

1. Introduction

Dans ce chapitre, on présente les procédures expérimentales réalisées dans le cadre de cette étude. On cherche à élaborer le capteur de force logiciel, après de prélevées plusieurs point sur le matériau, formant ainsi base de données réelle, sont affiner en utilisant la technique d'analyse en composantes principales (ACP), et à adapter au niveau de réseau de neurones artificielles (RNA) ayant pour sortie une estimation de la force appliquée sur le matériau.

2. Position du problème

Le contrôle destructif des matériaux par les grands machines mécanique de compression et de traction et flexion, qui besoin beaucoup d'énergie et de matérielle, en plus la perte de temps et les problèmes de transporter les éprouvette à laboratoire de contrôle. Par contre il existe des méthodes de contrôle non destructif basées sur les techniques de l'intelligence artificielles (IA) qui servent comme outil de base pour l'aide à la décision, capable de caractérisée l'état des matériaux précisément, Apres de prélever plusieurs point déterminer sur le matériau, formant ainsi une base de données réel, sant à affiner en utilisant la technique d'analyse en composantes principales (ACP), et adapter au niveau d'un réseau de neurones artificiel (RNA) ayant pour sortie estimation de la force appliquée sur matériau,

La technique citée ci-dessus permet de résoudre le problème de déterminer les résistances mécanique en compression, tel que dans notre application, concernant. Dans cette application, l'approche de surveillance ne s'applique en fait que si on se trouve dans le cas d'un apprentissage supervisé. Nous procédons alors lors d'une étape préliminaire d'apprentissage. A souligner encore une fois que les méthodes de reconnaissance de formes à base d'apprentissage statistique telles que : les RNAs, sont les plus utilisées dans les systèmes de classification. L'apprentissage est une étape assez moins de temps de calcul.

3. La base de données réelle

À partir de prend les différents mesures d'auscultations ultrasoniques d'un éprouvette on remplié le tableau ce dessous par ces mesures, et quand terminer passé a écrasé cette éprouvette dans la machine d'écrasement.

		1	2	99	100	
mode d'auscultations	Transparence μs					<i>c-c</i>
						<i>d₁-g₁</i>
						<i>d₂-g₂</i>
						<i>d₃-g₃</i>
	Rayonnement μs					<i>c-d₁</i>
						<i>c-d₃</i>
						<i>c-g₁</i>
						<i>c-g₃</i>
	Surface μs					<i>a₁-a₃</i>
						<i>g₁-g₃</i>
						<i>f₁-f₃</i>
						<i>d₁-d₃</i>
Force (KN)						

Table IV.1 : Table montre les différentes auscultations et leurs points sur l'éprouvette

- c : le centre de cylindre
- f: les points de fessade
- a : les points d'arrière
- d : les points de droite
- g : les points de gauche

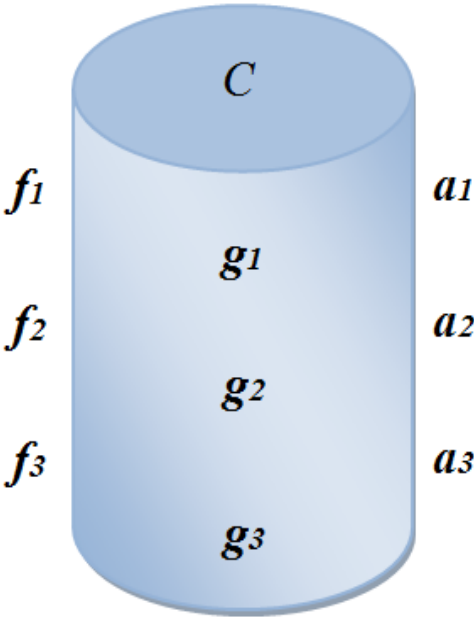


Figure IV.1 : les différents points de mesure sur l'éprouvette.

4. Réduction de dimensions par l'ACP

Une analyse en composante principale se décompose selon les étapes suivantes :

- **Etape 1** : calcul de la matrice des corrélations entre les variables.

Cette matrice fournit les premiers éléments de description des associations existant entre les variables. L'ACP permettra d'obtenir une synthèse de ces liaisons.

- **Etape 2** : calcul des valeurs propres associées à la matrice des corrélations

Les valeurs propres (ou inertie liée à un facteur) sont les variances des coordonnées de points individus sur l'axe correspondant. Ce sont donc des indices de dispersion du nuage des individus dans la direction définie par l'axe. Il est souvent intéressant de regarder la décroissance des valeurs propres. En effet, si les données sont peu structurées, le nuage a une forme « régulière » qui s'observe par une décroissance régulière des valeurs propres. Dans ces conditions, l'analyse factorielle ne fournira pas de résultat intéressant.

- **Etape 3** : calcul des vecteurs propres associés

Ces vecteurs propres représentent les axes factoriels du nouvel espace, combinaison linéaire des variables initiales. On procède alors axe par axe à partir des vecteurs propres associées aux plus grande valeurs propres, pour définir les composantes principales. L'examen du plan factoriel permet de visualiser les corrélations entre les variables et d'identifier des groupes d'individus ayant pris les mêmes valeurs pour les même variables.

4.1. Algorithme de l'ACP

- Calcul de \bar{M} .
- $A = \text{cov } \bar{M}'$.
- Calcul des valeurs et vecteurs propres.
- Calcul de « 1 »-le nombre de composantes à garder.
- Calcul de la matrice caractéristique = $[\text{eig1}, \text{eig2}, \dots, \text{eig1}]$.
- Les données réduites = (la matrice caractéristique)' * \bar{M}' .
- (Les données originales - la moyenne)' = (la matrice caractéristique)⁻¹ * les données réduites

- (Les données originales)' = (la matrice caractéristique)^T * les données réduites + la moyenne .

5. Détermination les composantes principales

Premièrement on à faire une réduction de dimension de la base de données réelle qui déjà élaborée, donc on à acquérir une nouvelle base de données de dimension réduite. On à déterminée le coefficient de corrélation entre la nouvelle base de données réduit de l'ACP et la base de données réelle, et la figure résumée l'opération :

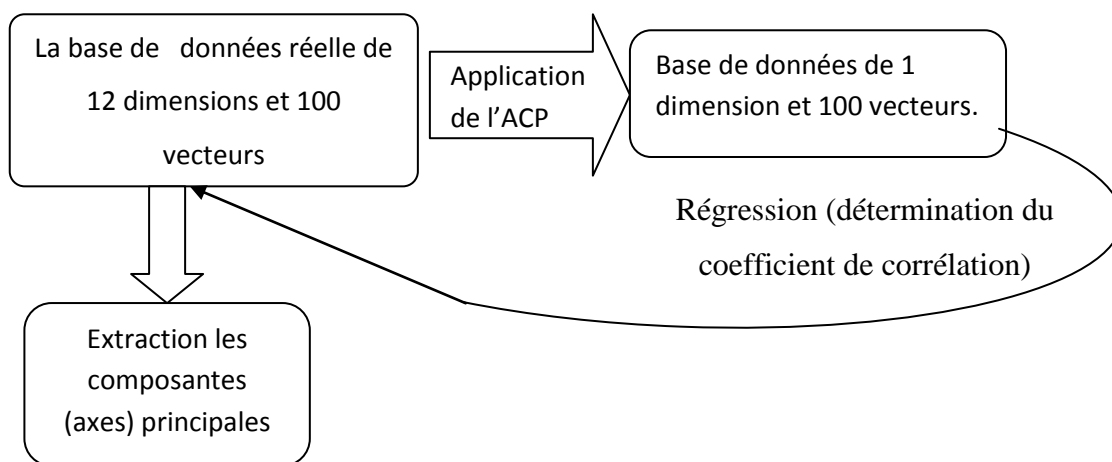


Figure IV.2 : présente les étapes pour extraire les composantes principales.

5.1. Table de corrélation

Nous avons vu la table de corrélation entre la base de données réelle et la nouvelle espace de l'ACP

	Les tngints de mesure											
	$c - c$	$d_1 - g_1$	$d_2 - g_2$	$d_3 - g_3$	$c - d_1$	$c - d_3$	$c - g_1$	$c - g_3$	$a_1 - a_3$	$g_1 - g_3$	$f_1 - f_3$	$d_1 - d_3$
1												
2												
⋮												
100												
$R^2(V_{ACP})$	0,401	0,461	0,514	0,521	0,23	0,731	0,172	0,728	0,753	0,591	0,781	0,704

Table IV.2 : Table présent les coefficients de corrélation entre le vecteur de l'ACP et la base de données réelle.

Donc les composants principales il est correspondre les modes de mesure (auscultation) suivantes :

- f_1-f_3
- a_1-a_3
- $c - d_3$
- $c - g_3$

Ces modes d'auscultations est ordonné celons leurs corrélation avec la base de données réelle.

Donc on a prend différentes auscultations pour l'entrée de RNA suivantes :

f_1-f_3 : auscultation par surface (indirect), 1 valeur d'entée ;

a_1-a_3 : auscultation par surface (indirect), 1 valeur d'entée ;

$c - d_3$: auscultation en rayonnement (mode semi-direct), 1 valeur d'entée ;

$c - g_3$: auscultation en rayonnement (mode semi-direct), 1 valeur d'entée ;

f_1-f_3 et a_1-a_3 , 2 valeurs d'entées ;

$c - d_3$ et $c - g_3$, 2 valeurs d'entées ;

f_1-f_3 et $c - d_3$, 2 valeurs d'entées ;

a_1-a_3 et $c - g_3$, 2 valeurs d'entées ;

f_1-f_3 et a_1-a_3 et $c - d_3$ et $c - g_3$, 4 valeurs d'entrées.

6. La base de données

L'information la plus importante pour un système basé sur l'apprentissage, est la base d'entraînement ou d'apprentissage. Dans cette base de données, chaque exemple (vecteur descripteur) doit avoir sa classe d'appartenance. Pour cette application, l'algorithme d'apprentissage reçoit des exemples relatifs aux différents états résistances.

Dans notre application on partager la base de données un partie de 75 vecteurs pour l'apprentissage et 25 vecteurs pour le test.

7. Réseaux de neurones artificiels (RNAs)

Les réseaux de neurones artificiels (RNAs), sont des outils de l'intelligence artificielle, capables d'effectuer des opérations de classification. Leur principal avantage par rapport aux autres outils est leur capacité d'apprentissage et de généralisation. Ils peuvent également être implémentés en circuits électroniques, offrant ainsi la possibilité d'un traitement temps réel.

Le processus d'apprentissage est donc une phase très importante pour la réussite d'une telle opération. Une des qualités de ce type de techniques, est leur adéquation pour la mise au point de systèmes de surveillance modernes, capables de s'adapter à d'éventuelles extensions et reconfigurations multiples.

8. Mise en oeuvre de l'algorithme RNA

Un réseau de neurones artificiels définit une famille de fonctions. L'apprentissage consiste à déterminer la solution du problème posé par cette famille, ces fonctions pourraient avoir des capacités limitées. Le principe de l'apprentissage est l'optimisation d'une fonction de coût qui représente le but d'apprentissage. Les méthodes numériques utilisées sont le plus souvent des méthodes approchées basées sur des techniques de gradient (parce qu'on ne sait pas résoudre analytiquement un système d'équations non linéaires).

8.1 Apprentissage

Nous avons posé précédemment le problème de l'apprentissage par réseau de neurones artificiels comme un problème d'optimisation d'une fonction de coût. L'algorithme de rétropropagation de l'erreur est parmi le plus utilisé dans le cas d'un problème de classification supervisée.

La structure générale du programme d'apprentissage de l'algorithme de rétropropagation de l'erreur suit les étapes suivantes :

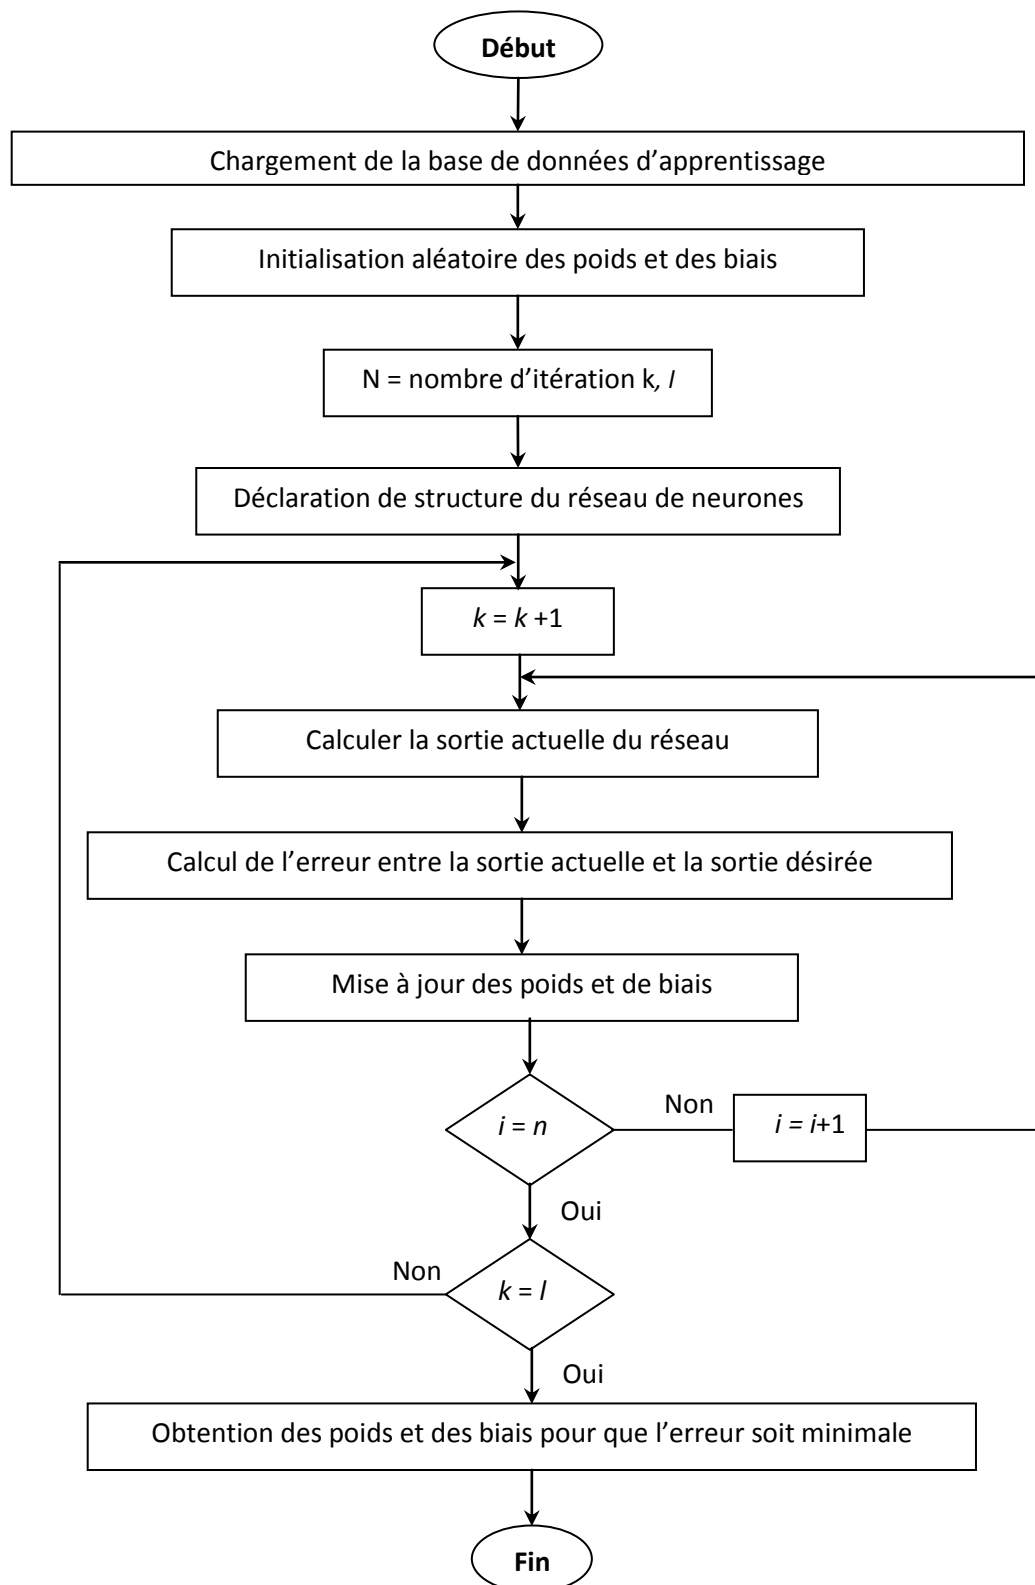


Figure IV.3: Structure générale du programme d'apprentissage par réseau de neurones.

8.2. Généralisation

La validation de l'algorithme de généralisation s'appuie sur la programmation de la première étape de l'apprentissage qui est la propagation des vecteurs de test comme une entrée au réseau adopté. En fixant la structure du réseau et leurs paramètres (poids, biais, fonction d'activation, nombre de couches cachées, le nombre de neurones correspondant), une fois son apprentissage est achevé. Et puis en testant le réseau sur des données qui n'ont pas servi à l'apprentissage.

La structure générale du programme de généralisation (test) suit les étapes suivantes :

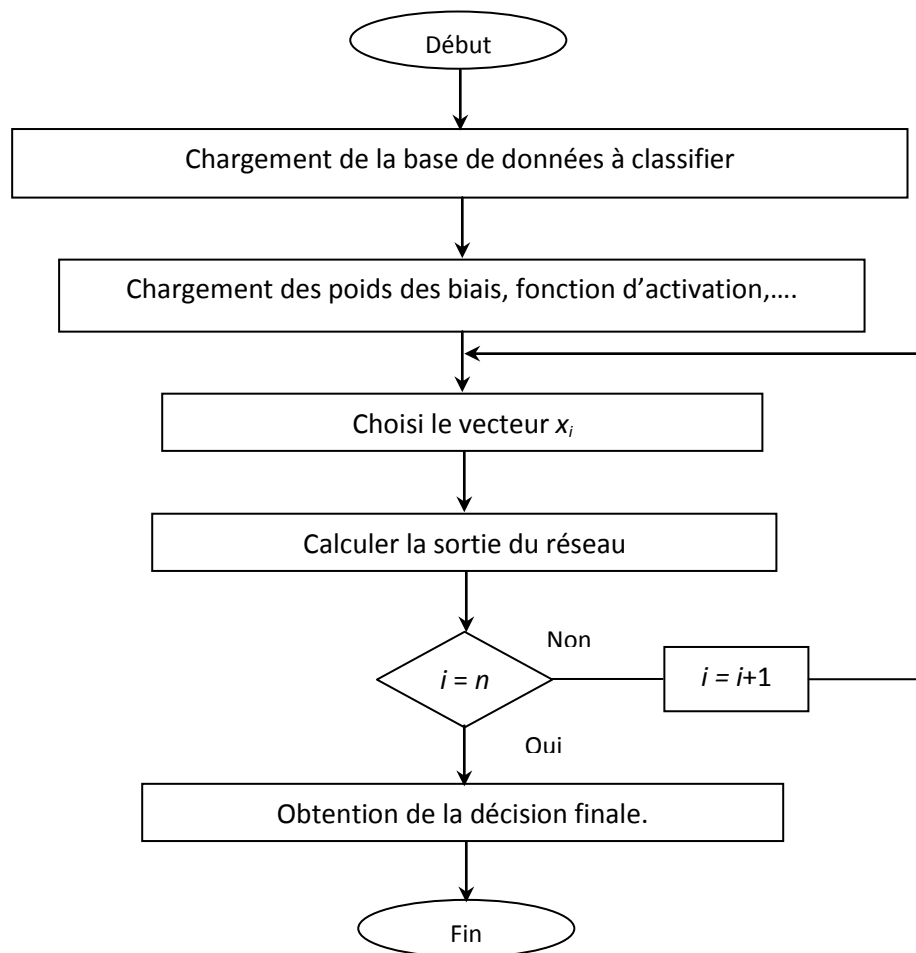


Figure IV.4: Structure générale du programme de généralisation par réseau de neurones

Dans la phase d'apprentissage par les RNAs, on découple la recherche de l'architecture de la détermination de ses paramètres ; il faut chercher les paramètres de plusieurs structures

afin de choisir celle qui garantit le meilleur pouvoir de généralisation. Ceci implique la partition de la base de données en une base d'apprentissage et une base de test.

9. Simulation

L'apprentissage est le processus d'ajustement des poids pour une classification optimale. Le nombre de neurones d'entrées est varia. Pour déterminer le nombre de couches cachées et le nombre de neurones correspondant à chacune d'entre elles, on a augmenté progressivement le nombre de couches et le nombre de neurones correspondants jusqu'à atteindre la précision voulue. Nous avons utilisés pour cette phase une seule base des données réelles de 100 vecteurs de dimension 12, constituée de données relatives aux différents états qualitatifs du temps de passage à travers les éprouvettes suivant les calculs recommandées.

L'algorithme d'apprentissage le plus couramment utilisé est celui de la rétropropagation de l'erreur. Le réseau de neurones choisi dans notre cas possède les caractéristiques suivantes:

- Couches d'entrées : 1, 2 et 4 neurones ;
- Couche de sortie : un neurone ;
- La fonction d'activation : tangente hyperbolique.

La mise en œuvre de cette méthode est réalisée sous environnement MATLAB suivant les étapes indiquées auparavant.

9.1. Résultats d'apprentissage et de généralisation

Plusieurs réseaux sont testés et validés en utilisant l'algorithme d'apprentissage le plus connus (Levenberg-Marquardt, LM). Les résultats de l'apprentissage dans la base de données réelle et leurs résultats en généralisation sont présentés.

On note la base de données par la notation (apprentissage, test) et nous utilisons (75,25) les résultats d'apprentissage et de test le suivants :

a- Le RNA d'auscultation d'une valeur d'entrée

Base de données (75,25)

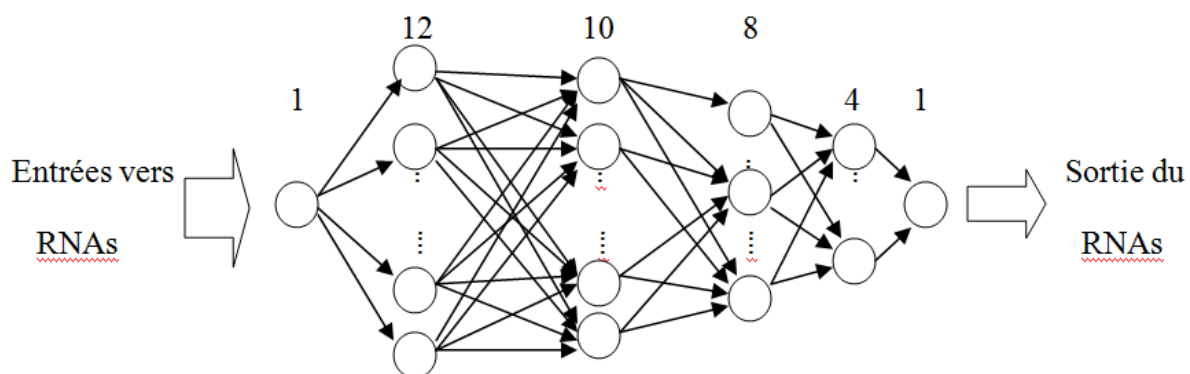


Figure IV.5: Réseaux à une entrée et trois couches cachées.

➤ Le mode f_1-f_3

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,160	0,650	0,81		0,337	0,131	0,160	0,640	0,38
RNA	0,343	0,117	0,159	0,640			0,346	0,152	0,005	0,640	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	0.0032	0.0565	0.0326		0.0158	0.1258	0.0670

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	58.67%	Taux_test	76%

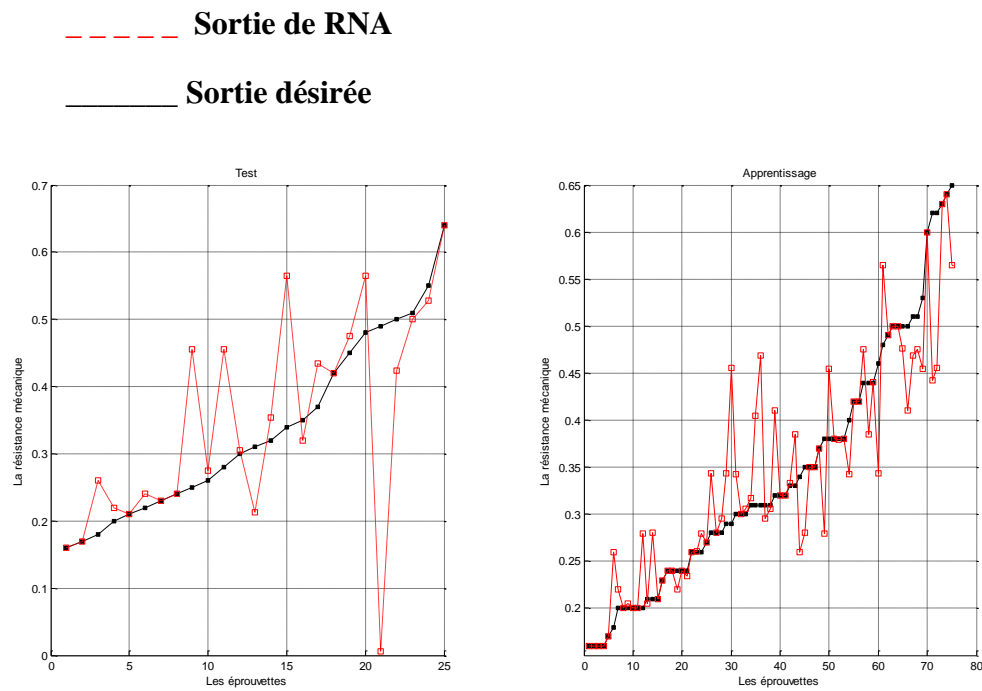


Figure IV.6 : la sortie de RNA et la sortie désirée pour la Base de données de (75,25)

➤ Le mode a_1-a_3

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,160	0,650	0,83		0,337	0,131	0,16	0,64	0,51
RNA	0,343	0,118	0,159	0,649			0,316	0,110	0,159	0,53	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	0.0028	0.0527	0.0228		0.0090	0.0949	0.0592

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	77.33%	Taux_test	72%

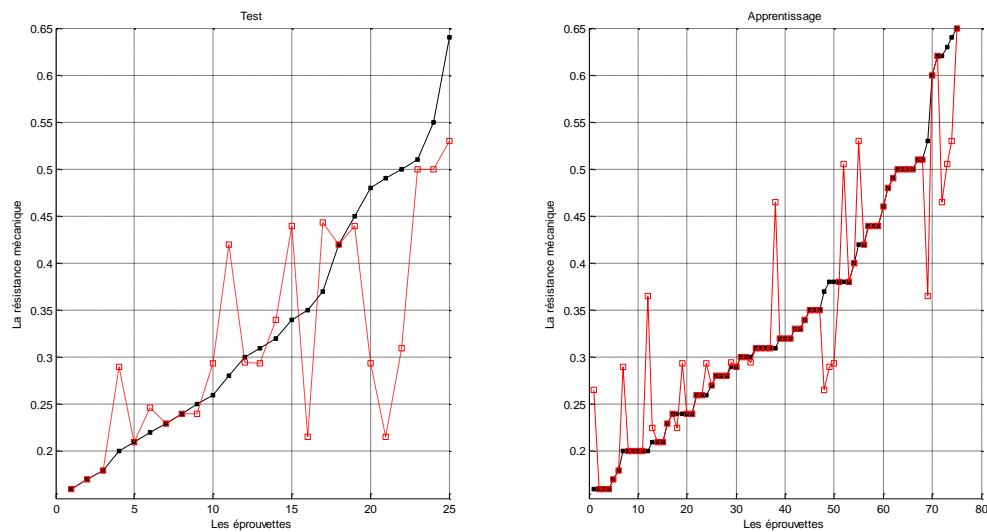


Figure IV.7 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

➤ Le mode $c - d_3$

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,160	0,650	0,726		0,337	0,131	0,160	0,640	0,78
RNA	0,343	0,110	0,159	0,649			0,322	0,138	0,159	0,672	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	0.0046	0.0680	0.0381		0.0043	0.0659	0.0450

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	64%	Taux_test	80%

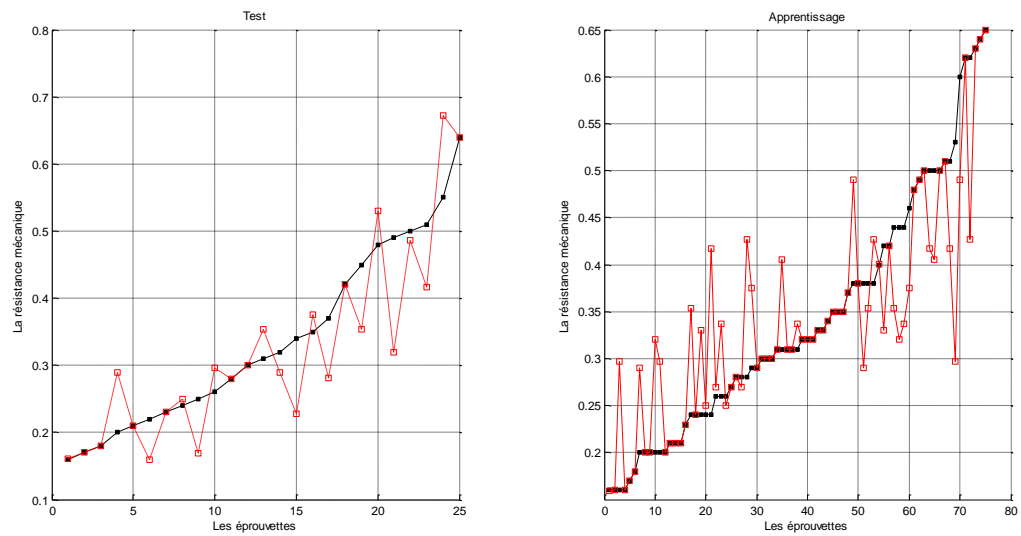


Figure IV.8 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

➤ Le mode $c - g_3$

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	0,80		0,337	0,131	0,16	0,64	0,32
RNA	0,343	0,116	0,159	0,65			0,282	0,142	0,009	0,64	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	0.0033	0.0570	0.0295		0.0191	0.1381	0.0925

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

$err_rel(k) <$	0.05	$err_rel(i) <$	0.25
Taux_appr	61.33%	Taux_test	56%

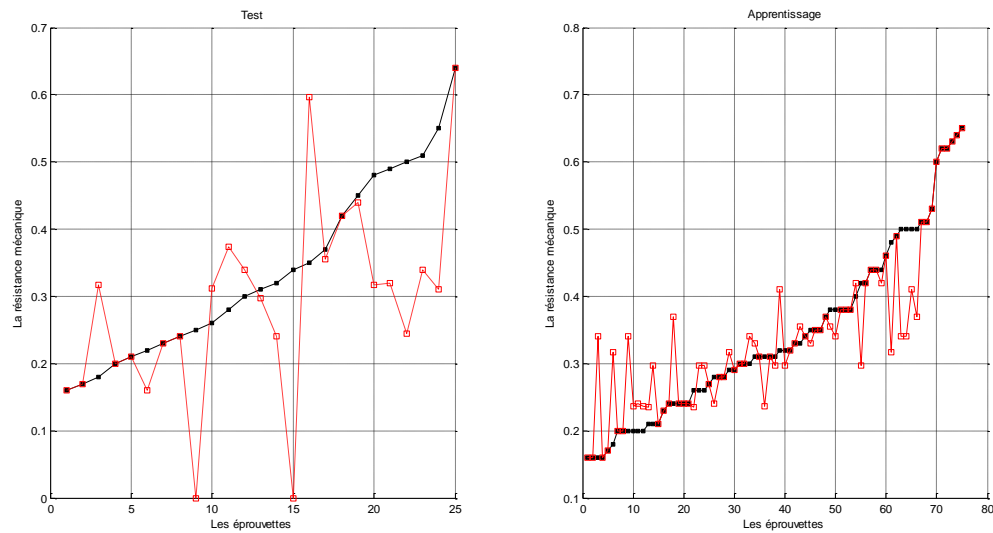


Figure IV.9 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

b- Le RNA d'auscultation de deux valeurs d'entrées

Base de données (75,25)

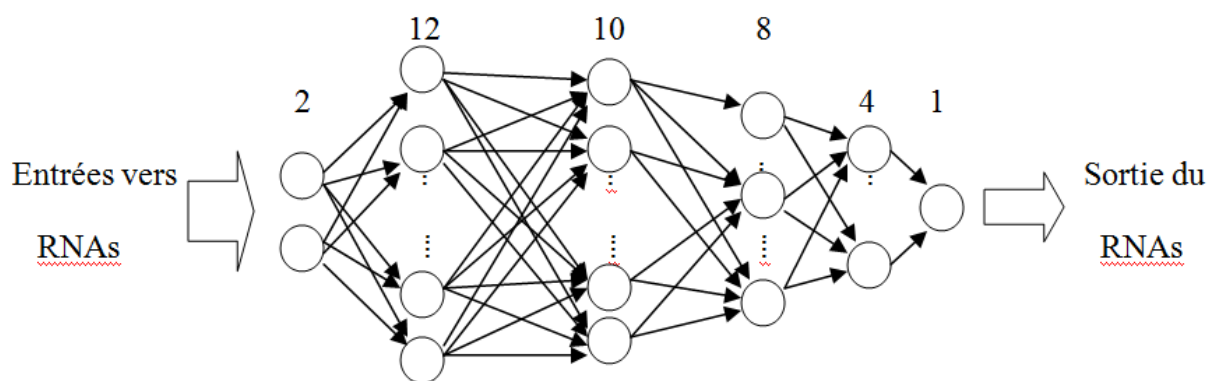


Figure IV.10: Réseaux à deux entrées et quatre couches cachées.

➤ Le mode f_1-f_3 et a_1-a_3

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	1		0,337	0,131	0,16	0,64	0,36
RNA	0,343	0,129	0,16	0,65			0,353	0,224	0,118	0,980	

Performances

Apprentissage				Généralisation		
	MSE	RMSE	EAM	MSE	RMSE	EAM
RNA	4.766e-015	6.904e-008	3.86e-008	0.0325	0.1803	0.0950

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	100%	Taux_test	72%

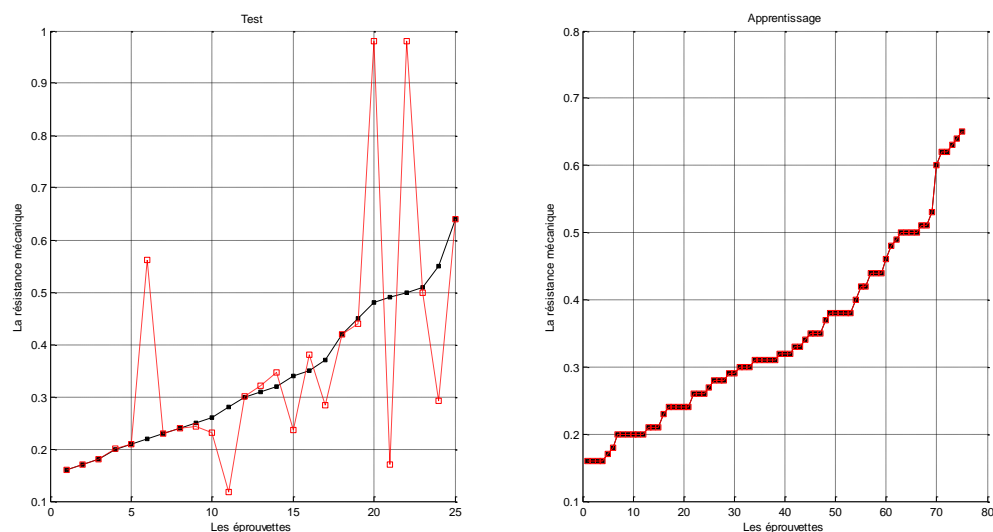


Figure IV.11 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

➤ Le mode $c - d_3$ et $c - g_3$

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	1		0,3372	0,131	0,16	0,64	0,25
RNA	0,343	0,129	0,16	0,65			0,29541579	0,228	3,84e-16	0,96	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	5,14e-23	7,17e-12	2.10e-012		0,0407	0,2018	0,1149

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	100 %	Taux_test	64 %

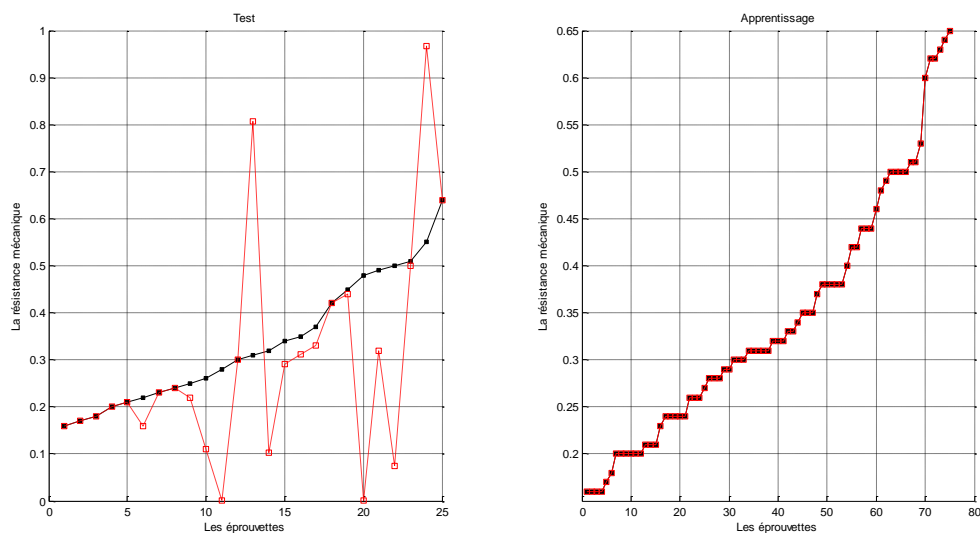


Figure IV.12 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

➤ Le mode f_1-f_3 et $c-d_3$

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	0,988		0,337	0,131	0,16	0,64	0,539
RNA	0,343	0,129	0,159	0,649			0,317	0,134	0,10	0,64	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	1.9e-004	0.0139	0.0023		0.0098	0.0988	0.0472

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	97.33 %	Taux_test	80 %

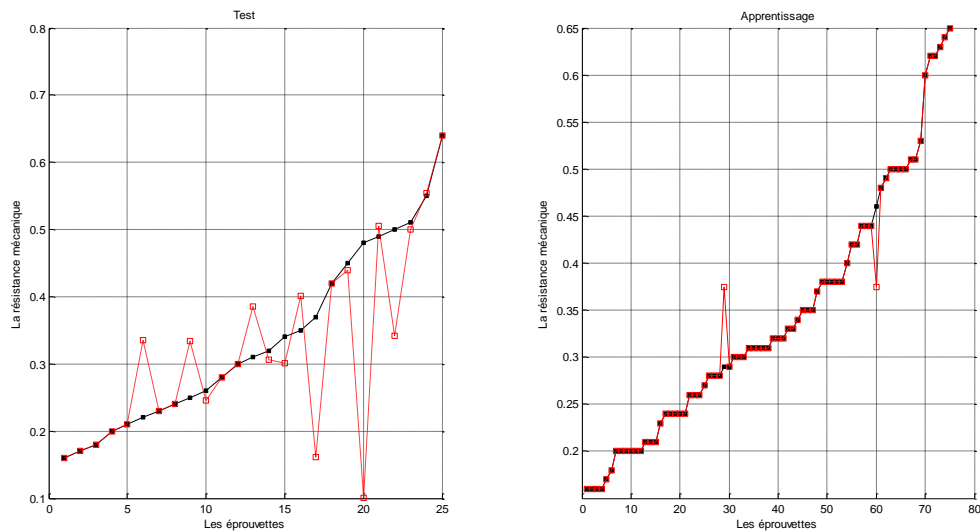


Figure IV.13 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

➤ Le mode a_1 - a_3 et c - g_3

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	1		0,337	0,131	0,16	0,64	0,30
RNA	0,343	0,129	0,16	0,65			0,377	0,213	0,001	0,997	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	1,30e-19	3,61e-10	2,01e-10		0,0336	0,1833	0,0964

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	100 %	Taux_test	72 %

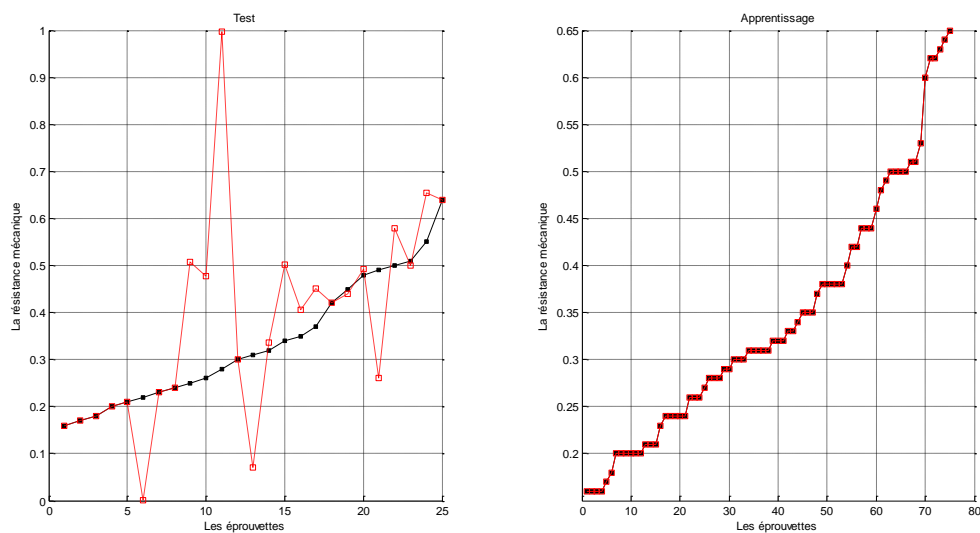


Figure IV.14 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

c- Le RNA d'auscultation de quatre valeurs d'entrées

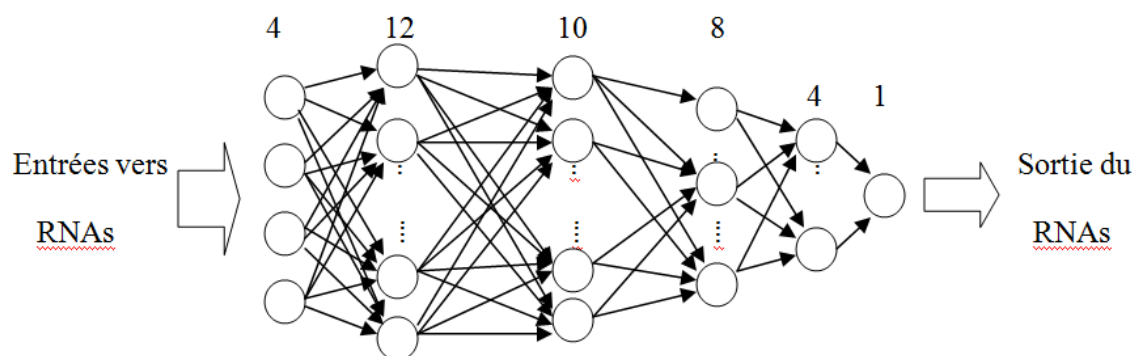


Figure IV.15: Réseaux à quatre entrées et quatre couches cachées.

➤ Le mode f_1-f_3 et a_1-a_3 et $c-d_3$ et $c-g_3$

Résultats statistiques (RNA) pour la base de données (75,25)

Apprentissage						Généralisation					
	Valeur moyenne	Standard de déviation	Min	Max	R^2		Valeur moyenne	Standard de déviation	Min	Max	R^2
Mesurer	0,343	0,129	0,16	0,65	1		0,337	0,131	0,16	0,3372	0,476
RNA	0,343	0,129	0,16	0,65			0,305	0,169	0,005	0,305	

Performances

Apprentissage				Généralisation			
	MSE	RMSE	EAM		MSE	RMSE	EAM
RNA	1.93e-021	4.40e-011	1.71e-011		0.0162	0.1274	0.0676

Evolution de l'erreur relative de généralisation (Taux de reconnaissance)

err_rel(k) <	0.05	err_rel(i) <	0.25
Taux_appr	100 %	Taux_test	76 %

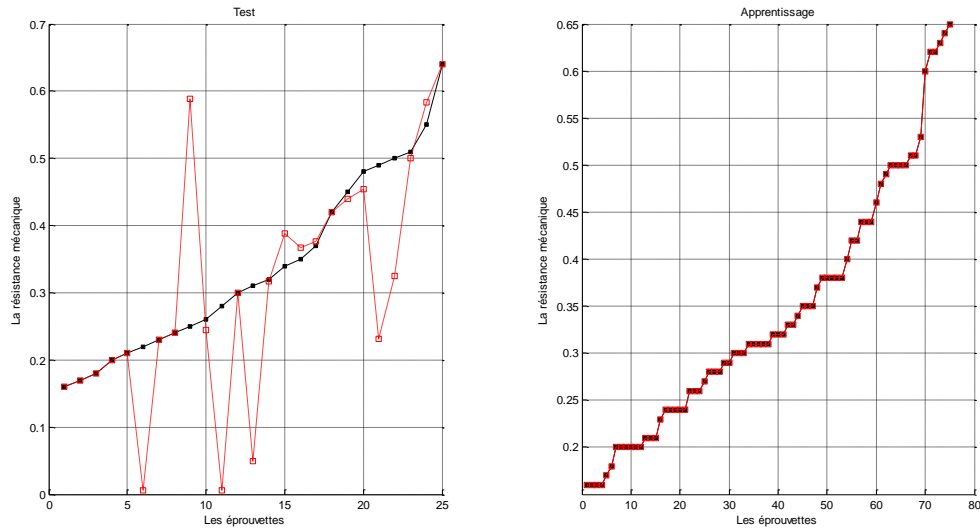


Figure IV.16 : la sortie de RNA et la sortie désirer pour la Base de données de (75,25)

L'effet d'application de l'ACP est présent à travers les résultats acquérir.

Parmi ces modes on à choisie le mode de mesure (auscultation) $c - d_3$, car le mesure est faire entre deux surface, plus corrélée avec la nouvelle base réduit .

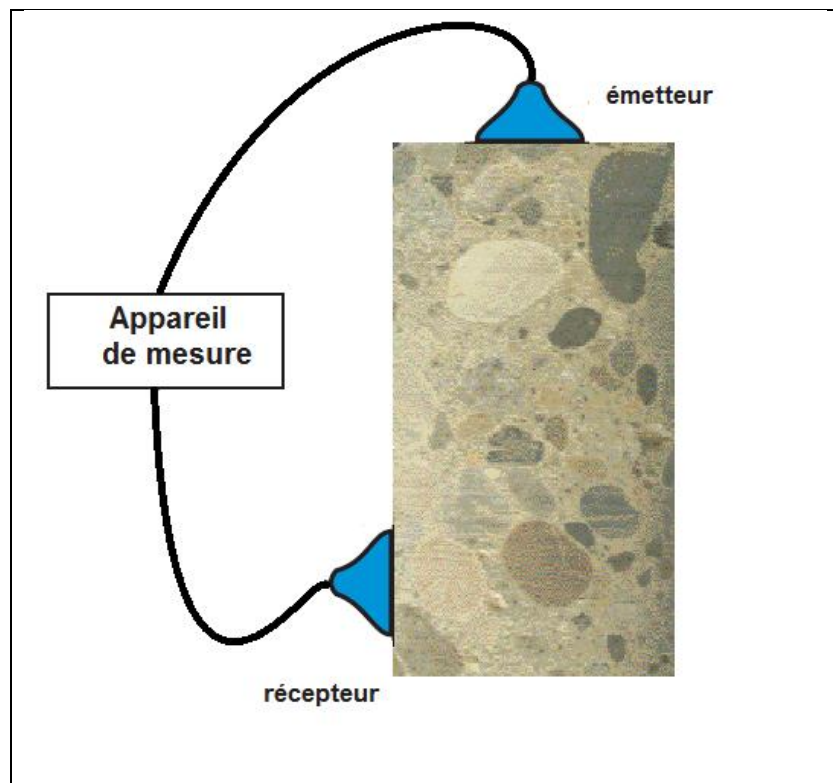


Figure IV.17 : principe du mode de mesure $c - d_3$ sur l'éprouvette

10. Conclusion

Ce dernier chapitre est apporté à une étude en simulation concernant la technique statistique ACP permettant de sélectionner les entrées et éliminer les informations redondantes, ainsi que la mise en œuvre des techniques d'apprentissage statistique PMC appliquées dans le domaine de contrôle de qualité des matériaux de construction. Cette étude a permis la validation et l'évaluation des performances de la détermination des points de mesure présentées. Les paramètres liés au taux de reconnaissance, au temps d'apprentissage, à l'erreur d'entraînement, ont été les facteurs pertinents qui nous ont permis d'évaluer les méthodes étudiées.