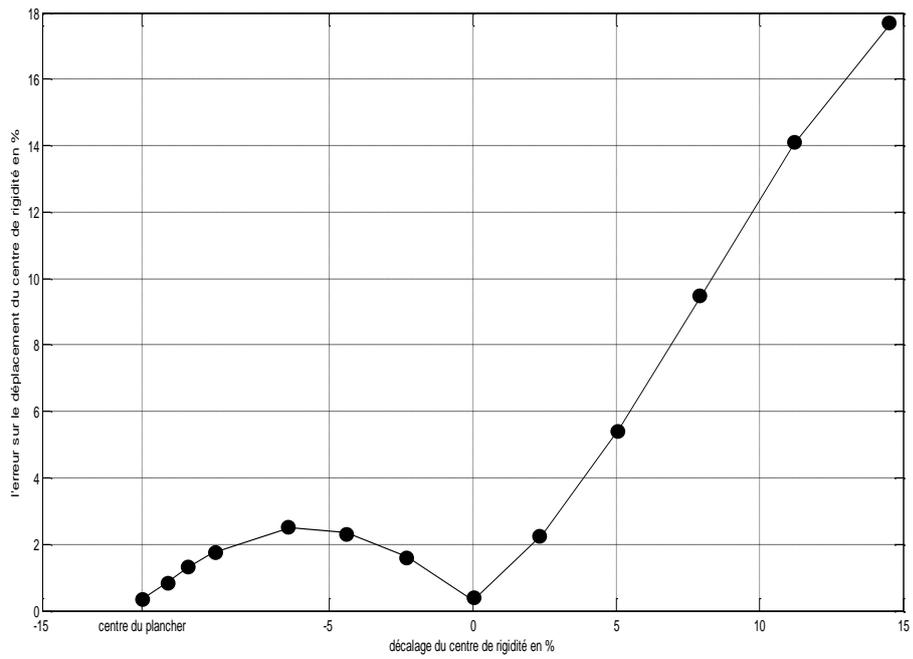
Figure 3.23: L'erreur sur le déplacement du centre de masse en fonction de la position du centre de masse.

Dans une deuxième phase, la position du centre de rigidité a été variée tout en gardant fixe la position du centre de masse. La simulation se fait par des modèles qui ont des centres de rigidité décalés par rapport à la position du centre de rigidité du modèle utilisé pour l'apprentissage.

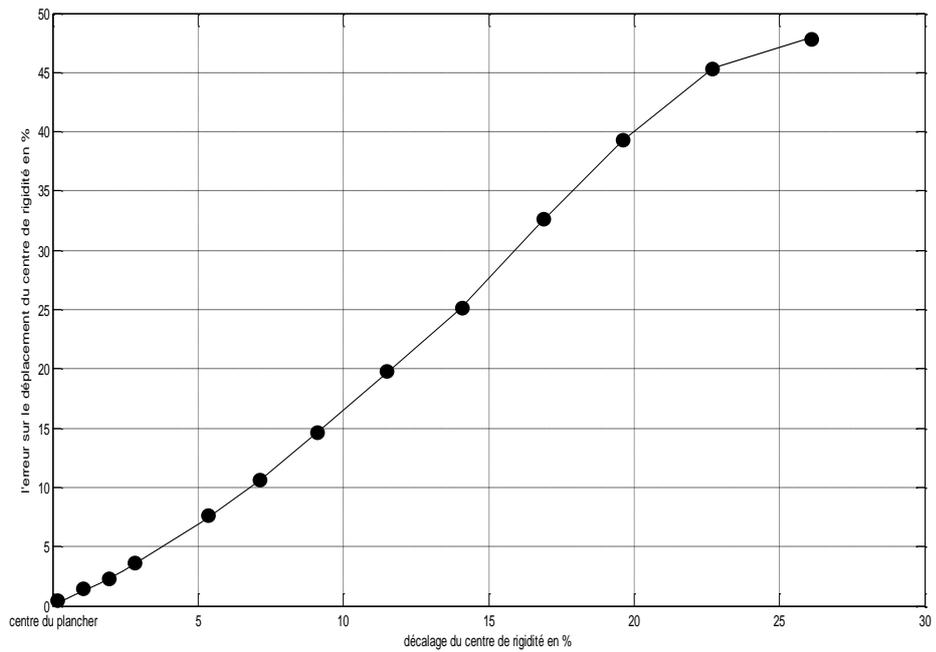
Les résultats sont montrés sur la figure 3.24 qui représente la variation de l'erreur relative sur le déplacement du centre de rigidité en fonction du rapport entre la distance décalée du centre de rigidité et la dimension du plancher perpendiculaire à l'excitation, c.à.d. un décalage du centre de rigidité égale à 0% correspond à la position du centre de rigidité lors de l'apprentissage qui est utilisée comme une référence.



(A) Le centre de rigidité est décalé de 26.19% par rapport au centre du plancher lors de l'apprentissage.



(B) Le centre de rigidité est décalé de 11.54% par rapport au centre du plancher lors de l'apprentissage.



(C) Le centre de rigidité est au centre du plancher lors de l'apprentissage.

Figure 3.24: L'erreur sur le déplacement du centre de rigidité en fonction de la position du centre de rigidité.

D'après les résultats précédents, on constate que :

- Plus la position du centre de masse ou de rigidité dans la simulation est proche de la position du centre de masse ou de rigidité dans l'apprentissage plus la précision du réseau est meilleure.
- L'erreur augmente lorsque la position du centre de masse ou de rigidité est très proche au milieu du plancher dans l'apprentissage, et loin du milieu dans la simulation.
- Lorsque la position du centre de masse ou de rigidité est loin du milieu du plancher dans l'apprentissage, l'erreur sera proportionnelle à la distance décalée du centre de masse ou de rigidité. Cependant plus on se rapproche du centre du plancher l'erreur sera diminuée, car les déplacements des centres de masse et de rigidité et des deux extrémités dans ce cas sont très proches (un petit couplage), ce qui facilite la prédiction précise des déplacements du centre de masse et du centre de rigidité à partir des déplacements des côtés rigide et flexible.

Dans la troisième phase, on varie simultanément la position du centre de masse et celle du centre de rigidité (Figures 3.25 et 3.26).

En premier lieu, on conserve la même excentricité c.à.d. le même décalage du centre de masse et de rigidité, puis on décale la position du centre de masse et de rigidité en variant l'excentricité c.à.d. le décalage du centre de masse diffère de celui de rigidité.

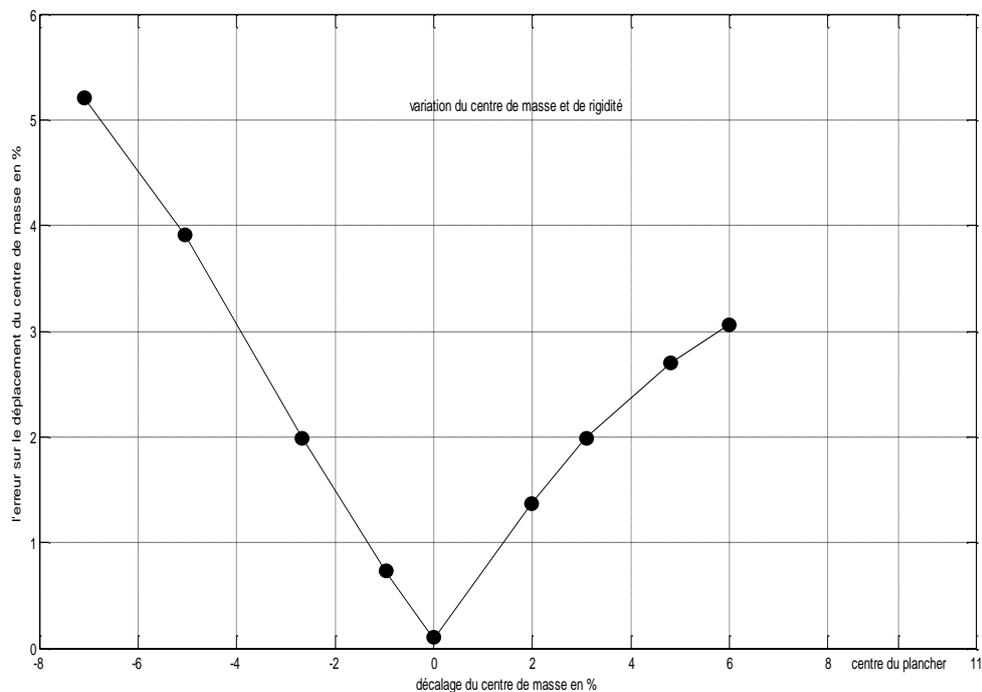


Figure 3.25: L'erreur sur le déplacement du centre de masse.

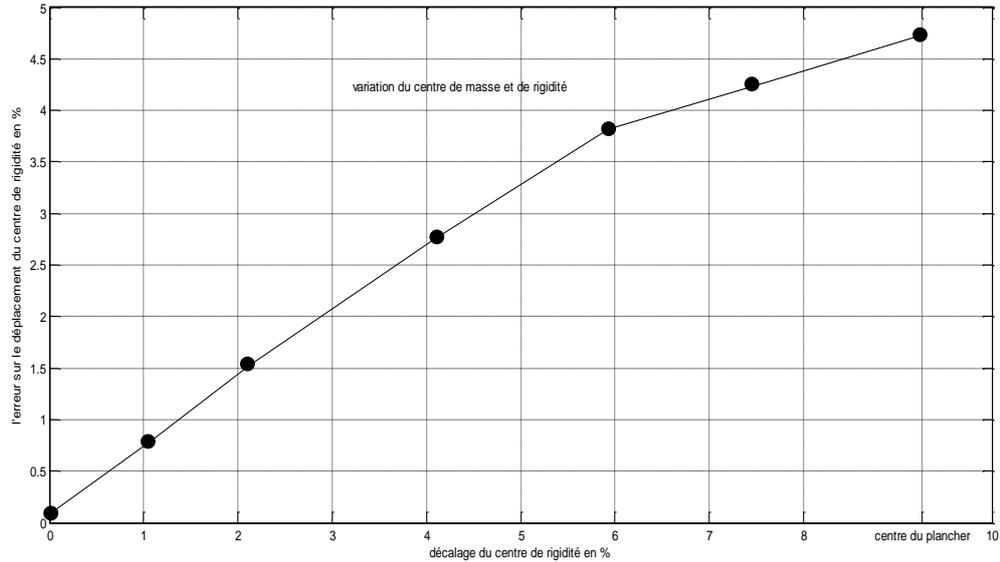


Figure 3.26: L'erreur sur le déplacement du centre de rigidité.

On remarque les mêmes constatations précédentes, seulement les erreurs ici sont assez petites.

3.10. Champs d'application de la méthode

En se basant sur les résultats de l'étude de sensibilité, il s'avère que dans le cas où on dispose des informations nécessaires pour la détermination du centre de masse et du centre de rigidité théorique (calculés), l'excentricité réelle peut être déterminée avec une bonne précision en suivant la procédure suivante:

- Calculer les positions naturelles (théoriques) du centre de masse et de rigidité.
- Calculer en pourcentage les rapports des positions du centre de masse et de rigidité P_{CM} et P_{CR} tel que :

$$P_{CM} = \frac{\text{la position de CM} - \frac{b}{2}}{b} \times 100 ; \quad P_{CR} = \frac{\text{la position de CR} - \frac{b}{2}}{b} \times 100 \quad \text{Où :}$$

b : est la dimension du plancher perpendiculaire à l'excitation.

- Elaborer un modèle en élément fini pour la phase apprentissage qui possède le même rapport de position du centre de masse (P_{CM}) que celle du plancher réel, utilisé pour la prédiction du déplacement du centre de masse.
- Elaborer un modèle en élément fini pour la phase apprentissage qui possède le même rapport de position du centre de rigidité (P_{CR}) que celle du plancher réel, utilisé pour la prédiction du déplacement du centre de rigidité.
- Calculer l'excentricité à partir de la formule (5).

3.11. Calcul des excentricités par les RNAs

Le tableau ci-dessous montre les excentricités calculées à partir des réseaux de neurones artificiels et les excentricités réelles des modèles numériques utilisés pour l'apprentissage et la validation, avec l'erreur sur l'excentricité et le rapport e_e calculé par la formule (6).

$$e_e = \frac{\text{erreur absolue}}{b} \quad (6)$$

e_e : est le rapport entre l'erreur absolue sur l'excentricité et la dimension b .

b : est la dimension du bâtiment en plan perpendiculaire à l'action sismique.

Tableau 3.1: Des excentricités calculées par RNAs.

modèles	Excentricité réelle (cm)	Excentricité calculée par RNAs (cm)	L'erreur absolue sur l'excentricité (cm)	L'erreur relative sur l'excentricité (%)	b (m)	e_e (%)
1	24.35	19.62	4.73	19.42	4	1.18
2	75.19	66.53	8.66	11.52	5	1.73
3	19.42	24.82	5.4	27.81	4	1.35
4	0	0	0	0	4	0
5	79.73	79.72	0.01	0.01	6	1.67×10^{-3}
6	83.21	92.88	9.67	11.62	7	1.38
7	16.91	19.35	2.44	14.43	5	0.49
8	16.26	18.97	2.71	16.66	4	0.68
9 niveau 1	43.23	34.56	8.67	20.05	7	1.24
9 niveau 2	43.23	35.38	7.85	18.16	7	1.12
9 niveau 3	83.21	92.28	9.07	10.9	7	1.29
10 niveau 1	16.42	17.61	1.19	7.25	4	0.30
10 niveau 2	59.98	60.63	0.65	1.08	4	0.16
11	112.8	100.2	12.6	11.17	4	3.15

3.12. Conclusion

Une méthodologie pour l'évaluation de l'excentricité d'un bâtiment à partir de sa réponse dynamique en se basant sur la technique des réseaux de neurones est exposée. Des explications et justifications ont été avancées pour le choix de l'architecture du réseau. Une base de données a été élaborée suivi d'un apprentissage et achevé par des tests de validation. Une étude de sensibilité a été menée pour différents paramètres. Il s'est avéré que le seul paramètre qui contrôle la précision du réseau est l'éloignement de la position du centre de masse ou du centre de rigidité dans la simulation par rapport à la position du centre de masse ou de rigidité dans l'apprentissage. En général, la précision du réseau augmente quand la position du centre de masse ou de rigidité réelle est proche de celle utilisée dans la phase d'apprentissage. Il est aussi important de noter que la précision dans la détermination des positions du centre de masse et de rigidité est presque insensible au nombre d'étages du bâtiment.

CONCLUSION GENERALE

Le phénomène de torsion d'axe vertical des bâtiments sous l'action sismique est connu pour ces effets destructeurs comme le témoignent plusieurs observations post-sismiques. En partie cette torsion est due à la torsion accidentelle qui a fait l'objet de plusieurs travaux de recherches durant plusieurs décennies. En conséquence, la plus part des codes parasismiques prennent en considération la torsion accidentelle sous forme d'une excentricité additionnelle forfaitaire ajoutée algébriquement à l'excentricité dynamique.

Certains codes parasismiques prennent cette excentricité égale à 5% et autres à 10% de la dimension en plan perpendiculaire à l'axe d'excitation pour tous les types de structures. Eu égard, à la nature aléatoire et incertaine des facteurs responsables de l'excentricité accidentelle, il s'avère très difficile d'évaluer explicitement et avec précision son effet sur la réponse sismique globale des constructions. Dans cette optique, nous avons proposé une procédure pour la quantification de l'excentricité accidentelle à partir d'une réponse dynamique de la structure.

Cette procédure fait appel à la technique des réseaux de neurones pour prévoir l'excentricité réelle du bâtiment et par la suite l'excentricité accidentelle.

La technique des RNA est une méthode puissante de régression non linéaire. Les possibilités, la commodité et la précision offertes par les RNAs sont à l'origine de son utilisation avec succès en génie civil dans les domaines des structures, de la géotechnique et les matériaux.

Les éléments essentiels qui permettent de comprendre le principe de fonctionnement et la composition des réseaux de neurones artificiels ont été exposés brièvement. La méthodologie proposée dans ce mémoire pour l'évaluation de l'excentricité réelle d'un bâtiment nécessite uniquement deux enregistrements des déplacements sur deux côtés extrêmes du bâtiment. Ces derniers sont utilisés comme un vecteur d'entrée aux réseaux de neurones et en sortie on obtient les déplacements du centre de masse et de rigidité. Connaissant ces déplacements, on peut calculer l'excentricité réelle du bâtiment et par la suite l'excentricité accidentelle.

Une étude de sensibilité a été menée et a permis de déduire les points suivants:

- La précision du modèle de réseau de neurones est meilleure quand la position du centre de masse ou de rigidité lors de l'apprentissage, est proche de la position du centre de masse ou de rigidité dans la simulation.
- Lorsque la position du centre de masse ou de rigidité est loin du centre du plancher dans le cas de l'apprentissage, l'erreur sera proportionnelle à la distance décalée du centre de

masse ou de rigidité, cependant plus on se rapproche du centre du plancher l'erreur diminue.

- La précision du modèle RNAs pour une structure symétrique ou pratiquement symétrique est plus grande que celle d'une structure asymétrique, car les déplacements des centres de masse et de rigidité et des deux extrémités sont très proches.
- La précision du modèle RNAs ne diminue pas pour des bâtiments à plusieurs niveaux.

L'avantage de cette méthode réside dans sa capacité de déterminer les excentricités à partir des réponses structurelles réelles enregistrées lors d'un événement sismique ou des essais de vibrations ambiantes pour les structures symétriques et asymétriques. Elle peut également être appliquée pour améliorer la formule empirique de l'excentricité accidentelle recommandée par les codes.

Ce travail ouvre différentes perspectives :

- Améliorer ce modèle d'évaluation de l'excentricité accidentelle à partir des réponses structurelles mesurables, en faisant des études paramétriques et statistiques sur différentes structures existantes.
- L'application de cette technique aux enregistrements sismiques sur des constructions réelles ayant subis des sollicitations sismiques pour tenir compte de l'effet du mouvement rotationnel à la base de la structure.
- Etendre le champ d'application de cette technique aux modèles de bâtiments avec une analyse dynamique non linéaire.

REFERENCES BIBLIOGRAPHIQUES

- [1] V.T. Kien. Incidence de la torsion sur la résistance sismique de bâtiments courants avec diaphragmes horizontaux rigides. Université blaise pascal - clermont II (thèse de doctorat), 2011.
- [2] T. Boukhemacha. Evaluation de l'excentricité accidentelle par la méthode des réseaux de neurones. Université de Blida (mémoire de magister), 2005.
- [3] O.A. Pekau and R. Guimond. Accidental torsion in yielding symmetric structures. Ninth World Conference On Earthquake Engineering. Vol.V, 1988.
- [4] A.K. Chopra and R.K. Goel. Evaluation of torsional provisions in seismic codes. Journal of Structural Engineering. Vol 117, No. 12, 1991.
- [5] J.C. De la Llera and A.K. Chopra. Evaluation of code-accidental torsion provisions using earthquake records from three nominally symmetric-plan buildings. SMIP92 Seminar on Seismological and Engineering Implications of Recent Strong-Motion Data, p. 4-1 - 4-16, 1992.
- [6] J.C. De la Llera and Anil K. Chopra. Using accidental eccentricity in code-specified Static and dynamic analyses of buildings. Earthquake Engineering and Structural Dynamics, vol. 23,947-967, 1994.
- [7] H. Shakib and R. Z. Tohidi. Evaluation of accidental eccentricity in buildings due to rotational component of earthquake. Journal of Earthquake Engineering, Vol. 6, No. 4, 2002.
- [8] J.L. Almazan and J.C. de la Llera. Accidental torsion due to overturning in nominally symmetric structures isolated with the FPS. Earthquake Engineering And Structural Dynamics, 32:919-948, 2003.
- [9] S.L. Dimova, I. Alashki. Seismic design of symmetric structures for accidental eccentricity. Fifth National Conference on Earthquake Engineering, No: AE-015, 2003.
- [10] H. Shakib. Evaluation of dynamic eccentricity by considering soil-structure interaction: a proposal for seismic design codes. Soil Dynamics and Earthquake Engineering, 24, 369-378, 2004.

- [11] N. Bourahla and T. Boukhamacha (2005), Extraction of accidental eccentricity parameters from ambient vibration records using artificial neural networks, Proceedings of the International Conference on Experimental Vibration Analysis for Civil Engineering Structures, Bordeaux, France, Octobre 2005.
- [12] G. Gasparini, S. Silvestri and T. Trombetti. A simple code-like formula for estimating the torsional effects on structures subjected to earthquake ground motion excitation. The 14 th World Conference on Earthquake Engineering, 2008.
- [13] O.M.O. Ramadan, S.S.F. Mehanny and A. Mostafa. Revisiting the 5% accidental eccentricity provision in Seismic design codes for multi-story buildings. The 14th World Conference on Earthquake Engineering, 2008.
- [14] C.J. Jose, T.P. Somasundaran and V. Mustafa. Prediction of seismic torsional effects in tall symmetric buildings. International Journal of Research & Reviews in Applied Sciences, 2010.
- [15] M. Badaoui, A. Chateaneuf, E. Fournely, N. Bourahla and M. Bensaïbi. Evaluation of accidental eccentricity for buildings by artificial neural networks. Structural Engineering and Mechanics, Vol. 41, No. 4, 2012.
- [16] M.D. Bensalah, A. Modaressi, M. Bensaibi, F. L. Caballero. Estimation des effets de la torsion dans les bâtiments soumis à l'action sismique. 20ème Congrès Français de Mécanique, 2011.
- [17] M. Parizeau. Réseaux de neurones, GIF-21140 et GIF-64326. Université de LAVAL, Automne 2004.
- [18] I. Ghania, Régression et modélisation par les réseaux de neurones. Université Mentouri-Constantine (mémoire de magister), 2009.
- [19] G. Dreyfus, Les réseaux de neurones. Mécanique Industrielle et Matériaux, n°51, 1998.
- [20] K. Kuzniar, E. Maciag, R. Obiact, Z. Waszczyszyn. Application of neural networks in natural periods identification and simulation of prefabricated buildings response. Soil Dynamics and Earthquake Engineering 20, 217-222, 2000.
- [21] N. Bourahla, R. Taleb and T. Boukhemacha. Structural response extraction from sound vibration measurements using neural networks. Proceedings of the Seventh International Conference on The Application of Artificial Intelligence to Civil and Structural Engineering, B.H.V. Topping (Editor), Civil-Comp Press, Stirling, Scotland, 2003.

- [22] S. Saadat, G.D. Buckner, T. Furukawa, M.N. Noori. An intelligent parameter varying (IPV) approach for non-linear system identification of base excited structures. *International Journal of Non-Linear Mechanics* 39, 993 – 1004, 2004.
- [23] J. Zhang, R.O. Foschi. Performance-based design and seismic reliability analysis using designed experiments and neural networks. *Probabilistic Engineering Mechanics* 19, 259–267, 2004.
- [24] N. Djarfour, T. Aïfaz, K. Baddari, A. Mihobi, J. Ferahtia. Application of feed-back connection artificial neural network to seismic data filtering. *C.R. Geoscience* (in press), 2008.
- [25] H. Noura, M. Abed et H. Bouarfa. Prédiction de la vulnérabilité des constructions par un système de réseaux de neurones. 8ème Colloque National AFPS, Ecole des Ponts ParisTech 9, 2011.
- [26] T. Aoki, R. Ceravolo, A. De Stefano, C. Genovese, D. Sabia. Seismic vulnerability assessment of chemical plants through probabilistic neural networks. *Reliability Engineering and System Safety* 77, 263–268, 2002.
- [27] J.L. Zapico, M.P. Gonzalez and K. Worden. Damage assessment using neural networks. *Mechanical Systems and Signal Processing* 17(1), 119–125, 2003.
- [28] K. Tsuchimoto, N. Wada and Y. Kitagawa. Diagnostic assessment system for structural seismic safety -damage identification based on neural networks and torsion-. 13th World Conference on Earthquake Engineering, 2004.
- [29] B. Siyahi, B. Akbas and N.D. Onder. Evaluation of liquefaction-induced lateral spreading by a neural network (nn) model. The 14 th World Conference on Earthquake Engineering, 2008.
- [30] T.R. Mehrzad and H.M. Reza. Using neural network for prediction of the dynamic period and amplification factor of soil for microzonation in urban area. The 14th World Conference on Earthquake Engineering, 2008.
- [31] M.H. Beale, M.T. Hagan, H.B. Demuth. *Neural network toolbox™ user's guide*, the Math Works, R2012b.

APPENDICE A- LES RESULTATS DE VALIDATION DES RESEAUX DE PREDICTION DES DEPLACEMENTS DE CENTRE DE MASSE ET DE CENTRE DE RIGIDITE

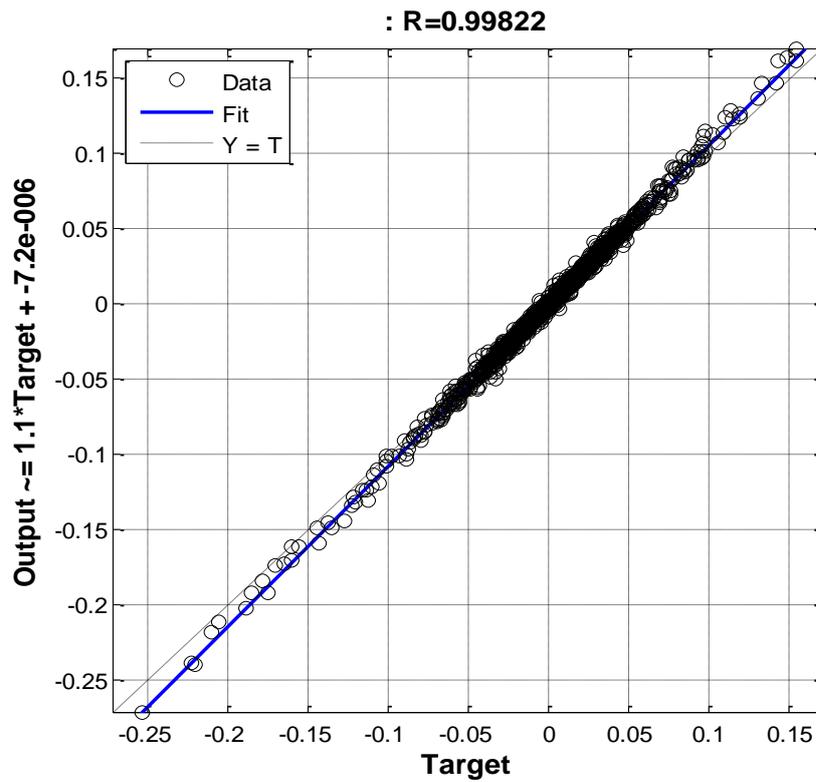


Figure A.1: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 1.

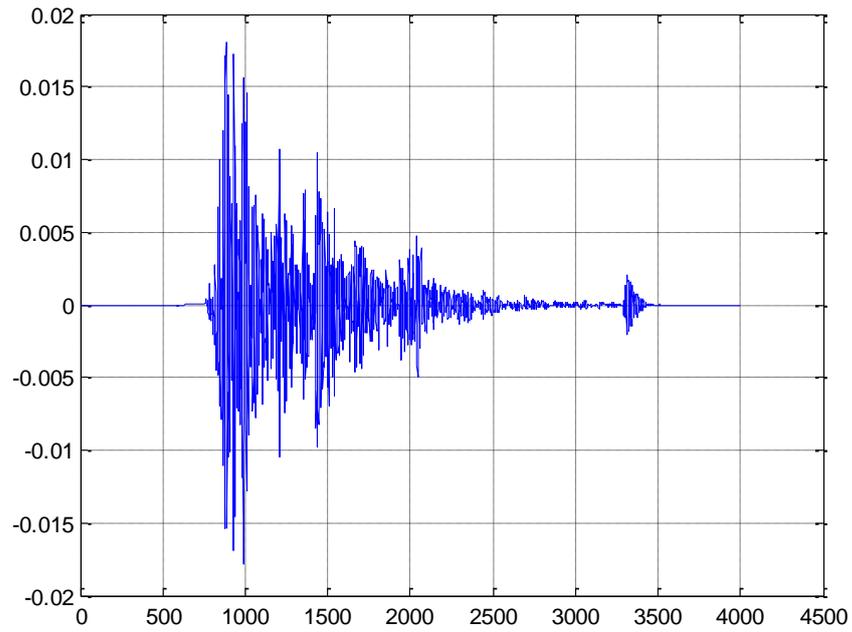


Figure A.2: La déference entre le signal x_{CM} cible et le signal output du modèle 1.

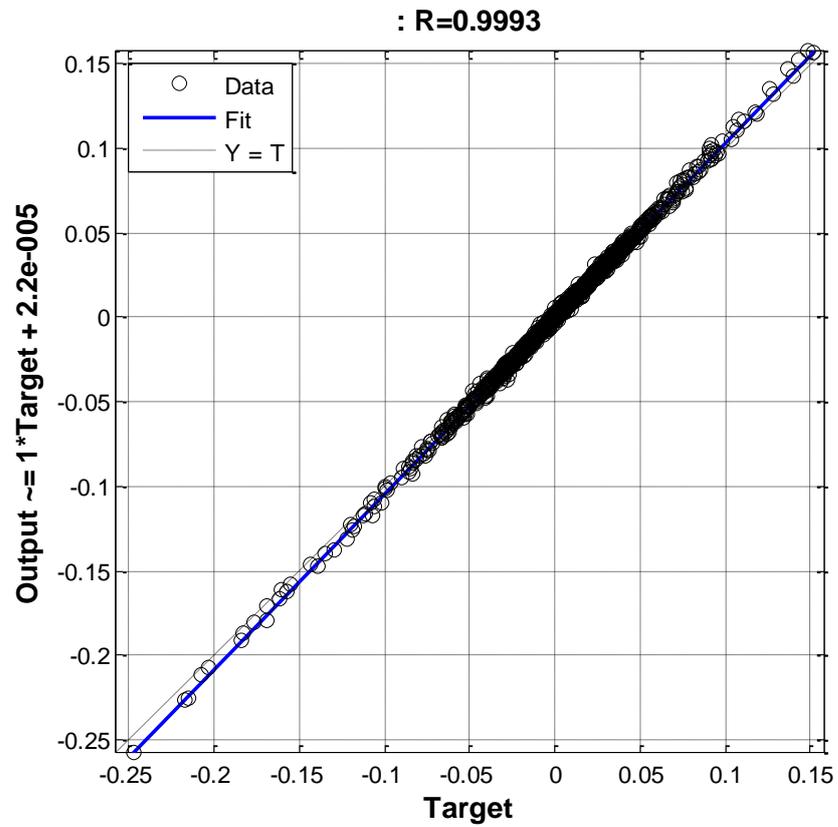


Figure A.3: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 1.

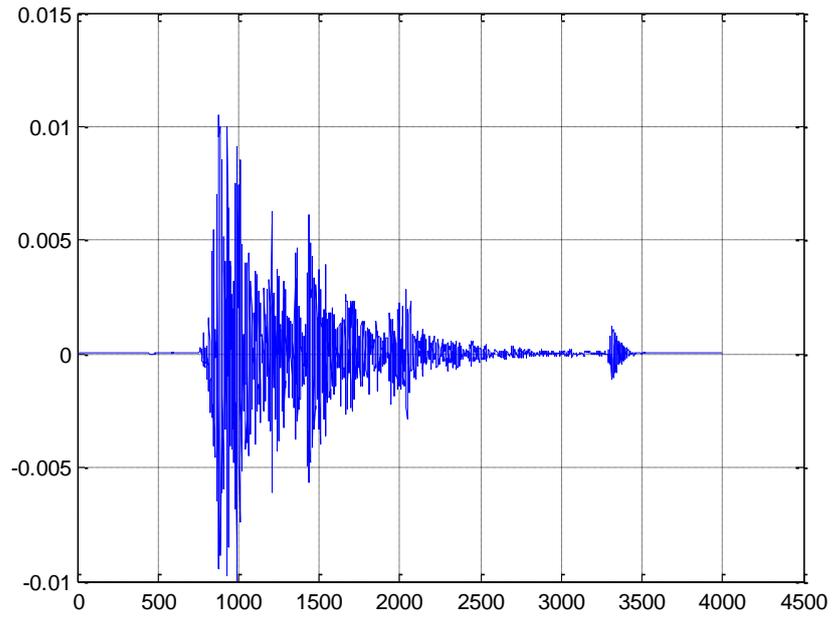


Figure A.4: La dérérence entre le signal x_{CR} cible et le signal output du modèle 1.

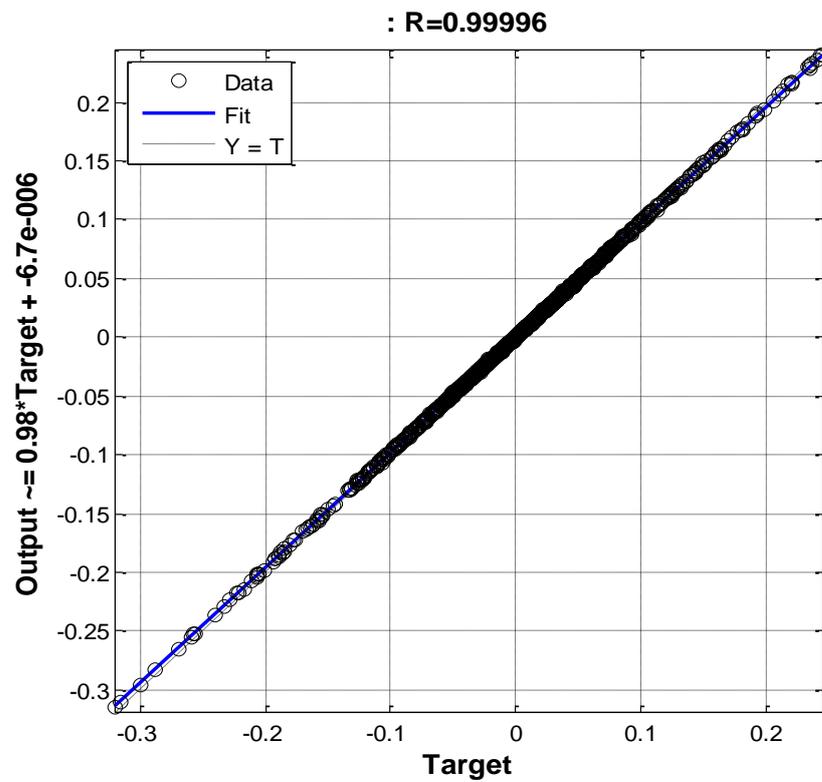


Figure A.5: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 2.

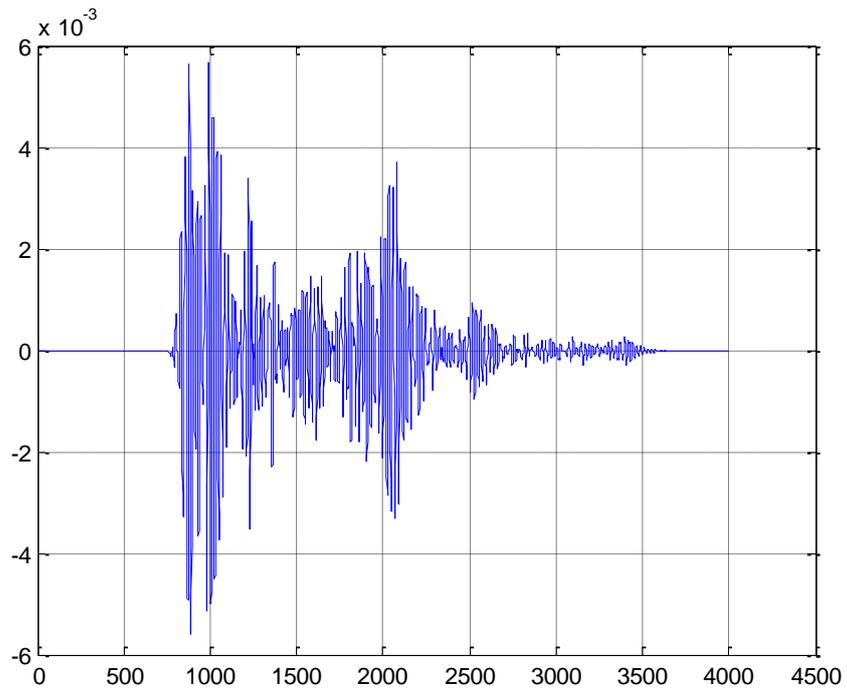


Figure A.6: La différence entre le signal x_{CM} cible et le signal output du modèle 2.

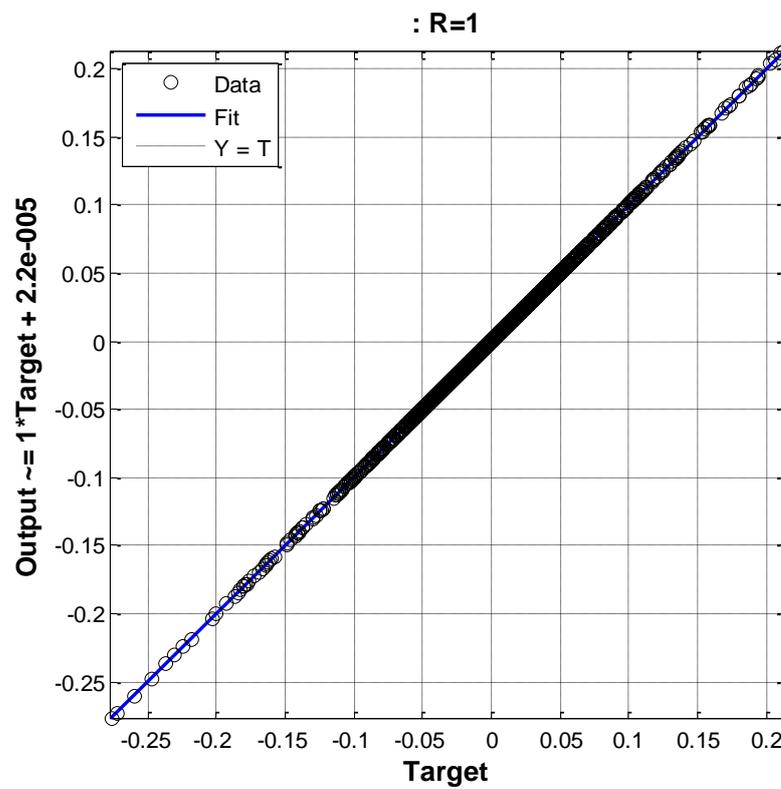


Figure A.7: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 2.

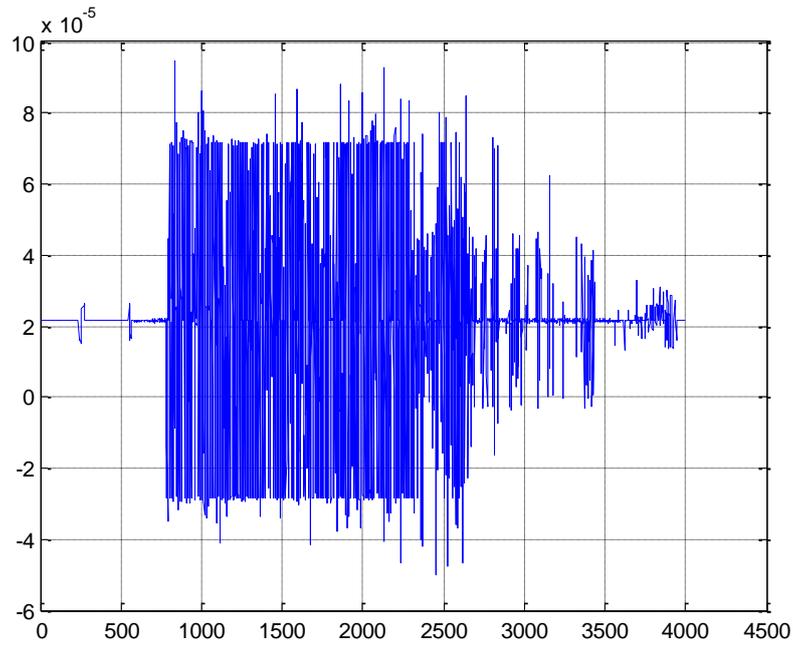


Figure A.8: La déférence entre le signal x_{CR} cible et le signal output du modèle 2.

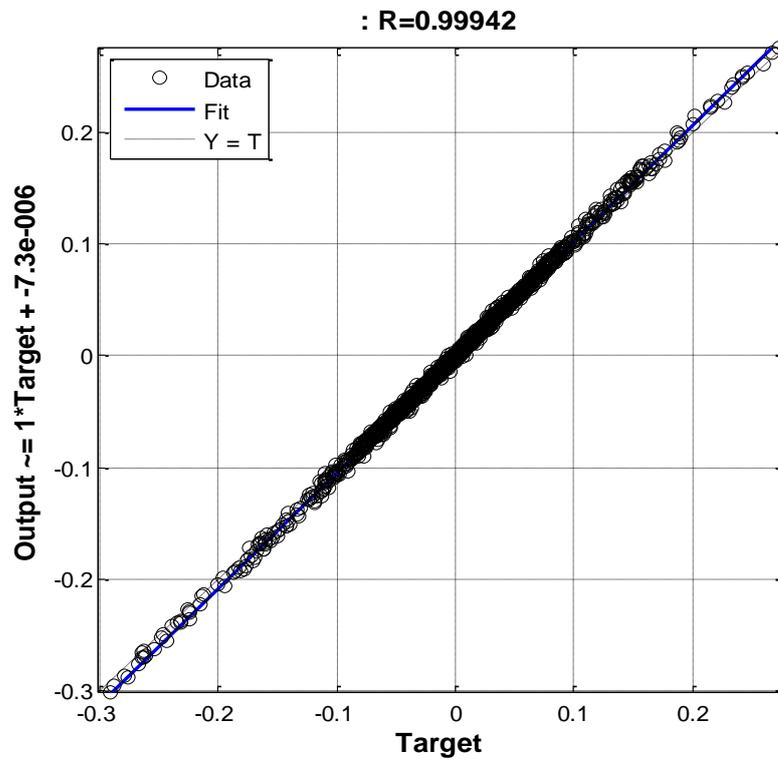


Figure A.9: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 3.

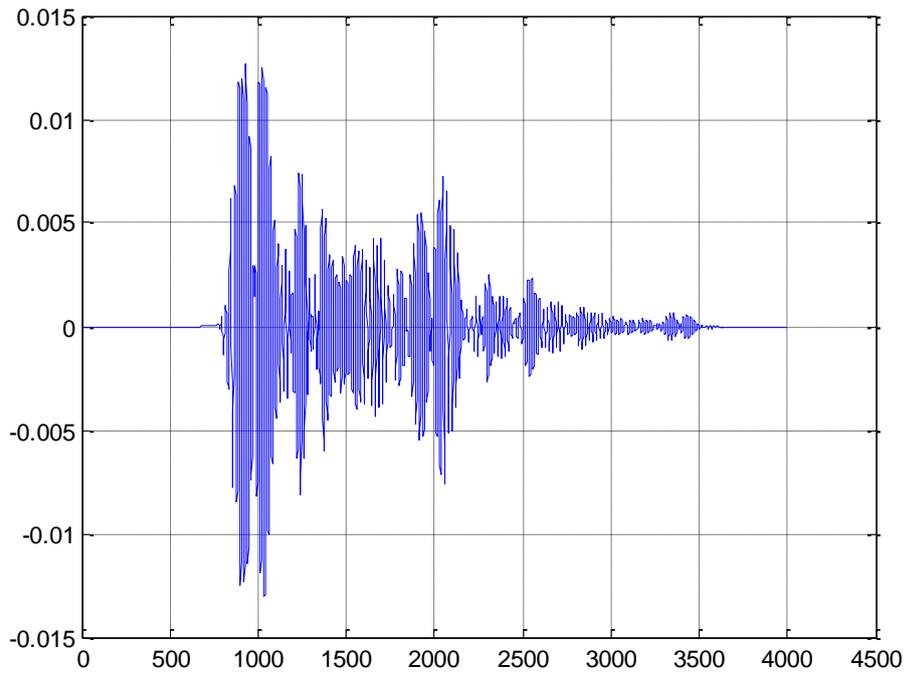


Figure A.10: La différence entre le signal x_{CM} cible et le signal output du modèle 3.

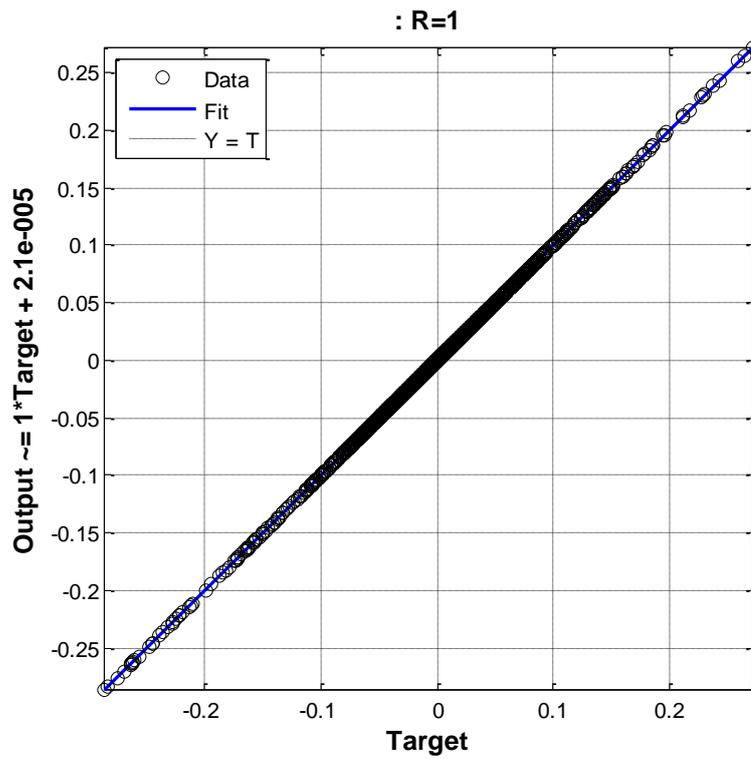


Figure A.11: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 3.

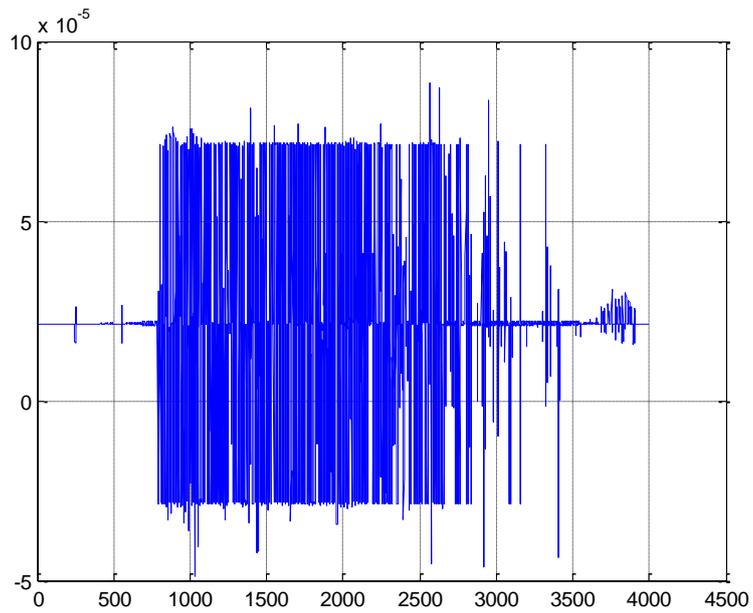


Figure A.12: La différence entre le signal x_{CR} cible et le signal output du modèle 3.

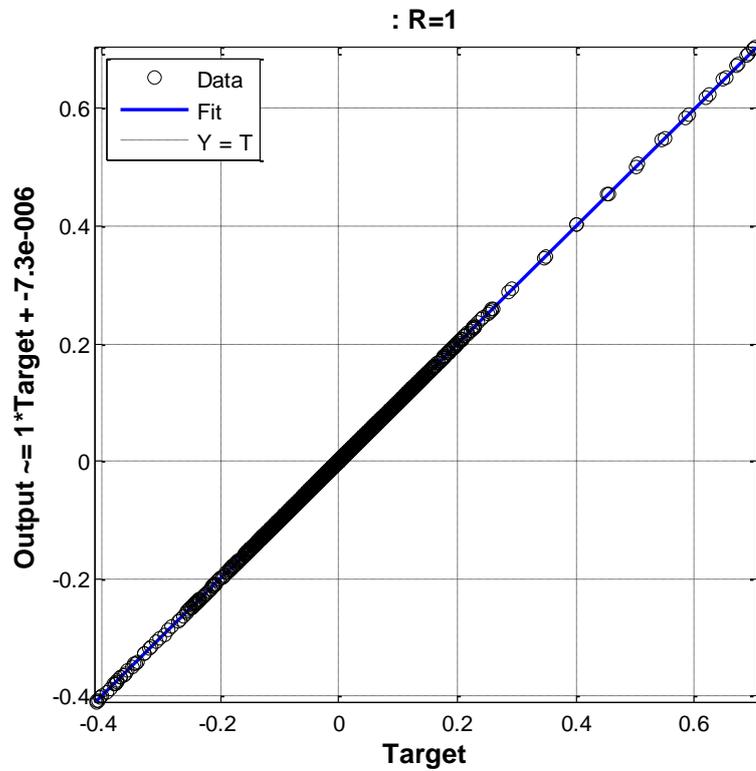


Figure A.13: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 4.

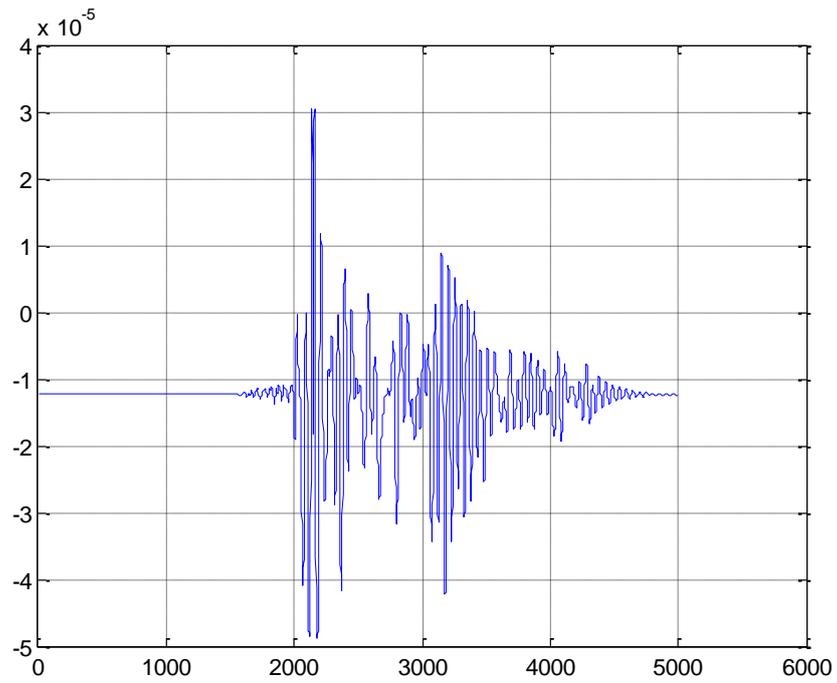


Figure A.14: La différence entre le signal x_{CM} cible et le signal output du modèle 4.

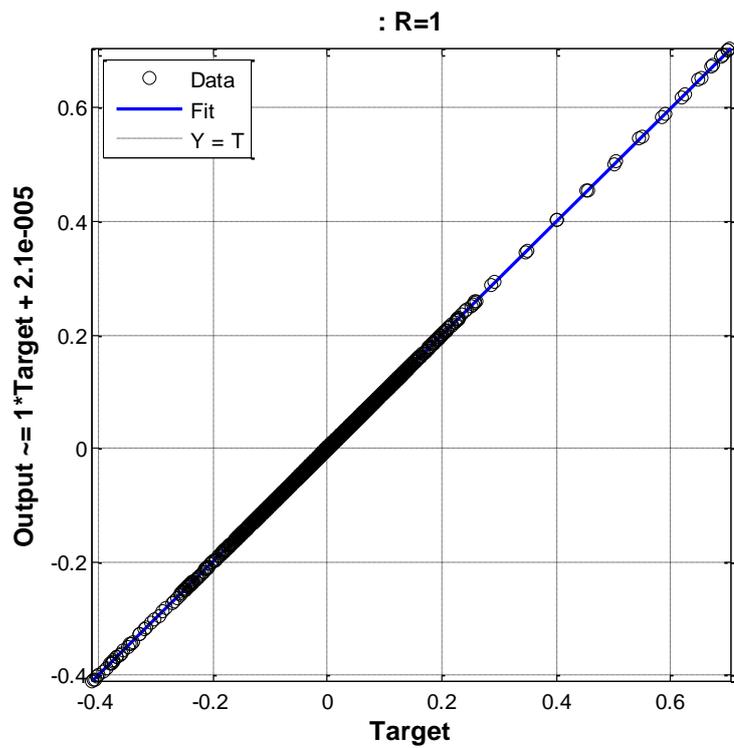


Figure A.15: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 4.

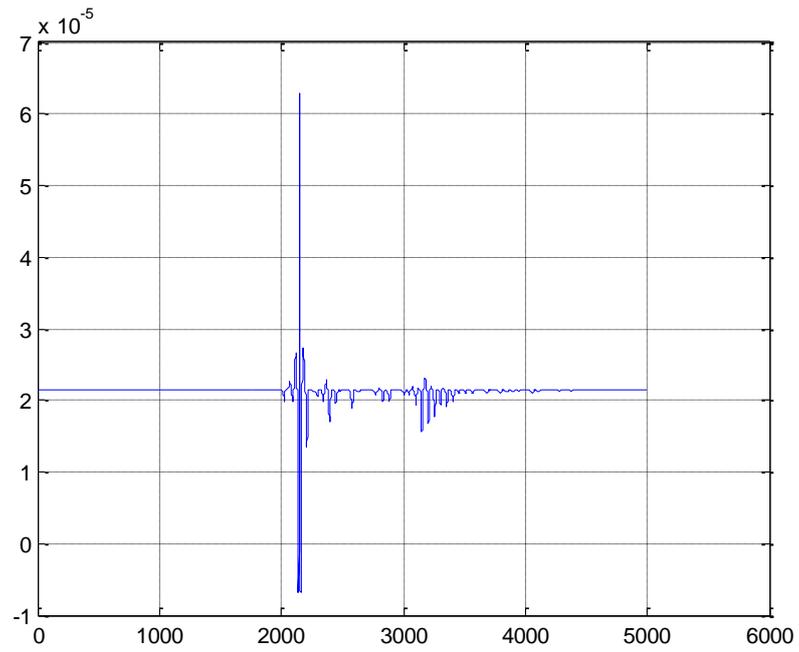


Figure A.16: La différence entre le signal x_{CR} cible et le signal output du modèle 4.

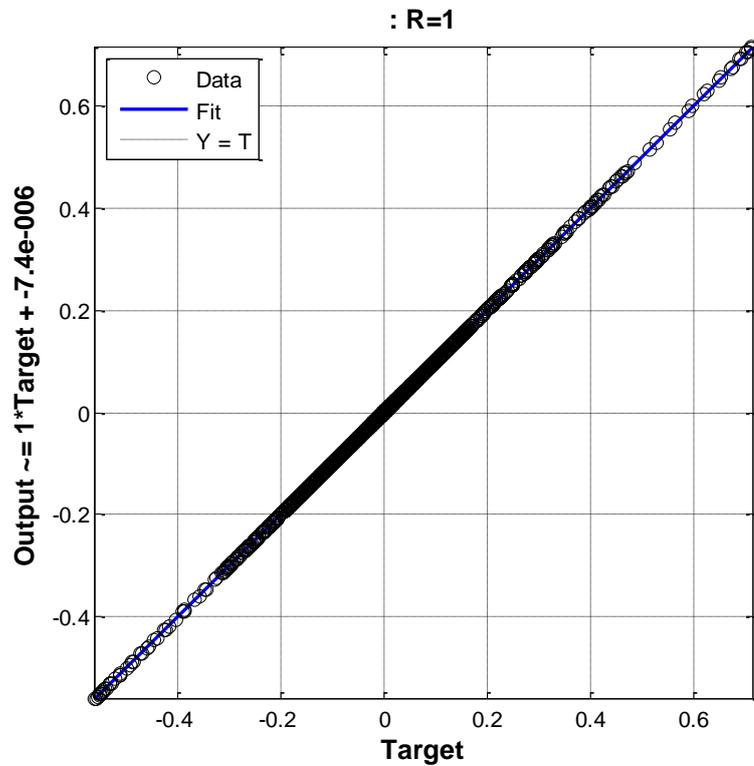


Figure A.17: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 5.

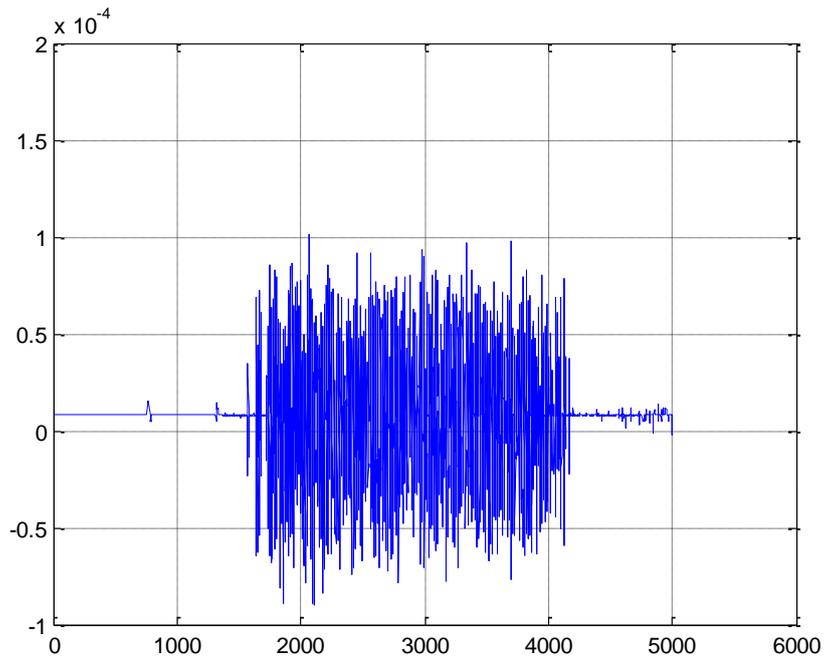


Figure A.18: La différence entre le signal x_{CM} cible et le signal output du modèle 5.

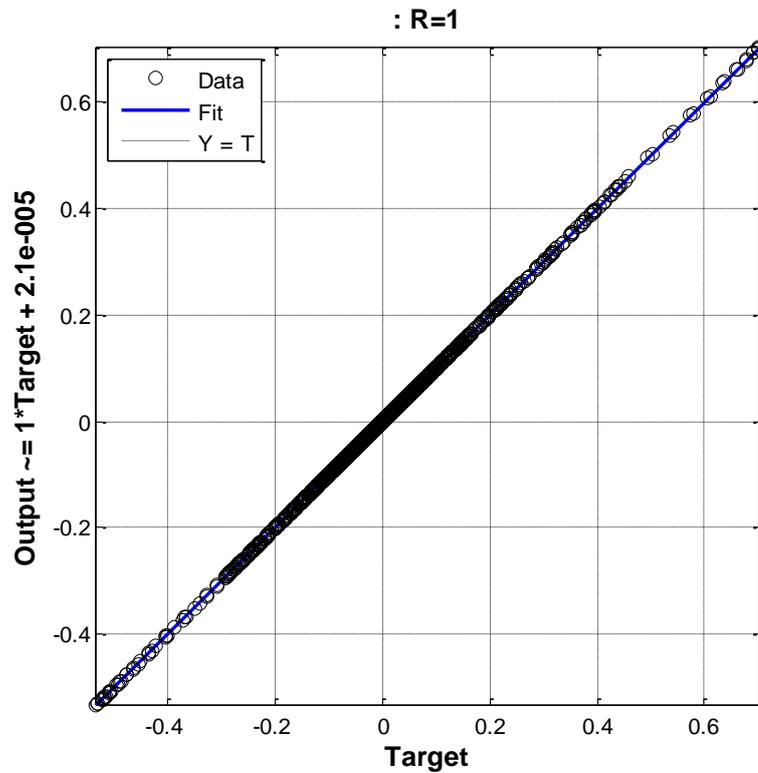


Figure A.19: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 5.

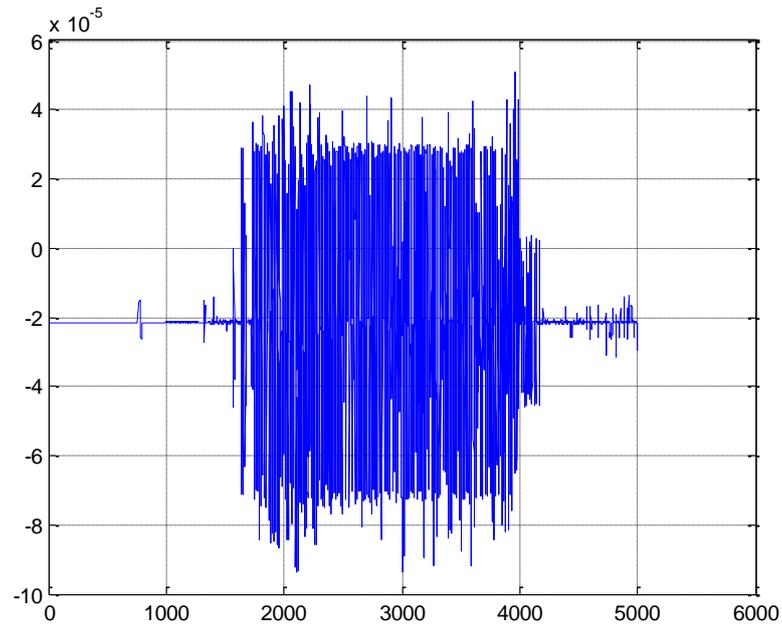


Figure A.20: La différence entre le signal x_{CR} cible et le signal output du modèle 5.

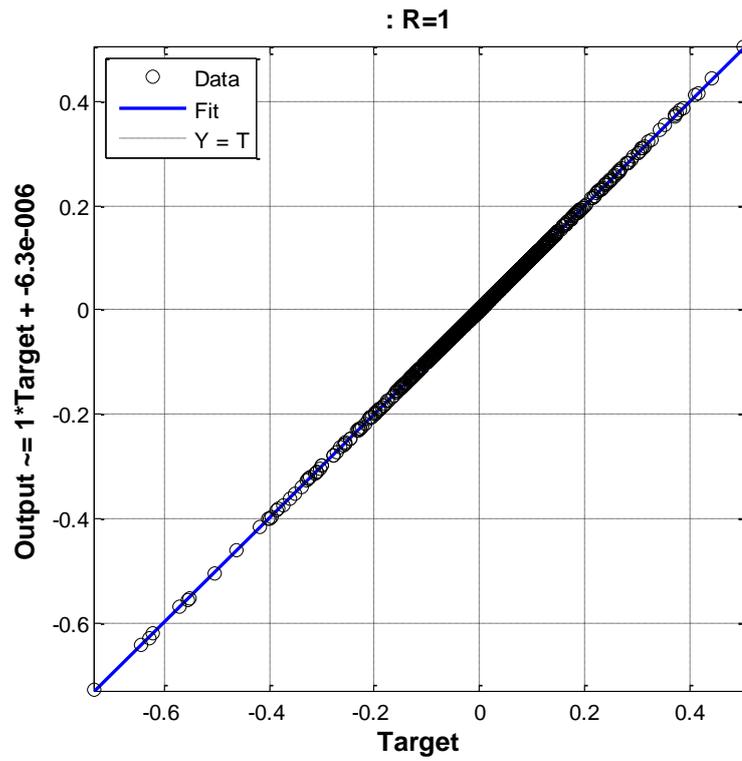


Figure A.21: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 6.

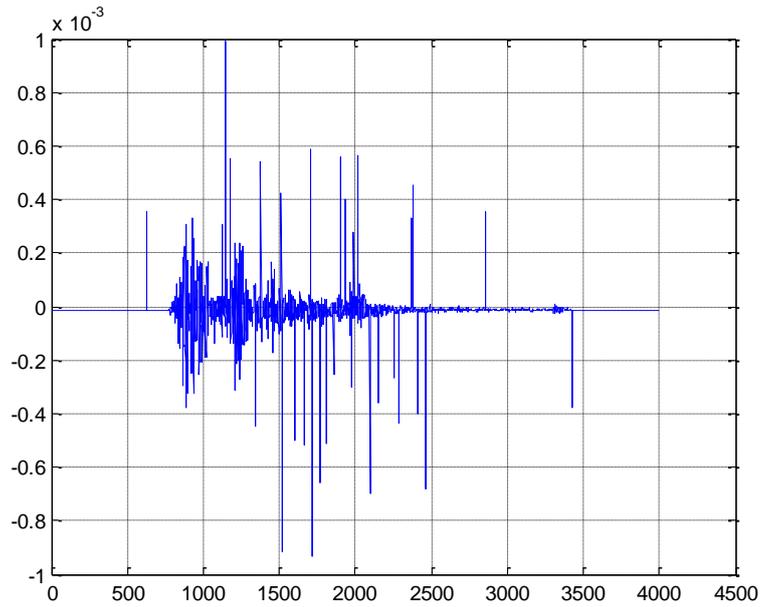


Figure A.22: La différence entre le signal x_{CM} cible et le signal output du modèle 6.

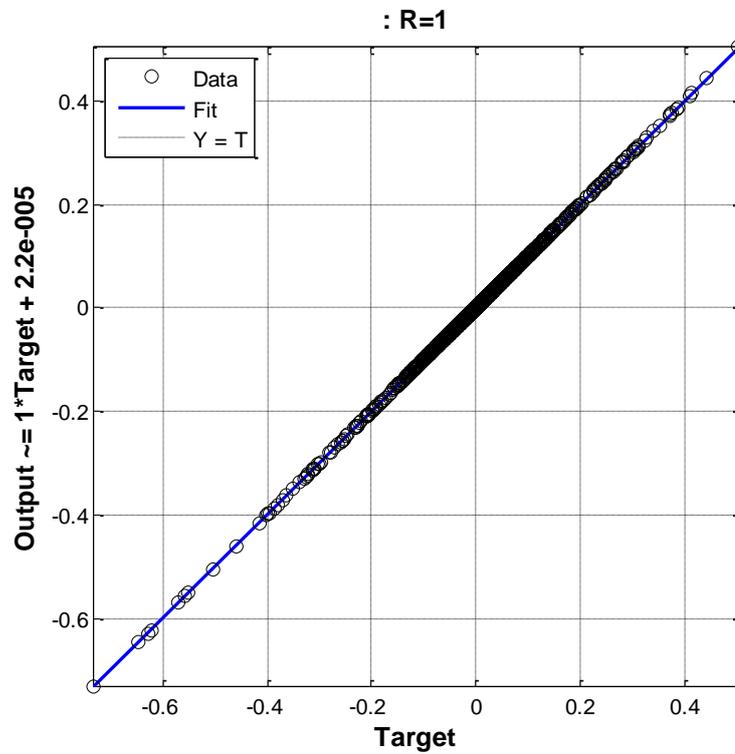


Figure A.23: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 6.

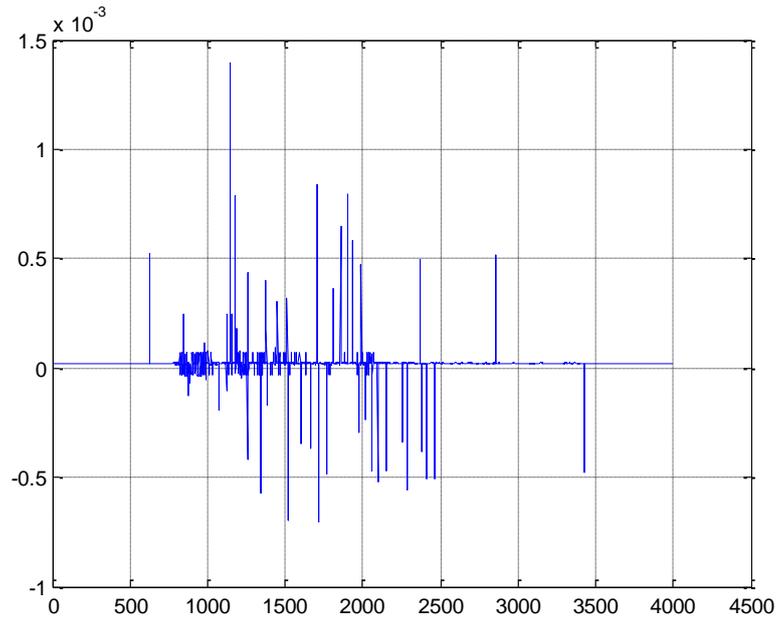


Figure A.24: La différence entre le signal x_{CR} cible et le signal output du modèle 6.

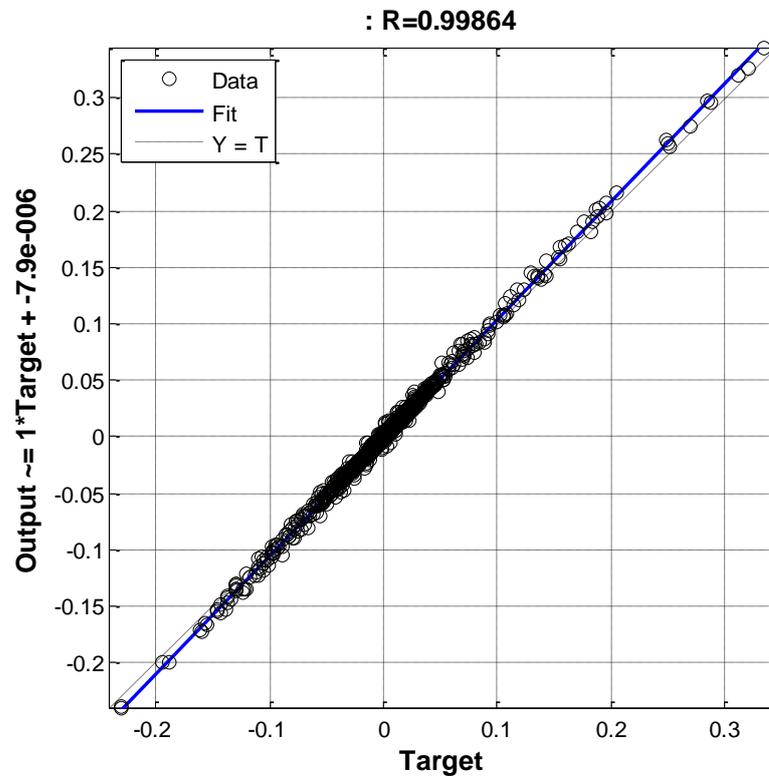


Figure A.25: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 7.

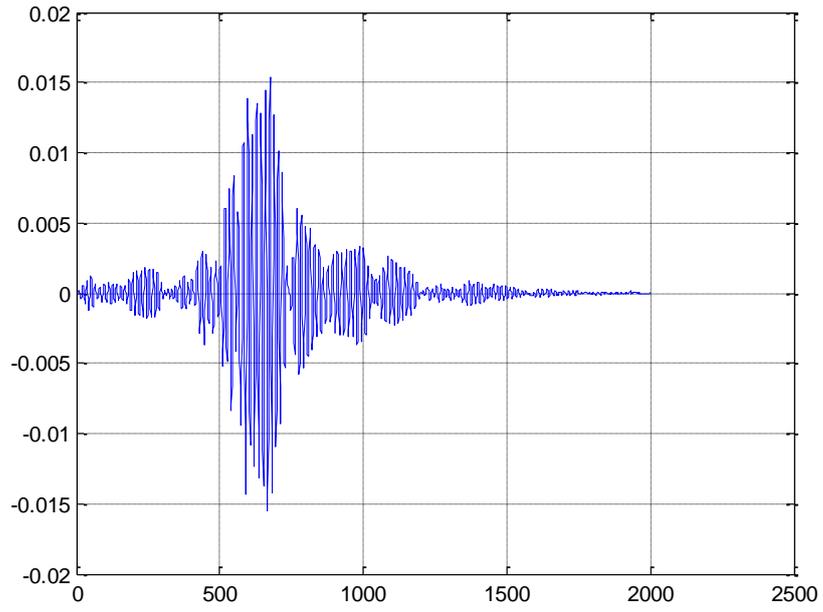


Figure A.26: La différence entre le signal x_{CM} cible et le signal output du modèle 7.

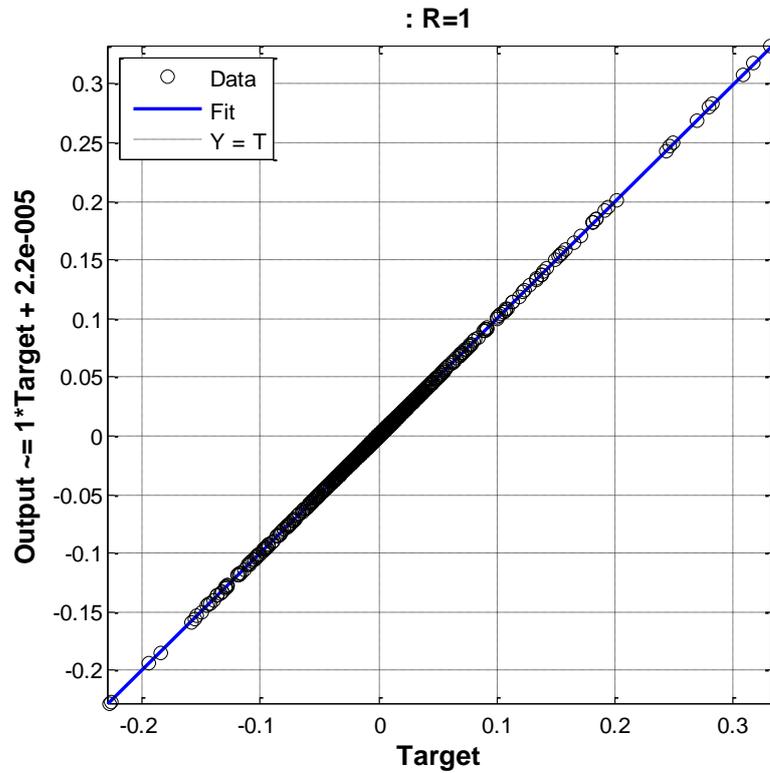


Figure A.27: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 7.

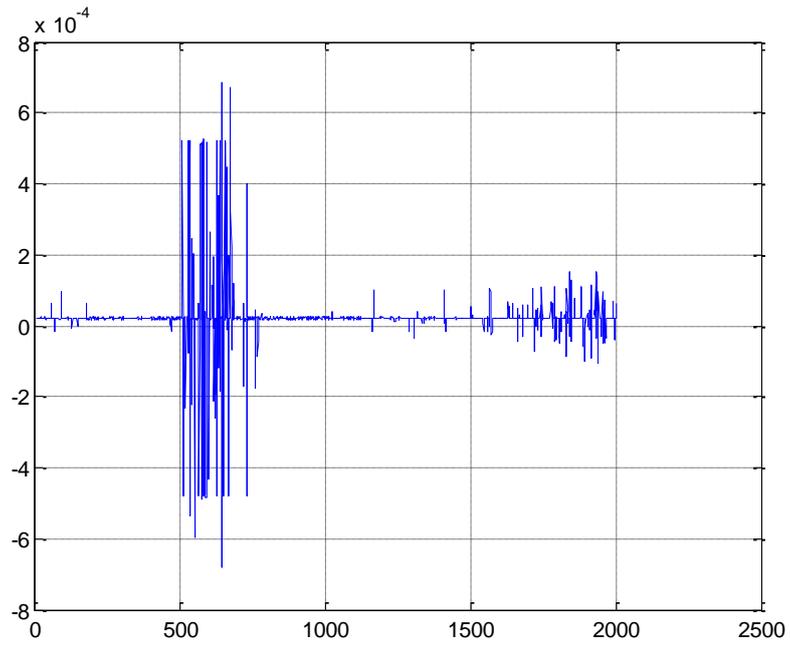


Figure A.28: La différence entre le signal x_{CR} cible et le signal output du modèle 7.

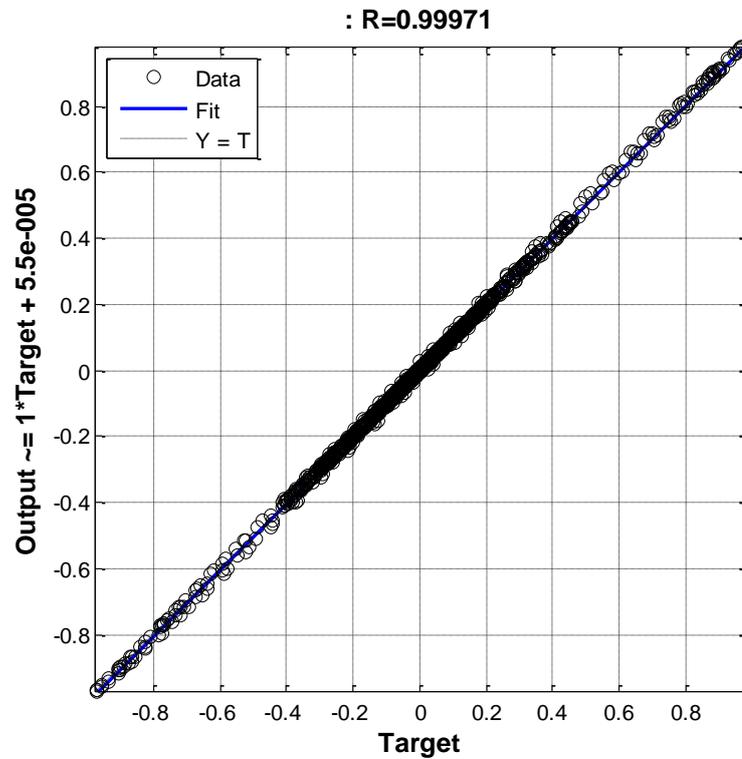


Figure A.29: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 8.

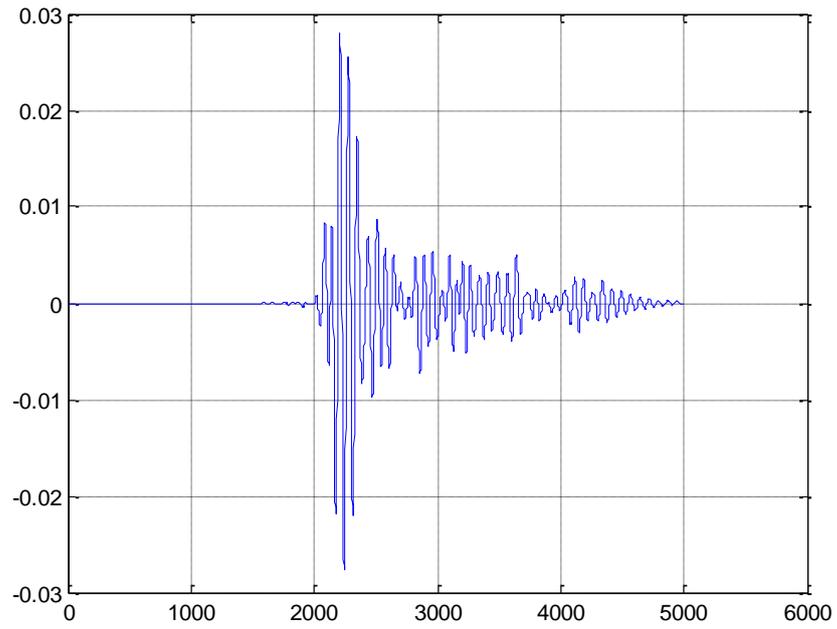


Figure A.30: La différence entre le signal x_{CM} cible et le signal output du modèle 8.

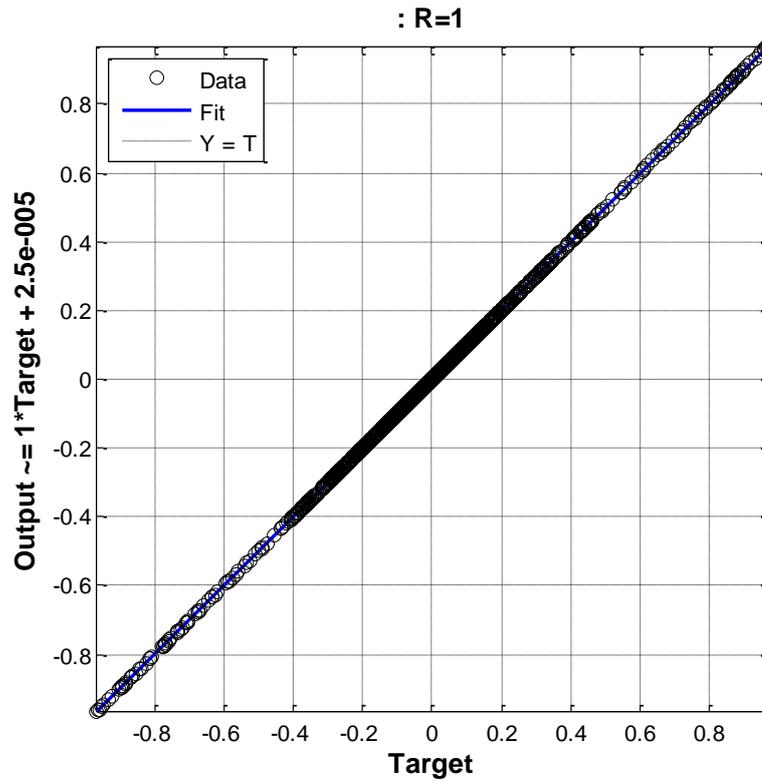


Figure A.31: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 8.

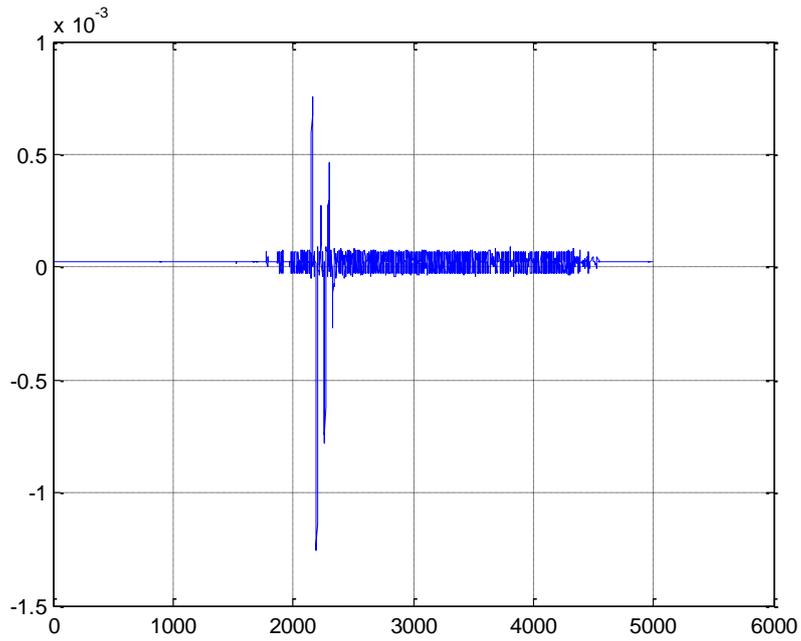


Figure A.32: La différence entre le signal x_{CR} cible et le signal output du modèle 8.

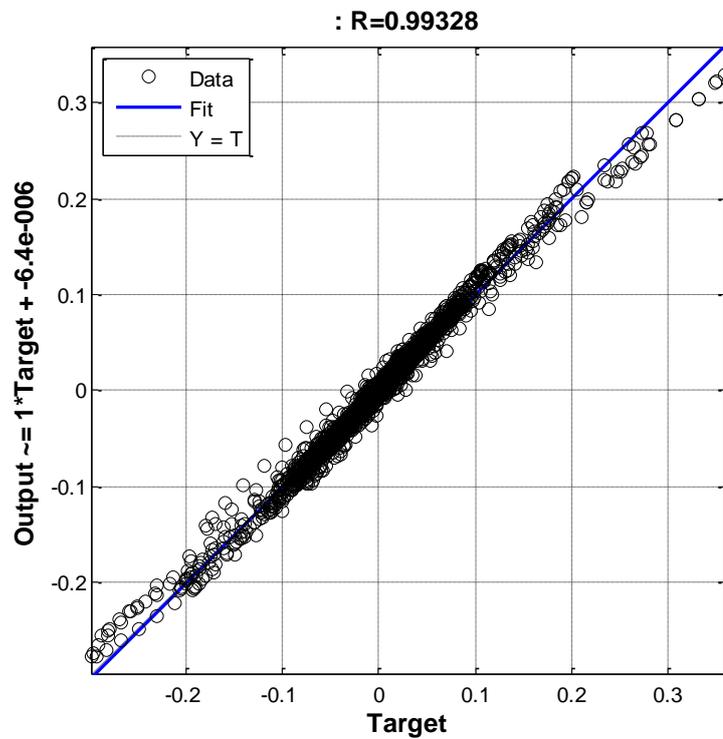


Figure A.33: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 9n1.

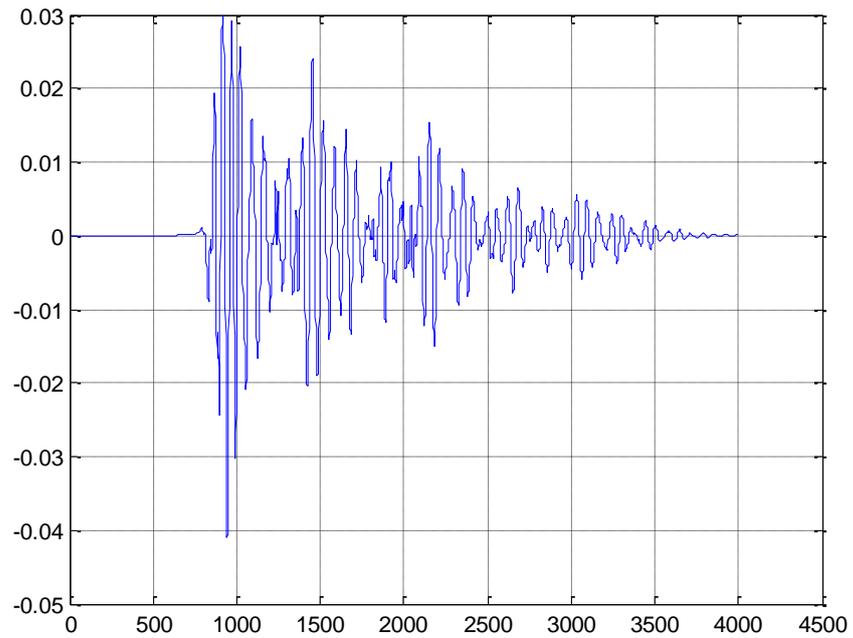


Figure A.34: La déférence entre le signal x_{CM} cible et le signal output du modèle 9n1.

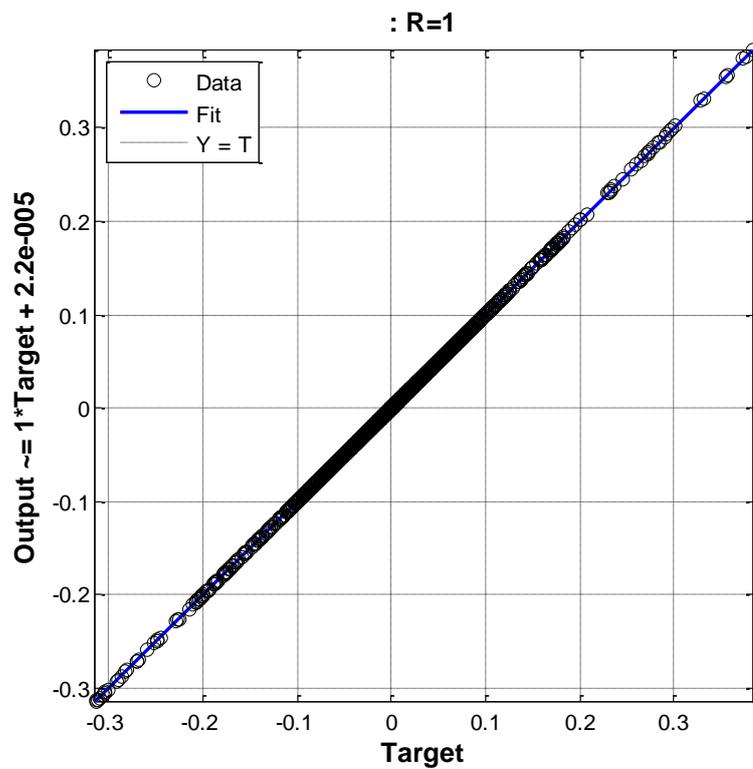


Figure A.35: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 9n1.

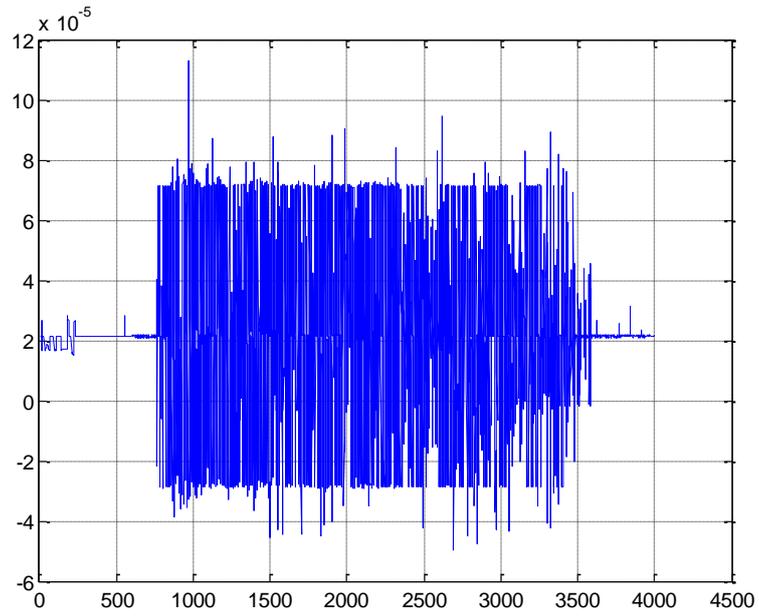


Figure A.36: La différence entre le signal x_{CR} cible et le signal output du modèle 9n1.

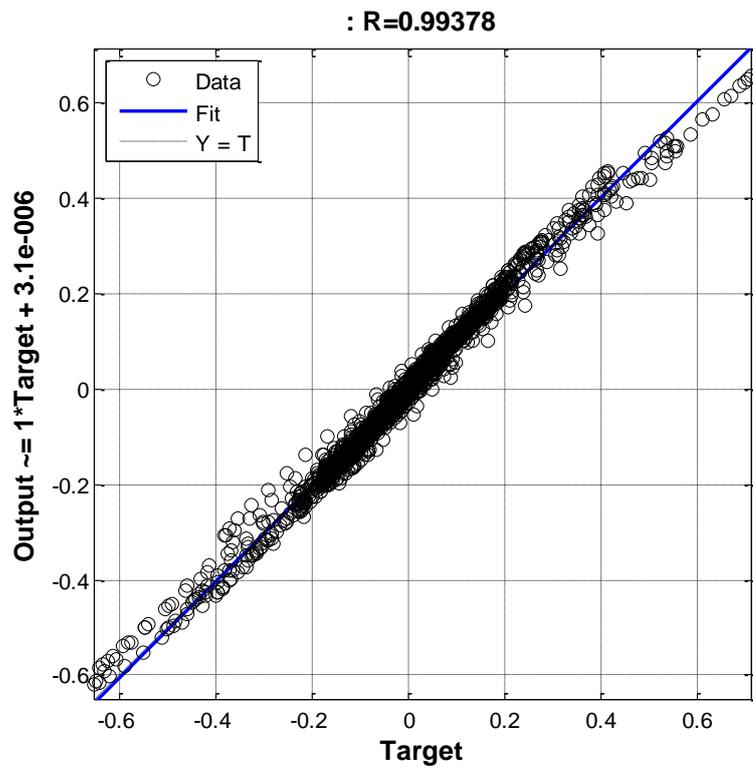


Figure A.37: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 9n2.

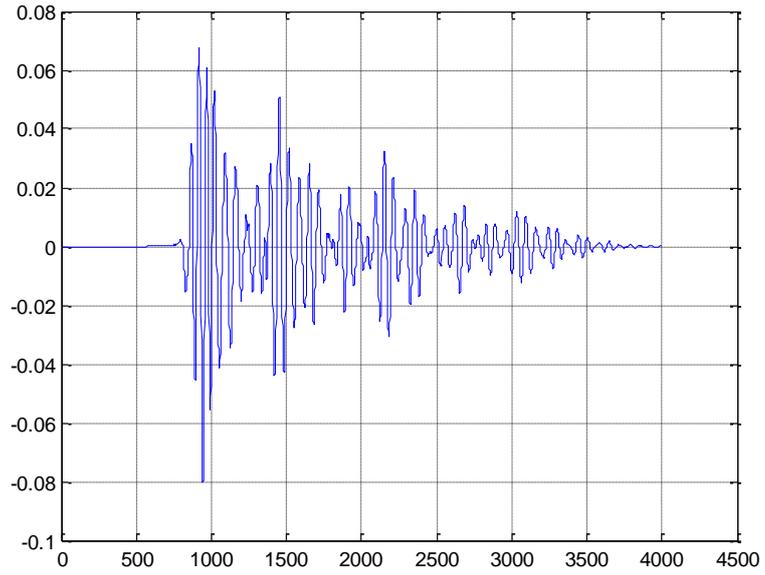


Figure A.38: La déférence entre le signal x_{CM} cible et le signal output du modèle 9n2.

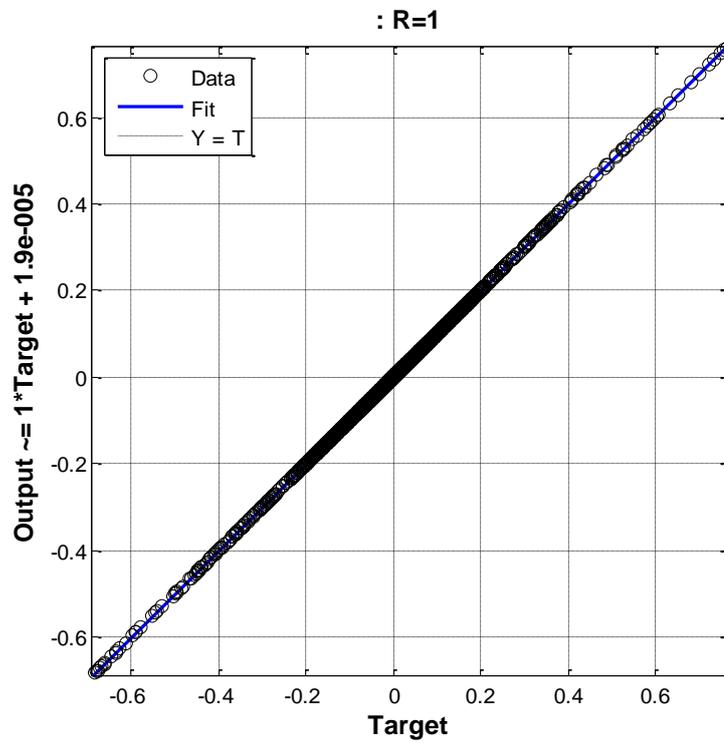


Figure A.39: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 9n2.

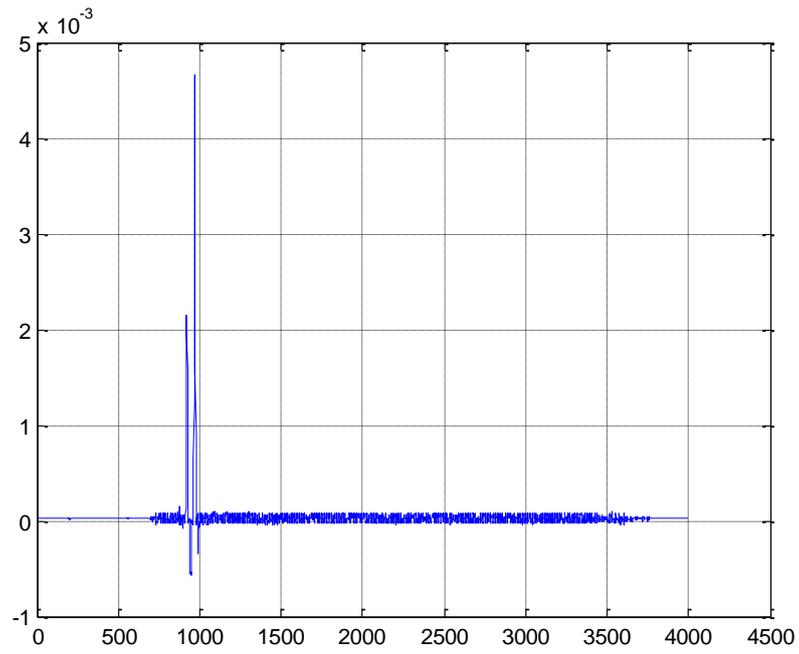


Figure A.40: La différence entre le signal x_{CR} cible et le signal output du modèle 9n2.

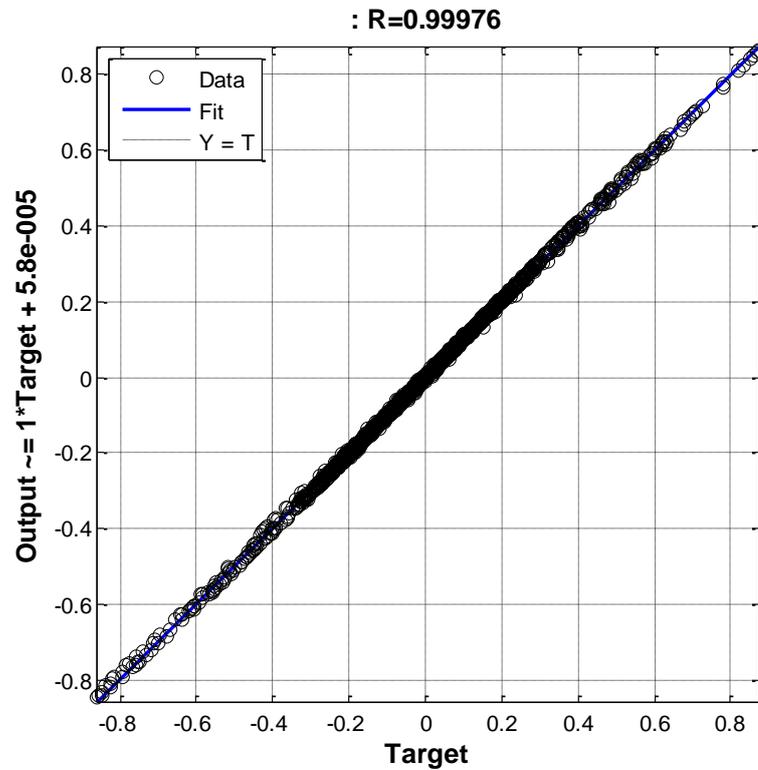


Figure A.41: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 9n3.

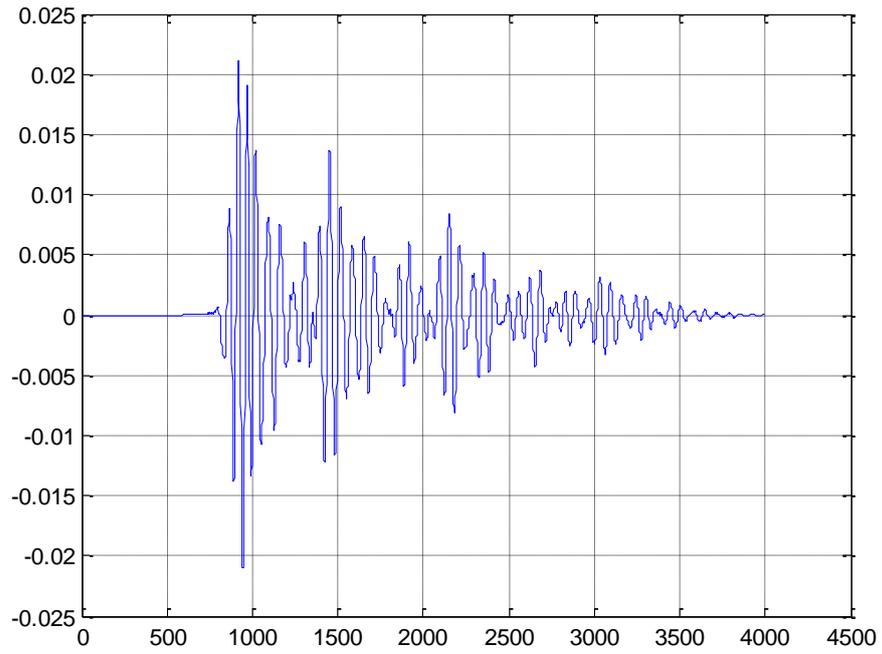


Figure A.42: La différence entre le signal x_{CM} cible et le signal output du modèle 9n3.

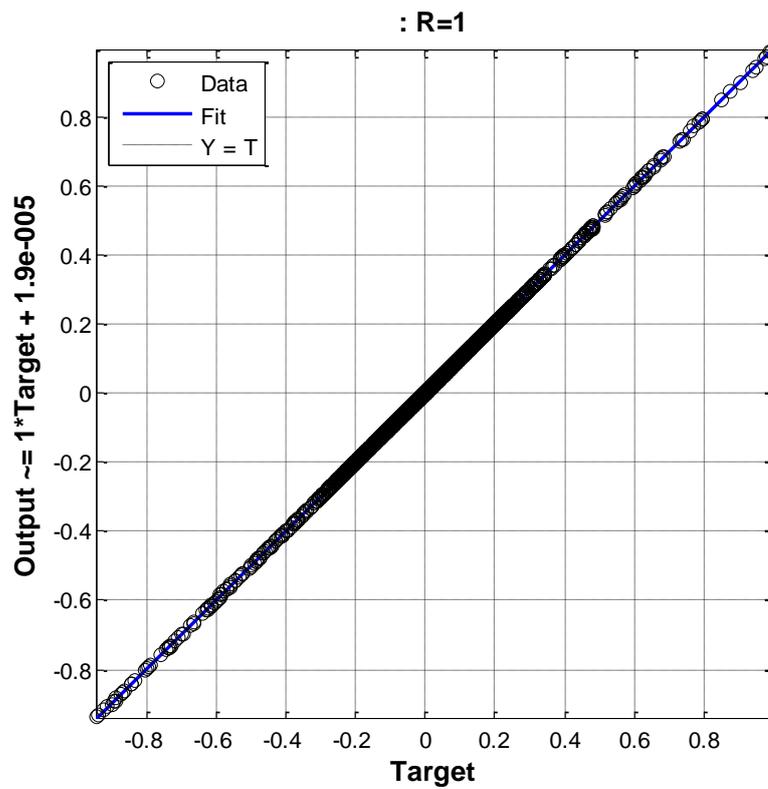


Figure A.43: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 9n3.

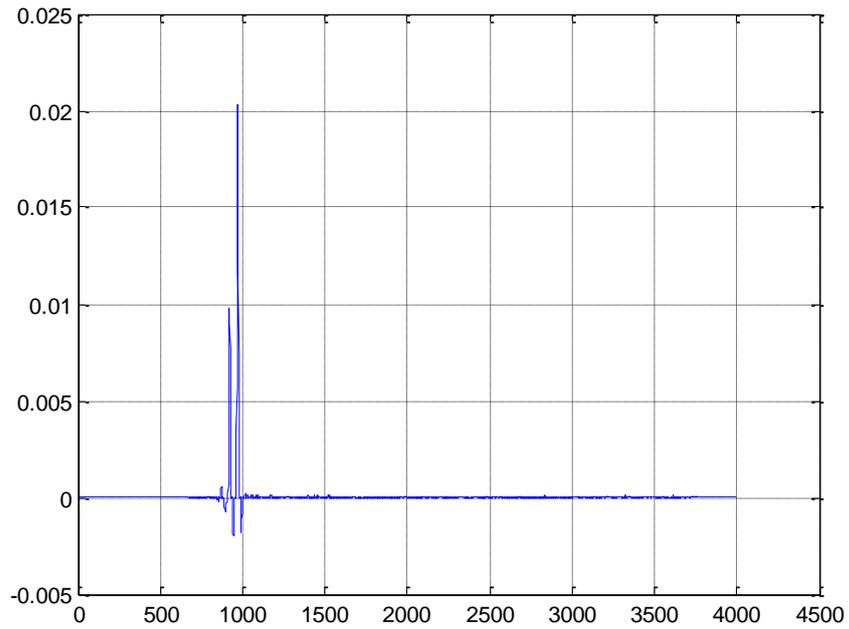


Figure A.44: La déférence entre le signal x_{CR} cible et le signal output du modèle 9n3.

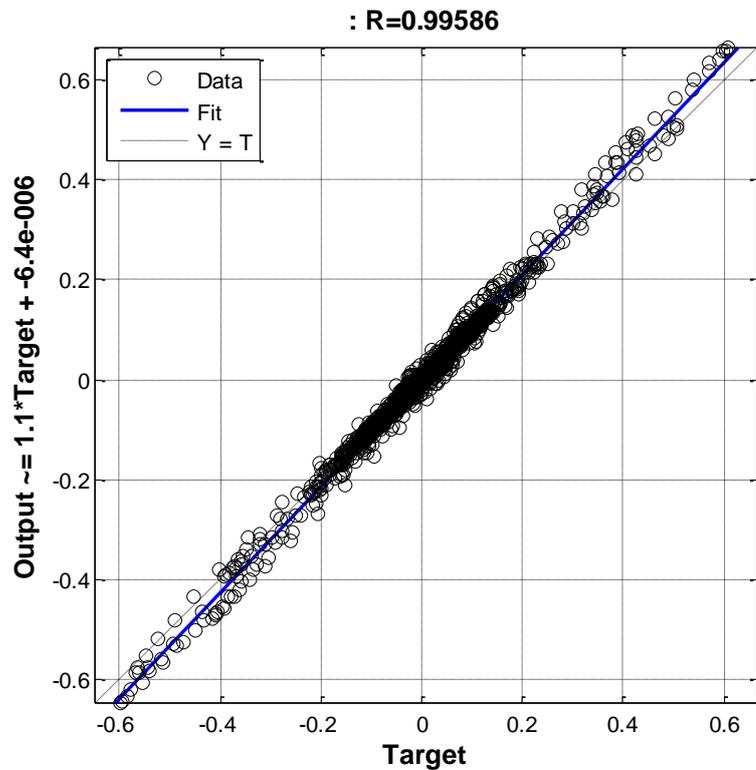


Figure A.45: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 10n1.

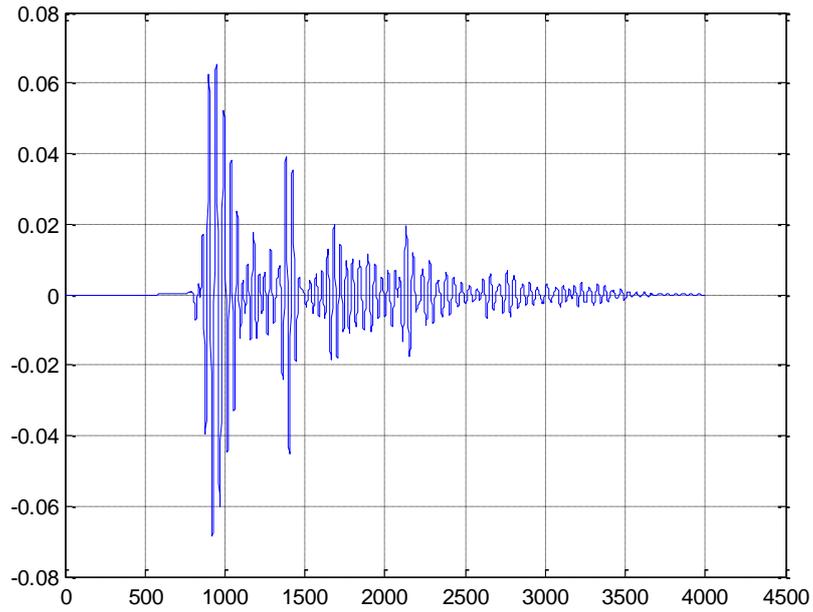


Figure A.46: La différence entre le signal x_{CM} cible et le signal output du modèle 10n1.

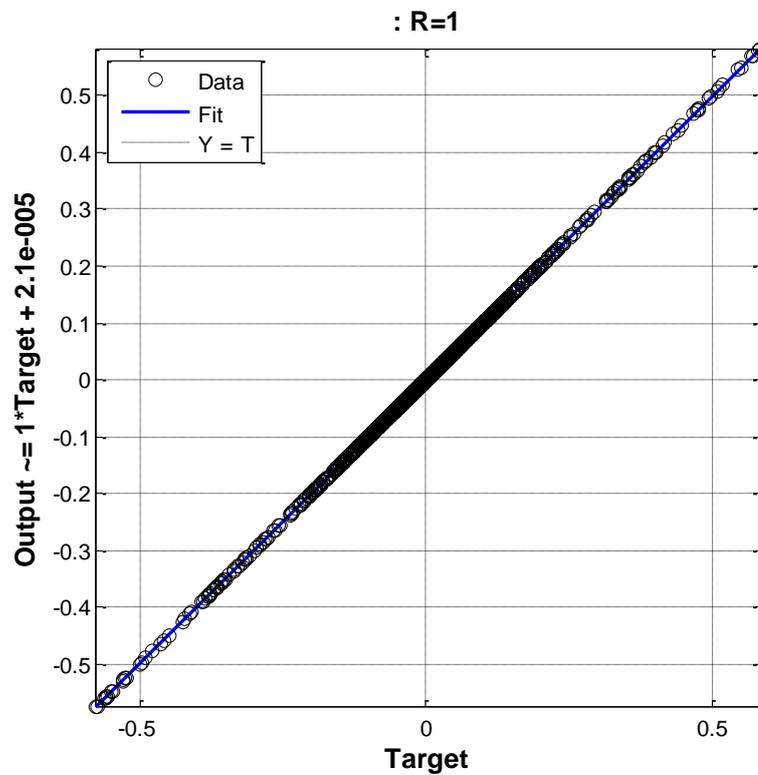


Figure A.47: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 10n1.

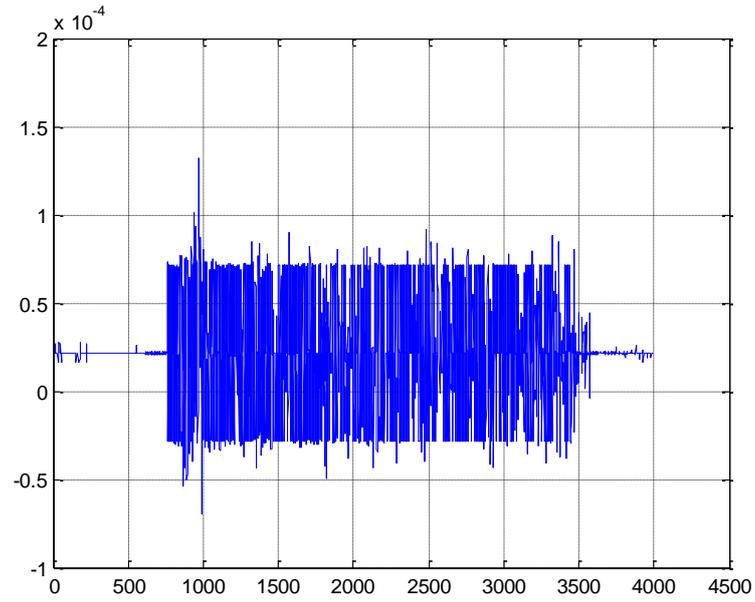


Figure A.48: La différence entre le signal x_{CR} cible et le signal output du modèle 10n1.

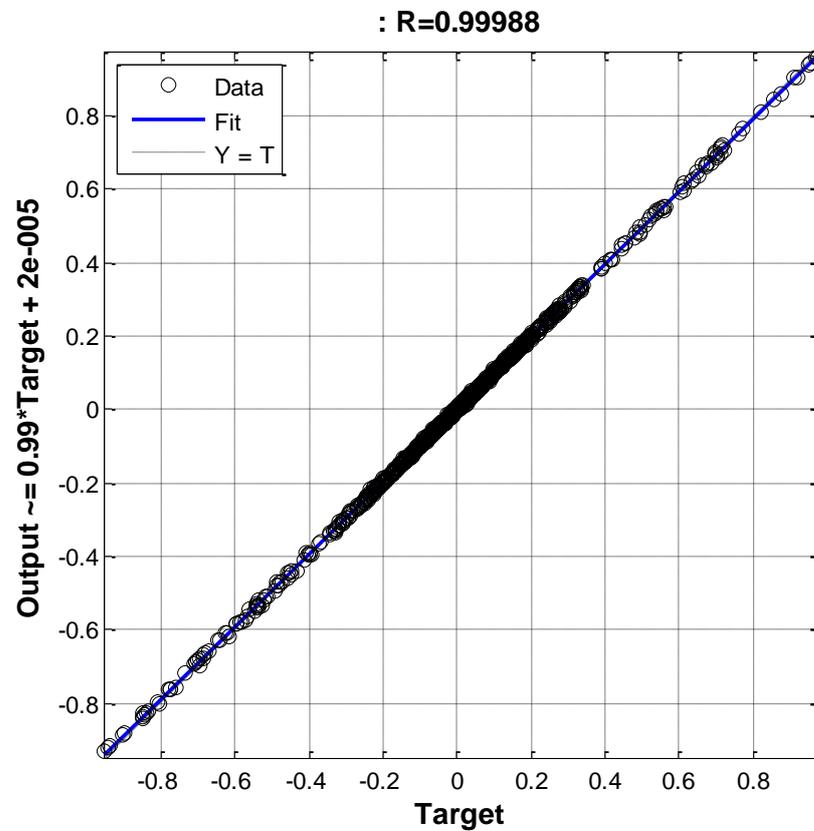


Figure A.49: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 10n2.

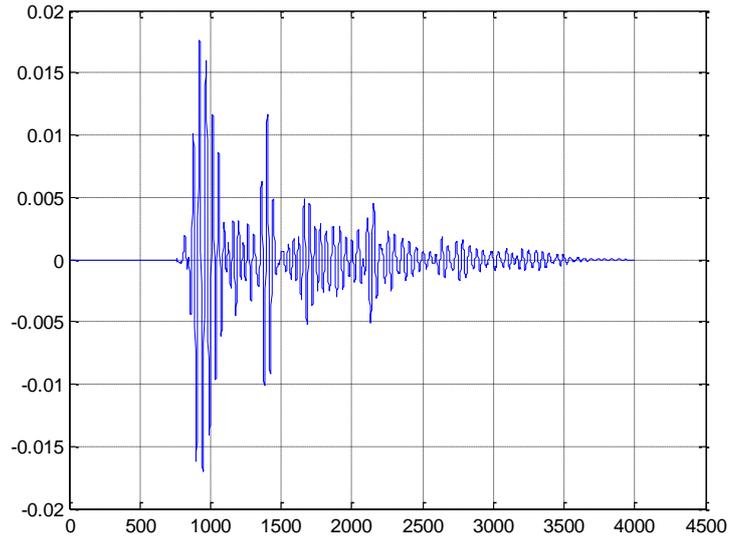


Figure A.50: La différence entre le signal x_{CM} cible et le signal output du modèle 10n2.

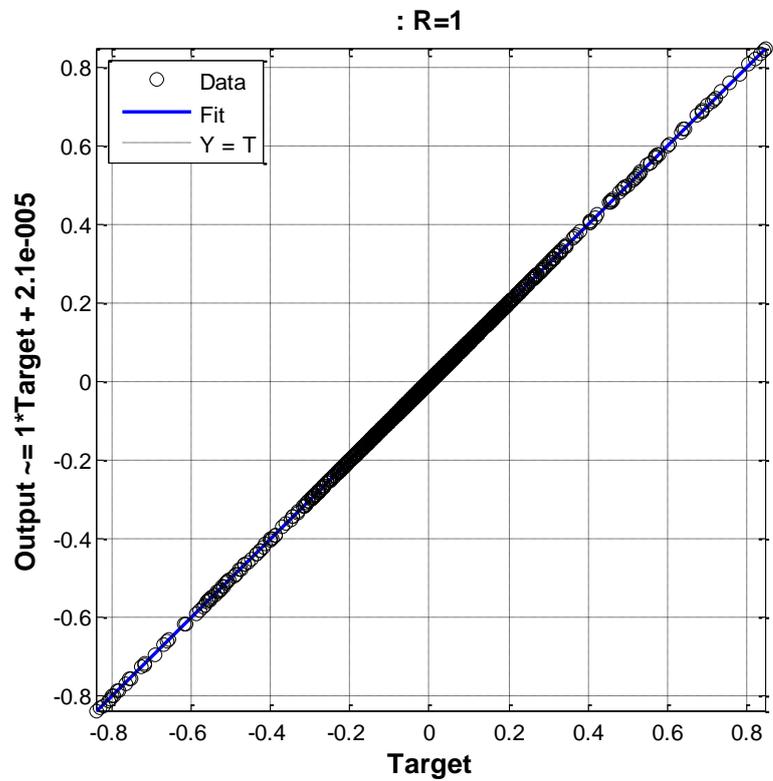


Figure A.51: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 10n2.

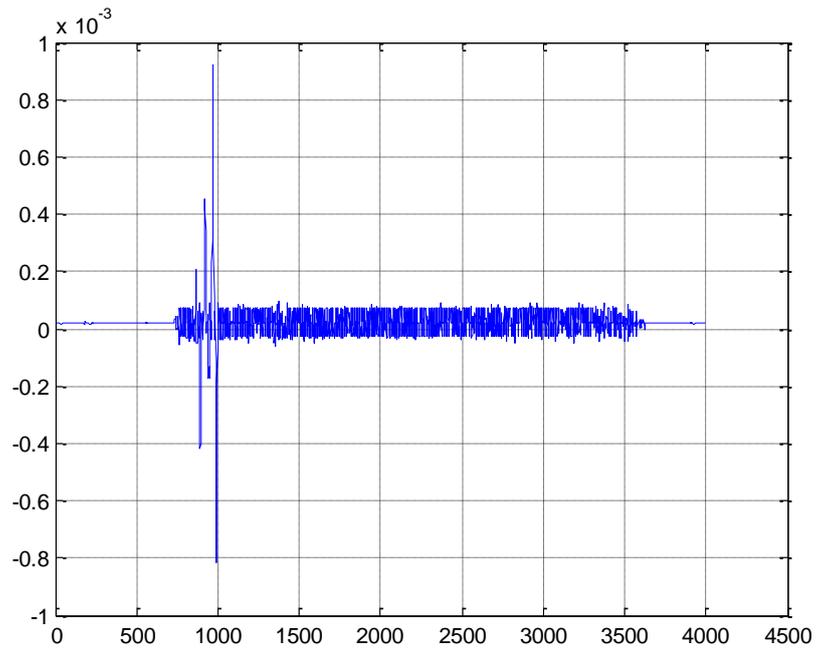


Figure A.52: La différence entre le signal x_{CR} cible et le signal output du modèle 10n2.

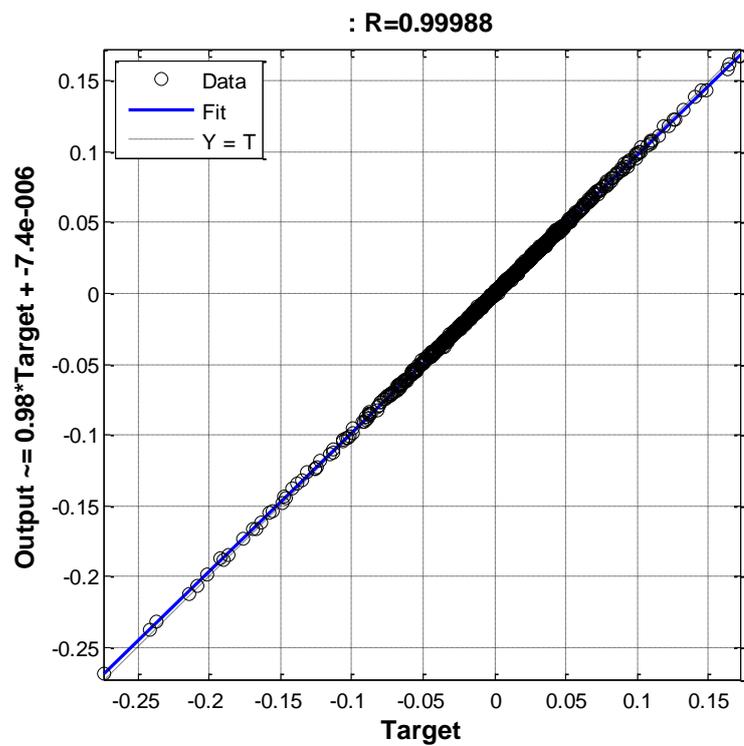


Figure A.53: La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 11.

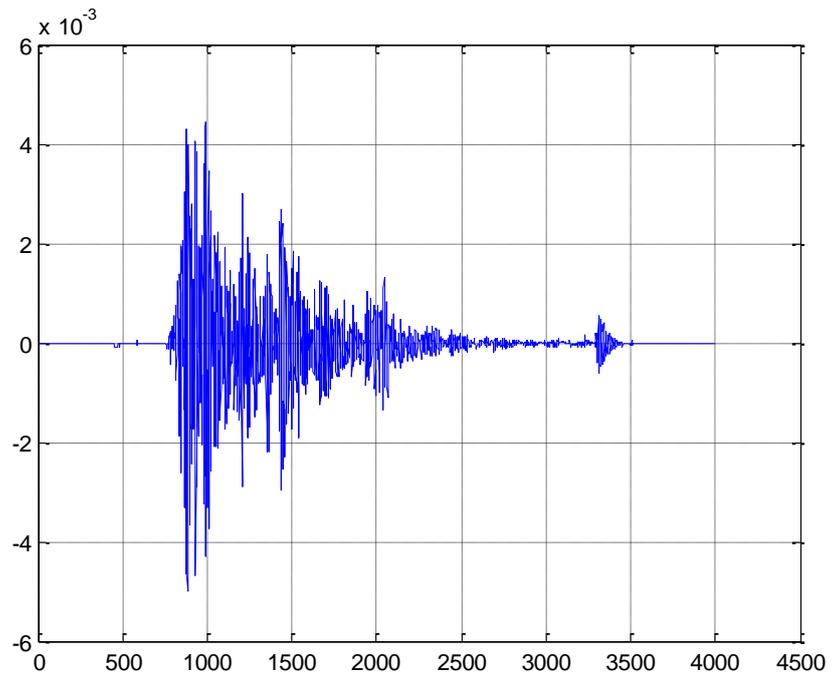


Figure A.54: La déférence entre le signal x_{CM} cible et le signal output du modèle 11.

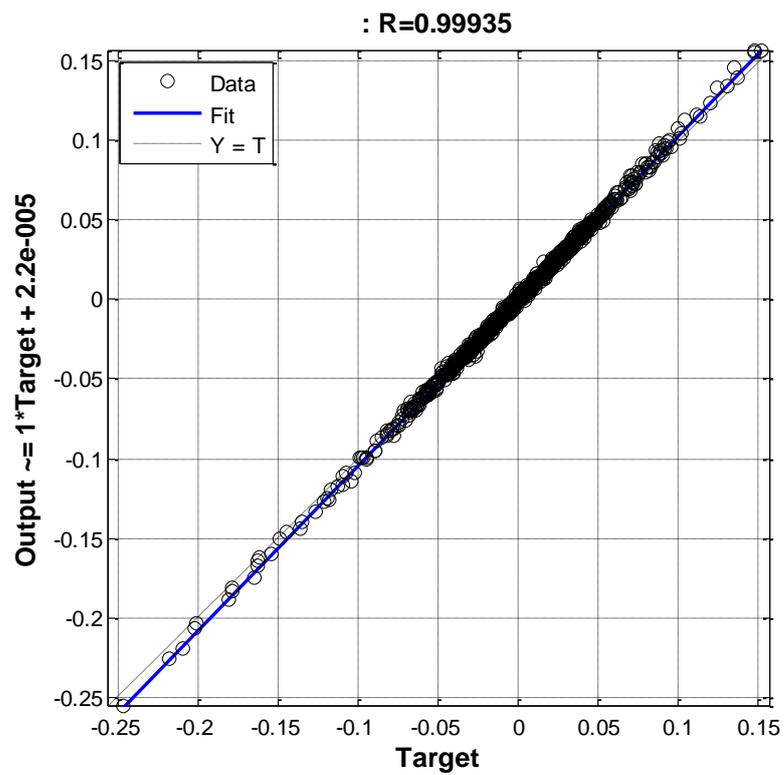


Figure A.55: La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 11.

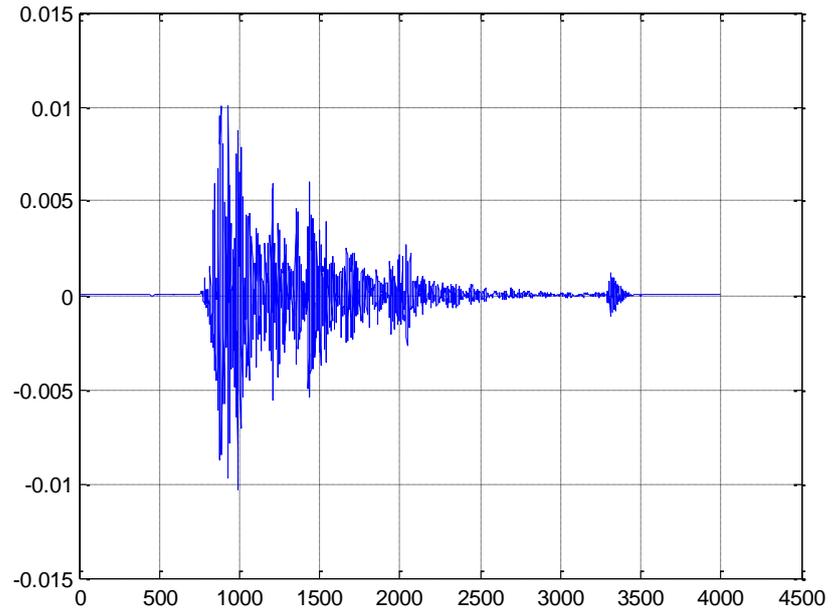


Figure A.56: La déférence entre le signal x_{CR} cible et le signal output du modèle 11.

APPENDICE B - ARTICLE

Titre : « Evaluation de l'excentricité accidentelle par les RNAs à partir d'une réponse dynamique»

Accepté pour : Conférence Nationale sur les Matériaux et Structures, L'Ecole Nationale Polytechnique. Algérie, Octobre 2013.

ÉVALUATION DE L'EXCENTRICITÉ ACCIDENTELLE PAR LES RNAS À PARTIR D'UNE RÉPONSE DYNAMIQUE

I. Derbal et N. Bourahla

Département de génie civil, Université Saad Dahlab de Blida

Résumé

Les règlements parasismiques spécifient l'excentricité accidentelle en pourcentage (5% ou 10%) de la dimension du bâtiment perpendiculaire à la direction de l'excitation, pour tenir compte des incertitudes et des erreurs d'évaluation de la masse et de la rigidité du bâtiment. Eu égard, à la nature aléatoire et incertaine des facteurs responsables de l'excentricité accidentelle, il s'avère très difficile d'évaluer explicitement et avec précision son effet sur la réponse sismique globale des constructions. L'objectif principal de cette étude est de développer une procédure basée sur les réseaux de neurones artificiels (RNAs) pour l'évaluation de l'excentricité accidentelle. Les déplacements sur les deux côtés du plancher sont utilisés comme entrée pour les modèles de RNAs, et les déplacements du centre de masse et du centre de rigidité comme sortie. Ainsi par un simple calcul géométrique on peut obtenir l'excentricité réelle et déduire l'excentricité accidentelle.

1. Introduction

La torsion présente un facteur important caractérisant le comportement global de la construction. Les codes parasismiques introduisent, deux moments de torsion dues aux excentricités calculée et accidentelle. L'introduction de cette dernière a pour but la considération de toutes les incertitudes et les erreurs d'évaluation des caractéristiques géométriques et mécaniques des éléments structuraux et la rupture aléatoire des éléments non structuraux, ou encore à la variabilité spatiale des charges permanentes, à une distribution défavorable des charges d'exploitation ou même les vibrations de torsion induites par le mouvement rotationnel des fondations. En raison du caractère aléatoire de ces paramètres, il est très difficile voire impossible d'évaluer l'excentricité accidentelle d'une manière déterministe. Dans ce contexte, plusieurs études ont été menées dans le but de déterminer avec plus de précision l'effet de la torsion induit par l'excentricité accidentelle. Les effets de la composante rotationnelle du séisme sur l'excentricité accidentelle, ont été évalués dans une étude qui a tenté de dissocier cette composante par rapport aux autres facteurs et a montré que la valeur proposée $0.05b$ ne suffit pas pour des conditions de conception des bâtiments ayant des petites périodes de torsion [1]. Une autre étude a présenté une procédure pour la détermination des efforts induits par la torsion provoquée par l'excentricité accidentelle à partir des enregistrements sur des bâtiments instrumentés sous une sollicitation sismique

réelle. Les résultats obtenus dans cette étude ont montré que la torsion accidentelle spécifiée par l'UBC est en bonne concordance avec la composante de la torsion dans les mouvements enregistrés [2]. Par ailleurs, une approche différente basée sur la méthode des réseaux de neurones (RNAs) a été utilisée pour la première fois pour estimer le niveau de l'excentricité accidentelle dans un bâtiment nominalelement symétrique [3]. Dans cette même tendance, une autre procédure utilisant la même méthode (RNAs) couplée à des simulations de Monte Carlo a montré son efficacité à déterminer l'excentricité accidentelle des structures à un seul étage [4]. L'objectif de ce travail est de localiser le centre de masse et le centre de rigidité et par conséquent quantifier l'excentricité accidentelle des bâtiments à partir d'une réponse dynamique en utilisant un réseau de neurones de type ELMAN.

2. Principe et méthodologie

L'idée de base de ce travail consiste à déterminer l'excentricité accidentelle causée par des incertitudes structurelles de rigidité et de masse à partir de la réponse dynamique du bâtiment au niveau du plancher (déplacements du côté flexible et rigide). Si on considère un bâtiment asymétrique représenté dans la figure 1, sous une excitation sismique, le mouvement de rotation du plancher peut être exprimé en fonction des déplacements des extrémités comme suit :

$$\theta = \frac{x_f - x_r}{b} \quad (1)$$

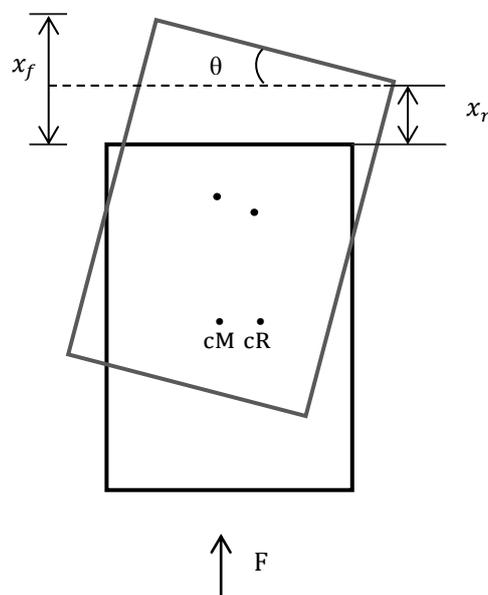


Figure 1: Modèle structural excentré dans un seul sens.

Θ est le signal de variation de l'angle de rotation du plancher ; x_r et x_f sont les signaux de déplacements de deux points situés sur le côté rigide et flexible du plancher, respectivement ; b est la dimension du bâtiment perpendiculaire au sens de l'excitation.

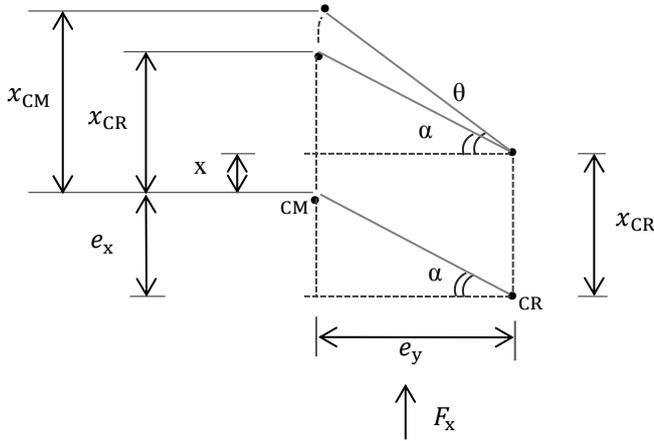


Figure 2 : Le déplacement du centre de masse et de rigidité lors d'une réponse couplée

D'après la figure 2, on a : α est l'angle entre l'horizontale et la droite qui relie le centre de masse avec le centre de rigidité ; Θ est l'angle de rotation du plancher ; e_x l'excentricité dans le sens x ; e_y l'excentricité dans le sens y ; x_{CM} le déplacement du centre de masse ; x_{CR} le déplacement du centre de rigidité ; x est la distance entre la position initiale du centre de masse et la position du centre de rigidité après déplacement. On peut écrire :

$$\alpha = \frac{x_{CR} - x}{e} \quad (2)$$

$$(\alpha + \theta) = \frac{x_{CM} - x}{e} \quad (3)$$

On remplace (2) dans (3) et on obtient :

$$e = \frac{x_{CM} - x_{CR}}{\theta} \quad (4)$$

Pour déterminer la valeur de l'excentricité e à partir de cette formule il faut connaître :

L'angle de rotation Θ , le déplacement du centre de masse et le déplacement du centre de rigidité.

x_f et x_r sont des réponses structurales qui peuvent être mesurées directement sur un étage d'un bâtiment lors des essais de vibrations ambiantes ou un enregistrement pendant une excitation sismique réelle. Par contre le déplacement du centre de masse et le déplacement du centre de rigidité seront déterminés en utilisant la technique des RNAs.

3. Élaboration des réseaux de neurones (RNAs)

Les RNAs sont inspirés de la biologie et représentent un modèle mathématique du fonctionnement du neurone biologique. L'idée est de présenter au RNAs des données d'entrée et de sortie, et de lui faire apprendre la relation entre les deux par un processus appelé

apprentissage. Ce dernier consiste à minimiser l'erreur par ajustement des paramètres du modèle. Les RNAs offrent une alternative pour la modélisation mathématique. Leur avantage réside dans leur capacité de généralisation.

3.1. Conception du réseau

On doit construire deux modèles de réseaux de neurones, un pour la prédiction du déplacement du centre de masse, et le deuxième pour prédire le déplacement du centre de rigidité. Les réseaux de neurones de type Elman, s'avèrent très appropriés pour la prédiction précise des deux déplacements, car ces derniers se présentent sous forme de séquences en fonction du temps. Le réseau est composé de deux couches. Les neurones de la couche cachée ont des fonctions de transfert de type sigmoïdes tangentielles. La fonction de transfert dans les neurones de la couche de sortie est de type linéaire. Cette combinaison est spéciale du fait que les réseaux de deux couches avec ces fonctions de transfert peuvent rapprocher n'importe quelle fonction. La seule condition est que la couche cachée doit avoir assez de neurones. Le nombre de neurones dans la couche cachée, est déterminé par des expériences, on a opté pour deux couches cachées de 21 neurones chacune pour le modèle qui détecte le déplacement du centre de masse, et deux couches cachées de 17 neurones chacune pour le modèle qui détecte le déplacement du centre de rigidité.

3.2. Bases de données

La base de données est divisée en deux parties, une pour l'apprentissage et l'autre pour le test et la validation. Un modèle numérique en éléments finis (EF) est utilisé pour la création de la base de données d'apprentissage des deux modèles de réseaux de neurones. Les signaux de déplacements des cotés flexible et rigide sont utilisés comme des entrées dans les deux modèles de RN. Le signal de déplacement du centre de masse est utilisé comme une sortie désirée du modèle de RN qui prédit le déplacement du centre de masse. Le signal de déplacement de centre de rigidité est utilisé comme une sortie désirée du modèle de RN qui prédit le déplacement du centre de rigidité.

3.3. Apprentissage des réseaux de neurones

L'apprentissage est une phase du développement du réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. Pour cette application, plusieurs essais ont été faits par les différents algorithmes disponibles dans MATLAB [5], et on a constaté que l'algorithme de Levenberg-Marquardt a la convergence la plus rapide. La fonction de performance utilisée pour l'apprentissage de réseau de neurones est l'erreur quadratique moyenne (MSE) donnée par :

$$MSE = \frac{1}{N} \left(\sum_k (X_{CM_{RN_k}} - X_{CM_{D_k}})^2 \right) \quad (5)$$

Où, X_{CMD} est le déplacement du centre de masse désiré, X_{CMRN} est le déplacement du centre de masse calculé par le réseau de neurones, N égal au nombre d'exemples de la base d'apprentissage et k est le numéro de l'échantillon. Pour éviter le sur-apprentissage du réseau, le procédé de l'arrêt précoce est utilisé. L'ordre d'entrée entier est présenté au réseau, et ses sorties sont calculées et comparées à l'ordre de cible pour produire l'ordre d'erreur. Pour chaque fois l'erreur est rétropropagée pour trouver des gradients des erreurs pour chaque poids et polarisation. Ce gradient est alors employé pour mettre à jour les poids avec la fonction d'apprentissage de rétropropagation. La courbe d'apprentissage d'exemple est représentée sur les figures 3 et 4.

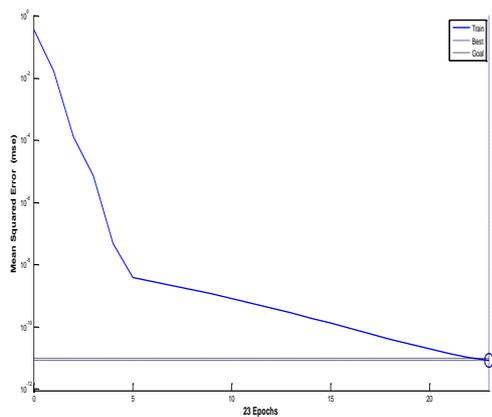


Figure 3 : Evaluation de l'erreur pour la prédiction de déplacement du centre de masse

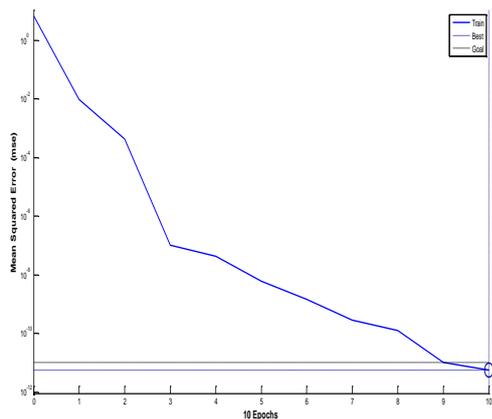


Figure 4 : Evaluation de l'erreur pour la prédiction de déplacement du centre de rigidité

3.4. Test et validation des réseaux

L'efficacité des modèles proposés de réseau de neurones est évaluée sur la base des possibilités du réseau de simuler exactement la corrélation entre les signaux d'entrée de déplacement des cotés flexible et rigide, et le signal ciblé de déplacement du centre du masse ou le déplacement du centre de rigidité du plancher. Après que le réseau de neurones soit entièrement formé pour un ensemble donné de paires d'entrée-sortie, il est examiné en utilisant un signal qui n'appartient pas à l'ensemble d'apprentissage. Pour le test de l'efficacité

des deux modèles de RN, une base de données a été construite en variant plusieurs paramètres dans des modèles numériques en EF (l'excentricité, l'excitation, les géométries du modèle, les dimensions des éléments résistants, les positions du centre de masse et de rigidité et le nombre des étages). 11 modèles numériques sont utilisés pour le test et la validation des réseaux de neurones. Afin de vérifier la qualité des RNs, l'ensemble des données utilisées pour le test et la validation a été passé à travers le réseau pour effectuer une régression linéaire entre les sorties du réseau Y et les cibles correspondantes T (target). Le coefficient de corrélation R obtenu permis de mesurer la qualité de la prédiction du réseau, une prédiction parfaite suggère que tous les points sont alignés le long de la diagonale $Y = T$ et le coefficient de corrélation est $R = 1$.

A titre d'exemple, nous avons présenté uniquement les résultats de validation du modèle 2.

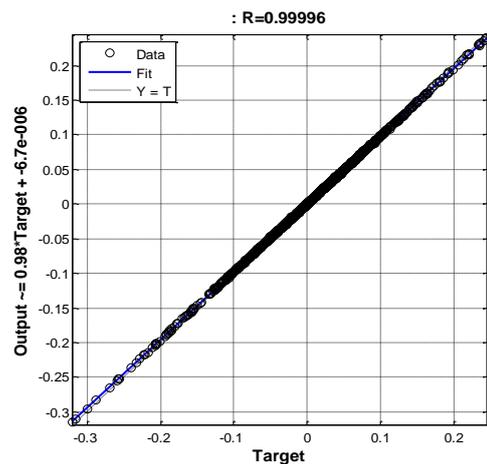


Figure 5 : La régression linéaire entre le signal x_{CM} output et le signal cible du modèle 2.

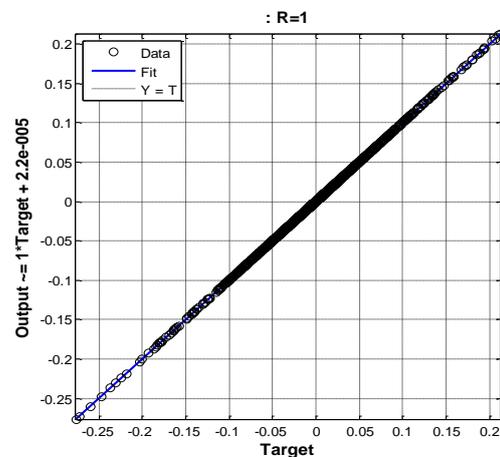


Figure 6 : La régression linéaire entre le signal x_{CR} output et le signal cible du modèle 2.

Pour les résultats de validation des réseaux de prédiction des déplacements du centre de masse et du centre de rigidité (figures 5 et 6), les lignes d'adaptation sont pratiquement superposées à la diagonale, et le coefficient de corrélation est très proche de l'unité, ce

qui signifie que les réseaux de neurones donnent des prédictions très précises des déplacements du centre de masse et du centre de rigidité.

4. Calcul des excentricités et performance du model RNA

En se basant sur les résultats des tests de validation, il s'avère que lorsque la position du centre de masse ou de rigidité dans la simulation est proche de la position du centre de masse ou de rigidité dans l'apprentissage, la précision du réseau est meilleure. Par ailleurs, l'erreur augmente lorsque la position du centre de masse ou de rigidité est proche du milieu du plancher dans la phase d'apprentissage, et plus loin du milieu dans la simulation. Par contre, lorsque la position du centre de

masse ou de rigidité est loin du milieu du plancher dans la phase d'apprentissage, et plus proche du milieu dans la simulation, l'erreur diminue. Il est à noter cependant que la précision du modèle est peu sensible au nombre d'étages. Le tableau ci-dessous montre les excentricités calculées à partir des RNAs et les excentricités réelles des modèles numériques utilisés pour l'apprentissage et la validation.

e_e : est le rapport entre l'erreur absolue sur l'excentricité et b est la dimension du bâtiment perpendiculaire à l'excitation, calculé comme suit :

$$e_e = \frac{\text{erreur absolue}}{b} \quad (6)$$

Tableau 1: Excentricités calculées par le RNA

modèles	Excentricité réelle [cm]	Excentricité calculée par RNAs [cm]	L'erreur absolue sur l'excentricité [cm]	L'erreur relative sur l'excentricité [%]	b [m]	e_e [%]
1	24.35	19.62	4.73	19.42	4	1.18
2	75.19	66.53	8.66	11.52	5	1.73
3	19.42	24.82	5.4	27.81	4	1.35
4	0	0	0	0	4	0
5	79.73	79.72	0.01	0.01	6	1.67×10^{-3}
6	83.21	92.88	9.67	11.62	7	1.38
7	16.91	19.35	2.44	14.43	5	0.49
8	16.26	18.97	2.71	16.66	4	0.68
9 niveau 1	43.23	34.56	8.67	20.05	7	1.24
9 niveau 2	43.23	35.38	7.85	18.16	7	1.12
9 niveau 3	83.21	92.28	9.07	10.9	7	1.29
10 niveau 1	16.42	17.61	1.19	7.25	4	0.30
10 niveau 2	59.98	60.63	0.65	1.08	4	0.16
11	112.8	100.2	12.6	11.17	4	3.15

5. Conclusions

Les facteurs qui sont à l'origine de l'excentricité accidentelle sont fortement aléatoires. Il s'avère donc très difficile d'évaluer explicitement et avec précision leurs effets sur la réponse sismique globale des constructions. Dans cet article, une procédure pour la quantification de l'excentricité accidentelle à partir d'une réponse dynamique d'une structure multi-étagée a été proposée. Cette procédure fait appel à la technique des réseaux de neurones pour prévoir l'excentricité réelle du bâtiment et par la suite l'excentricité accidentelle. Elle nécessite uniquement deux enregistrements des déplacements sur deux côtés extrêmes du bâtiment. Ces derniers sont utilisés comme un vecteur d'entrée aux réseaux de neurones et en sortie on obtient les déplacements du centre de masse et de rigidité. Une étude de sensibilité a montré que la précision du modèle du réseau de neurones est meilleure quand la position du centre de masse ou de rigidité lors de l'apprentissage, est proche de la position du centre de masse ou de rigidité dans la simulation.

Références

- [1] H. Shakib and R.Z. Tohidi. Evaluation of accidental eccentricity in buildings due to rotational component of earthquake. Journal of Earthquake Engineering, Vol. 6, No. 4, 2002.
- [2] J.C. De La Llera and A. K. Chopra. Evaluation of code-accidental torsion provisions using earthquake records from three nominally symmetric- plan buildings. SMIP92 Seminar on Seismological and Engineering Implications of Recent Strong-Motion Data, p. 4-1 - 4-16, 1992.
- [3] N. Bourahla and T. Boukhamacha. Extraction of accidental eccentricity parameters from ambient vibration records using artificial neural networks. Proceedings of the International Conference on Experimental Vibration Analysis for Civil Engineering Structures, France, October 2005.
- [4] M. Badaoui, A. Chateaneuf, E. Fournely, N. Bourahla and M. Bensaïbi. Evaluation of accidental eccentricity for buildings by artificial

neural networks. Structural Engineering and Mechanics, Vol. 41, No. 4, 2012.

- [5] M.H. Beale, M.T. Hagan, H.B. Demuth. Neural network toolbox™ user's guide, the math works, R2012b.