

استخدام تقنية التحويل المويجي والشبكات العصبية لتمييز المتكلم

رسالة مقدمة إلى

مجلس كلية العلوم - جامعة بابل

وهي جزء من متطلبات نيل درجة ماجستير علوم

في علوم الحاسبات

من قبل

علي يعقوب يوسف الخفاجي



رمضان - 1426 هـ

تشرين الأول - 2005 م

Using Wavelet Transform technique and Neural Network for Speaker Recognition

A Thesis
Submitted to the Council of Science
University of Babylon
in Partial Fulfillment of the requirements
for the Degree of Master of Science
in Computer Science

By
Ali Yaqob Yousif



October 2005

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

﴿ وَخَشَعَتِ الْأَصْوَاتُ لِلرَّحْمَنِ فَلَا تَسْمَعُ إِلَّا هَمْسًا ﴾

صدق الله العظيم

من سورة طه - آية 108

الاهداء

إلى من أنزل عليه القرآن وبعث بالقرآن وأوصى
بالقرآن عهداً علينا حتى نلقاه ...

صلى الله عليه وآله وسلم

إلى ...
من أضاء لي قناديل الحياة

أبي

إلى ...
شجرة الحب والظل الوافر ونبع الحنان

أمي

إلى ...
ينبوع الحنان الصافي

زوجتي

إلى ...
أحبتني وأعزائي

وأخواتي

أهدي جهدي المتواضع

علي

شكر وتقدير

الحمد لله رب العالمين والصلاة والسلام على سيد المرسلين محمد (صلى الله عليه وآله وسلم).

يسرني وقد انتهيت من أعداد رسالتي هذه ، أن أتقدم بفائق الشكر والتقدير إلى رئاسة جامعة بابل لدعمها المتواصل وتعاونها في تطوير الدراسات العليا في أقسام الجامعة .

كما أتقدم بالشكر الجزيل إلى عمادة كلية العلوم وأخص بذلك الدكتور عودة مزعل ياسر الزاملي لملاحظاته السديدة في دعم الدراسات العليا في كلية العلوم.

وبكل اعتزاز أتقدم بالشكر الجزيل إلى الأستاذين الفاضلين الاستاذ الدكتور نبيل هاشم كاغد والأستاذ الدكتور وليد أمين الجوهر الذين تفضلا مشكورين بالإشراف على هذه الرسالة، فقد كانا لي الأستاذ والمرشد لما قدمناه من توجيهات وآراء علمية قيمة وعلاقة إنسانية طيبة، أسأل الله تعالى أن يمن عليهم بالصحة والعمر المديد وأن يسدد خطاهما .

وأنتقدم بالشكر إلى الست إيمان صالح والست هدى ناجي والأخ صلاح مهدي، لما قدموه لي من نصح وإرشاد.

كما أتقدم بشكري الجزيل وامتناني إلى كل من ساعدني ومد لي يد العون في سبيل إنجاح البحث المقدم .

والله ولي التوفيق

الباحث

الخلاصة :

يهدف البحث إلى بناء نظام لتمييز المتكلم لكلمات عربية من خلال تطبيق التحويل المويجي المتقطع (DWT) Discrete Wavelet Transform والشبكات العصبية Neural Network (NN) .

تم الاستفادة من خصائص التحويل المويجي المتمثلة بقدرته على التعامل مع الإشارات غير الثابتة وقدرته على تقريب الإشارة Approximation لاستخلاص الصفات من الملف الصوتي للمتكلم وتوليد متجه الصفات الذي يستعمل بعد ذلك في الشبكة العصبية . يتم استخدام متجهات الصفات باعتبارها نماذج الإدخال إلى الشبكة العصبية التي سيتم تدريب الشبكة العصبية عليها .

تم اختيار خوارزمية انسياب الخطأ خلفا Error back propagation algorithm لغرض التصنيف Classification .

وفي البحث المقترح استعملت عينة من 29 متكلماً (15 ذكور و14 إناث) كل متكلم ينطق الكلمات الآتية : (ياسين ، يمين ، وفي ، صباح ، مساء ، الخير ، لندن) لاحتواء هذه الكلمات على حروف مهمة والتي يمكن استعمالها في عملية تمييز متكلم عن آخر.

تم إجراء عدد من التجارب ومنها تجربة استخدمت فيها تقنية ترميز التنبؤ الخطي Linear predictive coding (LPC) في عملية التحليل واستخلاص الصفات ، كان الغرض من هذه التجربة هو المقارنة مع التحويل المويجي في عملية استخلاص الصفات، وقد اثبت التحويل المويجي كفاءته في التعامل مع الإشارات الكلامية.

أوضحت نتائج تدريب الشبكة قدرتها على التعامل مع هذه النماذج الكلامية وتحسين قابلية التعميم للشبكة إذ استطاعت الشبكة التعرف على جميع أنماط الاختبار في تمييز المتكلم للكلمات التي تم تدريبها مسبقاً، أي إن نسبة التمييز كانت 100%، وأما الكلمات التي لم يتم تدريب الشبكة عليها مسبقاً فقد كانت نسبة التمييز بين 90-93 % .

تم تنفيذ الطريقة المقترحة على حاسب ذي معالج بنتيوم 4 وبسرعة معالج 1.4

،GHz وتم استخدام نظام MatLab 6.5 .

توصية الأساتذة المشرفين

نشهد إن إعداد هذه الرسالة تمت تحت إشرافنا في قسم علوم الحاسبات / كلية العلوم / جامعة بابل كجزء من متطلبات نيل درجة الماجستير في علوم الحاسبات .

التوقيع :	التوقيع :
اسم المشرف : وليد أمين الجوهر	اسم المشرف : د. نبيل هاشم كاغد
المرتبة العلمية : أستاذ	المرتبة العلمية : أستاذ
العنوان : كلية الهندسة / جامعة بغداد	العنوان : كلية العلوم / جامعة بابل
التاريخ : / /	التاريخ : / /

توصية رئيس القسم

إشارة إلى التوصية أعلاه المقدمة من قبل الأساتذة المشرفين أحيل هذه الرسالة إلى لجنة المناقشة لدراستها وبيان الرأي فيها .

التوقيع :
اسم رئيس القسم : د. نبيل هاشم كاغد
المرتبة العلمية : أستاذ
العنوان : كلية العلوم / جامعة بابل
التاريخ : / /

قرار لجنة المناقشة

نحن أعضاء لجنة المناقشة الموقعين أدناه، نشهد أننا قد اطلعنا على الرسالة الموسومة
(استخدام تقنية التحويل المويجي والشبكات العصبية لتميز المتكلم). وقد ناقشنا
الطالب (**علي يعقوب يوسف**) في محتوياتها وفيما له علاقة بها وذلك بتاريخ 2005/10/27
. ونعتقد انها جديرة بالقبول بدرجة (**جيد جداً**) لنيل درجة الماجستير في علوم الحاسبات .

التوقيع :

رئيس اللجنة : د. ستار بدر سدخان

المرتبة العلمية : أستاذ

العنوان : جامعة النهريين

التاريخ : / /

التوقيع :

عضو اللجنة : د. سمير جاسم محمد

المرتبة العلمية : مدرس

العنوان : المعهد التقني / بابل

التاريخ : / /

التوقيع :

عضو اللجنة : د. توفيق عبد الخالق

المرتبة العلمية : أستاذ مساعد

العنوان : جامعة بابل / كلية العلوم

التاريخ : / /

التوقيع :

عضو اللجنة (المشرف) : د. وليد أمين الجوهر

المرتبة العلمية : أستاذ

العنوان : جامعة بغداد / كلية الهندسة

التاريخ : / /

التوقيع :

عضو اللجنة (المشرف) : د. نبيل هاشم كاغد

المرتبة العلمية : أستاذ

العنوان : جامعة بابل / كلية العلوم

التاريخ : / /

مصادقة عمادة كلية العلوم

أصادق على ما جاء في قرار اللجنة أعلاه

التوقيع :

عميد الكلية : د. عودة مزعل ياسر

المرتبة العلمية : أستاذ

العنوان : جامعة بابل – كلية العلوم

التاريخ : / /

المحتويات

رقم الصفحة	الموضوع
أ	المحتويات
ب	قائمة المختصرات
ج	قائمة المصطلحات
هـ	قائمة الأشكال
الفصل الأول – تمييز المتكلم	
1	1.1 المقدمة
3	4.1 معالجة الإشارة
3	5.1 تمييز المتكلم
16	11.1 البحوث السابقة
الفصل الثاني – التحويل المويجي والشبكات العصبية	
21	1.2 التحويل المويجي
23	3.1.2 عائلات الموجة
27	5.1.2 محول الموجة المتقطع
32	2.2 الشبكات العصبية
47	2.5.2.2 شبكة انسياب الخطأ خلفا
الفصل الثالث – النظام المقترح	
54	1.3 المقدمة
56	1.2.3 المعالجة الابتدائية
60	2.2.3 استخلاص الصفات
71	4.3 التصنيف باستخدام الشبكة العصبية
الفصل الرابع – النتائج والأعمال المستقبلية	
77	1.4 النتائج العملية
98	2.4 التجربة الأولى
100	3.4 التجربة الثانية
102	4.4 الاستنتاجات
104	5.4 الأعمال المستقبلية
105	المصادر

قائمة المختصرات

المصطلح باللغة الإنكليزية	المختصر باللغة الإنكليزية
Artificial Intelligence	AI
Artificial Neural Networks	ANN
Automatic Speaker Recognition	ASR

Discrete Wavelet Transform	DWT
Dynamic Programming	DP
Dynamic Time Warping	DTW
Error Back Propagation	EBP
Fourier Transform	FT
High Pass Filter	HPF
Least Mean Squared Error	LMSE
Linear Predictive Coding	LPC
Low Pass Filter	LPF
Mean Squared Error	MSE
Multi-Resolution Analysis	MRA
Neural Networks	NN
Short Time Fourier Transform	STFT
Speaker Identification	SI
Speaker Recognition	SR
Speaker Verification	SV
Turbo Wavelet Packet Transform	TWPT
Vector Quantization	VQ

قائمة المصطلحات

المصطلح باللغة الإنكليزية	المصطلح باللغة العربية
Activation Function	دالة تنشيط
Approximation Coefficients	معاملات التقريب
Artificial Neural Networks	الشبكات العصبية الاصطناعية
Biorthogonal	ثنائية التعامد
Convolution	تلفيف
Degradation of Signal	تشويه الإشارة
Denoising	إزالة الضوضاء
Details Coefficients	معاملات التقريب
Discrete Wavelet Analysis	التحويل المويجي المتقطع

Down Sampling	عملية تنقيص الإشارة (أخذ المواقع الزوجية)
Error Back Propagation Network	شبكة انسياب الخطأ خلفا
Features Extraction	استخلاص الصفات
Intelligence systems	الأنظمة الذكية
Layered Networks	الشبكات الطباقية
Mother wavelet	الموجة الأم
Multi Resolution Analysis	التحليل متعدد المستويات
Non Stationary Signals	الإشارات غير الثابتة
Orthonormal	التنسيب المتعامد
Patterns Recognition	تمييز الأنماط
Redundant Information	المعلومات الفائضة
Scaling Function	دالة التقييس
Short time Fourier Transform	تحويل فوريير ذي الوقت القصير
Sigmoidal Activation Function	دالة التنشيط السيجماوية
Speaker Identification	تعريف المتكلم
Speaker Verification	إثبات المتكلم
Standard Deviation	الانحراف المعياري
Supervised Learning	تعلم مشرف عليه
Time Frequency Signal Analysis	تحليل الإشارة في مجال التردد – الزمن
Up sampling	عملية الاستكمال (إضافة أصفار إلى الإشارة)
Unsupervised Learning	تعلم غير مشرف عليه
Variance	التباين
Wavelet Frames	إطارات الموجة
Wavelet Function	دالة الموجة
Wavelet Transform	تحويل الموجة

قائمة الأشكال

رقم الصفحة	رقم الشكل
	الفصل الأول
4	شكل (1.1) : مخطط كتلي لنظام تمييز المتكلم
5	شكل (2.1) : الهيكل الأساس لتعريف المتكلم
6	شكل (3.1) : الهيكل الأساس لإثبات المتكلم
11	شكل (4.1) : مستوى التردد – الزمن لتحويل فورير
13	شكل (5.1) : مستوى التردد – الزمن لتحويل المويجة
	الفصل الثاني
23	شكل (1.2) : موجة Haar
23	شكل (2.2) : عوائل دوبشيز Daubechies Families
24	شكل (3.2) : موجة Biorthogonal
25	شكل (4.2) : موجة Coiflets
25	شكل (5.2) : موجة Symlets
26	شكل (6.2) : موجة Morlet
28	شكل (7.2) : التحليل لمستويين
28	شكل (8.2) : التركيب لمستويين
30	شكل (9.2) : أمثلة لمجموعة المتجهات للفضاء R^2
31	شكل (10.2) : دالة التقييس الأساسية لمويجة db_2
39	شكل (11.2) : الدالة أحادية القطب
39	شكل (12.2) : الدالة الثنائية القطب
40	شكل (13.2) : الدالة السيجماوية أحادية القطب
41	شكل (14.2) : الدالة السيجماوية ثنائية القطب
42	شكل (15.2) : دالة النبضة
43	شكل (16.2) : دالة كاوس
47	شكل (17.2) : شبكة المدرك
49	شكل (18.2) : شبكة انسياب الخطأ خلفاً
52	شكل (19.2) : انسياب المعلومات في شبكة انسياب الخطأ خلفاً
	الفصل الثالث
55	شكل (1.3) : مخطط لمعالجة الإشارة الكلامية وتصنيفها.
57	شكل (2.3) : عملية التراكب في الإطارات
58	شكل (3.3) : نافذة هامنك لمجال الوقت
58	شكل (4.3) : نافذة هامنك لمجال التردد
59	شكل (5.3) : الشكل الموجي لإطار من إشارة صوتية (كلمة الخير)

59	شكل (6.3) : الشكل الموجي للإطار بعد تطبيق نافذة هامنك عليه
60	شكل (7.3) : شجرة تحليل الموجة لثلاث مستويات
62	شكل (8.3) : تحليل الإشارة بمحول الموجة المتقطع
64	شكل (9.3) : تطبيق التحويل الموجي لكل إطار من الإشارة الصوتية
67	شكل (10.3) : تطبيق معادلة الطاقة على معاملات التقريب ومعاملات التفاصيل
68	شكل (11.3) : تطبيق معادلة الطاقة على إطار واحد من الإشارة الكلامية
70	شكل (12.3) : تطبيق معادلة التباين variance لاستخراج متجه الصفات
72	شكل (13.3) : مصنف الشبكة العصبية
75	شكل (14.3) : مخطط لتدريب الشبكة العصبية
الفصل الرابع	
85	شكل (1.4) : عملية تدريب الشبكة العصبية
96	شكل (2.4) : تدريب الشبكة العصبية على النماذج الناتجة من التحليل باستخدام تقنية الترميز التنبؤي الخطي.
98	شكل (3.4) : تدريب الشبكة العصبية على نماذج الإدخال

تمييز المتكلم

1.1 المقدمة Introduction :

نظرا للتطور الكبير الذي شهدته الأساليب الرياضية والحاسبات وأنظمة الاتصالات الحديثة والشبكات الأمر الذي شجع على البحث في مجال معالجة الكلام والاتصالات. فأصبحت تستولي على مساحة واسعة من العمل لبناء نماذج آلية للكلام تنافس قابليات الاتصال اللفظي للإنسان .

يعد حقل معالجة إشارة الكلام Speech signal processing من الحقول المهمة في معالجة الإشارة لأنه يتعامل مع إشارة الكلام التي تمثل أداة الاتصال الطبيعية [49] . وقد برزت تطبيقات عدة وأساسية في حقل معالجة الكلام منها : تحليل الكلام (speech analysis)، وترميز الكلام (speech coding)، وتحسين الكلام (Speech enhancement)، وفهم الكلام (speech understanding)، وتمييز الكلام (Speech recognition)، وتركيب الكلام (Speech synthesis)، وتمييز المتكلم آلياً (Automatic Speaker Recognition) (ASR) الذي يعد من التطبيقات المهمة في حقل معالجة إشارة الكلام .

إن ما يميز تطبيق تمييز المتكلم عن بقية التطبيقات هو انه في معظم تطبيقات الذكاء الاصطناعي (Artificial Intelligence) (AI) نجد من الصعوبة أن تؤدي الآلة أداء الإنسان بالضبط لكن هذا الأمر لا ينطبق على أنظمة تمييز المتكلم إذ أثبتت التجارب بان تمييز المتكلم آليا يمكن أن يماثل أداء الإنسان ويفوقه في بعض الأحيان [14] .

يختلف صوت الإنسان من شخص لآخر لذلك يمكن اعتبار البصمة الصوتية من المميزات التي يعتمد عليها في الكثير من المجالات، كالمجالات الأمنية والتسهيلات المصرفية.

2.1 هدف البحث :

إن الهدف الأساس من البحث المقدم هو بناء نظام لتمييز المتكلم لكلمات عربية، حيث يتم تحديد هوية المتكلم من خلال صوته. ومن اجل تحقيق هذا الهدف تم استخدام تقنية التحويل المويجي Wavelet Transform في عملية التحليل لاستخلاص صفات الإشارة الكلامية، أما في مرحلة التمييز فقد استخدمت تقنية الشبكات العصبية Neural Networks، تم اختيار مجموعة معينة من الكلمات في البحث المقدم، أما عدد المتكلمين فهو 29 متكلماً، إذ إن كل متكلم ينطق الكلمات المختارة نفسها.

3.1 هيكل الرسالة :

يتكون الهيكل العام للرسالة من أربعة فصول، إذ يتضمن الفصل الأول مقدمة عامة توضح الجوانب النظرية للتمييز الآلي للكلام ومراحل عملية تمييز المتكلم، ويحتوي أيضا على نبذة مختصرة عن البحوث السابقة، في حين تناول الفصل الثاني تحويل الموجة وعائلاتها والشبكات العصبية وأنواعها وأما الفصل الثالث فقد قدم وصفا للطريقة المقترحة، وفي الفصل الرابع تم طرح النتائج التي تم التوصل إليها والأعمال المستقبلية .

4.1 معالجة الإشارة [6] :

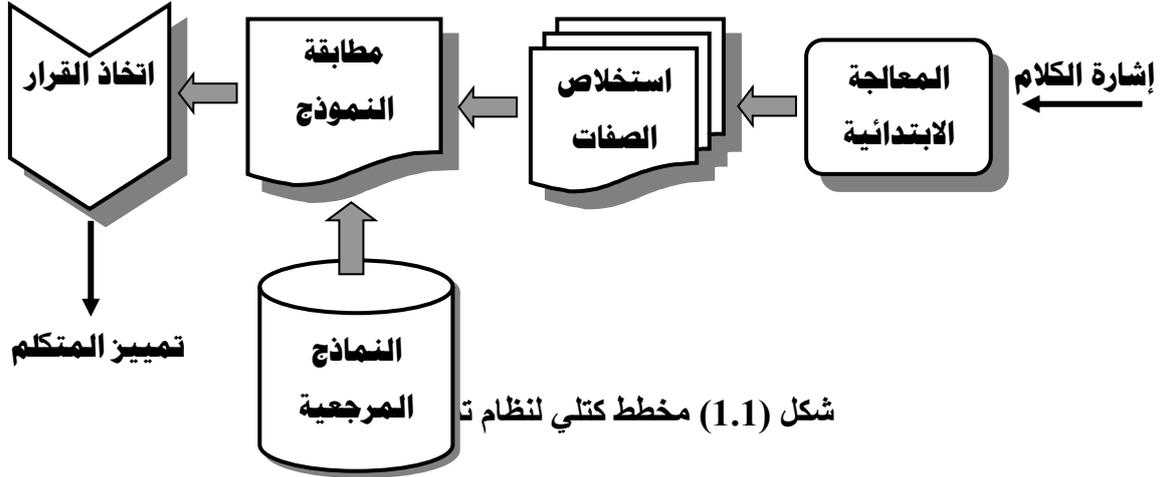
تؤدي الإشارات دورا مهما في حياتنا اليومية ، ومثال هذه الإشارات التي تواجهنا بشكل متكرر هي الكلام، الموسيقى، الصور. والإشارة هي دالة لمتغيرات مستقلة مثل الزمن، المسافة، الموقع، الحرارة، الضغط .
إن طرق معالجة الإشارة تعتمد على نوع الإشارة، وعلى طبيعة المعلومات التي تحملها .
كذلك إن معالجة الإشارة تهتم بالتمثيل الرياضي للإشارة وبالعمليات المطبقة عليها لاستخلاص المعلومات الموجودة . إن عملية استخلاص المعلومات ربما تحدث في مجال الوقت $time$ domain أو في مجال التردد $Frequency$ domain. فالإشارات ذات البعد الواحد هي دالة لمتغير مستقل . والإشارات ذات البعدين هي دالة لمتغيرين مستقلين.

5.1 تمييز المتكلم (SR) Speaker Recognition :

يمكن تعريف التمييز الآلي للمتكلم بأنه عملية تحديد هوية المتكلم باستخدام معلومات معينة موجودة في إشارة الكلام [4] . يطلق في بعض الأحيان على أنظمة تمييز المتكلم باسم البصمة الصوتية (Voice Signature) لذا تستخدم هذه التسمية في الكثير من الأبحاث لتحديد هوية المتكلم [47].

لبناء نظام لتمييز المتكلم يجب أن يحتوي على مرحلتين أساسيتين، الأولى تتمثل بمرحلة استخلاص الصفات التي هي عبارة عن مجموعة من القيم تؤخذ من الإشارة الصوتية، والثانية

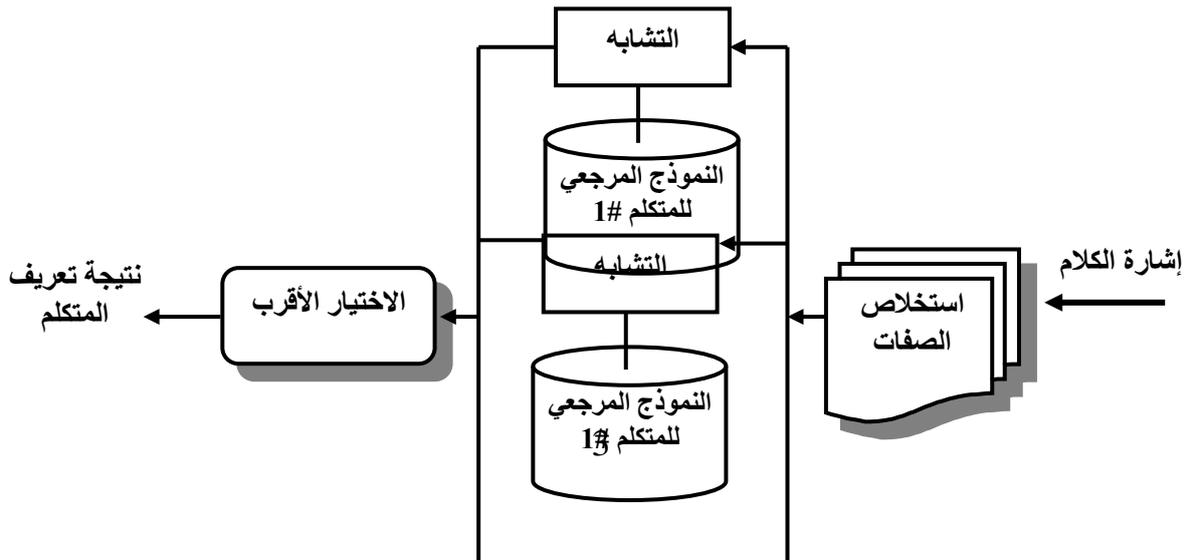
مرحلة المطابقة مع النماذج المرجعية الموجودة في ذاكرة النظام ليتم اتخاذ قرار التمييز وكما موضح في الشكل (1.1) :

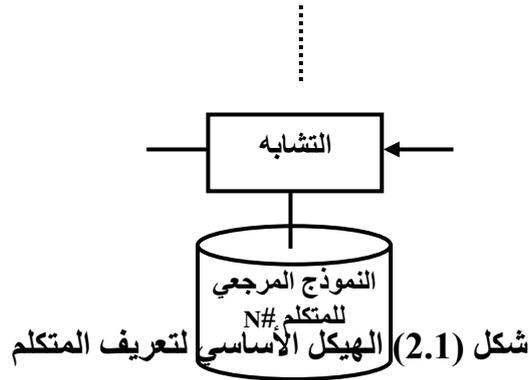


يمكن تصنيف عملية تمييز المتكلم إلى حقلين هما :

أ- تعريف المتكلم (SI) Speaker Identification :

إذ يتم إيجاد المتكلم الأكثر تشابهاً من بين N من المتكلمين إلى النموذج المدخل غير المعروف . ومعنى ذلك أن النموذج المدخل سوف يقارن مع النماذج المرجعية المخزونة ويتم بعد ذلك اتخاذ القرار النهائي لتحديد المتكلم وكما موضح في الشكل (2.1) :

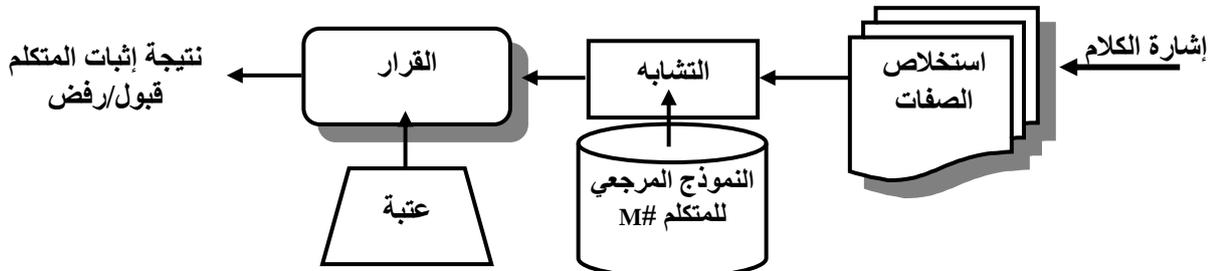




ب- إثبات المتكلم (SV) Speaker Verification :

ويتم فيه فحص الهوية المدعاة من قبل المتكلم ويحدد رفضها أو قبولها أي نحتاج هنا إلى مقارنة واحدة فقط للنموذج بغض النظر عن حجم قائمة المتكلمين .

نلاحظ في عملية إثبات المتكلم احتمالين فقط أما الرفض أو القبول بغض النظر عن حجم قائمة المتكلمين، في حين عملية تعريف المتكلم فإن عدد بدائل القرار يكون مساوياً لحجم قائمة المتكلمين في النظام . وبذلك فإن أداء عملية تعريف المتكلم ثابت غير معتمد على حجم قائمة المتكلمين . وكما موضح في الشكل (3.1) :



شكل (3.1) الهيكل الأساسي لإثبات المتكلم (Speaker Verification)

يوجد نوعان من الخطأ في عمليتي تعريف وإثبات المتكلم هما :

أولاً : الرفض الخاطئ False Refuse :

يحدث هذا النوع من الخطأ عندما يرفض النظام المتكلم الصحيح (الحقيقي) في عملية إثبات المتكلم أو في حصول عدم مطابقة mismatch في عملية تعريف المتكلم .

ثانياً : القبول الخاطئ False Accept :

ويحدث عندما يقبل النظام المتكلم الخاطئ (impostor) خلال عملية إثبات المتكلم (speaker identification) أو عند مطابقة النظام الشخص الخاطئ (تعريفه) في عملية تعريف المتكلم .

6.1 طرائق تمييز المتكلم Speaker Recognition Methods :

يمكن إن نقسم طرائق تمييز المتكلم إلى ثلاثة أنواع وهي :

أ. طريقة تمييز المتكلم المعتمد على النص Text dependent speaker recognition :

في هذه الطريقة يطلب النظام من المتكلم أن يزوده بالجمل أو النصوص نفسها في كل من مرحلتَي التدريب والتمييز . تعتمد هذه الطريقة على تقنية مطابقة الجداول المرجعية Template matching technique التي يتم فيها حساب التشابه بين الكلام الداخل والنصوص المرجعية المسجلة للمتكلمين . وبالرغم من أن هذه الطريقة تتعامل بصورة مباشرة مع صوت المتكلم فأنها تحقق بصورة عامة أداءً عالياً في التمييز.

ب. طريقة تمييز المتكلم غير المعتمد على النص :

Text independent speaker recognition

في هذه الطريقة لا يعتمد التمييز على نصوص خاصة لأن المتكلمين غير مقيدين بنطق نصوص معينة خلال مرحلة التمييز [4] .

ج. طريقة تمييز المتكلم المتقدم بالنص Text prompted speaker recognition .

في هذه الطريقة التي وضعت مؤخراً فإن النظام يسمح لكل متكلم أن يسجل نصاً جديداً في كل مرة ويقرر قبول النص الداخل فقط عندما يكرر المتكلم الذي يريد التسجيل نطق جملة متفق عليها مسبقاً وبذلك يكون قاموس المفردات غير محدود وبما ان غير المخولين لا يعرفون الجملة الجديدة المطلوبة فان النظام يعطي أمنية عالية فضلاً عن الدقة في تمييز المتكلم لكنه في الوقت نفسه قد يرفض الشخص الذي ينطق نصاً غير مسموح به حتى لو كان هذا المتكلم مخولاً وبذلك يكون النظام عرضة للرفض الخاطئ False Refuse [47] .

7.1 صعوبات التمييز الآلي للكلام :

يساعد التمييز الآلي للكلام وبشكل كبير في تطوير الاتصالات بين الحاسبات والبشر، لكن بعض الخصائص الصوتية للإنسان تحول دون الوصول إلى ذلك الهدف مما يجعل عملية التمييز الآلي للكلام عملية ليست سهلة ويمكن إدراج هذه الصعوبات بما يلي [49] :

1. المعلومات الفائضة redundant information في الإشارة الصوتية التي تكون غير ضرورية في التمييز بين الوحدات الكلامية مثل الكلمات أو الفونيمات.
 2. تشوه الإشارة الصوتية Degradation of signal في حالة وجود الضوضاء.
 3. الاختلافات الكبيرة في طرائق تلفظ الكلمات وفقاً للمعنى العام في الجملة .
 4. التأثيرات الصوتية الحاصلة على التركيب الصوتي للفونيمات أثناء تجاورها مع بعضها في عملية الكلام .
- تحتاج ميكانيكية تمييز الكلام عموماً مجموعة من الخطوات ، إذ أن هذه الخطوات تمثل خوارزمية عامة للتمييز الآلي للكلام . بغض النظر عن نوع الطرائق المستخدمة في التحليل أو التمييز [49] .

8.1 خوارزمية التمييز الآلي للكلام :

- الخطوة (1) :** تسجيل إشارة الكلام وتحويلها من الصورة التناظرية Analogue إلى الصورة الرقمية digital .
- الخطوة (2) :** تقسيم الإشارة الصوتية إلى عدد من المقاطع frames ذات الحجم الثابت .
- الخطوة (3) :** تحليل الإشارة الصوتية واستخلاص الخصائص .
- الخطوة (4) :** تدريب النظام على معاملات التحليل لتوليد النماذج المرجعية Reference pattern .
- الخطوة (5) :** مقارنة نموذج الاختبار Test Pattern مع النماذج المرجعية وإعطاء قرار التمييز .

عند بناء أي نظام لتمييز المتكلم يجب أن يمر هذا النظام بمرحلتين رئيسيتين وهما مرحلة استخلاص الصفات من الملف الصوتي ومرحلة التمييز.

9.1 مرحلة استخلاص الصفات Features Extraction Stage :

تُعد عملية استخلاص الصفات من الإشارة من المراحل المهمة التي تمر بها عملية تمييز المتكلم لأنها تمثل الإشارة الصوتية المدخلة التي سيتم مقارنتها ومن ثم تمييزها ، فهي تحتوي على أهم معلومات إشارة الكلام أي إنها ناتجة من تخلص الإشارة من كل المعلومات الفائضة فيها لكي تسهل تمييز الإشارات الصوتية ، فقد نحصل من عملية استخلاص الصفات على مجموعة

من المعاملات تمثل الإشارة المراد تحليلها بحيث تحافظ هذه القيم على الشكل الأساسي للإشارة مع التخلص من البيانات الفائضة وغير الضرورية التي تؤثر سلباً في تحليل الإشارة .

استخدمت تقنيات عدّة لعملية استخلاص الصفات من الإشارة الكلامية ومن أهم التقنيات المستخدمة لهذا الغرض هي تقنية ترميز التنبؤ الخطي Linear Prediction Coding (LPC) ، وتعد هذه الطريقة من الطرائق المميزة التي تتكون من n من الإطارات Frames تمثل عينات الكلام التي تم معالجتها بالحصول على متجه الخواص الذي يستخدم على معاملات LPC .

إن المشكلة الأساسية لتحليل التنبؤ الخطي هي تحديد مجموعة معاملات التنبؤ الخطي مباشرة من إشارة الكلام التي تطابق الاحتمالات الطيفية للإشارة التنبؤية لموجة الكلام مع نافذة التحليل [50] .

توجد هناك صيغ عدّة مستخدمة لتقنية التنبؤ الخطي معتمدة على نوع التطبيق ونجاحه في عملية تمييز موجة الكلام ، ومن هذه الصيغ ما يأتي [3] :

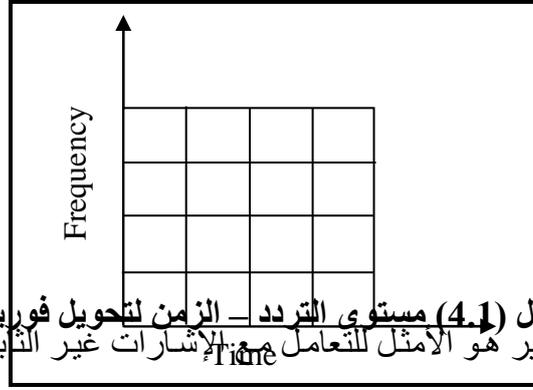
1. طريقة الارتباط الذاتي Auto-correlation method .
2. طريقة التباين المشترك covariance method .
3. الطريقة الشبكية Lattice method .
4. صيغة المرشح المعكوس Inverse filter Formulation .
5. صيغة التخمين الطيفي Spectral estimation Formulation .
6. صيغة الاحتمال الأعظم Maximum likelihood Formulation .
7. صيغة الضرب الداخلي Inner Production Formulation .

تستخدم الطريقة الأولى والثانية بصورة موسعة في الكثير من المجالات وذلك لقابلية هذه الطريقة إلى الارتباط بين مختلف العينات للإشارة الواحدة ويمكن عن طريق الارتباط الذاتي بين العينات حساب مجموعة معاملات التنبؤ الخطي التي تعطي معلومات حول طول المسار وأبعاد المسار الصوتي Vocal tract ، وأما طريقة التباين المشترك فتتجنب عملية القطع للإشارة الكلامية وتحدد عملية الحصول على المجموع في فترة ثانية ومن خلالها يحتسب متوسط مربع الخطأ (MSE) Mean Squared Error . وتستخدم الطريقة الشبكية في تأليف الكلام . وأما الطرائق الأخرى فهي تكافئ واحدة من الصيغ الثلاث السابقة [4] .

كما استخدمت بعض المحولات لتحويل الإشارة من المجال الزمني إلى المجال الترددي ومن هذه المحولات محول فوريير Fourier Transform (FT) وفي هذه الطريقة تحلل الإشارة لدراسة تردداتها وتتضمن أيضاً تحديد السعات وأطوار وحدات فوريير للصوت .

أصبح استعمال هذا التحويل شائعاً في تطبيقات عدّة في حقل تحليل الإشارة ، إذ يعطي هذا التحليل معلومات حول محتوى التردد للإشارة لكنه لا يعطي معلومات حول كيفية تغيير تلك الترددات مع الزمن وبذلك لا يمكن استعمالها لتقريب الإشارات غير الثابتة [8][18][45] .

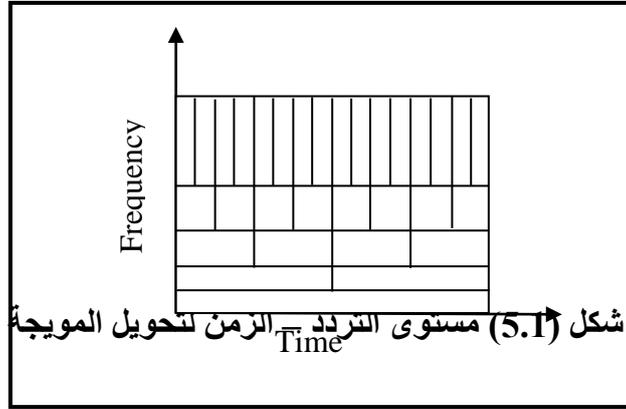
قام الباحث كابور Gabor عام 1946 بتطوير وتعديل تحويل فورير من خلال إضافة نافذة إمرار Window Pass ، وهو ما يعرف بتحويل كابور Gabor Transform أو تحويل فورير ذي الوقت القصير Short time Fourier transform (STFT) ، والغرض منه هو التعامل مع الترددات المختلفة من خلال تجزئة الإشارة باستعمال نافذة وقت وتطبيق تحويل فورير على كل جزء ، لكن الحجم الثابت لأجزاء النافذة لم يؤدّ إلى الغرض المطلوب [45][58] . كما موضح في الشكل (4.1) .



شكل (4.1) مستوى التردد - الزمن لتحويل فورير
 لم يكن تحويل فورير هو الأمثل للتعامل مع الإشارات غير الثابتة وأنه يعمل بصورة أفضل مع الإشارات الثابتة ، لذلك كان من الضروري العثور على طريقة للتعامل مع الإشارات غير الثابتة لكي تحقق نتيجة جيدة .

كانت بداية ظهور التحويل المويجي Wavelet Transform في أواخر السبعينيات ، حينما لاحظ مهندس فيزياء الأرض الفرنسي مورليت (Morlet) عدم قدرة STFT على تحليل إشارات الزلازل التي كان يرغب في معالجتها ، إذ تميزت هذه الإشارة بامتلاكها ترددات عالية خلال مدة زمنية قصيرة وترددات واطئة خلال مدة زمنية طويلة ، فتوصل إلى استعمال نافذة متغيرة الحجم تتفاعل مع تلك الترددات وأطلق على دوال التحويل الجديدة اسم المويجات Wavelets بعد ذلك تضافرت جهود الباحثين Grossman and Morlet لوضع الأسس الرياضية لتحويل المويجة [45] . وفي عام 1985 أعطى الباحث Mallat تحويل المويجة انطلاقةً جديدةً من خلال عمله في حقل معالجة الإشارة الرقمية ، إذ كشف العلاقة بين المرشحات الرقمية وتحويل المويجة ، فأصبح تمثيل المويجات بوساطة المرشحات تمثيلاً شائعاً في معظم التطبيقات [8] ، وفي الوقت ذاته قامت الباحثة Dubchies بتطوير مفهوم إطارات المويجة (Wavelet Frames) التي تسمح بحرية أكثر في اختيار الدوال الأساس ، ولها الفضل هي و Mallat بالانتقال من تحليل الإشارة المستمر إلى تحليل الإشارة المنقطع ، ثم قام الباحث مالات

Mallat عام 1986 بتطوير فكرة التحليل متعدد المستويات Multi-Resolution Analysis (MRA) لتحويل الموجة المتقطعة Discrete Wavelet Transform (DWT) [45]. وبهذا أصبح التحويل المويجي أحد الطرائق المهمة والمثلى لاستخلاص الصفات من الإشارات الصوتية لأنه يحافظ على الشكل الأساسي للإشارة بعد التخلص من الفائض في الإشارات الصوتية، فضلاً عن تعامله الأمثل مع الإشارات غير الثابتة إذ انه يستعمل عدداً غير محدد من الدوال الأساس، وتستعمل نافذة متغيرة للحجم إذ تختلف هذه النافذة مع الترددات، فتستعمل نافذة ضيقة في الترددات العالية ونافذة كبيرة في الترددات الواطئة، وبذلك يكون شكل مستوى التردد – الزمن متغير كما موضح في الشكل (5.1):



أدت هذه العوامل إلى تفضيل استخدام التحويل المويجي لاستخلاص الصفات من الإشارات الصوتية.

10.1 مرحلة التمييز : The Recognition Stage

تُعد مرحلة التمييز المرحلة الأساسية في أنظمة تمييز المتكلم لأنه ينتج عن هذه العملية قرار التمييز، ففي مرحلة التمييز يتم عمل مطابقة بطريقة معينة مع النماذج المرجعية المخزونة مسبقاً ويتم اتخاذ القرار أما الرفض أو القبول.

هناك الكثير من الطرائق المستخدمة للتمييز في أنظمة تمييز المتكلم وتعمل هذه الطرائق بكفاءات مختلفة، ومن تلك الطرائق نذكر الآتي:

أ- طريقة الارتباط Correlation :

تعد تقنية الارتباط واحدة من أبسط الطرائق لتمييز النموذج. حيث يمثل كل صنف بـ K من النماذج كمتجه وكالاتي [21]:

$$Y_K = (Y_{1K}, Y_{2K}, Y_{n \cdot K}) \dots \dots \dots (1.1)$$

وتدعى هذه النماذج بالطبقات Templates . ويمثل النموذج غير المعروف لمتجه الخاصية وكالاتي :

$$X = (X_1, X_2, \dots, X_n) \dots\dots\dots (2.1)$$

ثم يحسب الارتباط (correlation) بين النموذج غير المعروف وكل واحدة من الطبقات المرجعية المخزونة بواسطة التقييم الآتي :

$$c(x, y_k) = \sum_{i=1}^N x_i y_{ik} / (\sqrt{\sum_{i=1}^N x_i^2} \cdot \sqrt{\sum_{i=1}^N y_{ik}^2}) \dots\dots\dots (3.1)$$

وبعدها يختار أي نموذج من الطبقات قريب جدا إلى النموذج غير المعروف من خلال $c(x, y_k)$ ولكل k .

وتختار قيمة k من الدالة التي تمتلك أعلى قيمة [15] .

ب- البرمجة الديناميكية **Dynamic programming (DP)** :

يجمع هذا الإجراء بين إزاحة الوقت الديناميكية DTW (Dynamic time warping) والمسافة ويستخدم DTW لتحديد حدود القطعة المخصصة للطبقات لإيجاد إزاحة الزمن الذي يقل من قيمة المسافة الكلية والذي يمثل مجموعة مسافات الإطار في الطبقة المقارنة.

تخدم البرمجة الديناميكية (DP) تطبيع الزمن اللاخطي (الانتساع أو التضغيط لدالة الزمن) من خلال حساب المسافة بين أحجام النماذج المختلفة وأما خطوات هذه الخوارزمية فيمكن تمثيلها كالاتي :

1. حساب مصفوفة المسافة بين كل متجه للنموذج المدخل وكل متجه لطبقات المرجعية [44]. وحسب المعادلة الآتية :

$$d_k(i, j) = \sum_{q=1}^p [x_i(q) - y_{jk}(q)]^2 \dots\dots\dots (4.1)$$

حيث أن :

P : عدد المتجهات.

$x_i(q)$: هي الخواص لنموذج غير معروف ويتكون من متجهات.

$y_{ik}(q)$: هي العناصر للطبقة k التي تتكون من متجهات أيضا.

2. حساب مصفوفة المسافة المتراكمة Cumulative Distance Matrix :

$$g(i, j) = \min[g(i-1, j) + d(i, j), g(i-1, j-1) + d(i, j), g(i, j-1) + d(i, j)] \dots \dots (5.1)$$

3. التطبيق النهائي بإيجاد $G(m,n)$ المجموع الكلي للمسافة التراكمية باستخدام :

$$G(m,n) = g(m,n)/(m+n) \dots \dots \dots (6.1)$$

ج- مصنف المتجاور الأقرب Nearest-Neighbor classification :

يمثل هذا المصنف المسافة بين نقطتين ، فإذا كانت هناك نقاط x و y ، ذات بعد (n)

(أي إن كلاهما متجه بطول $1..N$ من النقاط) فيمكن إيجاد مصنف المتجاور الأقرب كالاتي :

$$D_r(x, y) = \left(\sum_{i=1}^N |x_i - y_i|^r \right)^{1/r} \dots \dots \dots (7.1)$$

فإذا كانت $r = 1$ فان المسافة هنا تعرف باسم مسافة كتلة المدينة (city block) [32] .

11.1 البحوث السابقة :

ابتدأ الاهتمام في مجال تمييز المتكلم منذ عام 1960، ولكن التقنيات والحاسبات المتوافرة في ذلك الوقت لم تكن متقدمة كفاية للتوسع في هذا المجال ، إلا أن التقدم الحاصل في تقنيات الحاسوب بعد عام 1960 أنتجت سلسلة من مشاريع البحث في موضوع تمييز المتكلم. استخدمت طرائق عدة لتمييز المتكلم وكانت نتائج الطرائق متفاوتة الكفاءة وسندرج نبذة مختصرة عن بعض البحوث التي استخدمت لغرض تمييز المتكلم .

(1) اقترح الباحث W. A. Mahmood [54] عام 1988 طريقة تصنيف وتمييز لإشارة الكلام باستخدام تقنية تكمية المتجه (VQ) Vector Quantization. هذا العمل استخدم دراسة المعاملات التي تؤثر في أداء هذه التقنية ، وقد خلص إلى الاستنتاجات الآتية :

1. إن تقنية VQ في تمييز المتكلم المعتمد على النص (Text dependent) وغير المعتمد على النص (Text independent) تحقق نتائج جيدة في هذا المجال.

2. إن استخدام تقنيات مختلفة هجينة في أنظمة تمييز المتكلم تساعد على تقليل الوقت المطلوب للحسابات ومساحة الخزن المطلوبة وهذا يؤدي إلى زيادة نسبة التمييز .

3. إن نظام التمييز المعتمد على كتاب الشفرة (Code book) (المولدة عن متكلم واحد) يعطي نتائج أفضل بالمقارنة مع النظام المعتمد على متكلمين عدة . وهذا يعزز الأداء لهذه التقنية في مجال تمييز المتكلم .

4. عند دراسة المعاملات التي تؤثر في نظام تمييز المتكلم استنتج ما يلي :
- أ- باستخدام تهيئة متجه كلمة الشفرة (Code word) (المشتقة من معدل متجه التدريب) يساعد في تقليل التشوه الحاصل عند توليد كتاب شفرة كبير الحجم .
- ب- باستخدام تقنية ترميز التنبؤ الخطي (LPC) فان الترتيب (12) هو الاختيار الأفضل لموازنة التأكد المطلوب والحسابات .
- ج- إن نسبة التمييز تزداد بزيادة حجم كتاب الشفرة (Code book) على حساب زيادة مساحة الخزن ووقت التعليم .

- (2) اقترح الباحث S. Abdulrahman [46] عام 1988 نظام بنك المرشح Filter Bank ، حيث قام بتحليل إشارات الكلام لكل متكلم باستخدام 8 مرشحات بنك ثم تحسب القوة من كل مرشح. هذا العمل بين الاستنتاجات الآتية :
1. الضوضاء تقلل أداء نظام التمييز لأنها قد تغير خصائص التردد لإشارة الكلام .
 2. إن نسبة التمييز قد تتأثر أيضا في طريقة النطق ونغمة الكلام ، وهذا قد يؤثر في اختيار المعاملات لتمثيل الأداء المطلوب .

- (3) اقترح الباحث S. D. AL-Sudani [50] عام 1997 عملاً مبنياً على خصائص عدة لتعريف المتكلم ، هذه الخصائص المختلفة هي شفرات التنبؤ الخطي (LPC) ، الحد الأعلى من فترة المعالجة ، الطاقة Energy ، الانحراف المعياري للتردد الأساسي ، ومعدل فترة المعالجة . النتائج تبين النسبة المئوية للتعريف الصحيح هو 90% لـ 14 متكلماً .

- (4) اقترح الباحث M. J. Haider [35] عام 1999 الطريقة التي تؤدي تحويل المويجي الحزمي السريع Turbo wavelet packet transform (TWPT) . الهدف من هذا العمل هو تطبيق تحويل الموجة على الأصوات العربية واستخدامها لتمييز تلك الأصوات . كما عمل تصنيف أكبر للفونيمات الملفوظة Voiced Phoneme وغير الملفوظة Unvoiced Phoneme كل على حده باستخدام الطريقة المقترحة.

إن تقنية تكمية المتجه VQ استخدمت أولاً في الحصول على 6 أصناف من الأصوات. هذا التصنيف قد غير فيما بعد خلال تطبيق التحويل المويجي لتمييز الفونيم . الطريقة المقترحة هنا TWPT استخلصت الصفات باستخدام خوارزمية سريعة للحصول على معاملات WPT .

هذه الخوارزمية تتطلب الطي convolution و Down Sampling فقط. تلك المتجهات تحتوي على أعداد ثنائية فقط التي تجعل العملية ابسط وأسرع.

(5) اقترحت الباحثة هند رستم محمد [4] طريقة لتعريف المتكلم باستخدام الشبكات العصبية متعددة الطبقات، حيث تم استخدام تقنية ترميز التنبؤ الخطي لاستخلاص الخواص الصوتية باستخدام طريقة الارتباط الذاتي. أما وحدة التركيب العصبي الأساس المستخدمة في هذا البحث فتتكون من مدرك ذو ثلاث طبقات Three Layers perceptron . إن الإدخال للنظام المقترح هو تلفظ كلامي للجملة والإخراج لهذا النظام هو هوية المتكلم.

أظهرت معدلات التمييز 100% لأنماط تم التدريب عليها مسبقاً، علماً أن التدريب قد استخدم أربعة تكرارات لكل جملة ولكل متكلم لاستخدام ثلاثة جمل مختلفة، كما تم الحصول على نتيجة 97.9% للنماذج التي لم يتم التدريب عليها للجملة الأولى وبمعدل 9 تكرارات لكل متكلم. إن مجموعة التدريب في البحث المقترح كانت أكثر من 10 متكلمين (ذكور وإناث) وبأعمار متقاربة.

(6) اقترحت الباحثة إيمان صالح صكبان [3] عام 2001 طريقة لتمييز المتكلم باستخدام شبكة تعليم المتجه الكمي، حيث قامت ببناء 6 أنظمة لتمييز المتكلم باستخدام تقنية ترميز التنبؤ الخطي وبوساطة طريقة داربن التكرارية تم الحصول على كل من معاملات الارتباط الذاتي، معاملات الطاقة المتبقية، معاملات الانعكاس، معاملات الارتباط الجزئي، معاملات نسبة المساحة اللوغارتمية والمعاملات الطيفية، كما تم استخراج بعض المعاملات القياسية، معدل الطاقة، معدل السعة، التقاطع الصفري ومعامل التشدد اللفظي. أما في مرحلة التمييز فقد تم توظيف تقنية الشبكات العصبية وتحديدًا شبكة LCQ3، حيث تم العمل على 20 متكلاً، 10 من الذكور و 10 من الإناث وبأعمار متقاربة. أظهر البحث النتائج الآتية: 90% للنظام المعتمد على المعاملات الطيفية، 88% للنظام المعتمد على معاملات الانعكاس، 87% للمعاملات المعتمدة على المساحة اللوغارتمية، 84% للنظام المعتمد على معاملات الطاقة المتبقية، 81% النظام المعتمد على المعاملات التقليدية و 80% للنظام المعتمد على معاملات الارتباط الذاتي.

(7) اقترحت الباحثة هدى ناجي المعموري [5] طريقة لتمييز أصوات المحركات الصاروخية باستخدام محول الموجة، إذ استخدم التحويل المويجي لبناء نموذج مرجعي لأصوات المحركات الصاروخية، أما عملية اتخاذ القرار فقد اعتمدت على طريقة حساب المسافة الأقل (Minimum

- (Distance) بين نماذج التدريب ونماذج الاختبار وتمت المقارنة بين النتائج في حالة استخدام الموجات الثلاثة db_1, db_2, db_3 . أوضحت النتائج التي تم التوصل إليها الآتي:
1. تختلف المعالم الناتجة عن حسابات محول الموجة لأي صاروخ في اختلاف المقاطع الزمنية للإشارة الصوتية.
 2. تختلف المعالم الناتجة عن حسابات محول الموجة للصواريخ الأربعة في أي مستوى تحليلي من المستويات الثلاثة.
 3. تتناقص قيمة معلم التقريب مع التقدم في المستويات التحليلية بينما تتزايد قيمة معلم التفاصيل مع التقدم في المستويات التحليلية لأي مقطع من مقاطع الإشارة الصوتية الخاضعة للتحليل.
 4. إذا كانت الفترة الزمنية للإشارة الصوتية الخاضعة للاختبار طويلة فإن نتائج تحليل محول الموجة غير مشجعة لإظهار اختلافات تساعد في موضوع المقارنة وتحديد الاختلاف بين الصواريخ المختلفة.
 5. يعد استخدام محول الموجة من الطرائق التحليلية المهمة والتي يمكن استثمارها بصورة موفقة ومشجعة في مثل هذا النوع من المشاكل العلمية.

التحويل المويجي والشبكات العصبية

1.2 التحويل المويجي :

1.1.2 ما هي الموجة wavelet : What is wavelet

الموجة هي موجة صغيرة غير منتظمة الشكل ، وتستمر لدورات قليلة . تملك طاقة محددة ، وفترة محددة وهذا يعني تتذبذب في الزمن بوصفها موجة قصيرة . ومن هنا جاء اسم الموجة [39] وهي موضحة في الشكل (1.2) . تتركز طاقة الموجة في الزمن لتعطي أداة جيدة في تحليل الظواهر غير الثابتة أو الوقتية [16]. بدلا من أن تبني من الدوال الجيبية (Sine, Cosine) ، تبني الموجة من دوال محددة بشكل تام في حيز الزمن (Compact support) . وتعرف الدوال المحددة بشكل تام في حيز الزمن بأنها الدوال التي تأخذ قيم غير صفرية داخل الفترة المعطاة وتأخذ صفرا خارج الفترة المعطاة . عائلة الدوال (دوال الأساس) المعطاة في معادلة (1.2) ، يمكن الحصول عليها من الموجة الابتدائية $\psi(t)$ (الموجة الأم) أما بالتزحيف (shift) أو التقييس (Scale) [10][17]. يوضح الشكل (2.2) بعض دوال الموجة الأم ، يغير كل من التقييس أو التزحيف من شكل الموجة الأم ولكن بأسلوب مسيطر عليه ، لهذا يمكن أن يعود الشكل الأصلي للموجة الأم مرة أخرى [7] :

$$\psi_{a,b} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \dots\dots (1.2)$$

فإن $a \neq 0$ و a هو معامل التقييس ، $a, b \in \mathbb{R}$ و b هو معامل الإزاحة $\psi(t) \in L_2(\mathbb{R})$ ، و $\psi(t)$ هي الموجة الأم ، و $L_2(\mathbb{R})$ هي فضاء الدوال . يستخدم العامل $1/\sqrt{a}$ للحفاظ على (Norm) ، هذا يعني إن $\|\psi_{a,b}(t)\| = \|\psi(t)\|$.

عندما تكون a صغيرة ($a < 1$) ، سوف تكون الموجة $\psi_{a,b}(t)$ قصيرة ، وتكون مرافقة للترددات الواطئة . يجهز تحويل الموجة تحليلاً في مستوي الزمن – التردد أو الزمن – التقييس .

2.1.2 لماذا الموجة wavelet : Why wavelet

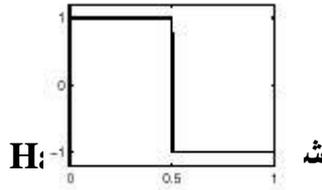
أثبتت التجارب إن التحويل المويجي يعد أداة ذات كفاءة عالية جدا في تحليل عدد كبير من الإشارات والظواهر . ويتجاوز بعض المساوي التي ترافق محول فورير Fourier Transform إذ يمكن تمثيل معاملات فورير بوحدات تستمر لفترة زمنية طويلة ، ولذلك فإن

الحوادث الوقتية توصف بخصائص الطور التي تمتد لدورات زمنية كبيرة [16]. إن قابلية إنجاز التحليل المحلي أو الوصفي للإشارات للكشف عن الأحداث الوقتية التي تحدث في الإشارة هي من أهم الصفات التي تتصف بها المويجة. وتجهز المويجة طريقة لتمثيل الإشارة بدرجات مختلفة من الدقة لذلك تعد مناسبة جدا لتحليل ومعالجة البيانات [10][55]، وبرغم معاملات تمدد المويجة (معاملات المويجات) تصبح اقل في حالة التزحيف والتقييس لعدد كبير جدا من الإشارات ، فان المويجات تعد ذات كفاءة جيدة في ضغط الصورة ، والإشارة ، وفي إزالة الضوضاء Denoising ، وفي الكشف Detection [16] . باستخدام 4% فقط من معاملات المويجة يمكن استرجاع الإشارة الأصلية [9] ، في حين أن ذلك لا يمكن أن يحدث في متسلسلة فورير، ولو استخدمنا معاملات أكثر بسبع مرات من المعاملات المستخدمة في متسلسلة المويجة [27] [41] .

3.1.2 عائلات المويجة :Wavelet Families

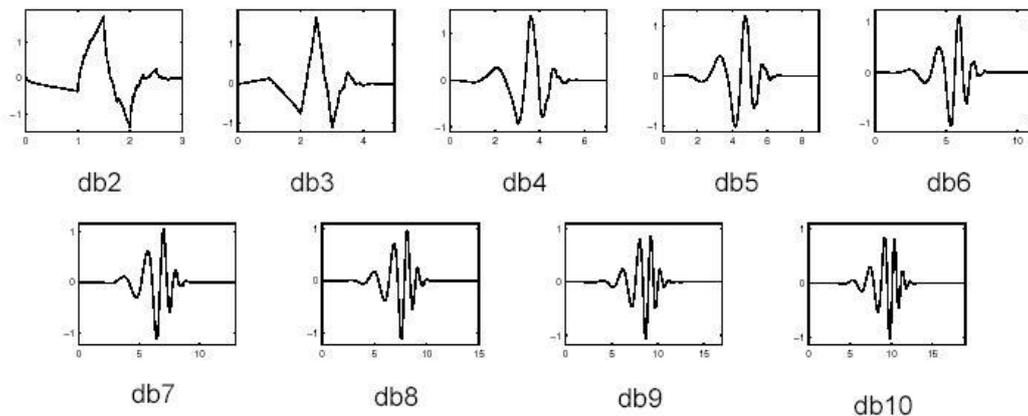
1. مويجة Haar :

وهو من ابسط عائلات المويجة ويشبهه 1 Daubechies (db1) .



2. مويجة Daubechies :

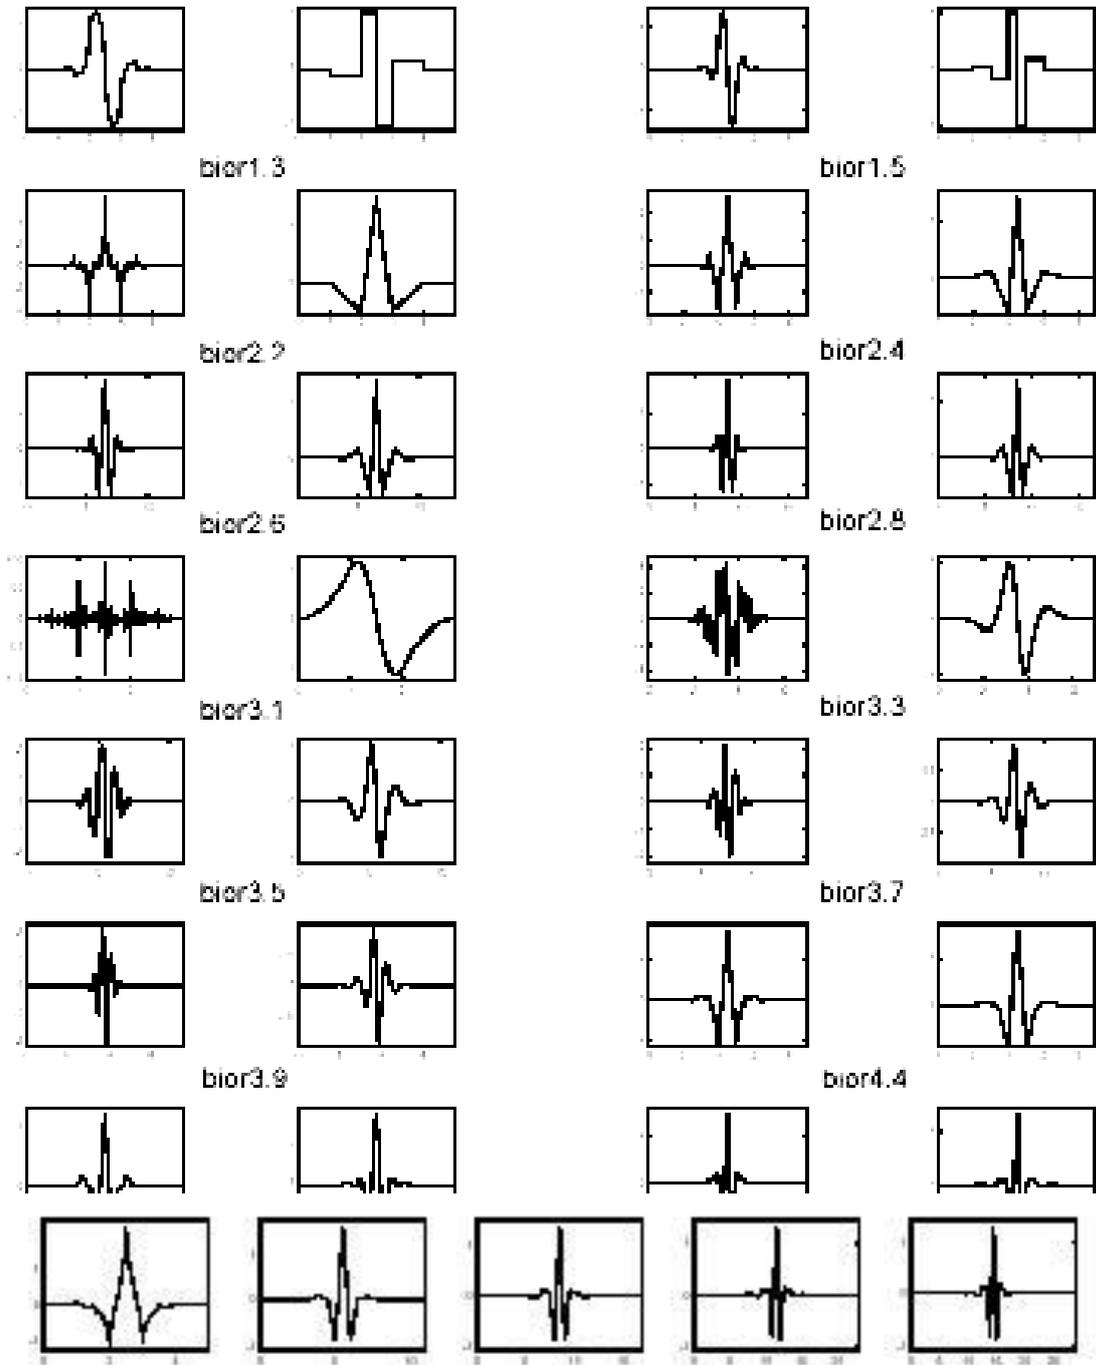
تعد الباحثة Ingrid Daubechies واحدة من المع الباحثين في مجال التحويل المويجي ، فقد ابتكرت ما يسمى بـ Compactly supported orthonormal wavelets لذلك جعلت تحليل المويجة المتقطع قابلاً للتطبيق عمليا .



شكل (2.2) عوائل دوبشيز Daubechies Families

3. موجة Biorthogonal :

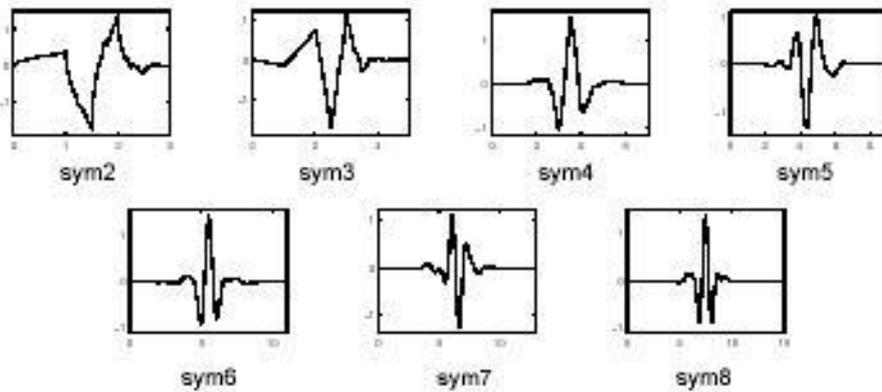
هذه العائلة من الموجات التي تعطي خاصية النمط الخطي، التي تكون ضرورية لإعادة بناء الصورة والإشارة . يتم استخدام موجتين، الأولى للتحليل (في الجهة اليسرى) والثانية لإعادة البناء (في الجهة اليمنى) بدلا من واحدة ، لغرض الحصول على خاصية مفيدة .



شكل (4.2) موجة Coiflets

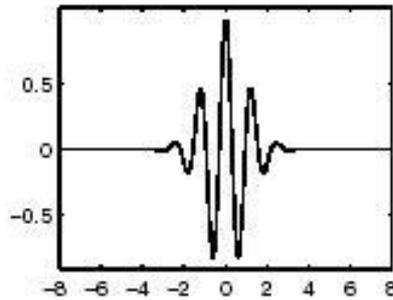
5. موجة Symlets :

تعد موجة Symlets قريبة من الموجات المتناظرة المقترحة من قبل الباحثة Daubechies التي هي تعديل لعائلة db . فالخواص العامة للعائلتين متشابهة . وكما مبين في الشكل الآتي :



6. موجة Morlet :

هذه العائلة من الموجات ليس لها دالة تقييس . وهي مبينة في الشكل الآتي :



4.1.2 التقييس والتفاصيل Scale and Resolution :

مفهوم التقييس يمكن التعبير عنه كالاتي : لو كانت لدينا الدالة $f(t)$ ، هذه الدالة يمكن أن

تُقَيَس :

$$f(t) \longrightarrow f(at)$$

الدالة $f(t)$ تتقلص إذا كانت $a > 1$ وتتوسع إذا كانت $a < 1$ [39] . التقييس هو عملية أساسية في محول الموجة .

من المعادلة (1.2) علمنا انه إذا كان معامل التقييس (a) صغيراً فإنه سيكون مطابقاً لدالة الأس ذات التردد العالي ، ولذلك فإن معامل التقييس هو معكوس التردد . أما التفاصيل في الإشارات فيمكن أن نعرفها بالعدد الأدنى للعينات المطلوبة لتمثيل الإشارات ، لهذا هي تتعلق بحجم المعلومات الموجودة في الإشارة [36][39].

5.1.2 محول الموجة المتقطع DWT :

تنجز تطبيقات محول الموجة باستخدام حاسبات رقمية لتحويل الإشارات المستمرة إلى عينات منفصلة (samples) . يطبق محول الموجة المتقطع عن طريق تحليل الحزم الفرعية . يمكن أن يطبق هيكل بنك المرشحات الذي يجمع ما بين تحليل الحزم الفرعية ومحول الموجة المتقطع بصورة ذات كفاءة عالية باستخدام الهيكل الشجري وعليه هناك عمليتان رئيسيتان [40] هما :

1. الترشيح و عملية التقليل Down Sampling :

عملية الترشيح لمتسلسلة من الأعداد تنفذ بتأليف المتسلسلة مع مجموعة أخرى من الأعداد وهي معاملات المرشح [16][34] . لو كانت $x(n)$ هي الإشارة و $h(n)$ هي معاملات المرشح :

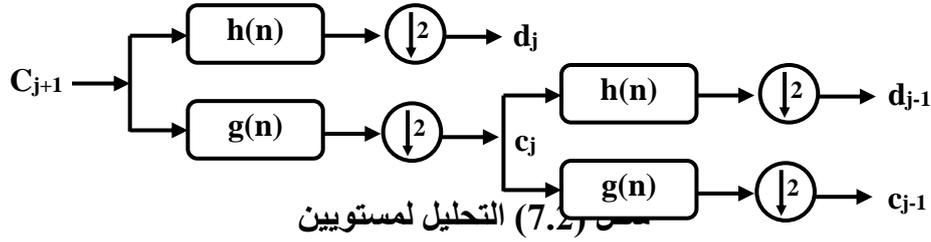
فان الناتج $y(n)$ يكون كالآتي :

$$y(n) = \sum_{b=0}^{N-1} h(n)x(n-b) \quad \dots\dots\dots (2.2)$$

علماً أن N هو طول الإشارة .

في عملية التنقيص تؤخذ الإشارة $x(n)$ كمدخل ، والناتج هو $y(n)=y(2n)$ أي انه ستؤخذ العينات ذات الفهارس الزوجية ، وفي بعض الحالات العينات ذات الفهارس الفردية [16] ، أي إن $y(n)=y(2n+1)$ ويرمز لهذه العملية بالرمز $\downarrow 2$. اعتمدت خوارزمية Mallat على هذا المبدأ من التقييس إذ إن معاملات التقييس ومعاملات $\downarrow 2$ يمكن الحصول عليها بمستويات مختلفة من التقييس عن طريق تأليف معاملات التقييس عند المستوى j مع معاملات الإمرار الواطئ (LPF) low pass filter ، ومعاملات مرشح الإمرار العالي high pass filter (HPF) ، ثم تجري عملية التنقيص (بأخذ الحدود ذات الفهارس الزوجية) للحصول على معاملات التقييس في المستوى (j-1) [16] . ومن ثم تكرر عملية الشطر ، الترشيح والانحلال

على معاملات التقييس [36] ، علماً أن تكرار هذه العملية يحدد بواسطة عدد المستويات وهو موضح في الشكل (7.2) :



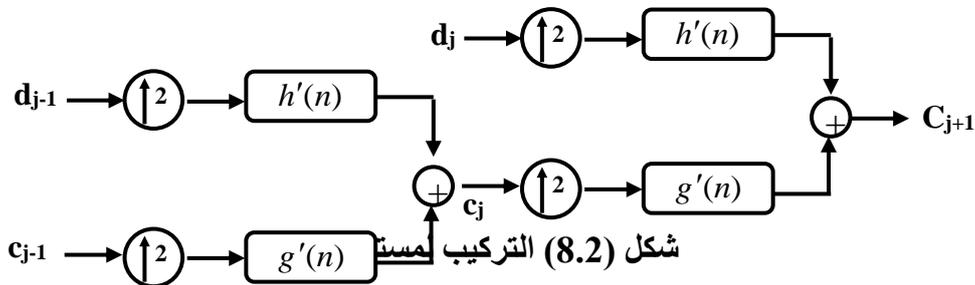
2. الترشيح وعملية الاستكمال Up Sampling :

عملية التركيب (الاستكمال) في بنك المرشحات تحدث بزيادة عدد العينات الموجودة في الناتج $y(n)$ (إضافة أصفار بين كل عينة وأخرى) [16][39] :

$$y(2n) = y(n) \quad \text{and} \quad y(2n + 1) = 0$$

فإن n هي رقم العينة .

يبين الشكل (8.2) عملية التركيب ويرمز لهذه العملية بالرمز $\uparrow 2$ تدعى المرشحات المستخدمة في عملية التركيب بمرشحات التركيب وتتكون أيضاً من مرشحي الإمرار الواطئ والإمرار العالي [12] .



تكون المرشحات المستخدمة من نوع استجابة نبضة محددة (FIR) ، ويرتبطان بتلك العلاقة [39] :

$$h(L - n - 1) = (-1)^n g(n) \quad \dots\dots\dots(3.2)$$

علماً أن L هو طول المرشح (الذي يكون دائماً زوجي) . و n تعني فهرس (index). أفضل حالة للتحليل عندما تكون مرشحات التحليل $(h'(n), g'(n))$ متطابقة (مع انعكاس الزمن)

6.1.2 التنسيب المتعامد وثنائية التعامد :

Orthonormal and Biorthogonal

لنفرض إن لدينا إشارة مثل x من أي فضاء مثل (S) ، إذ أن (S) هو بعد محدد أو غير محدد . لإيجاد مجموعة من الإشارات الأولية $(\psi_j)_{j \in \mathbb{Z}}$ لذلك الفضاء ، إذ أن x يكون تجميعاً خطياً يعبر عنه بالعلاقة الآتية :

$$x = \sum_i \alpha_i \psi_i \dots\dots\dots (4.2)$$

علماً ان المجموعة ψ_i تمثل (مرشحات التركيب) أما α_i فهي تمثل معاملات التوسع، ويمكن أن تحسب هذه المعاملات وكما في المعادلة (9.2) لكن ذلك يتطلب مجموعة أخرى وتسمى القاعدة الثنائية (Dual basis) مرشحات التحليل [36] :

$$\alpha_i = \sum_n \tilde{\psi}(n)x(n) \dots\dots\dots(5.2)$$

علماً x و $\tilde{\psi}_i$ هي متسلسلات زمنية منفصلة حقيقية [36] . ويمكن أن نطلق على المجموعة $\psi_i(n)$ في المعادلة (8.2) بأنها مجموعة أساس لمجال معطى إذا المجموعة α_i هي وحيدة لأي $x(n)$ تنتمي إلى ذلك المجال . والمجموعة نفسها تسمى مجموعة أساس متعامدة، إذاً [16] [36]:

$$\langle \psi_i(n), \psi_j(n) \rangle = 0$$

حيث $i \neq j$.

أما التناسب المتعامد (orthonormal) فهو، حالة خاصة للموجة ويتحقق عندما [16][39] :

$$\langle \psi_i(n), \psi_j(n) \rangle = \delta[i - j]$$

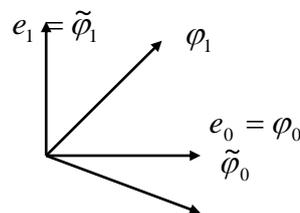
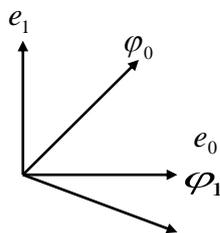
في هذه الحالات مجموعة الأساس ، ومجموعة الأساس الثنائية تكونان متشابهتان :

$$\psi_i = \tilde{\psi}_i$$

أما التعامد الثنائي (Biorthogonal) فهو يتحقق عندما تكون مجموعة الأساس ومجموعة الأساس الثنائية تحقق :

$$\langle \psi_i, \tilde{\psi}_j \rangle = \delta[i - j]$$

يوضح الشكل (9.2) التعامد المنسب والتعامد الثنائي :



(ب)

(أ)

شكل (9.2) أمثلة لمجموعة المتجهات للفضاء \mathbb{R}^2

(أ) تعامد ثنائي ، (ب) تعامد منسب

7.1.2 دالة التقييس Scaling Function :

الدالة الأساسية $\varphi(t)$ هي دالة توسيعية لـ $\varphi(2t)$ ، تتضمن دالة التقييس $\varphi(t)$ سلاسل محددة من الحدود ، كل حد من الحدود يتضمن $\varphi(2t)$ لكن في مواقع مختلفة على المحور الأفقي . لهذا فان دالة التقييس الأساس تكون [16] :

$$\varphi(t) = \sum_n h_0(n) \sqrt{2} \varphi(2t - n) \dots\dots\dots (6.2)$$

علماً ان $h_0(n)$ هو مرشح إمرار واطئ والدالة $\varphi(t)$ التي تعد الدالة النهائية التي تتجه إليها الإشارة الأصلية ، وتدعى دالة التقييس scaling function لأنها تستخدم للتحويل من المقياس الدقيق إلى المقياس الخشن [39] .

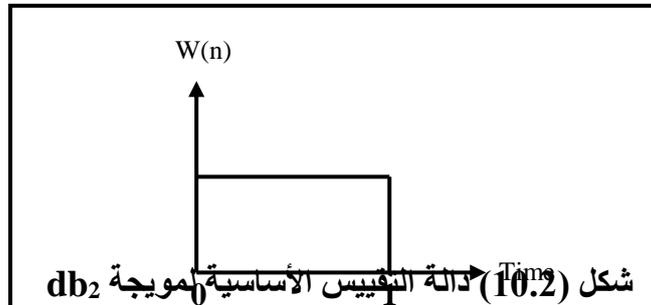
يمكننا تعريف مجموعة من دوال التقييس في حدود من دالة التقييس الأساس $\varphi(t)$ [16] :

$$\varphi_b(t) = \varphi(t - b) \quad b \in \mathbb{Z}, \varphi \in L^2 \dots\dots\dots (7.2)$$

يمكن أن تتولد عائلة من الدوال ذات البعدين من دالة التوسع الأساسية عن طريق التقييس والإزاحة [16] :

$$\varphi_{j,b}(t) = 2^{\frac{j}{2}} \varphi(2^j t - b) \dots\dots\dots (8.2)$$

دالة التقييس الأساسية $\varphi(t) = 1$ عندما $0 \leq t < 1$ و $\varphi(t) = 0$ في حالات أخرى [18] وهي موضحة في الشكل (10.2) .



أما دالة الموجة فهي مشتقة من دالة التقييس المرافقة وتمثل بواسطة المجموع الوزني

(Sum weighted) لدالة التقييس المزاحة $\varphi(2t)$ [18] :

$$\psi(t) = \sum_n h_1(n) \sqrt{2} \varphi(2t - n) \quad n \in \mathbb{Z} \quad \dots\dots\dots(9.2)$$

حيث $h_1(n)$ ، مرشح إمرار العالي ، هو المرشح العاكس لمرشح الإمرار الواطئ $h_0(n)$ [16] .
 8.1.2 فضاء دوال الأساس :

يمكن تمثيل مستوى الزمن – التردد بواسطة خلايا المعلومات بمساحات متساوية وتغطي المستوي بمستطيلات حيث تتركز الطاقة [38] . القاعدة القياسية تغطي المستوي بخلايا للمعلومات على شكل مستطيلات لهذا هي تصف مجال الزمن ولا تصف مجال التردد في حين قاعدة فورير تصف مجال التردد ، ولا تصف مجال الزمن. يمكن ان نعد محول فورير بأنه انقلاب ب 90 درجة للقاعدة الأساسية [38] .

إن فضاء مستوى الزمن – التردد لمحول فورير ذي الزمن القصير STFT تكون خلايا المعلومات فيه منتظمة ومتساوية الحجم في حين فضاء محول الموجة المتقطع نحصل عليه بواسطة إزاحة ، تقبيل دوال الموجة لهذا تبدو خلايا المعلومات بأحجام مختلفة .

2.2 الشبكات العصبية Neural Network :

تعد الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN) إحدى أهم تطبيقات الذكاء الاصطناعي التي لاقت نجاحا واسعا منذ مطلع الثمانينيات إذ إنها استطاعت التغلب على مشاكل فان نيومان Von Neuman والأنظمة الخبيرة [29][37] ، وكذلك للخصائص التي تتمتع بها الشبكات العصبية الاصطناعية التي ميزتها عن خوارزميات أخرى [24] وهي :

- قابلية التعميم The generalization capacity .
- التوازي Parallelism .
- الذاكرة الموزعة Distributed Memory .
- السلوك الذكي Intelligent Behavior .
- التعلم Learning.

يمكن تعريف الشبكة العصبية بأنها نظام لمعالجة المعلومات بشكل متوازٍ، ويتكون من مجموعة عناصر معالجة تسمى خلايا عصبية Neurons أو عقد Nodes ترتبط مع بعضها البعض بواسطة مجموعة من الموصلات العصبية Connections . تمتلك كل خلية حالة خاصة بها تدعى نشاط Activation الخلية ، ناتجة عن تطبيق دالة نشاط Activation Function مناسبة على مدخلاتها للحصول على إخراج تلك الخلية [31][42] [56] .

اقترح ماكلوخ وبيتز McCulloch & Pitts عام 1943 أول نموذج لخلية عصبية اصطناعية [26] ، تضمن استعمال مبدأ عتبة Threshold الخلية ، أي إن إخراج الخلية يكون ثنائي Binary اعتمادا على قياس نشاط الخلية بقيمة معينة [31] . وللحصول على تفاصيل أكثر يمكن مراجعة [8][18][26][31] .

حققت الشبكات العصبية نجاحا في الكثير من التطبيقات ، ومن بينها معالجة الإشارة Signal processing ، وتمييز الأنماط Pattern Recognition ومسائل الامثلية Optimization Problems وغيرها من التطبيقات ، لتمييز الشبكات العصبية بإمكانياتها العالية في إجراء المعالجة المتوازية وعدم احتياجها إلى علاقات معقدة في عملها ، بل تحتاج إلى مجموعة من الأمثلة لغرض تعلمها وبالنتيجة سهولة الإجابة عن الأمثلة المقاربة والمحتوية على نسبة من الضوضاء وهو ما يعرف بقابلية التعميم Generalization Capability [26] .

1.2.2 أنواع الشبكات العصبية Types of Neural Network :

تنظم خلايا الشبكة العصبية في طبقات Layers ، وتعالج خلايا الطبقة الواحدة المعلومات بطريقة مشابهة . يحدد سلوك أي خلية عصبية بدالة نشاطها ونمط الموصلات العصبية الموزنة Weighted Connections التي ترسل الإشارات وتستلمها. يدعى ترتيب الخلايا في الطبقات وأنماط الاتصال العصبية ضمن وبين الطبقات بمعمارية الشبكة Net Architecture [31] .

تصنف معماريات الشبكات العصبية بالاعتماد على هيكلها العام على ثلاثة أصناف :

1.1.2.2 شبكات التغذية الأمامية Feed Forward Networks [6][37] :

تتكون شبكات التغذية الأمامية من طبقة واحدة أو أكثر من وحدات معالجة أساسية غير خطية Nonlinear Processing Elements أو خلايا عصبية . ترتبط الخلايا الموجودة في طبقة معينة بخلايا الطبقة المجاورة من خلال مجموعة من الموصلات العصبية. تتناسب المعلومات في هذا النوع من الشبكات باتجاه واحد من طبقة الإدخال إلى طبقة الإخراج، ونوع التعلم في هذه الشبكات هو التعلم المشرف عليه Supervised Learning ، أشهر أنواع هذه الشبكات و أكثرها شيوعا واستعمالا هي شبكة انسياب الخطأ خلفا .

2.1.2.2 شبكات التغذية العكسية [6][26][37] :

ترتبط الخلايا في هذا النوع مع بعضها البعض ، إذ يرتبط إخراج كل خلية عصبية مع مدخلات الخلايا الأخرى في الطبقة المجاورة نفسها . تعرف المدخلات الحالة الابتدائية للشبكة العصبية ، وبعد تغيير حالات الخلايا وصولاً إلى حالة التوازن أو الاستقرار Equilibrium State المتمثلة بأقل طاقة Minimum Energy ، تصبح حالات الخلايا مطابقة لنتيجة الحساب (المخرجات المطلوبة) . من الأنواع الشائعة لهذا النوع من الشبكات هو شبكة هوبفيلد (Hopfiled Network) .

3.1.2.2 الشبكات التنافسية Competitive Networks [26][31] :

تسمى أحيانا شبكات تجميع Clustering Nets ، يقوم هذا النوع من الشبكات باكتشاف علاقات بين أنماط التدريب من خلال إجراء عملية تجميع Clustering أنماط التدريب إلى تجمعات متشابهة الأنماط ، تمثل كل وحدة إخراج تجمع Cluster ، وينسب إلى أقرب تجمع إليه من خلال قياس المسافة (Distance) بين النمط ومراكز التجمعات المختلفة وتنتج الشبكة متجها نموذجاً أو مثلاً Representative Vector لكل تجمع يمثل مركز الفئة. إن التعلم في هذه الشبكات غير مشرف عليه Unsupervised ولذلك تسمى بالشبكات ذاتية التنظيم Self-Organization Networks من الأنواع المشهورة لهذه الشبكات خرائط الصفات ذاتية التنظيم Self-Organization Map لكوهينين عام 1988 وشبكة اكتشاف التجمع Cluster Discovery Network المطورة من قبل كارينتر وجروسبيرج عام 1988 والمسماة أيضاً بنظرية التناغم التأقلمي Adaptive Resonance Theory .

2.2.2 التعلم في الشبكات العصبية :

يعرف التعلم بأنه عملية اكتساب النظام العصبي القدرة على تنفيذ وظائف معينة بإعطاء صورة تقريبية عن المشكلة بواسطة تعديل معاملاته الداخلية (الأوزان) ، وفقاً لقاعدة معينة [37][52] ، وتنتج عملية التعلم باستعمال الأمثلة .

تعد قاعدة التعلم جوهر خوارزمية تعلم الشبكة العصبية فهي تحدد كيفية تغيير أوزان الموصلات العصبية ، ومن قواعد التعلم الأكثر شعبية قاعدة تعلم دلتا Delta Rule والقاعدة الهيبيية Hennian Rule وقاعدة التعلم التنافسي The competitive Learning Rule [56]. تمتلك قواعد التعلم خصائص تميز قاعدة عن أخرى اعتماداً على طبيعة عمل القاعدة في تعديلها للأوزان ، إذا كانت عامة Global أو محلية Local [52] .

في قواعد التعلم العامة ، لا توجد هناك علاقة بين جزء من فضاء الإدخال والأوزان القابلة للتعديل ، ففي كل مرحلة تجري عملية التعديل على كل الأوزان، وتمتلك هذه العملية فوائد من بينها الحصول على شبكة محكمة Compact Network وتعميم أفضل Better generalization، لكنها تمتلك دقة اقل Poor Accuracy ، وتعد الشبكات السيجماوية متعددة الطبقات The Multilayer Sigmoidal Networks شبكات تعلم عامة Global Learning Networks .

أما التعلم المحلي ، فيتميز بأوزانه المقابلة لمنطقة صغيرة من فضاء الإدخال ، ودرجة عالية من الدقة ، وعدد قليل من عمليات تعديل الأوزان ، هذا فيما يتعلق بالجانب الإيجابي ، أما الجانب السلبي فيحتاج إلى عدد أكبر من الوحدات ، وقابليات تعميم قليلة . ينقسم التعلم في الشبكات العصبية على نوعين أساسيين [11][26][56] هما :

1.2.2.2 تعلم مشرف عليه Supervised Learning :

يعتمد هذا النوع من التعلم على موازنة مباشرة بين الإخراج الفعلي Actual output للشبكة العصبية والإخراج المرغوب Desired output لها وعلى المسافة بينهما ، يتم قياس الخطأ ليستعمل في عملية تعديل أوزان الشبكة .

2.2.2.2 تعلم غير المشرف عليه Unsupervised Learning :

يكون الإخراج الهدف في هذا النوع من التعلم غير معروف وبذلك لا توجد معلومات معروفة عن الخطأ يمكن أن تستعمل في عملية تعديل الأوزان تلقائياً Autonomously للوصول إلى حالة التوازن Equilibrium State ، ومن الشبكات التي تستعمل هذا النوع من التعلم هو شبكة هوبفيلد .

ويوجد نوع آخر من التعلم يسمى التعلم بالتقوية Reinforcement Learning الذي هو حالة خاصة من التعلم المشرف عليه [56] ، أو حالة وسطية بين التعلم المشرف عليه والتعلم غير المشرف عليه [11] ، ويعتمد فقط على المعلومات المتوافرة حول الإخراج الفعلي إذا كان صحيحاً أو لا يصنف النظام سلوك استجابة بيئة المشكلة حول الإخراج الفعلي إلى جيد (يكافئ) أو سيئ (يعاقب) ، ووفقاً لها يعد معاملات ، وتستمر عملية التعديل حتى تظهر حالة التوازن ، ويحدد الأوزان التي تمنع الأداء السيئ في المستقبل [22] ، ويصنف تعلم شبكة التنظيم الذاتي تحت هذا النوع من التعلم .

3.2.2 دوال التنشيط Activation Functions :

تعتمد فكرة بناء الشبكات العصبية على المعلومات العصبية المتوافرة عن الشبكات العصبية في الدماغ البشري ، وكما معروف فان الخلية العصبية في دماغ الإنسان لا تقوم بإنجاز معالجة خطية Linear processing على مدخلاتها ، بل أنها تستلم مجموعة من المدخلات التي تقوم على أساسها بإنجاز فعل معين ، ولذلك تمتلك عملية محاكاة لهذا السلوك بواسطة مجموعة من الدوال اللاخطية Nonlinear Functions [6][26][31] .

إن وجود تلك المجموعة من دوال النشاط واستعمالها ضمن خلايا الشبكة يعتمد على نوع خصوصية الشبكة Particular Class Network ، وأيضا على قيم الهدف Target values .

1.3.2.2 دوال التنشيط العامة : Global Activation Functions

تتميز هذه الدوال بأنها تقسم مدخلاتها على مناطق غير محددة infinite Regions ومن أمثلتها :

1. دالة الإشارة Sign Function :

تعتمد مخرجات هذه الدالة على إشارة المدخلات ، وتعد من الدوال البسيطة لكنها غير قابلة للاشتقاق ، لذلك فان أكثر خوارزميات التعلم معتمدة على المشتقة لا تستطيع استعمال هذه الدالة ، تقسم هذه الدالة على نوعين [20][26][31] :

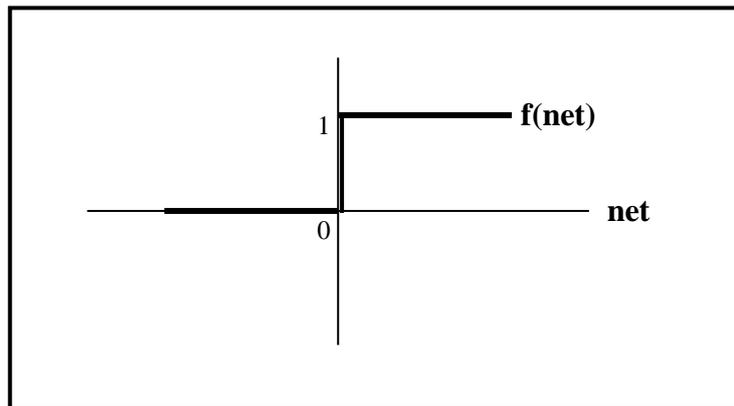
أ-الدالة الثنائية أحادية القطب Unipolar Binary function :

تكون مخرجات هذه الدالة هي القيم 0 أو 1 وصيغتها العامة هي :

$$f(net) = \begin{cases} 1 & \text{if } net \geq 0 \\ 0 & \text{if } net < 0 \end{cases} \quad \dots\dots(10.2)$$

ولهذه الدالة اسم آخر هو Heaviside Function [20] . الهيكل العام لمخرجات هذه

الدالة يوضحه الشكل (11.2) :



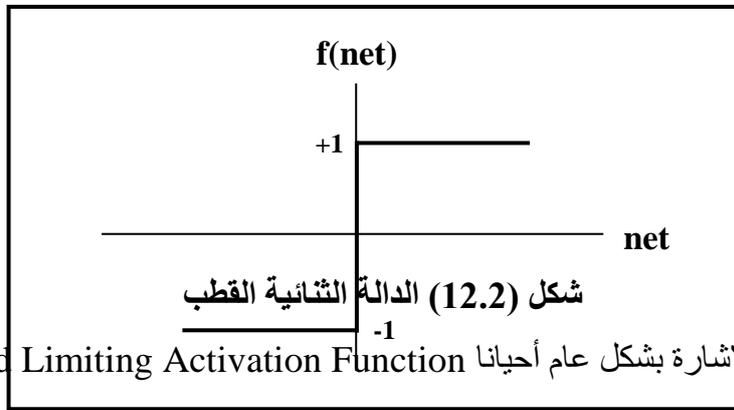
شكل (11.2) الدالة أحادية القطب

ب-الدالة ثنائية القطب **Bipolar Binary Function** :

تكون مخرجات هذه الدالة هي القيم الثنائية (-1) أو (+1) وصيغتها العامة هي :

$$f(net) = \begin{cases} +1 & \text{if } net \geq 0 \\ -1 & \text{if } net < 0 \end{cases} \dots\dots\dots(11.2)$$

وإحدى المسميات الأخرى لهذه الدالة هي **Signum Function** [11] ، والشكل (12.2) يوضح هذه الدالة .



يطلق على دالة الإشارة بشكل عام أحيانا **Hard Limiting Activation Function** [26] .

2. الدالة السجماوية **Sigmoidal Function** :

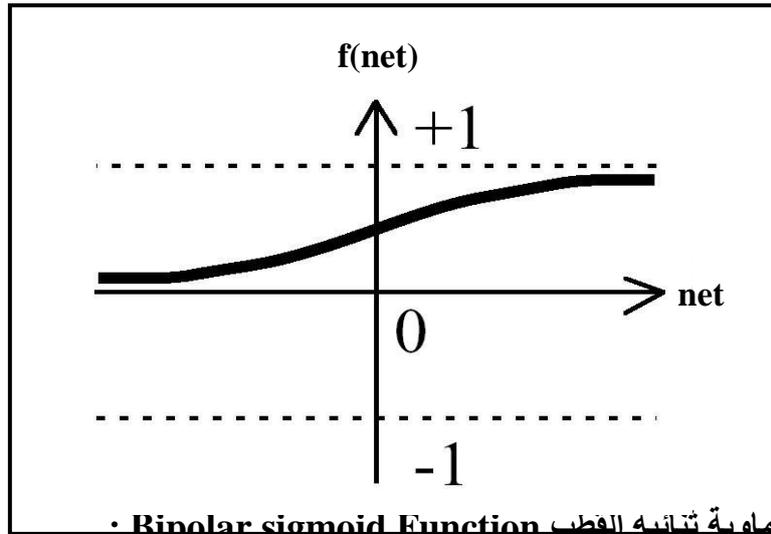
هي من الدوال الشائعة الاستعمال في الكثير من خوارزميات التعلم [19] ، لأنها من الدوال اللاخطية والقابلة للاشتقاق ، وسميت كذلك لان شكلها يشبه الحرف S [31][33] ، وتقسم هذه الدالة على نوعين [20][26][31] :

أ-الدالة السجماوية أحادية القطب **Unipolar Sigmoidal Function** :

تكون قيم مخرجات هذه الدالة ضمن الفترة [0, 1] والصيغة العامة لها هي :

$$f(net) = \frac{1}{1 + e^{-\lambda net}} \dots\dots\dots(12.2)$$

إذ إن net هي مجموع المدخلات إلى الخلية ، و λ عبارة عن قيمة موجبة تحدد ميل (انحدار) الدالة بالقرب من القيمة $net=0$ ، وإذا كانت قيمة λ عالية أي ∞ فإن الدالة تقترب من دالة الخطوة **Step function** [26] وتسمى هذه الدالة أحيانا بالدالة المنطقية **logistic function** [20][31] ، والشكل (13.2) يوضح هذه الدالة .

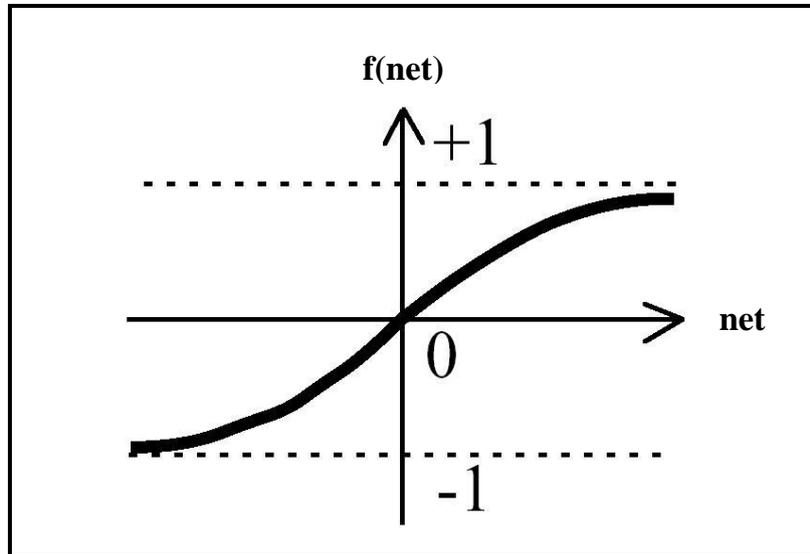


ب-الدالة السيجمواوية ثنائية القطب **Bipolar sigmoid Function** :

يكون إخراج هذه الدالة ضمن الفترة $[-1,1]$ والصيغة العامة لها هي :

$$f(net) = \frac{1}{1 + e^{-\lambda net}} - 1 \quad \dots\dots\dots(13.2)$$

وتسمى هذه الدالة أيضا Hyperbolic Tangent Function [13][26][48] ، هذه الدالة موضحة في الشكل (14.2) :



2.3.2.2 دوال التنشيط المحلية **Local Activation Function** :

تعد هذه الدوال بديلاً عن الدوال السابقة وتطبق على حقل محلي (Local Field) من

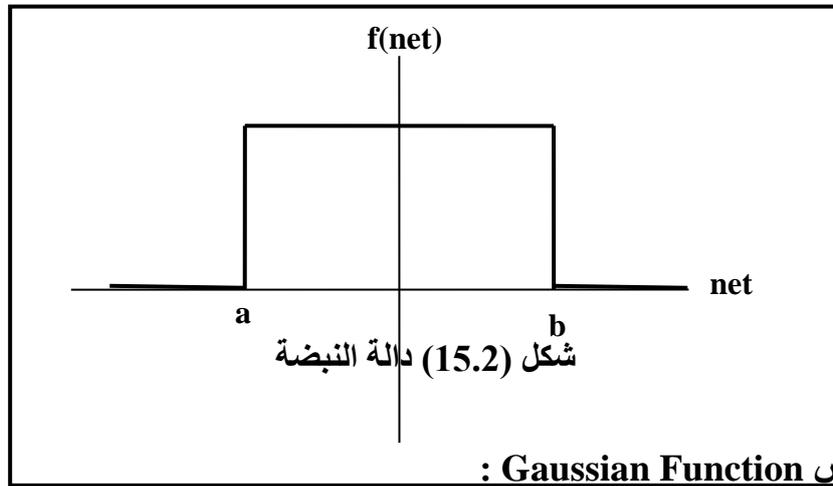
الإدخال ، وهناك نوعان من هذه الدوال [13][31][43][48] :

1- دالة النبضة **Pulse Function** :

هي دالة ثنائية (Binary Signal Function) وتأخذ هذه القيم الدالة القيم [1,0]،
الصيغة العامة لها هي :

$$f(net) = \begin{cases} 1 & \text{if } a \leq net \leq b \\ 0 & \text{otherwise} \end{cases} \dots\dots\dots (14.2)$$

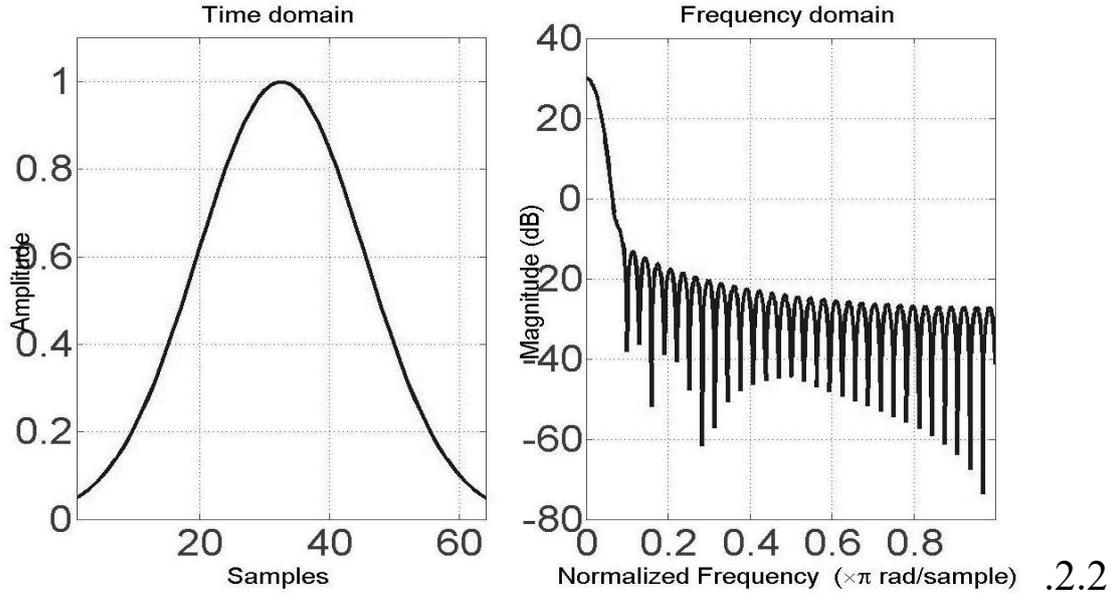
إذ تمثل a و b الحد الأدنى والأعلى للفترة التي تقع ضمنها مدخلات الخلية (net)،
ومن مشاكل هذه الدالة إنها غير قابلة للاشتقاق ولا يمكن استعمالها في خوارزميات التعلم
المعتمدة على المشتقة [6] ، والشكل (15.2) يوضح هذه الدالة .



تمتلك هذه الدالة مشتقة من استعمالها في خوارزميات التعلم المعتمدة على المشتقة ،
والصيغة العامة لها هي :

$$f(net) = e^{-\frac{(net-c)^2}{2\sigma^2}} \dots\dots\dots (15.2)$$

net : المدخلات إلى دالة كاوس ،
σ : تمثل الانتشار (Spread) للدالة ،
c : نقطة المنتصف (Point Center) . الشكل (16.2) يوضح هذه الدالة .



أظهرت الدراسات التي أجريت على دماغ الإنسان وجود عدد هائل من الارتباطات ، وبيّن الباحثون أن قشرة الدماغ مقسمة على عدد من الطبقات المختلفة ، وهناك عدد كبير من الخلايا العصبية في كل طبقة وترتبط خلايا الطبقة الواحدة مع خلايا الطبقات الأخرى لتكون نظاماً عصبياً معقداً [20] [21] . يمكن تقسيم الشبكات العصبية الاصطناعية اعتماداً على هيكل الشبكة العصبية على نوعين [20] هما :

1- الشبكات الطبقيّة Layered Networks :

تتكون هذه الشبكات من مجموعة من الطبقات (Layered) ، وتحتوي كل طبقة على مجموعة من الخلايا العصبية ، وترتبط خلايا كل طبقة بالطبقة المجاورة بواسطة مجموعة من الموصلات العصبية ، وهناك ثلاثة أنواع من الطبقات هي :

أ. طبقة الإدخال Input Layered :

تكون هذه الطبقة مسؤولة عن استلام إشارة التحفيز الخارجية الداخلة إلى الشبكة العصبية.

ب. الطبقة (الطبقات) المخبأة (Hidden Layered (s)) :

تحتوي الشبكة العصبية الاصطناعية على طبقة مخفية واحدة أو مجموعة من الطبقات المخفية المتعاقبة ، تعمل على اكتساب معلومات حول الصفات الخاصة بمجموعة أنماط التحفيز .

ج. طبقة الإخراج Output Layered :

تكون هذه الطبقة مسؤولة عن إظهار مخرجات الشبكة ، ومن الأمثلة الشائعة لهذه الشبكة

هي شبكة المدرك (Perceptron) وشبكة انسياب الخطأ خلفاً (Error Back propagation)

(Network) وشبكة دالة الأساس نصف القطرية (Radial Basis Function Network)

2- الشبكات تامة الارتباط Fully Connected Network :

ترتبط كل خلية عصبية في هذا النوع من الشبكات مع كافة الخلايا العصبية الموجودة في الشبكة بالإضافة إلى نفسها . إذ يوجد ارتباطان بين كل خليتين متجاورتين وفي كلا الاتجاهين وهذا يعطي الشبكة خاصية الانعكاس (Recursive) ، لأن مخرجات كل خلية تصبح مدخلات لخلية أخرى في الطبقة نفسها أو في طبقة أخرى وهذا يساعد الشبكة في الوصول إلى حالة الاستقرار ، من أمثلتها شبكة هوبفيلد [21] [26] [31] .

5.2.2 الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية :

Multi-layers Feed Forward Neural Network

تستعمل هذه الشبكات مجموعة من خلايا الإدخال المتصلة بمجموعة خلايا الإخراج عن طريق طبقة واحدة أو أكثر من الموصلات الوسيطة القابلة للتعديل (Modifiable Intermediate Connections) [20] ، وتكمن أهميتها بقدرتها على إنجاز عملية التعلم تحت أي تعقيد ، واعتمادها على تقويم متكرر لأتملة التدريب وكما في الشبكات ذات الطبقة الواحدة [26] ، ولمعرفة الظروف التي أدت إلى التوجه نحو هذا النوع من الشبكات، ستناقش النماذج الأولى للشبكات العصبية المكونة من طبقة واحدة وبالأخص شبكة المدرك (Perceptron) والمحددات على هذه الشبكات التي أدت إلى التفكير بالشبكات متعددة الطبقات .

1.5.2.2 شبكة المدرك Perceptron Network :

تعد شبكة المدرك المقترحة من قبل روزنبلات (Rosenblatt) عام 1958 أول تصميم لشبكة عصبية تتكون من مجموعة خلايا بالاعتماد على نموذج ماكلوخ – بيتز للخلية وقانون هيب للموصلات [13] [20] ، تتكون هذه الشبكة من طبقة إدخال وطبقة إخراج ، ومجموعة من الموصلات بين هاتين الطبقتين يتم تعديل أوزانها أثناء عملية تدريب الشبكة . تكون قيمة الإدخال والإخراج للشبكة العصبية (0) أو (1) أو تكون (-1) أو (+1) ، وتكون أوزان الموصلات قيم حقيقية . تكون دالة التنشيط في خوارزمية تعلم المدرك هي دالة

الإشارة (Sign Function) . تتعلم شبكة المدرك بوساطة قاعدة تعلم مشرف عليه لتصحيح الأخطاء ، وتعديل أوزان الشبكة خلال عملية التعلم بحسب المعادلة الآتية : [20][26][31][48] :

$$W_{ij}(new) = W_{ij}(old) + c(d_j - \text{sgn}(\sum_{i=1}^n x_i \cdot W_{ij}(old)))x_i \dots\dots\dots(16.2)$$

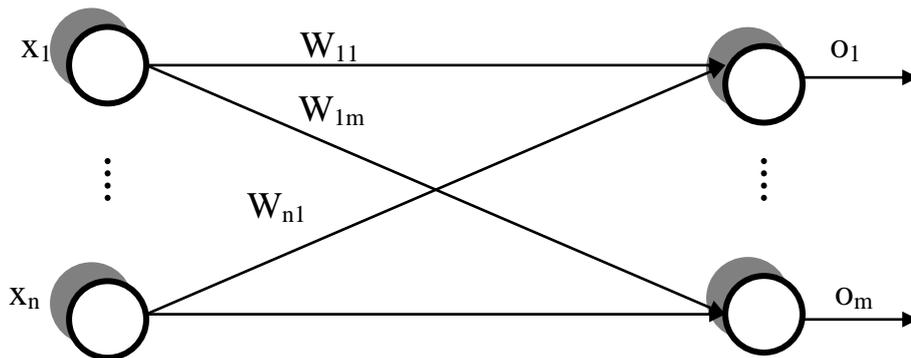
W_{ij} : وزن الموصل بين الخلية المصدر i والخلية j .

c : معامل التعلم .

x_i : إدخال الخلية i .

d_j : قيمة الإخراج المرغوبة للخلية j .

عُدت شبكة المدرك بداية انطلاق الموجة الأولى لنظرية الشبكات العصبية الحديثة [13] ، استطاعت هذه الشبكة حل بعض المشاكل الخطية ولكنها بالمقابل فشلت في حل المشاكل اللاخطية (Nonlinear Problems) مثل مشكلة الدالة XOR [33] [53] ، إذ أوضح نلس نلسون (Nils Nilsson) عام 1965 وآخرين عدم قدرة المدرك على حل هذه المشاكل [24][48] وأوضح مارفن منسكي وسيمور بيبيرت (Marivin Minsky and Seymour Papert) في كتابهما المنشور عام 1969 عدم إمكانية الشبكات العصبية في حل هذه المشكلة لأن الخوارزمية المدركة تعتمد على معرفة الإخراج المرغوب لكل خلية إخراج وتفترض أن أوزان الموصلات بين طبقة الإدخال وطبقة الإخراج هي الوحيدة التي تجري عليها عملية التعديل ، ولكن إضافة طبقة ثالثة (أو أكثر) تسمى الطبقة المخبأ ، يجعل من الصعوبة معرفة الإخراج المرغوب لخلايا الطبقة (الطبقات) المخفية ، وبذلك انحصرت كفاءة المدرك في حل المشاكل الخطية [26][31][33][48] ، وسجل كتاب منسكي وبيبيرت النهاية لموجة شبكة المدرك وتوجه الباحثون نحو ترك هذا الاتجاه وتحويل اهتمامهم إلى تقنيات الذكاء الاصطناعي الأخرى ، والشكل (17.2) يوضح الهيكل العام لشبكة المدرك .



$$W_{nm}$$

حيث أن :

n : تمثل عدد خلايا الإدخال ، m : تمثل عدد خلايا الإدخال.

شكل (17.2) شبكة مدرك

2.5.2.2 شبكة انسياب الخطأ خلفاً :

Error Backpropagation Network

تعد هذه الشبكة من الشبكات الأكثر شيوعاً في التطبيق ، وهي عبارة عن شبكة تغذية أمامية متعددة الطبقات مدربة باستعمال خوارزمية انسياب الخطأ خلفاً ، استطاعت هذه الشبكة تجاوز المشاكل التي عانت منها شبكة المدرك ، ففي عام 1986 قام روميلهارت ورفاقه (Rumelhart et.al) بتصميم هذه الشبكة التي تميزت بخوارزمية تعلم مشرف عليه وتعتمد هذه الشبكة على المشتقة في عملية تعديل أوزانها بدلاً من دالة العتبة (Threshold Function) المستعملة في الشبكات الخطية ، وهذه الشبكة قادرة على حل مشاكل التقريب بتعقيدات مختلفة [20][26][31][33] .

1.2.5.2.2 معمارية الشبكة Network Architecture :

تتكون شبكة انسياب الخطأ من ثلاثة أنواع من الطبقات [20][26][31][33] هي :

1. طبقة الإدخال Input Layer :

هذه الطبقة مسؤولة عن استلام مدخلات الشبكة وتوزيعها على خلايا الطبقة المخبأة .

2. الطبقة المخبأة Hidden Layer :

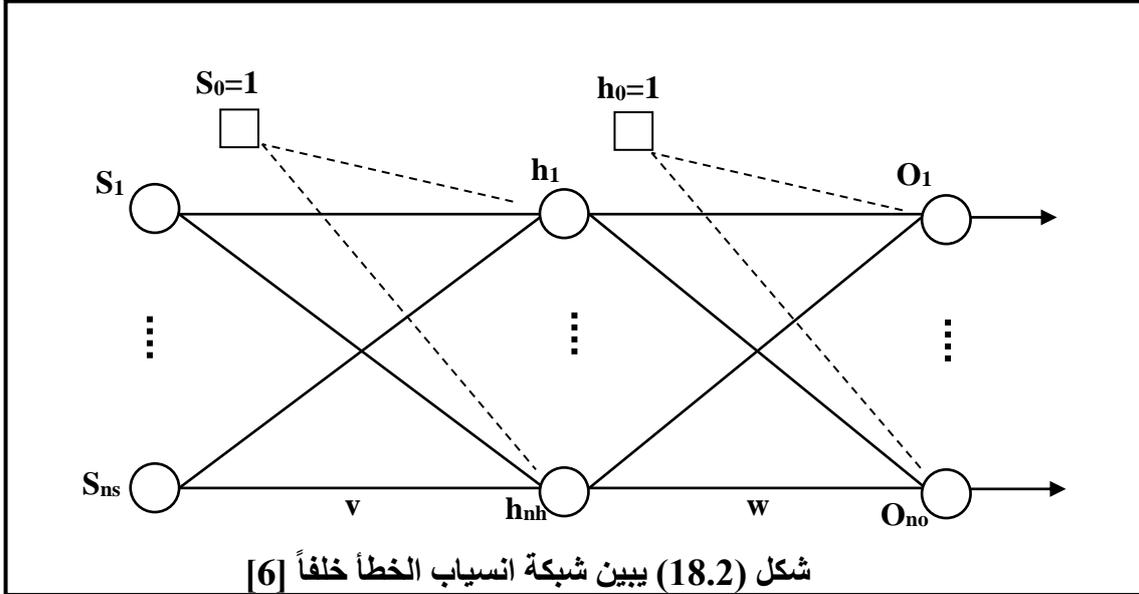
تعمل هذه الطبقة على استخلاص معلومات حول الصفات الموزعة ضمن مجموعة أمثلة التدريب (تقوم باستخلاص الصفات) وإرسالها إلى الطبقة المخبأة المجاورة أو إلى طبقة الإخراج . إذ يمكن استعمال أكثر من طبقة مخبأة واحدة ، لكنه يؤدي إلى زيادة تعقيدات الشبكة ، ولكن تكمن الصعوبة في تحديد الطبقات المخبأة وعدد الخلايا في كل طبقة .

أوضح الكثير من الباحثين أن الشبكة العصبية الاصطناعية مع طبقة مخبأة وعدد كافٍ من الخلايا المخبأة ، مدربة باستعمال خوارزمية انسياب خلفاً على تقريب أي دالة إلى دقة معينة وهذا ما يشار إليه بنظرية التقريب الشامل (Universal Approximation Theorem) [21][23][33][52][53] .

3. طبقة الإخراج Output Layer :

تستلم هذه الطبقة شفرة النمط المحفز (Stimulus Pattern Code) من الطبقة المخبأة وإيجاد الإخراج الفعلي للشبكة .

تحتوي كل من طبقة الإدخال والطبقة المخبأة على خلية إضافية تسمى خلية العتبة (Bias / Threshold Units) تكون قيمتها ثابتة (1) أو (-1) وترتبط مع كل خلايا الطبقة اللاحقة ويتم تدريب أوزانها مع بقية أوزان الشبكة ، والشكل (18.2) يوضح هذه الشبكة .



علماً أن :

S_i : مخرجات الإدخال ، h_k : مخرجات الخلية المخبأة ، O_j : مخرجات خلية الإخراج j ،
 v : منظومة أوزان الموصلات بين طبقة الإدخال والطبقة المخبأة ، w : منظومة
 أوزان الموصلات بين الطبقة المخبأة وطبقة الإخراج ، ns : عدد خلايا الإدخال ، nh : عدد
 الخلايا المخبأة ، no : عدد خلايا الإخراج .

2.2.5.2.2 خوارزمية التعلم Learning Algorithm :

تعد خوارزمية تعلم شبكة انسياب الخطأ من الخوارزميات الفعالة وتصنف ضمن خوارزميات التعلم المشرف عليه (Supervised Learning Algorithms) التي تعتمد على المشتقة في تعديل الأوزان [11] [25] [33] [48] ، وتستعمل هذه الشبكة دال تنشيط سيجماوية (Sigmoid Function) لتحديد نشاط خلاياها ، وهي دالة قابلة ، تستعمل هذه الخوارزمية دالة أقل متوسطات مربعات الخطأ (LMSE (Least Mean Square Error) مقياساً يحدد

تقارب مخرجات الشبكة باتجاه الحل المرغوب ، توضح المعادلة (17.2) صيغة هذه الدالة [26] [33] [48] :

$$E = \frac{1}{2} \sum_{p=1}^{n_p} \sum_{k=1}^{n_o} (d_{pk} - o_{pk}) \dots\dots\dots (17.2)$$

E : الخطأ الكلي للشبكة بعد إدخال كافة الأنماط .

n_o : عدد خلايا الإخراج .

n_p : عدد أنماط التركيب .

d_{pk} : الإخراج المرغوب من الخلية k لنمط التدريب p .

o_{pk} : الإخراج الفعلي للخلية k لنمط التدريب p .

تعمل مشتقة دائمة الكلفة أعلاه على تعديل أوزان الشبكة العصبية بالاتجاه الذي يؤدي إلى تقليل قيمة الخطأ الكلي للشبكة [21][26][48] .

تمر خوارزمية التعلم في شبكة انسياب الخطأ خلفاً بمرحلتين أساسيتين [20][33] هما :

1. مرحلة التغذية الأمامية Feed Forward Phase :

يتم في هذه المرحلة إدخال التدريب إلى الشبكة وينساب النشاط (Activity) الناتج خلال الشبكة من طبقة الإدخال إلى طبقة الإخراج مروراً بالطبقة (الطبقات) المخبأة ، ويتم حساب قيمة الإخراج بحسب المعادلات الآتية [26] :

$$h_k = f(net_k) = f\left(\sum_{i=0}^{n_z} Z_i \cdot v_{ik}\right) \dots\dots\dots (18.2)$$

$$o_j = f(net_j) = f\left(\sum_{k=0}^{n_h} h_k \cdot w_{kj}\right) \dots\dots\dots (19.2)$$

Z_i : مخرجات خلية الإدخال z بضمنها خلية العتبة s₀ = 1 .

h_k : مخرجات الخلية المخبأة k بضمنها خلية العتبة y₀ = 1 .

v_{ik} : وزن الموصل بين خلية الإدخال i والخلية المخبأة k .

w_{kj} : وزن الموصل بين الخلية المخبأة k وخلية الإخراج j .

f(net_j) دالة نشاط الخلية j ، f(net_k) : دالة نشاط الخلية k .

n_h : عدد الخلايا في الطبقة المخبأة .

بعد الحصول على الإخراج الفعلي (Actual Output) للشبكة لنمط معين تتم مقارنته مع الإخراج المرغوب ، ويتم حساب قيمة الخطأ ، وتستمر العملية على كل أنماط التدريب فإذا كانت قيمة الخطأ الكلي للشبكة مقبولة تتوقف عملية التدريب وإلا يتم الانتقال إلى المرحلة الثانية .

2.مرحلة انسياب الخطأ خلفاً **Error Back Propagation Phase**:

تعمل هذه المرحلة على حساب قيمة الخطأ في كل خلية موجودة في طبقة الإخراج ويغذى هذا الخطأ خلال الشبكة لتعديل الأوزان بين طبقة الإخراج والطبقة المخبأة وحساب قيمة الخطأ في الخلايا المخبأة وتعديل الأوزان بين الطبقة المخبأة وطبقة الإدخال ، وتكرر المرحتين حتى يتحقق شرط التوقف وهو الوصول إلى الخطأ المقبول ، والشكل (19.2) يوضح عملية التعلم وانسياب المعلومات في المرحتين [26] .

3.2.5.2.2 عامل التعلم Learning factor :

يمثل مقدار الخطوة التي تخطوها خوارزمية التعلم في فضاء المشكلة لتقليل خطأ التدريب ، ويكون تأثيره كبيراً على إنجازية خوارزمية التعلم وتكون قيمته ضمن الفترة [1,0] ، [21][26][48] . تعتمد قيمة معامل التعلم على المشكلة المراد حلها ، إذ لا توجد قيمة ثابتة ملائمة لمشاكل مختلفة وهي مشكلة بحد ذاتها ، ومن المهم اختيار القيمة المناسبة لمعامل التعلم ، لأن القيمة العالية تؤدي إلى الوقوع في مشكلة التجاوز (Overshooting) ، في حين القيمة الواطئة تتجنب تلك المشكلة لكنها تؤدي إلى تأخير في عملية التقارب [20][26] ، وبسبب تلك المشاكل يلجأ الباحثون إلى استخدام قيمة متغيرة لمعامل التعلم خلال تعلم الشبكة ، ومنها البدء بقيمة كبيرة في بداية التعلم ، وتبدأ هذه القيمة بالتناقص مع استمرار عملية التعلم [6][20][33] حسب المعادلة :

$$\eta = \eta_0 \cdot \left(1 - \frac{t}{T_{\max}}\right) \dots\dots\dots (20.2)$$

η : القيمة لمعامل التعلم ،

η₀ : قيمة معامل التعلم الابتدائية ،

t : قيمة الدورة (Epoch) الحالية ،

T_{max} : العدد الأقصى لدورات التعلم .

النظام المقترح

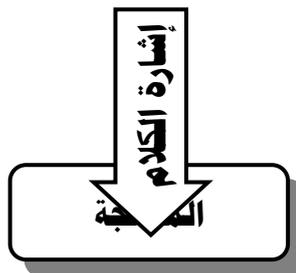
تمييز المتكلم باستخدام التحويل المويجي والشبكات العصبية

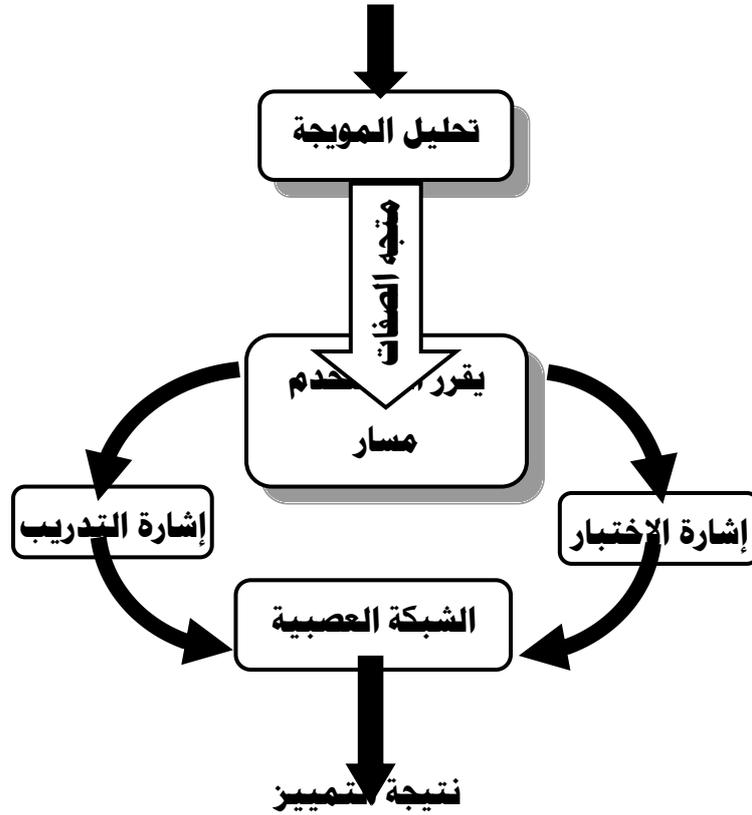
1.3 المقدمة :

للتغلب على بعض المشاكل التي تعاني منها الطرائق السابقة والمستخدمه لغرض تمييز المتكلم والمذكورة في الفصل الأول، تم اقتراح طريقة لتمييز المتكلم وهي مبنية على أساس استخدام التحويل المويجي لاستخلاص الصفات من الإشارة الكلامية والاستفادة من مميزات التحويل المويجي، حيث يكون ملائم للتعامل مع الإشارات الكلامية غير الثابتة، وكذلك استخدام الشبكات العصبية في عملية التمييز Recognition وقد تم اختيار خوارزمية انسياب الخطأ خلفا . Error back propagation algorithm

تم اختيار مجموعة من الكلمات التي ستعتمد في النظام المقترح في عمليتي التدريب والفحص training and testing، وهي (صباح، مساء، الخير، ياسين، يمين، لندن، وفي)، إذ تحتوي هذه الكلمات على حروف مهمة التي يمكن من خلالها تمييز متكلم عن متكلم آخر. وكذلك تم اختيار عينة من 29 متكلماً (15 ذكور و14 إناث) لنطق هذه الكلمات وتم تطبيق النظام على تسجيلات صوتية للكلمات السبع و- 29 متكلماً.

إن الأداة المطبقة في مرحلة استخلاص الصفات هي التحويل المويجي المتقطع Discrete Wavelet Transform ، حيث يقوم بتوليد متجه الصفات Feature Vector لكل متكلم، ومن ثم تدخل متجهات الصفات فيما بعد إلى الشبكة العصبية Neural network ليتم تدريب الشبكة العصبية على هذه النماذج في نمط التدريب Training phase ومن ثم تعطي قرار التمييز، في نمط الفحص testing phase ، حيث يتم اختبار النماذج التي تم تدريبها والنماذج غير المدربة كذلك. وكما مبين في الشكل (1.3) :





شكل (1.3) مخطط لمعالجة الإشارة الكلامية وتصنيفها

2.3 تفصيل النظام المقترح :

1.2.3 المعالجة الابتدائية Preprocessing :

إن إشارة الكلام المستخدمة في البحث المقترح أخذت بتردد 11.25 KHz. لأن أعلى تردد لإشارة الكلام هو بحدود 5 KHz، وبما أن عملية التقطيع تستوجب أن تكون بمعدل ضعف هذا التردد على الأقل. لذا تم استخدام التردد 11.25 KHz.

إن المعالجة الابتدائية تتضمن العمليات الآتية :

النمذجة sampling، والتأطير framing، وعملية تطبيق النافذة على كل إطار التي تسمى بـ windowing .

النموذج Sample تمثل قيمة من بيانات الإشارة الكلامية، وعملية النمذجة Sampling تعني تحويل الإشارة الكلامية المستمرة إلى إشارة رقمية، أما عملية التأطير Framing فتقوم بتحويل إشارة الكلام إلى إطارات frames، وكل إطار يحتوي على N من النماذج Samples، وكل إطارين متجاورين يفصلان بواسطة M، علماً أن $M < N$.

كل إطار من إطارات الإشارة الكلامية يحتوي على N من النماذج Samples ، فقد اختيرت قيمة $N=256$ ، حيث تمثل N عدد النماذج في الإطار الواحد والتي تساوي تقريباً 23 ملي ثانية.

الإطار الأول يحتوي على أول N من النماذج، والإطار الثاني يحتوي على M من النماذج بعد الإطار الأول، حيث M تحتوي على 128 عينة، وتتم عملية التراكب Overlapping بين الإطار الأول والثاني بـ $N-M$ من العينات، وكذلك بين الإطار الثاني والثالث، وهكذا تستمر العملية لبقية الإطارات في الإشارة الصوتية، والشكل (2.3) يوضح عملية التراكب :

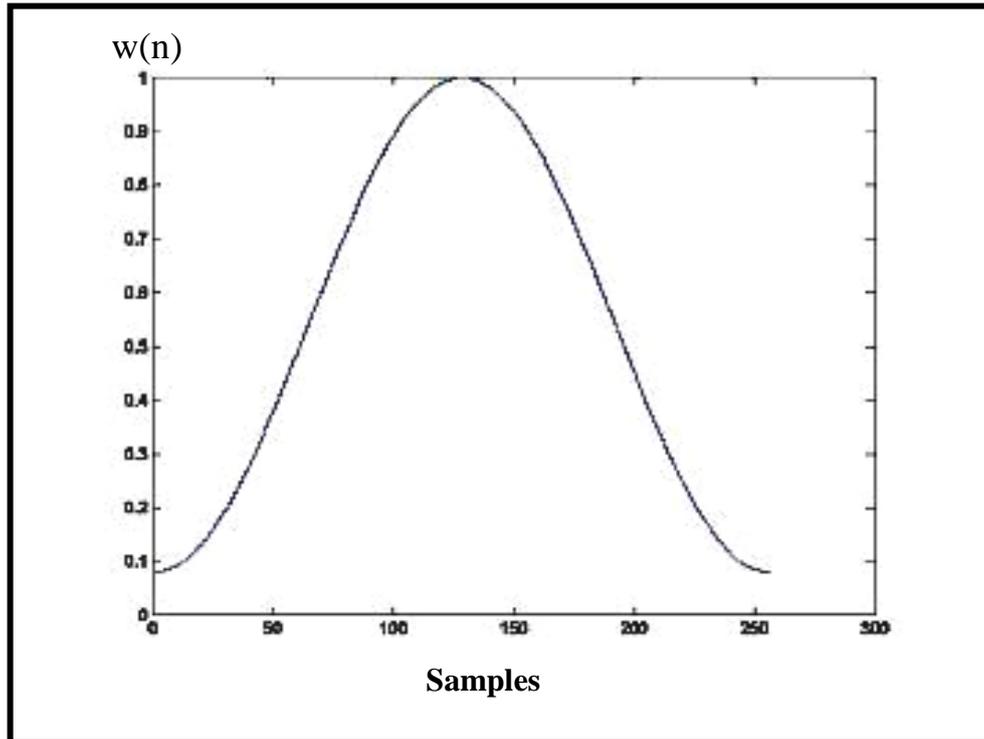


والخطوة التالية في مرحلة المعالجة الابتدائية هي تطبيق نافذة على كل إطار من إطارات الإشارة الصوتية التي تسمى بـ Windowing، وذلك لتحديد الإشارة لمدى محدود من الوقت . ولإجراء عملية تطبيق النافذة على الإطارات يمكن ضرب الإشارة بدالة ليست صفيرية لكن لها مدى محدوداً Finite range، تلك الدالة تسمى نافذة window. إن عملية اختيار النافذة يجب أن يلائم التطبيق ويعتمد على طبيعة البيانات.

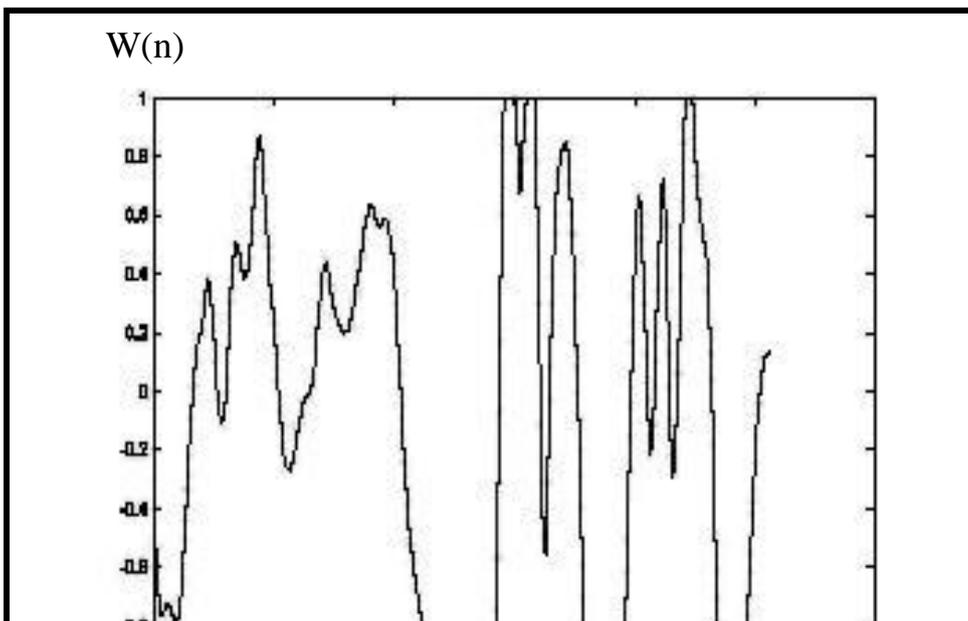
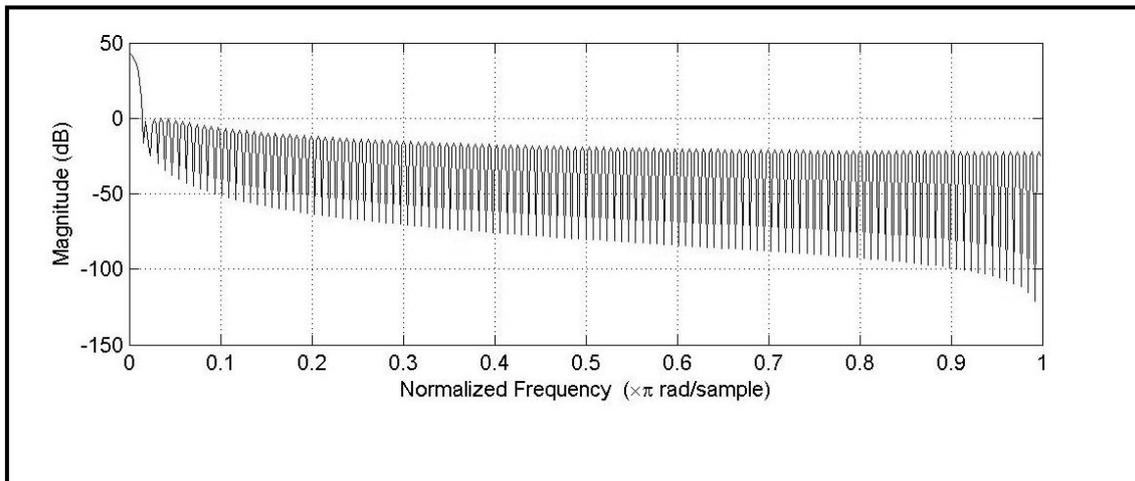
إن الغرض من عملية ضرب كل إطار بالنافذة هو لتقليل عدم اتصالية الإشارة Signal Discontinuities عند بداية كل إطار ونهايته.

وفي البحث المقترح تم استخدام نافذة هامنك Hamming window المبينة في الشكل (3.3) لمجال الوقت وفي الشكل (4.3) لمجال التردد، وتم تطبيقها على كل إطار في الإشارة الكلامية، كما موضح في الشكل (5.3) وذلك لتقريب بداية الإطار ونهايته من الصفر، ولكنها لا تكون صفراً . كما موضح في الشكل (6.3) والمعادلة (1.3) تمثل نافذة هامنك :

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \quad 0 \leq n \leq N-1 \quad \dots\dots\dots(1.3)$$

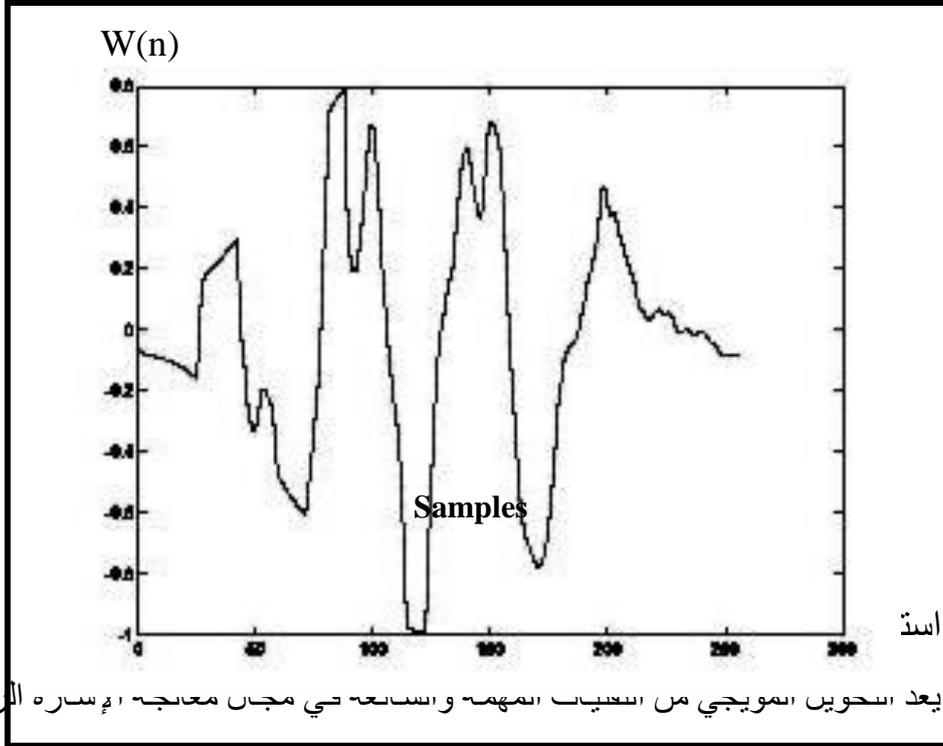


شكل (3.3) نافذة هامانك Hamming window لمجال الوقت Time domain



Samples

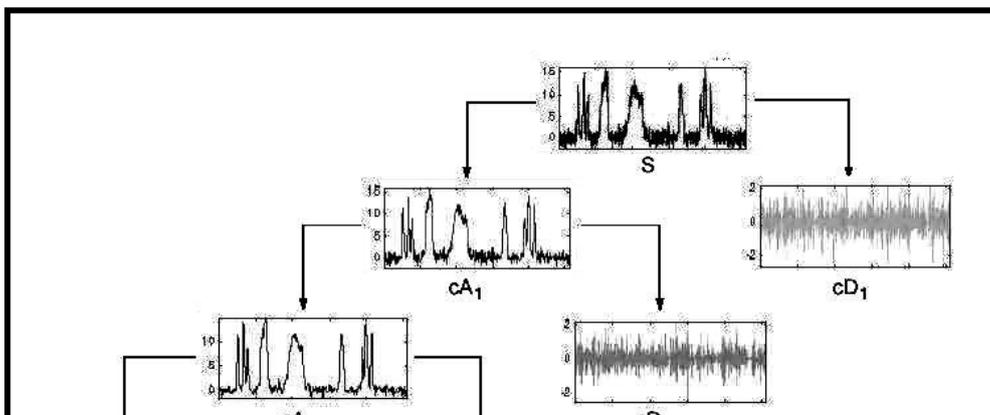
شكل (5.3) الشكل الموجي لإطار إشارة كلامية (كلمة الخير)



2.2.3 است

يعد السحويين الموجي من السعيات المهمة والساحة تي مجان معالجة الإساره الرقمية، وبالأخص الإشارات غير الثابتة Non stationary signals . وفي النظام المقترح تم استخدام التحويل الموجي كأداة لاستخلاص الصفات من الإشارة الكلامية، ومن اجل تمثيل الإشارة الكلامية يجب أولاً تحليل الإشارات باستخدام خوارزمية Mallat [57] . وطبقاً لخوارزمية Mallat فإنه يمكننا الحصول على التحويل الموجي التقليدي من خلال عملية التحليل (الإمرار الواطئ مع التنقيص Low pass & down sampling) .

إن هذا التحليل يستمر فقط على جزء التردد الواطئ لأنه الجزء الأكثر أهمية لاحتوائه على معظم معلومات الإشارة، والشكل (7.3) يبين شجرة تحليل الموجة wavelet : decomposition tree



شكل (7.3) شجرة تحليل الموجة لثلاث مستويات

علماً أن :

S : تمثل الإشارة الأصلية .

cA_i : تمثل معاملات التقريب Approximation coefficients .

cD_i : تمثل معاملات التفاصيل Details coefficients .

تعتمد إمكانية التحويل الموجي المتقطع لاستخلاص الصفات من الإشارة على الاختيار المناسب لدالة الموجة الأم [57] . علماً إن هناك الكثير من العوائل الشائعة لدوال الأساس للموجة مثل Harr ، Daubechies ، Coiflet ، Symlet ، Morlet ، Mexican Hat .

3.3 خطوات عملية استخلاص الصفات :

The Steps of Features Extraction process

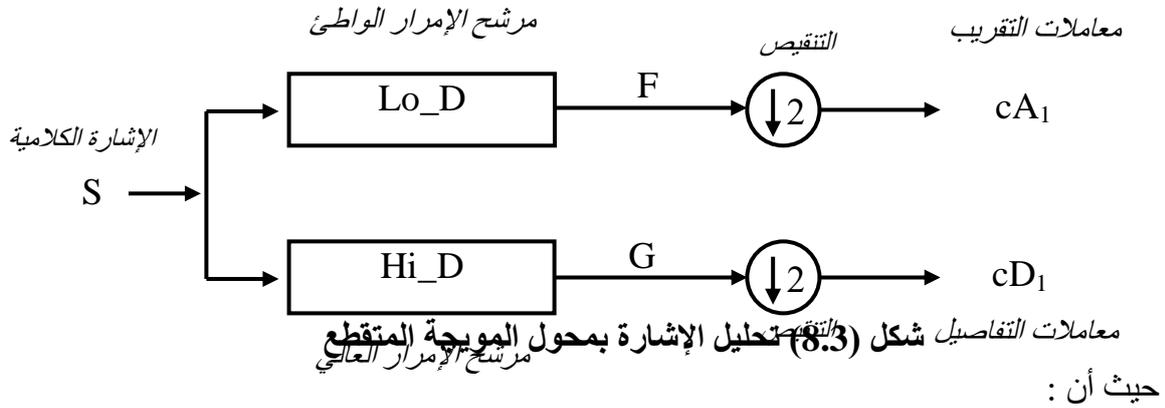
الخطوة (1) :

بعد الانتهاء من مرحلة المعالجة الابتدائية، تصبح إطارات الإشارة الكلامية جاهزة لمرحلة استخلاص الصفات وتطبيق التحويل الموجي على كل إطار .
إن كل إطار Frame من الكلمة المنطوقة يطبق عليه التحويل الموجي المتقطع ولثمانية مستويات من التحليل، وفي النظام المقترح طبقت عائلة db5 وذلك لإعطائها نتائج أفضل من بقية العوائل عند تحليلها ومقارنتها مع بقية العوائل، فقد تم إجراء أكثر من تجربة على عائلة Haar و db1 و db2 و db3 و db4 وآخرها كانت عائلة db5 فأعطت أفضل النتائج عند تطبيقها وإدخال النماذج الناتجة (متجهات الصفات) إلى الشبكة العصبية، فقد لوحظ إن الشبكة العصبية تستغرق وقت أقل في عملية التدريب عند استخدام عائلة db5 في عملية التحليل عن الوقت الذي تستغرقه عند استعمال العوائل (Haar, db1, db2, db3, db4) في عملية التحليل.

تم اختيار ثمانية مستويات من عملية التحليل للإشارة باستخدام DWT لأنها كافية لتحليل أغلب الإشارات الكلامية وانتفاء الحاجة لمستويات أكثر لعدم إستحصال فائدة عملية ولموسسة،

لأنه معظم القيم المستحصلة بعد هذا المستوى تكون قريبة جداً من الصفر وليس هناك تغيير ملحوظ في القيم.

وللتوضيح أكثر نأخذ الإشارة S التي طولها N ، فإن التحويل المويجي المتقطع DWT يتضمن $\log_2 N$ من المراحل على الأغلب. في المرحلة الأولى ينتج مجموعتين من المعاملات وهي: معاملات التقريب (cA_1) Approximation coefficients، ومعاملات التفاصيل (cD_1) Details coefficients. نحصل على هذين المتجهين عن طريق تلافيف convolving الإشارة S مع مرشح الإمرار الواطئ (LPF) low-pass filter للتقريب، وكذلك تلافيف الإشارة S مع مرشح الإمرار العالي (HPF) high-pass filter للتفاصيل. ثم تتبع عملية التنقيص down sampling للإشارة الناتجة بعد عملية تحليل الإشارة. وفي الشكل (8.3) توضيح أكثر للمرحلة الأولى.



حيث أن :

Lo_D تعني تلافيف الإشارة الكلامية مع مرشح الإمرار الواطئ.

Hi_D تعني تلافيف الإشارة الكلامية مع مرشح الإمرار العالي.

تعني الاحتفاظ بالعناصر ذات المواقع الزوجية .

F : الإشارة الناتجة من تلافيف الإشارة مع مرشح الإمرار الواطئ.

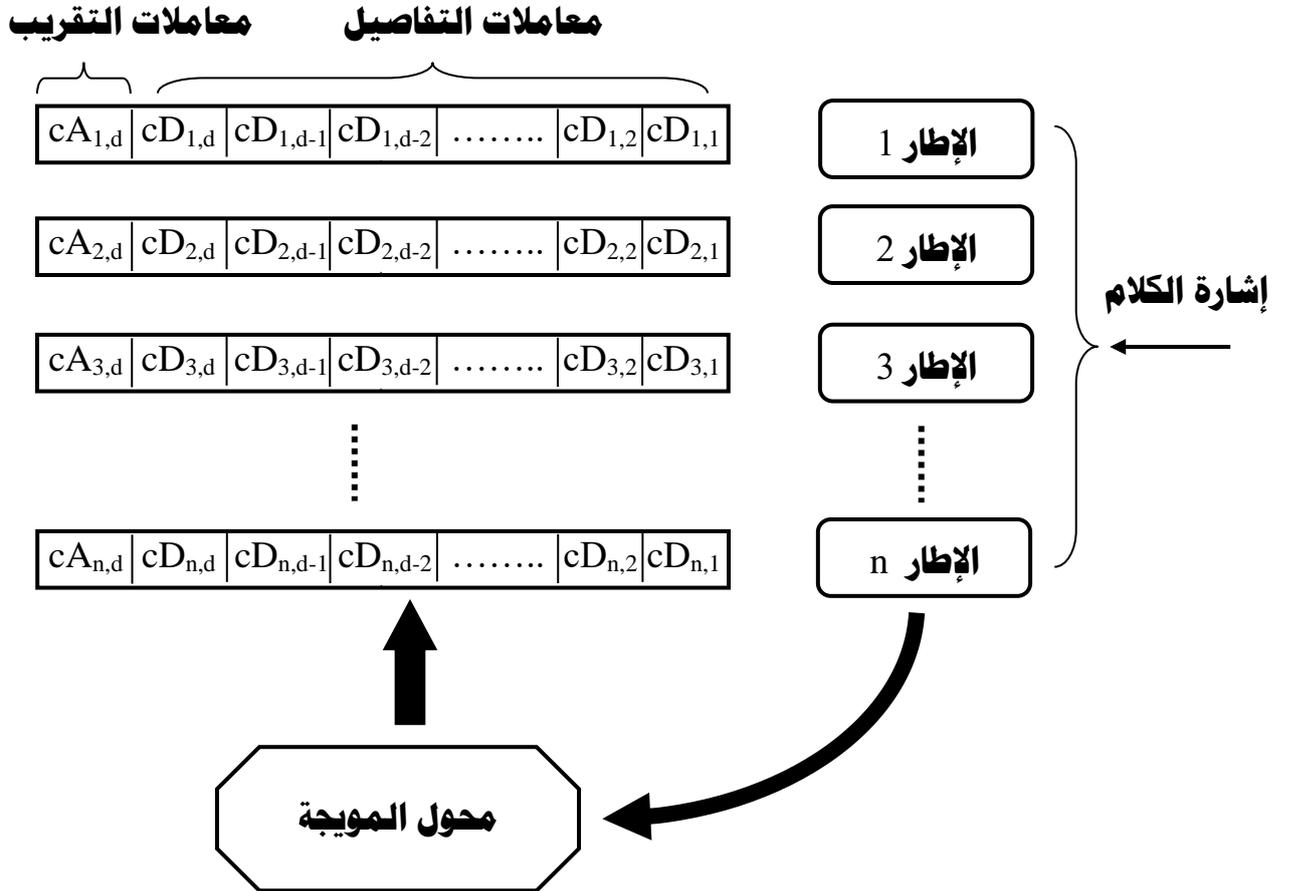
G : الإشارة الناتجة من تلافيف الإشارة مع مرشح الإمرار العالي.

إذا كانت N هي رتبة النوع المويجي، فإن طول كل مرشح filter يكون مساوياً لـ $2N$. وإذا كانت n هي طول الإشارة S ، فإن كل من الإشارات F و G لها طول يساوي $n+2N-1$ والمعاملات cA_1 و cD_1 لهما طول يساوي L ، حيث :

$$L = \text{floor}\left(\frac{n-1}{2}\right) + N$$

وفي المرحلة الثانية نقسم معاملات التقريب Approximation coefficients على قسمين وبالطريقة نفسها، إذ نقوم باستبدال الإشارة S بالإشارة cA_1 ، ثم ينتج عنه المعاملات cA_2 و cD_2 ، وهكذا لبقية المراحل.

بعد أن يتم تطبيق التحويل المويجي على كل إطار Frame من الإشارة الكلامية، تخزن معاملات التقريب ومعاملات التفاصيل في مصفوفة عدد صفوفها يساوي عدد الإطارات الموجودة في الإشارة الكلامية، وعدد أعمدها يساوي مجموع أطوال معاملات التقريب ومعاملات التفاصيل لكل مقطع، وبما إن التركيز يكون على معاملات التقريب فسوف تهمل معاملات التفاصيل في عملية التحليل. وكما موضح في الشكل (9.3) :



شكل (9.3) تطبيق التحويل المويجي لكل إطار من الإشارة الصوتية

علماً أن :

cA_i : تمثل معاملات التقريب.

cD_i : تمثل معاملات التفاصيل.

d : تمثل عدد مستويات التحليل.

وكمثال لعملية استخلاص الصفات من الإشارة الصوتية نأخذ الإشارة الآتية ونطبق عليها التحويل المويجي (عائلة db5) :

1	0	-1	2	1	3	-2	0
---	---	----	---	---	---	----	---

إن مرشحات التحليل Analysis Filters لعائلة db4 هي كالآتي :

Low pass filter of Decomposition :

[0.0033 -0.0126 -0.0062 0.0776 -0.0322 -0.2423 0.1384 0.7243 0.6038 0.1601]

High pass filter of Decomposition :

[-0.1601 0.6038 -0.7243 0.1384 0.2423 -0.0322 -0.0776 -0.0062 0.0126 0.0033]

Low pass filter of Reconstruction :

[0.1601 0.6038 0.7243 0.1384 -0.2423 -0.0322 0.0776 -0.0062 -0.0126 0.0033]

High pass filter of Reconstruction :

[0.0033 0.0126 -0.0062 -0.0776 -0.0322 0.2423 0.1384 -0.7243 0.6038 -0.1601]

سيتم التحليل فقط على جزء معاملات التقريب Approximation coefficients،

لعدم الحاجة لإجراء التحليل على جزء معاملات التفاصيل details coefficients .

Level 1 :

signal Filter	1	0	-1	2	1	3	-2	0
0.0033	0.0033	0	-0.0033	0.0066	0.0033	0.0099	-0.0066	0
-0.0126	-0.0126	0	0.0126	-0.0252	-0.0126	-0.0378	0.0252	0
-0.0062	-0.0062	0	0.0062	-0.0124	-0.0062	-0.0186	0.0124	0
0.0776	0.0776	0	-0.0776	0.1552	0.0776	0.2328	-0.1552	0
-0.0322	-0.0322	0	0.0322	-0.0644	-0.0322	-0.0966	0.0644	0
-0.2423	-0.2423	0	0.2423	-0.4846	-0.2423	-0.7269	0.4846	0
0.1384	0.1384	0	-0.1384	0.2768	0.1384	0.4152	-0.2768	0
0.7243	0.7243	0	-0.7243	1.4486	0.7243	2.1729	-1.4486	0
0.6038	0.6038	0	-0.6038	1.2076	0.6038	1.8114	-1.2076	0
0.1601	0.1601	0	-0.1601	0.3202	0.1601	0.4803	-0.3202	0

The results of convolution is :

[0.0033 -0.0126 -0.0095 0.0968 -0.0479 -0.3350 0.2752 0.9864 0.1938
-0.7815 0.3207 2.6716 2.8201 0.5229 -0.7273 -0.3202 0]

Down sampling is :

[-0.0126 0.0968 -0.3350 0.9864 -0.7815 2.6716 0.5229 -0.3202]

Level 2 :

signal Filter	-0.0126	0.0968	-0.3350	0.9864	-0.7815	2.6716	0.5229	-0.3202
0.0033	-4.158E-05	0.00031944	-0.0011055	0.00325512	-0.002579	0.00881628	0.00172557	-0.0010567
-0.0126	0.00015876	-0.0012197	0.004221	-0.0124286	0.0098469	-0.0336622	-0.0065885	0.00403452
-0.0062	0.00007812	-0.0006002	0.002077	-0.0061157	0.0048453	-0.0165639	-0.003242	0.00198524
0.0776	-0.0009778	0.00751168	-0.025996	0.07654464	-0.0606444	0.20731616	0.04057704	-0.0248475
-0.0322	0.00040572	-0.003117	0.010787	-0.0317621	0.0251643	-0.0860255	-0.0168374	0.01031044
-0.2423	0.00305298	-0.0234546	0.0811705	-0.2390047	0.18935745	-0.6473287	-0.1266987	0.07758446
0.1384	-0.0017438	0.01339712	-0.046364	0.13651776	-0.1081596	0.36974944	0.07236936	-0.0443157
0.7243	-0.0091262	0.07011224	-0.2426405	0.71444952	-0.5660405	1.93503988	0.37873647	-0.2319209
0.6038	-0.0076079	0.05844784	-0.202273	0.59558832	-0.4718697	1.61311208	0.31572702	-0.1933368
0.1601	-0.0020173	0.01549768	-0.0536335	0.15792264	-0.1251182	0.42772316	0.08371629	-0.051264

The results of convolution is :

[-0.0000 0.0005 -0.0022 0.0059 -0.0050 -0.0135 0.0350 -0.0312 0.0104
0.0962 -0.2695 0.2293 1.7710 1.8224 0.5115 -0.1096 -0.0513]

Down sampling is :

[0.0005 0.0059 -0.0135 -0.0312 0.0962 0.2293 1.8224 -0.1096]

Level 3 :

signal Filter	0.0005	0.0059	-0.0135	-0.0312	0.0962	0.2293	1.8224	-0.1096
0.0033	0.00000165	0.00001947	-4.455E-05	-0.000103	0.00031746	0.00075669	0.00601392	-0.0003617
-0.0126	-0.0000063	-7.434E-05	0.0001701	0.00039312	-0.0012121	-0.0028892	-0.0229622	0.00138096
-0.0062	-0.0000031	-3.658E-05	0.0000837	0.00019344	-0.0005964	-0.0014217	-0.0112989	0.00067952
0.0776	0.0000388	0.00045784	-0.0010476	-0.0024211	0.00746512	0.01779368	0.14141824	-0.008505
-0.0322	-0.0000161	-0.00019	0.0004347	0.00100464	-0.0030976	-0.0073835	-0.0586813	0.00352912
-0.2423	-0.0001212	-0.0014296	0.00327105	0.00755976	-0.0233093	-0.0555594	-0.4415675	0.02655608
0.1384	0.0000692	0.00081656	-0.0018684	-0.0043181	0.01331408	0.03173512	0.25222016	-0.0151686
0.7243	0.00036215	0.00427337	-0.0097781	-0.0225982	0.06967766	0.16608199	1.31996432	-0.0793833
0.6038	0.0003019	0.00356242	-0.0081513	-0.0188386	0.05808556	0.13845134	1.10036512	-0.0661765
0.1601	0.00008005	0.00094459	-0.0021614	-0.0049951	0.01540162	0.03671093	0.29176624	-0.017547

The results of convolution is :

[0.0000 0.0000 -0.0001 0.0001 0.0012 -0.0016 -0.0008 -0.0118 0.0150
0.1009 -0.1392 -0.3576 0.4979 1.4586 1.0577 0.2256 -0.0176]

Down sampling is :

[0.0000 0.0001 -0.0016 -0.0118 0.1009 -0.3576 1.4586 0.2256]

الخطوة (2) :

يتم حساب القوة Power أو الطاقة Energy لكل مقطع في كل مستوى من التحليل طبقا

للمعادلة (2.3) :

$$P_{norm} = \frac{\sum_{i=1}^n S_i^2}{n} \dots\dots\dots (2.3)$$

حيث إن :

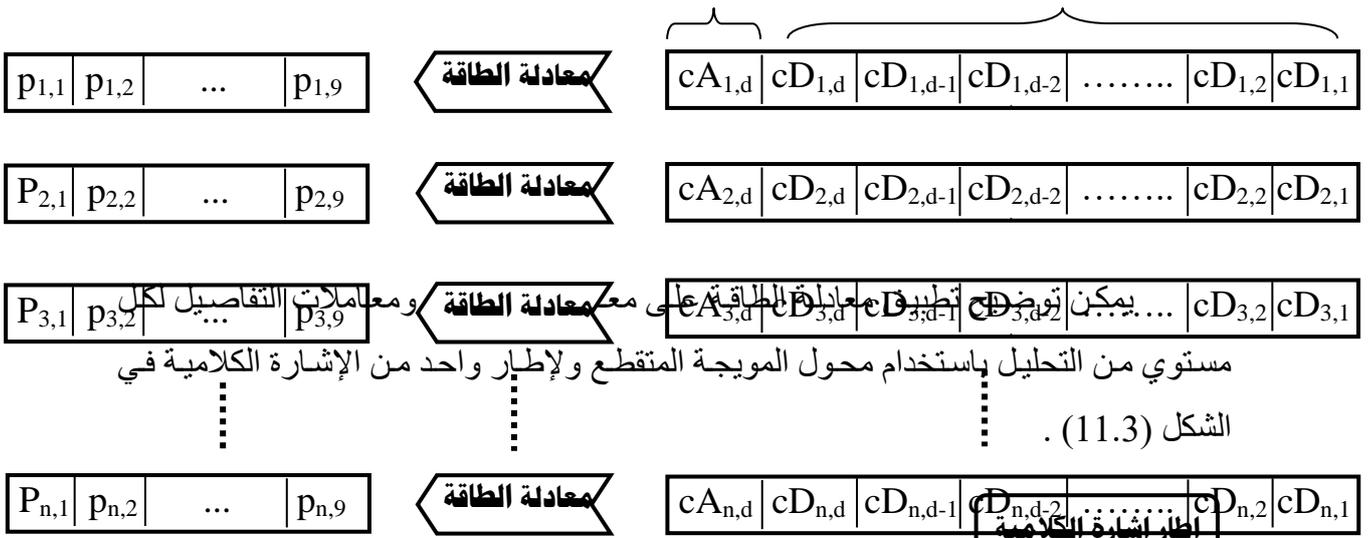
S_i : عنصر من مجموعة المعاملات، n : عدد العناصر .

يتم تطبيق المعادلة (2.3) على معاملات التقريب Approximation coefficients ومعاملات التفاصيل Details coefficients الناتجة في كل مستوى من التحليل لكل إطار من إطارات الإشارة الكلامية، ومن ثم نحصل على متجهات القوة Power vectors . إن عدد هذه المتجهات يساوي عدد الإطارات Frames في الإشارة الكلامية، أي متجه لكل إطار، وكل متجه يحتوي على تسعة قيم، هذا في حالة استخدام عائلة db5 ولثمانية مستويات من التحليل. كما في مبين في الشكل (10.3) .

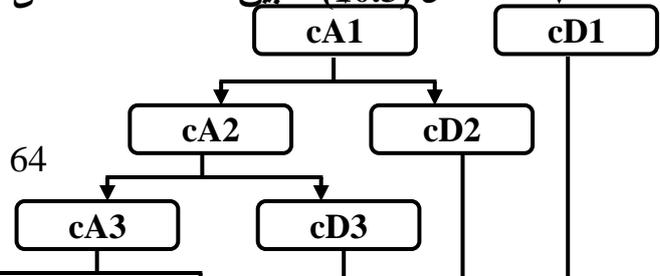
متجهات القوة

معاملات التقريب

معاملات التفاصيل



شكل (10.3) تطبيق معادلة الطاقة على معاملات التقريب ومعاملات التفاصيل



شكل (11.3) تطبيق معادلة الطاقة على إطار واحد من الإشارة الكلامية

الخطوة (3) :

بعد حساب متجهات القوة Power vectors لكل إطار في الإشارة الصوتية، يتم تطبيق معادلة التباين Variance Equation لكل عمود في مصفوفة متجهات القوة، لنحصل على متجه الصفات Features Vector الذي يتكون من تسعة قيم، حيث أن هذه القيم تمثل صفات الإشارة الصوتية المدخلة، كما مبين في الشكل (12.3) ، والتي ستكون مدخل إلى مصنف الشبكة العصبية Neural Network Classifier، ليتم تدريب الشبكة على نماذج الإدخال Input Patterns.

إن التباين Variance هو عبارة عن مربع الانحراف المعياري Standard deviation، حيث أن:

$$\text{Standard Deviation} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} ,$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

حيث أن :

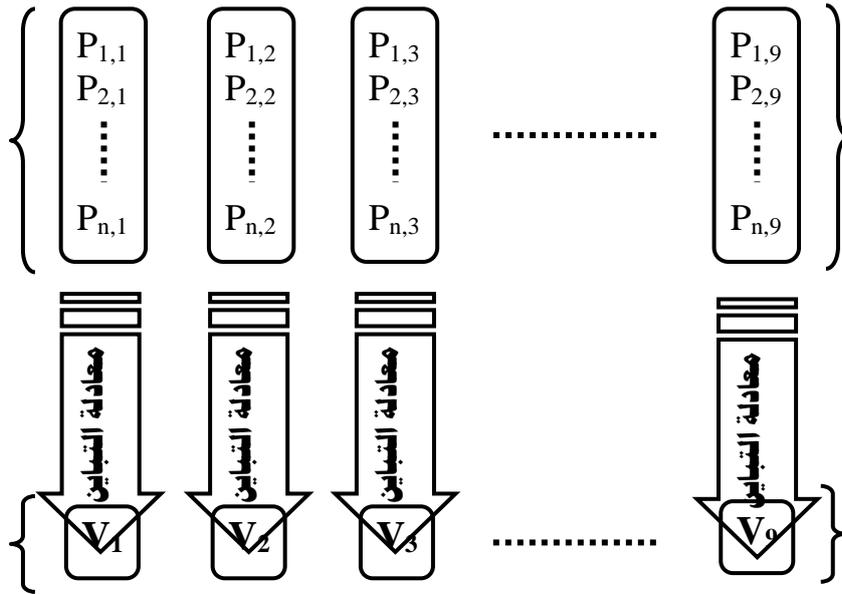
x : تمثل متجه القيم .

n : عدد القيم في المتجه .

$$\text{Variance} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 ,$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

متجهات القوة



متجه الصفات

شكل (12.3) تطبيق معادلة التباين Variance Eq لاستخراج متجه الصفات

نقوم بتكرار تطبيق عملية استخلاص الصفات لكل كلمة من الكلمات المستخدمة في البحث (صباح، مساء، الخير، ياسين، يمين، وفي، لندن) ولتسعة وعشرون متكلاً (15 ذكوراً و14 إناثاً)، وبعد ذلك يتم تخزين متجهات الصفات في ملف، ليتم تدريبها في الشبكة العصبية في طور التدريب Training phase، لغرض تكوين النماذج المرجعية ليتم تمييزها بعد ذلك في طور التمييز Recognition Phase .

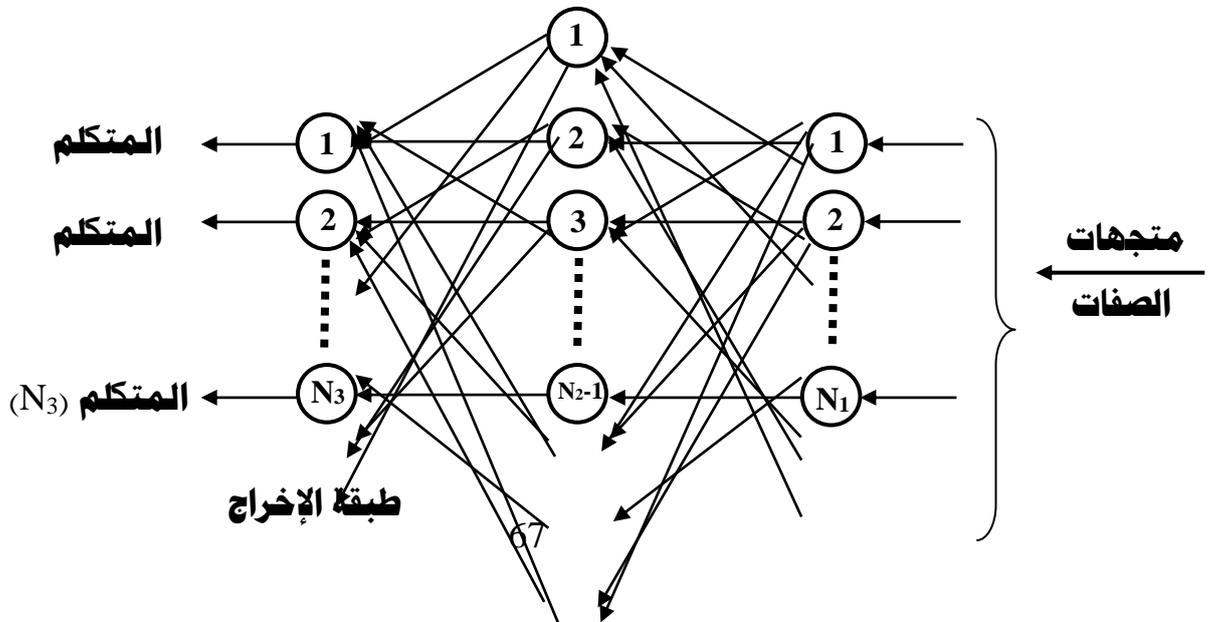
4.3 التصنيف باستخدام الشبكة العصبية :

The Classification using Neural Network :

استخدمت الشبكات العصبية Neural Network كمصنف classifier لتمييز نماذج الإدخال وذلك للاستفادة من خواص الشبكات العصبية التي تتميز بها مثل قابلية المعالجة المتوازية وكذلك لقدرتها على معالجة كمية كبيرة من البيانات وكفاءتها في التعامل مع البيانات كبيرة الحجم. وقد تم اختيار خوارزمية انسياب الخطأ خلفا Error Back propagation Algorithm لأنها تعتمد على إستراتيجية التعلم المراقب Supervised Learning وهي متعددة الطبقات ذات تغذية أمامية وملائمة جدا لتطبيقات تمييز النماذج Patterns Recognition، وفي مجالات عدة. كما إنها أثبتت دقة عالية في تمييز المتكلم فضلاً عن تمييز الفونيم المنفرد.

بالرغم من إن التدريب في هذه الشبكة بطيء تقريبا إلا إن التصنيف وتحديد النتائج يكون سريعاً نسبياً. كما إنها أثبتت نجاحا عاليا في المعالجة خلال الوقت الحقيقي Real time، كما إن هذه الخوارزمية تسمح بالتجريب حتى في بيئة تحتوي على ضوضاء حيث يتم فيها الاهتمام بالمتكلم أما في البيئة الخالية من الضوضاء فيكون الاهتمام بالإشارة الصوتية فقط [49].

وفي النظام المقترح تتكون الشبكة العصبية من ثلاث طبقات هي : طبقة الإدخال Input layer والطبقة المخفية Hidden Layer وطبقة الإخراج Output Layer، وقد تم استخدام دالة التنشيط السيجماوية Sigmoidal Activation Function، وكما موضح في المخطط العام لمصنف الشبكة العصبية في الشكل (13.3) :



طبقة الإدخال

(N₂)

الطبقة المخفية

شكل (13.3) مصنف الشبكة العصبية

حيث أن :

N₁: تمثل عدد خلايا الإدخال،

N₂: تمثل عدد الخلايا المخفية،

N₃: تمثل عدد خلايا الإخراج.

إن المدخلات Inputs (نماذج التدريب training pattern) إلى الشبكة العصبية Neural Network هي متجهات الصفات Features Vectors والمخزونة في ملف خاص.

5.3 تدريب الشبكة العصبية Training Neural Network :

هناك مرحلتين رئيسيتين تمر بها الشبكة العصبية هما : مرحلة التدريب Training

stage (تعلم الأوزان Learning weights)، ومرحلة التمييز Recognition stage .

من خلال التجربة، فإنه في مرحلة التدريب تجرى حسابات دقيقة، ولكن يمكن ان ينفذ مرة واحدة . أما في مرحلة التمييز فإنه يمكن أن ينفذ أكثر من مرة.

تم اختيار تدريب الشبكة العصبية باستخدام خوارزمية انسياب الخطأ خلفاً Error back propagation algorithm إذ أن هذه الخوارزمية تستطيع التعامل مع التغيرات الطفيفة على الأوزان ومعاملات الانحياز (Bias) عندما يكون الانحراف صغيراً جداً.

إن مرحلة التدريب في الشبكة العصبية يبدأ بتهيئة الأوزان والمحفات بعدها تتم عملية التدريب، وإعطاء قيم ابتدائية لمعامل التعلم Learning Factor ، وكذلك تحديد عدد الدورات القصوى Max Epoch ..

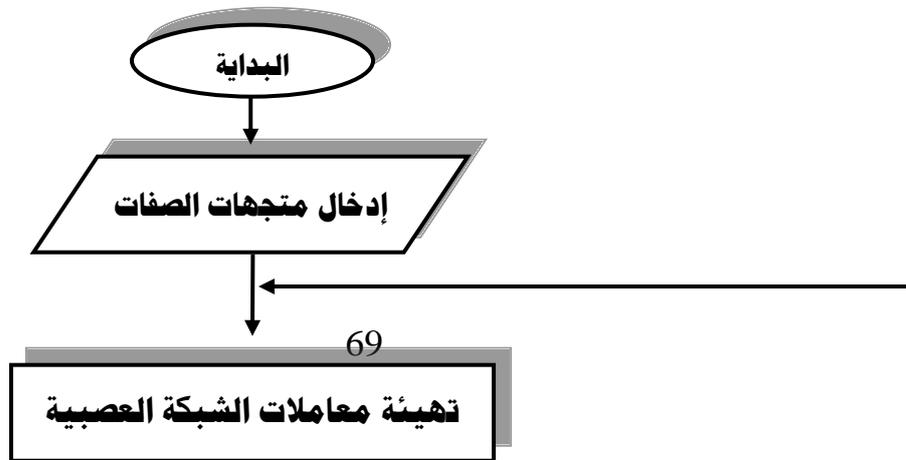
إن للشبكة العصبية المقترحة (9) خلايا للإدخال، أي إنها بعدد قيم متجه الصفات، و(20) خلية مخفية وقد تم اختيارها بعد إجراء عدد من التجارب، علماً إن هذا العدد من الخلايا المخبأة أعطى نتائج جيدة في عملية التمييز، إذ انه اثر إيجاباً في زيادة سرعة تدريب الشبكة العصبية، أما عدد خلايا الإخراج فهي (29) خلية إخراج، أي انه لكل متكلم خلية إخراج واحدة.

تجري العمليات الحسابية في الطبقة المخفية Hidden Layer ، ويتم احتساب الخطأ، ثم يتم تعديل الأوزان في كل تكرار. وقد تم استخدام الدالة السيجمودية Sigmoidal function كدالة تنشيط Activation function. أما أعلى عدد لدورات التدريب Max Epoch فقد حدد بـ 3000 دورة وقد تم اختيار هذا العدد بالتجربة.

أما نسبة الخطأ (أقل خطأ مسموح به) فهو 0.0006، أن الشبكة العصبية تستمر بعملية التدريب لنماذج الإدخال حتى تصبح قيمة متوسط مربع الخطأ Mean square error (MSE) بين قيمة الهدف Target والقيمة المقربة Approximated Value لنموذج الإدخال تصل إلى 6×10^{-4} ، عند هذه النقطة فان التدريب سوف يتوقف وتخزن الأوزان وكل معاملات الشبكة في الملف الذي سوف يستخدم في مرحلة التمييز، علماً أنه يستعمل للمقارنة مع نماذج الإشارات الكلامية غير المعروفة في نمط الفحص.

يمكن اختصار خطوات خوارزمية تدريب الشبكة العصبية كالآتي:

- إدخال نماذج الإشارات المراد تدريبها (متجهات الصفات) إلى الشبكة العصبية.
- تهيئة معاملات الشبكة العصبية (الأوزان والمحفزات) .
- البدء بعملية التدريب مع نماذج الإدخال حتى تصبح قيمة $MSE=6 \times 10^{-4}$ ، عند ذلك تتوقف عملية التدريب.
- خزن الأوزان وكل معاملات الشبكة التي تم التوصل إليها بعد عملية التدريب في الملف الأساسي Base file .
- استخدام معاملات التدريب في حساب إخراج الشبكة العصبية.
- خزن مخرجات الشبكة العصبية في ملف آخر لتستخدم في نمط الفحص وذلك للمقارنة مع الإشارات غير المعروفة. كما موضح في الشكل (14.3) .



شكل (14.3) مخطط لتدريب الشبكة العصبية

6.3 اتخاذ القرار :

بعد إنهاء خوارزمية انسياب الخطأ خلفاً يكون عملها بتحقيق احد شروط التوقف، هي إما الوصول إلى اقل خطأ مسموح به، أو تجاوز عدد التكرارات الحد الأقصى لدورات التعلم المسموح به دون وصول خطأ الشبكة إلى قيمة أقل من القيمة المطلوبة.

فإذا تم الوصول إلى قيمة خطأ أقل من القيمة المطلوبة فهذا يعني إن الشبكة استطاعت تدريب نفسها على الإشارة الصوتية المدخلة إليها وتميزها، أي نجاح الشبكة في عملية التعلم. أما إذا تحقق الشرط الثاني وهو عدم وصول الشبكة إلى الخطأ المقبول وتجاوز عدد التكرارات ما مسموح به ، فإن الشبكة تكون قد فشلت في عملية التدريب وتمييز الإشارة الداخلة.

النتائج والأعمال المستقبلية

1.4 النتائج العملية :

يتضمن هذا البند نتائج التطبيق العملي للتحويل المويجي، واستخلاص صفات الإشارة الكلامية لنماذج الاختبار، وكذلك استعراض النماذج المرجعية الناتجة من تدريب الشبكة العصبية باستخدام خوارزمية انسياب الخطأ خلفاً، وتقديم بعض نماذج الاختبار. كما تم عرض تجربتين عمليتين، فالتجربة الأولى تتعلق باستبدال التحويل المويجي بتقنية ترميز التنبؤ الخطي، وذلك للمقارنة مع تقنية التحويل المويجي المستخدمه في البحث المقترح.

وأما التجربة الثانية فقد استخدمت التقنيات نفسها (التحويل المويجي والشبكة العصبية) لكن بتغيير الكلمات التي يتم تدريب الشبكة عليها ، وكذلك الكلمات المستخدمة لاختبار الشبكة العصبية .

1.1.4 النتائج التحليلية :

تمثل الجداول (1.4)، (2.4)، (3.4)، (4.4)، (5.4)، (6.4)، (7.4) النتائج التحليلية الناتجة عن تطبيق التحويل المويجي المتقطع Discrete Wavelet Transform لتسعة وعشرين متكلماً، إذ إن كل متكلم ينطق عدداً من كلمات وهي (ياسين، صباح ، مساء ، وفي، الخير، يمين، لندن).

إن كل عمود في الجدول متكون من تسع قيم، تمثل متجه الصفات Features vector الناتج من استخدام محول المويجة لكلمة منطوقة، إن هذه المتجهات سوف يتم إدخالها إلى الشبكة العصبية ليتم تدريبها على هذه النماذج.

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.16005	0.087293	0.19044	0.089381	0.2021	0.71852	0.29628	0.054764
0.37662	0.39779	0.41678	0.15471	0.39912	0.23141	0.50137	0.37084
1	1	1	0.71907	0.87327	1	1	1
0.60845	0.30902	0.48196	1	1	0.32651	0.38413	0.19376
0.014338	0.017078	0.009465	0.026075	0.029639	0.008984	0.013465	0.013938
0.000603	0.00306	0.000832	0.000118	0.00119	0.002367	0.000328	4.77E-05
0.000806	0.000163	0.000908	0.000552	0.005235	0.000494	0.001285	1.46E-05
0.001098	5.95E-05	0.000662	0.000392	0.001483	0.000371	0.000789	0.000337
1.29E-05	3.04E-06	1.33E-06	5.12E-07	2.76E-05	1.19E-06	2.94E-06	6.33E-06

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.068147	0.077068	0.040497	0.2448	0.10318	0.076289	0.071984
0.19942	0.16183	0.18019	0.39231	0.15431	0.29276	0.41951
1	1	1	1	1	1	1
0.46837	0.19461	0.27982	0.59145	0.70091	0.60651	0.27695
0.001666	0.00645	0.013096	0.026802	0.015007	0.025701	0.020085
8.38E-05	7.17E-05	0.00075	0.001487	0.000378	0.001091	0.001515
7.86E-06	0.000142	5.61E-05	0.003562	1.66E-05	0.000226	0.000115
8.03E-05	0.000127	4.28E-05	0.002523	4.95E-05	0.002057	6.57E-06
1.65E-06	6.18E-08	7.38E-08	1.71E-05	5.52E-07	3.08E-05	1.12E-07

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.17461	0.033194	0.13738	0.10413	0.36372	0.20551	0.26255
0.35111	0.23985	0.22231	0.42213	0.66605	0.4453	0.47989
1	1	1	1	1	1	0.87963
0.6361	0.3046	0.56801	0.34284	0.42899	0.58105	1
0.03639	0.015353	0.031973	0.026945	0.009093	0.055688	0.008108
0.001293	0.001201	0.000779	0.003157	0.000199	0.00066	0.002793
0.000855	3.46E-05	0.000151	0.000522	0.006803	1.31E-05	0.006079
0.000531	0.000175	3.77E-05	0.001856	0.001728	2.00E-05	0.00117
3.01E-06	3.39E-06	9.02E-08	6.27E-05	1.45E-05	8.70E-08	1.22E-05

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.074573	0.31095	1	0.23303	0.084939	0.15621	0.045859
0.087921	0.3689	0.53174	0.34517	0.53765	0.33282	0.31651
0.86496	1	0.93299	1	1	0.98256	1
1	0.55016	0.46257	0.42194	0.47951	1	0.16633
0.02285	0.021455	0.016065	0.031741	0.021293	0.037724	0.004857
0.000382	0.000715	0.004199	0.000639	0.000623	0.00126	4.81E-05
3.84E-05	0.002709	0.000192	0.000265	2.95E-05	0.00951	1.54E-06
3.18E-05	0.000611	0.000217	0.0003	0.000101	0.000775	1.81E-05
3.53E-08	6.51E-06	1.21E-06	4.16E-07	1.57E-05	7.46E-06	1.67E-07

جدول (1-4) نتائج تحليل كلمة "ياسين"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.38142	0.33657	0.41758	0.33824	0.39433	0.019306	0.2826	0.05644
0.70072	0.66814	0.84806	1	0.6735	0.10141	0.52207	0.18713
1	1	1	0.76461	1	1	1	1

0.067983	0.28002	0.13682	0.007208	0.090774	0.050708	0.11993	0.30169
0.002395	0.006002	3.78E-03	3.92E-05	0.003434	0.001296	0.00103	0.001879
2.24E-03	0.00011	4.51E-04	0.000265	1.35E-03	2.36E-05	7.91E-05	3.31E-05
0.00109	5.91E-06	1.41E-04	9.82E-05	0.000317	2.56E-06	9.52E-05	0.000733
3.87E-06	3.74E-08	5.31E-07	1.12E-08	1.64E-06	6.61E-09	1.90E-07	1.47E-05
0.38142	0.33657	0.41758	0.33824	0.39433	0.019306	0.2826	0.05644

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.51128	0.33284	0.27241	0.20815	0.16751	0.27998	0.16998
0.42817	0.31905	0.39995	0.21578	0.26732	0.36724	0.17792
1	0.59086	0.36161	0.33058	0.44516	0.7325	0.58489
0.67047	1	1	1	1	1	1
0.0709	0.043044	0.43548	0.029935	0.075019	0.059937	0.1219
0.00058	0.001021	0.023707	0.002004	0.000708	0.001872	0.009037
2.48E-05	2.61E-05	4.57E-05	6.33E-04	2.99E-06	0.000991	0.000219
0.000345	4.11E-06	2.24E-05	1.32E-04	8.28E-06	0.000459	2.00E-06
3.91E-07	3.27E-09	2.45E-08	4.72E-07	3.75E-08	9.73E-07	4.88E-08

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.35985	0.13679	0.21969	0.1975	0.62303	0.26006	0.1846
0.38643	0.2248	0.20565	0.35764	0.39443	0.16301	0.35765
0.89054	0.33323	0.49979	0.9403	1	0.39196	0.7104
1	1	1	1	0.92117	1	1
0.23536	0.26843	0.12743	0.318	0.10073	0.29225	0.10366
0.005015	0.005692	0.003733	0.023741	0.001954	0.000947	0.007379
0.00039	0.000419	0.000473	0.000988	0.000366	1.49E-05	0.000218
0.000636	6.67E-06	4.65E-05	0.001655	0.000237	1.72E-05	4.56E-05
3.28E-06	2.08E-07	5.28E-07	1.27E-05	6.52E-08	5.19E-08	1.08E-07

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.24301	0.25281	1	0.34195	0.32727	0.51954	0.3918
0.093833	0.10455	0.32939	0.56133	0.69206	0.40199	0.61187
0.23738	0.13123	0.53136	1	1	0.58686	1
1	1	0.48574	0.88247	0.26774	1	0.57666
0.16391	0.04604	0.161	0.046935	0.058269	0.10965	0.41204
0.000657	0.000943	0.003069	0.001921	0.003594	0.002226	0.005208
1.72E-05	0.000536	9.37E-05	0.000376	0.000232	0.00485	9.61E-05
1.63E-05	0.000202	2.44E-06	0.000451	0.000507	0.000173	1.07E-05
1.82E-08	3.62E-06	1.82E-08	7.02E-07	4.37E-05	5.05E-07	1.17E-07

جدول (2-4) نتائج تحليل كلمة "صباح"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.14571	0.17582	0.25334	0.095197	0.21287	0.11615	0.26294	0.18636
0.48737	0.3633	0.46012	0.38281	0.26133	0.095815	0.29572	0.37486
1	1	1	1	0.50614	0.51754	0.24665	0.72002
0.82181	0.85922	0.73145	0.4728	1	1	1	1
0.085758	0.24445	0.16834	0.097249	0.046553	0.1276	0.061389	0.37792
0.002102	0.009488	0.002312	0.002333	0.001571	0.045489	0.001995	2.76E-03
0.000614	0.000143	0.000247	0.000214	0.0044	0.000593	0.000283	2.13E-04
0.000656	7.45E-05	0.000214	0.000513	0.002013	0.000155	0.000643	0.000221

2.91E-06	1.84E-06	6.34E-07	4.15E-07	2.60E-05	4.39E-07	3.80E-06	1.30E-05
----------	----------	----------	----------	----------	----------	----------	----------

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.27324	0.22186	0.30515	0.29038	0.25124	0.33866	0.16234
0.39579	0.14488	0.68544	0.32058	0.4458	0.59559	0.52065
1	0.36468	1	0.97517	0.96296	0.81536	1
0.83918	1	0.5778	1	1	1	0.50491
0.033141	0.068674	0.20899	0.076385	0.61894	0.088195	0.29025
2.89E-03	5.36E-04	0.026725	0.00238	0.003623	0.004569	0.00618
1.85E-05	0.000674	1.75E-04	0.005582	1.11E-04	0.000963	0.000233
6.63E-05	0.000226	1.49E-04	0.002144	5.86E-05	0.00531	1.63E-05
8.50E-07	1.16E-07	3.10E-07	1.53E-05	6.10E-07	4.23E-05	8.05E-08

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.27949	0.219	0.18916	0.14083	0.56058	0.23641	0.17258
0.49162	0.69501	0.2154	0.59294	0.71969	0.26558	0.33927
0.92665	0.92518	0.50628	1	1	0.53831	0.54548
1	1	1	0.41477	0.76175	1	1
0.049621	0.23797	0.10259	0.17702	0.066546	0.28155	0.040474
1.95E-03	0.018806	0.001751	0.025365	0.000331	0.001396	0.001586
0.001411	3.09E-04	2.95E-04	3.31E-04	8.87E-03	4.01E-05	0.002664
9.61E-04	5.09E-05	3.11E-05	5.00E-03	0.001455	4.01E-05	0.000462
4.17E-06	1.35E-06	3.93E-07	1.43E-04	8.89E-06	3.86E-07	4.86E-06

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.031069	0.35198	0.69432	0.47298	0.23988	0.49127	0.072592
0.022231	0.44314	0.39644	0.82163	0.75302	0.38763	0.53102
0.19749	0.39784	1	1	1	1	1
1	1	0.63699	0.79853	0.22258	0.63801	0.12402
0.20793	0.069076	0.056605	0.065117	0.026421	0.094592	0.016294
0.001672	0.000762	0.001942	0.001975	0.001401	0.003593	2.61E-04
1.10E-04	4.04E-03	8.90E-06	0.000416	2.49E-05	0.00641	1.24E-06
2.05E-05	1.38E-03	2.36E-05	1.81E-03	9.79E-05	6.02E-04	3.32E-06
3.09E-08	2.02E-05	3.65E-08	5.43E-06	6.89E-06	4.14E-06	1.43E-08

جدول (3-4) نتائج تحليل كلمة "مساء"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.29013	0.13467	0.29279	0.12782	0.32068	0.072561	0.31324	0.31608
0.4913	0.2392	0.39827	0.2503	0.41336	0.037668	0.28648	0.2681
1	1	1	1	0.63853	0.19131	0.74895	0.56233
0.60558	0.55064	0.68797	0.68365	1	1	1	1
0.010109	0.005873	0.016176	0.001867	0.014463	0.068123	0.01588	0.10665
0.001236	0.000234	0.001538	8.31E-06	0.000959	0.001009	0.000732	2.15E-03
3.20E-05	6.87E-05	6.95E-05	1.92E-06	4.91E-05	4.03E-05	6.24E-05	2.35E-04
6.76E-07	7.48E-07	9.40E-06	1.25E-07	1.35E-06	8.85E-07	1.19E-05	9.67E-06
7.83E-09	2.14E-08	1.67E-07	2.21E-10	1.79E-08	1.12E-08	2.61E-07	9.32E-08

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.11653	0.52485	0.24127	0.29551	0.24684	0.25433	0.24768

0.35798	0.38004	0.46372	0.37598	0.15051	0.73616	0.15659
0.75285	0.74536	1	1	0.46868	1	0.53036
1	1	0.71016	0.58671	1	0.78899	1
0.018649	0.024508	0.056368	0.017946	0.020464	0.012417	0.008348
1.84E-04	2.12E-04	0.000398	0.000962	8.67E-05	0.001064	0.00077
7.73E-06	3.26E-06	1.29E-06	5.33E-05	2.57E-05	8.57E-05	3.57E-05
3.31E-07	8.27E-08	3.90E-09	1.80E-06	4.03E-07	4.14E-06	2.29E-07
2.74E-09	1.13E-09	8.49E-11	4.61E-08	1.23E-09	1.71E-07	3.12E-09

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.25779	0.17334	0.20963	1	0.45711	0.55151	0.29466
0.26174	0.34415	0.32584	0.19341	0.59496	0.40341	0.50206
0.56877	1	1	0.40103	1	1	1
1	0.57113	0.98986	0.72133	0.29155	0.42726	0.42416
0.02875	0.025792	0.017618	0.032579	0.009585	0.077863	0.004136
1.01E-03	0.001394	0.000852	0.000809	0.000639	6.38E-05	0.003265
0.000225	3.48E-05	1.94E-04	3.18E-05	5.05E-05	6.87E-06	0.000163
1.54E-05	4.16E-07	8.09E-06	4.46E-07	3.25E-06	3.85E-07	6.92E-07
5.40E-08	2.78E-09	4.55E-08	1.23E-08	4.52E-07	3.67E-09	4.27E-09

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.27892	0.35457	0.61811	0.48299	0.084101	0.51295	0.28456
0.093	0.37221	0.18082	0.76805	0.46099	0.47214	0.47448
0.83393	1	0.42113	1	1	0.74397	0.7258
1	0.90985	1	0.45097	0.13666	1	1
0.073745	0.04103	0.024959	0.012983	0.002076	0.007797	0.053611
0.001111	0.0009	0.000754	0.000234	3.40E-05	0.00041	6.42E-04
9.33E-06	1.50E-04	4.23E-06	6.36E-05	1.90E-06	4.88E-06	1.56E-05
1.66E-07	1.25E-06	1.25E-07	2.40E-06	4.26E-08	8.78E-08	4.88E-08
4.89E-09	5.87E-08	9.49E-09	6.91E-09	1.53E-09	1.12E-09	9.28E-10

جدول (4-4) نتائج تحليل كلمة "وفي"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.16614	0.16157	0.18018	0.16375	0.40627	0.18062	0.10185	0.11392
0.45614	0.092446	0.32637	0.14847	0.36752	0.10571	0.18908	0.24302
0.95419	0.28105	0.50138	0.48443	0.66845	0.36409	0.38059	0.46604
1	1	1	1	1	1	1	1
0.011576	0.067232	0.047275	0.027895	0.043682	0.053017	0.028801	0.14495
0.000863	0.001195	0.00088	0.000815	0.003274	0.002219	0.000756	0.000918
0.00018	9.45E-05	0.000106	3.38E-05	0.000625	0.000246	5.54E-05	2.24E-05
6.85E-06	4.10E-07	2.13E-06	4.34E-07	2.12E-05	1.24E-06	2.91E-06	3.79E-07
3.18E-08	1.13E-08	7.72E-08	5.45E-09	6.25E-07	1.36E-08	2.51E-08	1.31E-08

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.14454	0.4964	0.10727	0.10349	0.23873	0.24418	0.090827
0.29388	0.47012	0.23266	0.2096	0.26902	0.17543	0.10596
1	1	1	0.64358	0.5922	0.55003	0.27836
0.22138	0.42937	0.38668	1	1	1	1
0.026716	0.010066	0.048204	0.017986	0.04398	0.014637	0.14821
0.00019	0.000263	0.001817	0.00194	6.16E-05	0.000635	0.003577

1.28E-05	2.24E-05	0.000105	0.000224	1.19E-05	8.03E-05	0.000144
5.60E-07	1.59E-06	1.53E-07	8.29E-06	9.98E-08	1.45E-06	1.53E-06
1.78E-09	6.89E-10	1.06E-09	2.68E-07	3.21E-10	1.17E-08	2.19E-08

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.15231	0.10583	0.13125	0.17906	0.49679	0.13444	0.57707
0.16413	0.14296	0.20799	0.17417	0.5621	0.114	0.49437
0.52873	0.42544	0.5939	0.54634	1	0.40087	1
1	1	1	1	0.45045	1	0.72372
0.061815	0.076036	0.020598	0.13102	0.01017	0.092523	0.012125
0.001763	0.006739	0.000983	0.003622	0.001963	0.000935	0.000984
0.000103	0.000138	9.93E-05	0.00017	0.000173	1.37E-05	0.000236
5.00E-06	3.26E-06	7.72E-06	2.49E-06	9.08E-06	2.93E-07	2.73E-05
5.34E-08	2.68E-08	3.23E-08	5.39E-08	7.33E-08	4.20E-09	8.13E-08

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.14314	0.11003	0.73561	0.56524	0.24376	0.14457	0.10938
0.062295	0.12626	0.526	0.80184	0.63044	0.30911	0.45241
0.22421	0.51531	1	1	1	0.52476	1
1	1	0.59714	0.71665	0.48993	1	0.28335
0.092442	0.015494	0.022944	0.038522	0.07604	0.046066	0.025628
0.000432	0.001193	0.001135	0.000638	0.000796	0.001187	0.000154
1.55E-05	0.000127	6.06E-05	9.37E-05	0.000126	0.000865	3.81E-06
1.32E-07	2.55E-06	2.96E-07	2.91E-06	9.55E-06	9.20E-06	2.43E-08
9.84E-09	4.14E-08	7.60E-10	6.99E-09	1.20E-08	2.73E-07	6.65E-10

جدول (5-4) نتائج تحليل كلمة "الخير"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.12549	0.11082	0.1467	0.11255	0.3549	0.11328	0.14368	0.078269
0.45575	0.5052	0.59826	0.20109	0.70293	0.21428	0.46166	0.47387
1	1	1	1	1	1	1	1
0.42232	0.2012	0.36473	0.9163	0.8329	0.51717	0.26663	0.17683
0.00599	0.000662	0.004641	0.003856	0.015339	0.004518	0.004094	0.001764
0.00052	0.000937	0.001873	3.72E-05	0.001205	0.000491	0.000356	2.73E-05
3.39E-05	0.000403	0.000193	1.00E-05	0.000401	0.000152	0.000186	1.45E-05
1.39E-06	1.20E-06	3.97E-06	5.64E-08	1.40E-05	7.65E-07	1.51E-06	5.03E-08
3.00E-08	1.98E-08	5.22E-08	1.29E-09	7.11E-07	6.00E-09	6.24E-09	9.12E-10

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.07365	0.21335	0.033353	0.15238	0.075614	0.11369	0.10647
0.19052	0.62514	0.157	0.59612	0.081741	0.46773	0.54096
1	1	1	1	1	1	1
0.41403	0.18092	0.22865	0.22205	0.65973	0.55181	0.13241
0.000611	0.001016	0.000303	0.003856	0.001756	0.007327	0.001062
2.94E-06	7.07E-05	2.84E-06	0.005047	5.11E-05	0.000701	0.000942
6.31E-07	1.19E-05	1.14E-06	0.001776	1.15E-05	3.97E-05	0.000175
1.36E-08	4.66E-08	9.93E-09	6.44E-05	1.22E-08	1.98E-06	2.72E-06
2.37E-10	6.59E-10	6.23E-11	2.13E-06	7.50E-10	5.40E-08	2.57E-08

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.07402	0.046411	0.10025	0.13865	0.25013	0.16013	0.13696
0.35503	0.44484	0.20907	0.42863	0.5674	0.45403	0.35877
1	1	1	1	1	1	1
0.24785	0.098013	0.42801	0.30789	0.35336	0.19406	0.24313
0.004576	0.002082	0.004736	0.00956	0.010407	0.000763	0.004411
0.000712	0.000109	0.00031	0.0021	0.000311	1.99E-05	0.000299
0.000107	1.30E-05	4.16E-05	0.000767	1.14E-05	2.87E-06	1.15E-05
2.05E-06	3.03E-08	1.15E-06	4.59E-06	5.68E-07	3.43E-08	1.18E-07
8.21E-09	7.68E-10	1.12E-08	3.14E-08	2.67E-09	5.33E-10	1.47E-09

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.067114	0.21823	0.21178	0.22887	0.24106	0.10203	0.045695
0.05464	0.29517	0.58368	0.52361	1	0.44362	0.50892
1	1	1	1	0.68686	1	1
0.53565	0.35019	0.13728	0.36816	0.13315	0.40704	0.086705
0.002424	0.003792	0.000485	0.00818	0.002192	0.003252	0.000431
6.11E-05	0.000217	0.000278	0.00031	5.00E-05	0.000566	2.86E-06
9.12E-06	1.06E-05	7.62E-05	0.000113	9.03E-06	6.33E-05	1.71E-06
4.23E-08	1.76E-07	3.40E-07	5.11E-07	5.16E-08	8.32E-07	5.64E-09
1.76E-09	2.17E-09	2.45E-10	5.85E-09	1.25E-09	9.87E-09	1.62E-10

جدول (6-4) نتائج تحليل كلمة "يمين"

المتكلم 8	المتكلم 7	المتكلم 6	المتكلم 5	المتكلم 4	المتكلم 3	المتكلم 2	المتكلم 1
0.22159	0.11464	0.2707	0.12389	0.16666	0.093548	0.19098	0.096943
0.58332	0.45586	0.45371	0.23334	0.5836	0.17266	0.45733	0.37124
1	1	1	1	0.88511	1	1	1
0.86093	0.45839	0.45867	0.52173	1	0.90285	0.7608	0.67419
0.012573	0.012236	0.020173	0.008095	0.025369	0.038214	0.019791	0.082431
0.00108	0.000817	0.002392	2.37E-05	0.001524	0.007559	0.000924	0.000633
0.000175	0.000133	0.00023	4.04E-06	0.000331	0.000879	6.29E-05	1.15E-05
2.62E-06	1.38E-06	9.54E-06	1.01E-07	2.12E-05	2.52E-06	7.96E-07	2.87E-07
4.70E-08	1.73E-08	1.67E-07	1.92E-09	6.06E-07	3.05E-08	6.53E-09	5.55E-09

المتكلم 15	المتكلم 14	المتكلم 13	المتكلم 12	المتكلم 11	المتكلم 10	المتكلم 9
0.046245	0.61197	0.050355	0.17345	0.10988	0.17924	0.076639
0.16912	0.73747	0.1768	0.55316	0.13986	0.42601	0.46961
1	1	1	1	1	1	1
0.2593	0.4401	0.21745	0.63899	0.85138	0.77522	0.40353
0.001009	0.004703	0.001803	0.014745	0.006115	0.023359	0.011042
4.94E-06	0.000216	5.61E-05	0.003467	3.24E-05	0.002093	0.000222
8.08E-07	2.95E-06	2.01E-05	0.001617	2.13E-05	7.27E-05	7.53E-05
1.61E-08	1.87E-07	2.45E-08	2.99E-05	1.31E-07	3.61E-06	5.94E-07
3.05E-10	9.61E-10	1.36E-10	1.01E-06	9.07E-10	2.54E-08	2.86E-09

المتكلم 22	المتكلم 21	المتكلم 20	المتكلم 19	المتكلم 18	المتكلم 17	المتكلم 16
0.080732	0.07195	0.13384	0.14638	0.45695	0.17623	0.23798
0.37592	0.57422	0.32286	0.46812	0.5423	0.24449	0.48346
1	1	0.93465	1	1	1	1
0.75505	0.23989	1	0.66945	0.4448	0.76017	0.41926
0.017597	0.024696	0.024384	0.061759	0.011515	0.10767	0.008418

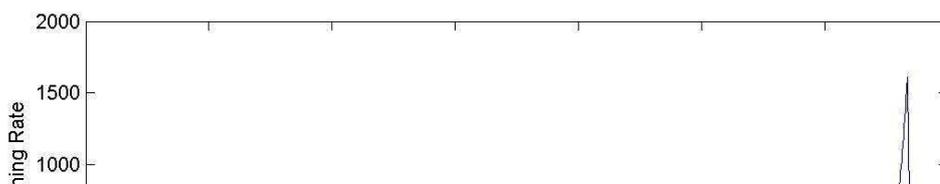
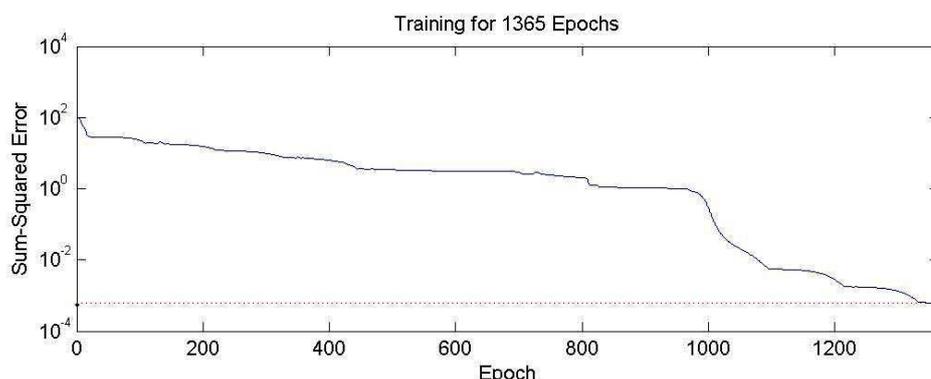
0.000697	0.001908	0.00185	0.002568	0.000554	0.00051	0.000354
2.38E-05	0.000183	7.24E-05	0.000505	1.87E-05	6.81E-06	1.36E-05
7.63E-07	1.25E-06	1.85E-06	5.33E-06	1.39E-06	9.69E-08	1.81E-07
8.94E-09	1.93E-08	1.48E-08	4.25E-08	1.36E-08	3.02E-09	2.71E-09

المتكلم 29	المتكلم 28	المتكلم 27	المتكلم 26	المتكلم 25	المتكلم 24	المتكلم 23
0.12659	0.23614	0.24107	0.2138	0.26719	0.25348	0.046755
0.10541	0.41071	0.57189	0.56901	1	0.7324	0.48328
1	1	1	1	0.69267	1	1
0.80607	0.82	0.3047	0.49059	0.16099	0.56089	0.12671
0.025506	0.01521	0.002097	0.030106	0.021386	0.013546	0.002219
0.001146	0.001643	0.002796	0.000817	0.000721	0.003325	3.16E-05
3.49E-05	5.68E-05	0.000223	2.67E-05	4.38E-05	0.001894	1.19E-06
8.56E-07	1.29E-06	1.84E-06	4.82E-07	6.52E-07	2.74E-05	1.59E-08
1.35E-08	3.19E-08	1.33E-08	8.10E-09	6.68E-09	4.59E-07	2.00E-10

جدول (7-4) نتائج تحليل كلمة "لندن"

2.1.4 نتائج طور التدريب :

يبدأ طور التدريب بتوليد الأوزان العشوائية التي تتراوح قيمتها بين (-1، 1)، وكذلك توليد المحفزات وتحديد القيم الابتدائية لعامل التعلم Learning factor، وأقصى عدد دورات Max Epoch، ونسبة الخطأ Error. بعدها يتم إدخال متجه الصفات لكل إشارة كلامية، وتستمر عملية المطابقة والتعديل على الأوزان وفقاً لخوارزمية انسياب الخطأ خلفاً المستعرضة في الفصل الثاني. والشكل (1.4) يوضح منحنى لعملية تدريب الشبكة العصبية. وأما المحصلة النهائية لهذا الطور فيمكن توضيحها بالجدول (8.4) التي تمثل الأوزان النهائية للشبكة العصبية لتسعة وعشرين متكلماً، التي تدربت الشبكة عليها ليتم استخدامها في طور الاختبار، عند المقارنة مع النماذج المرجعية Reference Template لـ (29) متكلماً.



شكل (1.4) عملية تدريب الشبكة العصبية

No.	Node 01	Node 02	Node 03	Node 04	Node 05	Node 06	Node 07	Node 08
1	0.15175	-1.0259	-2.6709	-3.4646	-1.1364	-2.2492	2.8077	-2.081
2	2.0021	0.30963	2.8124	-4.2015	-2.0072	-0.19116	1.2958	0.16787
3	2.1434	-0.97789	-2.8853	2.9803	-0.75038	2.1381	2.057	-1.8539
4	0.042922	-1.824	1.1002	3.3743	-0.75475	3.2125	-2.6991	-1.4649
5	-0.28273	-1.7026	2.1825	2.8091	-1.4169	-1.3691	-2.7655	-0.12814
6	2.0543	-1.2414	4.9476	-4.4194	-1.3335	-1.3712	-1.1516	-0.8586
7	1.3319	-1.0648	1.4622	-5.0546	-0.39001	0.35454	4.9887	-0.9039
8	1.109	-0.49913	0.66839	3.565	-0.30161	-3.598	-3.9161	-1.1565
9	2.0117	-1.242	-2.1312	-3.8105	-0.06751	0.98916	4.6981	-0.57957
10	1.5981	-0.46123	5.3725	-3.3686	-1.8618	5.8659	-2.0616	-0.58636
11	1.6642	-0.63215	-5.588	2.4654	-0.06262	-0.99196	1.9137	-1.1695
12	-0.12167	-0.78536	4.4538	3.8936	-1.9392	0.21801	3.9553	-1.755
13	1.1479	-0.96595	-2.4309	-1.8097	-1.6464	0.95409	-3.5192	-1.9163
14	-0.3124	-0.24256	-4.5698	0.13152	-2.1056	-1.6426	-1.8948	-0.43051
15	-0.05809	-1.8406	-3.768	-1.5727	-0.19172	2.849	-1.3292	-0.66832
16	1.7519	-0.1135	3.1199	4.1035	-1.3016	2.3845	-3.6383	-1.9041
17	0.41416	-1.3939	3.3012	1.7453	-0.026	-0.72682	3.619	-2.0937
18	0.001404	-1.7089	0.80782	-3.2174	0.15419	2.039	-2.7282	-1.2391
19	1.8073	-0.98478	-1.4921	-1.9533	-0.03412	-1.1489	2.2119	-1.3477
20	1.5318	-1.5552	3.7339	2.31	-1.3796	-1.5138	-2.7841	0.13456
21	1.8357	-1.0674	2.9225	-2.3649	-0.9973	0.17488	2.6307	-0.46212
22	2.1082	-1.1829	4.5025	-0.26393	-1.2856	-1.4951	-2.0043	-2.1095
23	1.784	-1.2349	-3.7349	-3.5809	-1.3833	-0.8471	-5.0534	-2.3247
24	-0.381	-0.81818	-0.48143	2.9239	-1.3145	3.6955	2.4279	-1.0665
25	0.61613	-0.60367	2.6805	-3.2553	-1.6761	-0.98771	-2.6429	-1.788
26	0.018029	-1.1051	-1.6876	-1.046	-1.5931	3.598	-3.467	-2.2474
27	2.1473	0.32742	-2.9207	3.093	-2.1482	1.5531	1.4281	-0.05531
28	1.0276	-1.0788	4.4735	2.5748	-2.286	-0.423	2.2606	-0.98741
29	1.7615	-0.24541	0.79379	3.7854	-0.66612	-1.1704	4.2611	-1.7963

No.	Node 09	Node 10	Node 11	Node 12	Node 13	Node 14	Node 15	Node 16
1	-0.09002	1.6056	0.3356	-0.79929	-3.8264	0.74612	3.6559	-1.6055
2	1.208	1.0497	0.607	0.49305	3.2771	1.4412	3.5729	0.58038
3	0.88045	0.041265	0.002527	-2.1338	-3.0118	0.46701	-2.1018	-0.39751
4	-0.3575	1.8851	1.2539	-2.2437	2.5696	0.62511	3.0963	-1.5565
5	0.95274	1.4758	0.8004	1.9204	2.9322	1.4818	-2.3296	-1.292
6	1.3286	0.029408	0.98	-0.59879	6.2319	2.2803	-2.8908	-1.0406
7	0.72519	-0.29295	1.8354	6.2467	0.014098	0.26099	-2.5156	-1.9413
8	0.66554	1.6269	1.5162	-3.1676	-1.8333	1.4857	-2.3394	-1.0253
9	1.6911	1.7149	1.6529	-1.4859	2.1694	0.27229	-4.2252	-0.18268
10	0.544	1.2057	1.2388	0.77912	-0.69957	-0.55601	-0.77063	-0.39671
11	1.7613	1.5611	0.66512	1.3144	-0.25294	0.99208	-4.386	-1.4884
12	1.2936	0.86868	1.658	3.04	-4.5459	1.8611	-2.1133	-1.1304
13	1.4999	0.48055	1.7239	-2.6125	-4.2288	-0.1735	1.6787	-0.2569
14	1.9939	-0.11737	2.018	2.9477	1.9195	-0.11244	4.153	-1.7133
15	0.89926	1.4546	0.57378	3.3515	-2.3813	0.21923	-2.8691	-0.29429
16	1.7095	1.3384	0.96671	2.8587	-2.8615	0.88349	3.2298	-1.0273
17	0.51415	1.8136	1.3219	1.488	3.0242	0.045312	4.0285	-0.72369
18	1.7122	0.22728	1.6984	1.2624	3.5328	-0.00457	4.3748	-1.4244
19	1.7588	1.2846	1.7583	-3.7824	3.5703	-0.23086	2.0056	-0.57925
20	1.0739	1.7963	1.7478	2.3982	-4.2184	0.44564	-2.474	-0.33784
21	0.93736	-0.05996	1.4091	-5.1138	-2.7873	2.2974	-2.0357	-0.13205
22	0.13689	1.0246	-0.31505	-6.3442	1.2717	0.20281	-2.9575	-0.58941
23	1.618	0.25882	1.3676	-1.4867	5.209	-0.01884	-2.1193	-2.299
24	1.6669	1.1621	1.3429	-1.2043	4.1268	0.4346	-2.1751	-1.3431
25	1.9028	1.3274	-0.01939	1.7849	-4.1245	1.5581	-1.8124	-1.8235
26	1.3857	1.3038	0.97068	-4.3174	-0.53505	1.2558	-2.8354	-1.0843
27	1.0813	0.31868	1.2374	-1.111	-1.4588	1.3949	4.3119	0.009658
28	0.25142	1.1474	0.033732	-0.75407	-3.9157	1.5984	4.666	-1.5193
29	0.35787	1.3628	0.664	1.7647	3.5755	1.5062	-1.7041	0.59174

No.	Node 17	Node 18	Node 19	Node 20	Bias
1	-0.83844	2.6358	-0.5154	1.0349	-2.6247
2	-0.681	3.3672	-0.00581	0.99273	-2.3378
3	-1.5844	5.3788	-1.2332	1.8826	-0.80695
4	-1.8862	3.8133	-1.3096	1.0058	1.6886
5	-0.06366	0.92816	-3.7478	1.5563	-1.8975
6	-0.26063	-4.5627	0.30372	2.6681	-2.3912
7	-0.99696	0.07593	0.27664	0.88318	-3.7539
8	-0.28044	-3.2457	1.2704	1.1608	-3.323
9	-1.0607	3.7273	-0.42422	1.7211	-1.0062
10	-0.57067	2.2274	0.37967	0.32048	-2.6058
11	-0.69765	-3.2957	1.8118	0.7518	-2.1856
12	-0.86354	-2.7885	-0.3184	2.3687	-2.1039
13	-0.66983	-2.6053	3.2789	0.76232	-3.6933
14	-0.87594	2.4424	0.44395	0.43738	-2.6093
15	-0.88305	2.2008	0.6498	0.57437	-3.2441
16	-1.6662	-1.8851	-0.9532	-0.24667	-0.5944
17	-1.8648	-3.6115	-0.80598	1.3127	-1.4904
18	-1.1754	-2.3345	-1.4875	1.282	-0.85016
19	0.024027	-3.1874	-1.1292	-0.00566	-2.5683
20	-0.52419	4.61	1.689	1.8656	-3.8263
21	-1.3882	-2.2082	0.84262	1.2297	-1.1891
22	-1.5386	3.9763	-1.1804	0.083462	-3.271
23	-1.436	0.48744	0.59938	0.63246	-1.2294
24	0.31255	-1.1181	-2.8931	-0.42208	-2.8025
25	-0.10327	-1.3807	-2.8732	1.8707	-0.0652
26	-1.8319	-1.6598	-3.3993	0.74928	1.1332
27	-0.93244	-2.1779	-1.7516	-0.05091	-1.8984
28	-0.03599	3.2188	-1.6558	0.19196	-1.9201
29	-1.3364	4.202	0.34022	1.2447	-3.5242

جدول (8.4) يوضح الأوزان النهائية والمحفزات للشبكة العصبية

3.1.4 نتائج طور الاختبار :

تم في هذا الطور استعراض 29 متكلماً (15 ذكوراً و14 إناثاً)، علماً أن لكل متكلم ملفين صوتيين جديدين لكلمتي "يمين" و "لندن" لم يتم تدريبها مسبقاً لإجراء عملية الاختبار وتقويم النظام، ومقارنتها مع النماذج المرجعية المخزونة مسبقاً ومن ثم تحديد النموذج الأقرب. يمثل الجدول رقم (9.4) نتائج اختبار الشبكة العصبية على النماذج المدخلة لكلمة "يمين"، إذ تم إدخال متجه الصفات Features Vector لكل متكلم إلى الشبكة العصبية، ومن خلال الجدول رقم (9.4) يبين ان الشبكة العصبية استطاعت التعرف على معظم النماذج المدخلة وتصنيفها، فقد تمكنت من التعرف على 27 نموذجاً من أصل 29 .

وأما الجدول رقم (10.4) فيمثل نتائج اختبار الشبكة العصبية على النماذج المدخلة لكلمة "لندن" ، تم إدخال متجه الصفات لكل متكلم إلى الشبكة العصبية، ومن خلال الجدول رقم (10.4)، يتضح لنا بان الشبكة العصبية استطاعت التعرف على معظم النماذج المدخلة وتصنيفها، وتمكنت من التعرف على 27 نموذجاً من أصل 29 .

ان صحة قرار الشبكة العصبية هي التي تحدد الاختبار صحيحاً أو غير صحيح اعتماداً على مطابقة الصنف مع الخلية العصبية الفائزة .

بعد هذه الاختبارات تم تقويم النظام على وفق القانون الآتي :

$$100 \times \frac{\text{عدد المحاولات الناجحة}}{\text{عدد المحاولات الكلي}}$$

No.	Output 01	Output 02	Output 03	Output 04	Output 05	Output 06	Output 07	Output 08
1	0.9969	0.0009	0.0008	0.0000	0.0000	0.0000	0.0000	0.0000
2	0.0015	0.9970	0.0000	0.0015	0.0000	0.0002	0.0160	0.0000
3	0.0012	0.0000	0.9973	0.0000	0.0000	0.0000	0.0000	0.0000
4	0.0000	0.0002	0.0002	0.9695	0.0006	0.0000	0.0000	0.0000
5	0.0000	0.0000	0.0000	0.0001	0.9972	0.0010	0.0000	0.0001
6	0.0000	0.0003	0.0000	0.0000	0.0020	0.9963	0.2591	0.0000
7	0.0000	0.0004	0.0000	0.0000	0.0000	0.0014	0.1025	0.0000
8	0.0000	0.0000	0.0000	0.0000	0.0010	0.0001	0.0000	0.9972

9	0.0013	0.0002	0.0019	0.0000	0.0000	0.0000	0.0976	0.0000
10	0.0000	0.0004	0.0000	0.0005	0.0000	0.0006	0.0002	0.0000
11	0.0000	0.0000	0.0018	0.0000	0.0000	0.0000	0.0000	0.0007
12	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0004
13	0.0019	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0011
14	0.0014	0.0006	0.0000	0.0631	0.0000	0.0000	0.0000	0.0000
15	0.0000	0.0000	0.0013	0.0000	0.0000	0.0000	0.0000	0.0000
16	0.0000	0.0000	0.0000	0.0035	0.0012	0.0000	0.0000	0.0010
17	0.0000	0.0011	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
18	0.0000	0.0008	0.0000	0.0009	0.0000	0.0008	0.0000	0.0000
19	0.0011	0.0003	0.0000	0.0000	0.0000	0.0001	0.0001	0.0000
20	0.0000	0.0000	0.0000	0.0000	0.0012	0.0000	0.0000	0.0013
21	0.0012	0.0000	0.0004	0.0000	0.0000	0.0001	0.0117	0.0015
22	0.0000	0.0010	0.0000	0.0000	0.0016	0.0004	0.0222	0.0006
23	0.0000	0.0000	0.0000	0.0000	0.0000	0.0015	0.0000	0.0000
24	0.0000	0.0000	0.0000	0.0000	0.0016	0.0000	0.0000	0.0000
25	0.0000	0.0000	0.0000	0.0000	0.0003	0.0013	0.0000	0.0006
26	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0001
27	0.0004	0.0000	0.0012	0.0001	0.0000	0.0000	0.0000	0.0000
28	0.0011	0.0018	0.0018	0.0003	0.0000	0.0000	0.0000	0.0000
29	0.0000	0.0008	0.0010	0.0003	0.0015	0.0000	0.0004	0.0000
	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	غير مطابق	مطابق

No.	Output 09	Output 10	Output 11	Output 12	Output 13	Output 14	Output 15	Output 16
1	0.0015	0.0000	0.0000	0.0000	0.0017	0.0000	0.0000	0.0000
2	0.0013	0.0004	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
3	0.0011	0.0000	0.0010	0.0000	0.0000	0.0000	0.0003	0.0000
4	0.0000	0.0006	0.0000	0.0000	0.0000	0.0000	0.0000	0.0013
5	0.0000	0.0000	0.0000	0.0000	0.0000	0.0001	0.0000	0.0006
6	0.0000	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
7	0.0007	0.0000	0.0000	0.0013	0.0000	0.0000	0.0006	0.0000
8	0.0000	0.0000	0.0013	0.0007	0.0012	0.0000	0.0000	0.0010
9	0.9965	0.0000	0.0000	0.0000	0.0000	0.0000	0.0001	0.0000

10	0.0000	0.9966	0.0000	0.0000	0.0000	0.0000	0.0017	0.0014
11	0.0008	0.0000	0.9966	0.0024	0.0000	0.0003	0.0009	0.0000
12	0.0000	0.0000	0.0019	0.9962	0.0000	0.0000	0.0000	0.0019
13	0.0000	0.0000	0.0000	0.0000	0.9972	0.0000	0.0008	0.0000
14	0.0000	0.0000	0.0000	0.0000	0.0001	0.6532	0.0014	0.0000
15	0.0002	0.0017	0.0004	0.0000	0.0003	0.1444	0.9972	0.0000
16	0.0000	0.0001	0.0000	0.0015	0.0000	0.0000	0.0000	0.9968
17	0.0000	0.0000	0.0000	0.0014	0.0000	0.0000	0.0000	0.0009
18	0.0000	0.0005	0.0000	0.0000	0.0007	0.0000	0.0000	0.0018
19	0.0017	0.0000	0.0000	0.0000	0.0004	0.0000	0.0000	0.0000
20	0.0000	0.0002	0.0000	0.0005	0.0000	0.0003	0.0017	0.0000
21	0.0008	0.0000	0.0001	0.0015	0.0005	0.0000	0.0000	0.0000
22	0.0021	0.0017	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
23	0.0025	0.0000	0.0000	0.0000	0.0001	0.0202	0.0012	0.0000
24	0.0000	0.0000	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000
25	0.0000	0.0010	0.0000	0.0000	0.0000	0.0000	0.0004	0.0004
26	0.0000	0.0005	0.0000	0.0000	0.0019	0.0000	0.0000	0.0000
27	0.0000	0.0000	0.0006	0.0000	0.0011	0.0000	0.0000	0.0016
28	0.0000	0.0000	0.0000	0.0008	0.0000	0.0000	0.0000	0.0013
29	0.0015	0.0000	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000
	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق

No.	Output 17	Output 18	Output 19	Output 20	Output 21	Output 22	Output 23	Output 24
1	0.0000	0.0000	0.0013	0.0000	0.0001	0.0000	0.0000	0.0000
2	0.0013	0.0010	0.0004	0.0000	0.0000	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000	0.0001	0.0000	0.0000	0.0000	0.0001
4	0.0000	0.0004	0.0000	0.0000	0.0000	0.0000	0.0000	0.0007
5	0.0000	0.0001	0.0000	0.0012	0.0000	0.0017	0.0000	0.0013
6	0.0005	0.0008	0.0007	0.0000	0.0005	0.0001	0.0020	0.0000
7	0.0001	0.0000	0.0000	0.0000	0.0022	0.0000	0.0000	0.0000
8	0.0000	0.0000	0.0000	0.0017	0.0002	0.0400	0.0003	0.0000
9	0.0000	0.0000	0.0014	0.0000	0.0004	0.0000	0.0022	0.0001
10	0.0000	0.0011	0.0000	0.0005	0.0003	0.0004	0.0000	0.0000

11	0.0000	0.0000	0.0002	0.0000	0.0000	0.0000	0.0006	0.0010
12	0.0009	0.0000	0.0000	0.0004	0.0011	0.0033	0.0000	0.0000
13	0.0000	0.0000	0.0000	0.0000	0.0001	0.0000	0.0001	0.0000
14	0.0000	0.0014	0.0001	0.0000	0.0000	0.0000	0.0007	0.0000
15	0.0000	0.0000	0.0000	0.0007	0.0000	0.0000	0.0005	0.0000
16	0.0001	0.0016	0.0000	0.0007	0.0000	0.0015	0.0000	0.0000
17	0.9972	0.0005	0.0014	0.0000	0.0000	0.0000	0.0000	0.0011
18	0.0003	0.9975	0.0011	0.0000	0.0000	0.0000	0.0000	0.0000
19	0.0009	0.0014	0.9973	0.0000	0.0001	0.0000	0.0008	0.0009
20	0.0000	0.0000	0.0000	0.9967	0.0000	0.0006	0.0000	0.0000
21	0.0000	0.0000	0.0003	0.0000	0.9972	0.0005	0.0000	0.0000
22	0.0000	0.0000	0.0000	0.0005	0.0008	0.0001	0.0010	0.0000
23	0.0000	0.0004	0.0005	0.0000	0.0000	0.0000	0.9965	0.0000
24	0.0000	0.0001	0.0002	0.0000	0.0000	0.0000	0.0000	0.9975
25	0.0000	0.0002	0.0000	0.0001	0.0006	0.1609	0.0000	0.0000
26	0.0000	0.0009	0.0000	0.0000	0.0000	0.0001	0.0004	0.0020
27	0.0001	0.0004	0.0011	0.0000	0.0000	0.0000	0.0000	0.0010
28	0.0007	0.0000	0.0000	0.0009	0.0000	0.0000	0.0000	0.0000
29	0.0018	0.0000	0.0000	0.0005	0.0000	0.0000	0.0000	0.0009
	مطابق	مطابق	مطابق	مطابق	مطابق	غير مطابق	مطابق	مطابق

No.	Output 25	Output 26	Output 27	Output 28	Output 29
1	0.0000	0.0000	0.0002	0.0017	0.0000
2	0.0000	0.0000	0.0000	0.0006	0.0015
3	0.0000	0.0000	0.0013	0.0019	0.0000
4	0.0000	0.0000	0.0001	0.0011	0.0001
5	0.0014	0.0000	0.0000	0.0000	0.0012
6	0.0014	0.0000	0.0000	0.0000	0.0000
7	0.0013	0.0000	0.0000	0.0000	0.0021
8	0.0011	0.0002	0.0000	0.0000	0.0000
9	0.0000	0.0000	0.0000	0.0000	0.0001
10	0.0005	0.0005	0.0000	0.0001	0.0000
11	0.0000	0.0000	0.0008	0.0000	0.0000

12	0.0000	0.0000	0.0000	0.0013	0.0001
13	0.0000	0.0018	0.0003	0.0000	0.0000
14	0.0000	0.0000	0.0000	0.0000	0.0000
15	0.0006	0.0004	0.0000	0.0000	0.0000
16	0.0001	0.0000	0.0011	0.0003	0.0000
17	0.0000	0.0000	0.0004	0.0004	0.0015
18	0.0001	0.0011	0.0000	0.0000	0.0000
19	0.0000	0.0005	0.0011	0.0000	0.0000
20	0.0000	0.0000	0.0000	0.0014	0.0016
21	0.0001	0.0006	0.0000	0.0002	0.0000
22	0.0000	0.0001	0.0000	0.0000	0.0000
23	0.0000	0.0019	0.0000	0.0000	0.0000
24	0.0000	0.0016	0.0017	0.0000	0.0001
25	0.9975	0.0013	0.0000	0.0000	0.0000
26	0.0017	0.9970	0.0001	0.0000	0.0000
27	0.0000	0.0001	0.9975	0.0004	0.0000
28	0.0000	0.0000	0.0010	0.9967	0.0003
29	0.0000	0.0000	0.0000	0.0005	0.9970
	مطابق	مطابق	مطابق	مطابق	مطابق

جدول (9.4) نتائج اختبار كلمة "يمين"

في الجدول الآتي نتائج اختبار كلمة "الندن" :

No.	Output 01	Output 02	Output 03	Output 04	Output 05	Output 06	Output 07	Output 08
1	0.0011	0.0012	0.0001	0.0008	0.0000	0.0003	0.0000	0.0000
2	0.2159	0.9976	0.0016	0.0004	0.0000	0.0001	0.0000	0.0000
3	0.0031	0.0014	0.9971	0.0002	0.0000	0.0000	0.0000	0.0000
4	0.0000	0.0004	0.0018	0.9966	0.0000	0.0014	0.0000	0.0000
5	0.0000	0.0000	0.0000	0.0006	0.9421	0.0001	0.0000	0.0000
6	0.1362	0.0000	0.0000	0.0021	0.0000	0.9966	0.0000	0.0007
7	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.9969	0.0001
8	0.0000	0.0000	0.0000	0.0000	0.0040	0.0002	0.0010	0.9974
9	0.0001	0.0000	0.0000	0.0000	0.0000	0.0012	0.0017	0.0000
10	0.0000	0.0000	0.0000	0.0000	0.0272	0.0000	0.0000	0.0015
11	0.0000	0.0000	0.0011	0.0000	0.0001	0.0000	0.0000	0.0000
12	0.0000	0.0003	0.0000	0.0000	0.0070	0.0000	0.0013	0.0006
13	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0009	0.0000

14	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
15	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
16	0.0000	0.0000	0.0000	0.0018	0.0003	0.0000	0.0000	0.0000
17	0.0000	0.0009	0.0000	0.0009	0.0000	0.0000	0.0000	0.0008
18	0.0000	0.0002	0.0000	0.0000	0.0000	0.0000	0.0000	0.0016
19	0.8054	0.0016	0.0000	0.0000	0.0000	0.0001	0.0017	0.0009
20	0.0000	0.0000	0.0000	0.0000	0.0004	0.0000	0.0014	0.0000
21	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0005	0.0000
22	0.0920	0.0000	0.0014	0.0000	0.0000	0.0000	0.0017	0.0000
23	0.0000	0.0000	0.0000	0.0000	0.0000	0.0010	0.0000	0.0013
24	0.0000	0.0000	0.0000	0.0000	0.0000	0.0003	0.0000	0.0004
25	0.0003	0.0000	0.0000	0.0000	0.0070	0.0011	0.0000	0.0007
26	0.0000	0.0000	0.0000	0.0018	0.0000	0.0000	0.0000	0.0000
27	0.0006	0.0000	0.0014	0.0000	0.0000	0.0000	0.0000	0.0000
28	0.0000	0.0003	0.0006	0.0000	0.0000	0.0000	0.0000	0.0000
29	0.0000	0.0000	0.0008	0.0003	0.0000	0.0000	0.0001	0.0000
	غير مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق

No.	Output 09	Output 10	Output 11	Output 12	Output 13	Output 14	Output 15	Output 16
1	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0013
2	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0007	0.0000	0.0000	0.0000	0.0000	0.0000
4	0.0000	0.0000	0.0001	0.0000	0.0000	0.0000	0.0000	0.0013
5	0.0005	0.0005	0.0003	0.0009	0.0000	0.0000	0.0000	0.0010
6	0.0015	0.0000	0.0000	0.0000	0.0000	0.0000	0.0001	0.0000
7	0.0014	0.0000	0.0000	0.0000	0.0008	0.0000	0.0000	0.0000
8	0.0005	0.0010	0.0000	0.0000	0.0001	0.0000	0.0000	0.0000
9	0.9965	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
10	0.0000	0.9971	0.0000	0.0000	0.0006	0.0000	0.0000	0.0021
11	0.0000	0.0000	0.9936	0.0002	0.0000	0.0000	0.0012	0.0016
12	0.0000	0.0000	0.0000	0.9969	0.0000	0.0009	0.0000	0.0000
13	0.0000	0.0001	0.0000	0.0000	0.9973	0.0001	0.0004	0.0000

14	0.0000	0.0000	0.0000	0.0000	0.0018	0.9970	0.0001	0.0000
15	0.0000	0.0000	0.0031	0.0000	0.0013	0.0000	0.9971	0.0006
16	0.0000	0.0022	0.0010	0.0000	0.0000	0.0000	0.0002	0.9960
17	0.0018	0.0007	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
18	0.0000	0.0000	0.0000	0.0000	0.0000	0.0004	0.0000	0.0001
19	0.0013	0.0000	0.0000	0.0006	0.0000	0.0000	0.0000	0.0000
20	0.0000	0.0015	0.0032	0.0013	0.0011	0.0000	0.0010	0.0000
21	0.0016	0.0015	0.0004	0.0000	0.0000	0.0000	0.0000	0.0001
22	0.0000	0.0000	0.0022	0.0000	0.0000	0.0010	0.0009	0.0000
23	0.0000	0.0002	0.0000	0.0000	0.0014	0.0000	0.0009	0.0000
24	0.0016	0.0010	0.0000	0.0003	0.0001	0.0000	0.0000	0.0000
25	0.0000	0.0000	0.0000	0.0013	0.0000	0.0001	0.0014	0.0014
26	0.0000	0.0005	0.0000	0.0013	0.0000	0.0000	0.0000	0.0007
27	0.0000	0.0000	0.0000	0.0000	0.0000	0.0006	0.0012	0.0000
28	0.0000	0.0000	0.0001	0.0000	0.0000	0.0008	0.0000	0.0008
29	0.0015	0.0001	0.0013	0.0000	0.0000	0.0000	0.0000	0.0000
	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق	مطابق

No.	Output 17	Output 18	Output 19	Output 20	Output 21	Output 22	Output 23	Output 24
1	0.0010	0.0004	0.0000	0.0000	0.0011	0.0013	0.0016	0.0000
2	0.0014	0.0010	0.0003	0.0000	0.0000	0.0001	0.0000	0.0000
3	0.0000	0.0000	0.0003	0.0051	0.0000	0.0008	0.0000	0.0000
4	0.0008	0.0000	0.0000	0.0000	0.0002	0.0000	0.0000	0.0000
5	0.0000	0.0000	0.0000	0.1317	0.0013	0.0000	0.0000	0.0000
6	0.0000	0.0000	0.0014	0.3950	0.0006	0.0000	0.0008	0.0000
7	0.0000	0.0000	0.0010	0.0146	0.0000	0.0018	0.0000	0.0000
8	0.0012	0.0004	0.0006	0.0000	0.0000	0.0000	0.0012	0.0000
9	0.0017	0.0000	0.0018	0.0317	0.0011	0.0000	0.0000	0.0005
10	0.0000	0.0000	0.0000	0.0000	0.0005	0.0000	0.0001	0.0006
11	0.0000	0.0000	0.0000	0.1763	0.0000	0.0023	0.0000	0.0000
12	0.0000	0.0000	0.0014	0.0000	0.0000	0.0000	0.0000	0.0009
13	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0031	0.0000

14	0.0000	0.0014	0.0000	0.0000	0.0000	0.0013	0.0000	0.0000
15	0.0000	0.0000	0.0000	0.0116	0.0000	0.0009	0.0022	0.0000
16	0.0000	0.0005	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
17	0.9973	0.0013	0.0000	0.0000	0.0003	0.0000	0.0001	0.0000
18	0.0005	0.9969	0.0000	0.0000	0.0000	0.0000	0.0006	0.0000
19	0.0000	0.0000	0.9967	0.0000	0.0000	0.0000	0.0000	0.0000
20	0.0000	0.0000	0.0000	0.2023	0.0004	0.0000	0.0000	0.0017
21	0.0005	0.0000	0.0000	0.0012	0.9973	0.0000	0.0005	0.0000
22	0.0000	0.0000	0.0003	0.0000	0.0000	0.9967	0.0000	0.0000
23	0.0000	0.0001	0.0000	0.0000	0.0012	0.0000	0.9960	0.0001
24	0.0001	0.0000	0.0008	0.0000	0.0000	0.0000	0.0008	0.9968
25	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
26	0.0000	0.0018	0.0000	0.0000	0.0000	0.0000	0.0000	0.0017
27	0.0000	0.0018	0.0024	0.0000	0.0000	0.0000	0.0004	0.0000
28	0.0002	0.0007	0.0000	0.0000	0.0000	0.0010	0.0000	0.0000
29	0.0002	0.0000	0.0000	0.0058	0.0002	0.0000	0.0000	0.0014
	مطابق	مطابق	مطابق	غير مطابق	مطابق	مطابق	مطابق	مطابق

No.	Output 25	Output 26	Output 27	Output 28	Output 29
1	0.0000	0.0000	0.0010	0.0014	0.0000
2	0.0001	0.0000	0.0000	0.0004	0.0000
3	0.0000	0.0000	0.0000	0.0008	0.0023
4	0.0000	0.0020	0.0000	0.0000	0.0002
5	0.0004	0.0000	0.0000	0.0000	0.0008
6	0.0014	0.0000	0.0011	0.0000	0.0000
7	0.0000	0.0000	0.0000	0.0001	0.0003
8	0.0011	0.0000	0.0000	0.0000	0.0000
9	0.0000	0.0000	0.0000	0.0000	0.0032
10	0.0000	0.0007	0.0000	0.0000	0.0000
11	0.0000	0.0000	0.0000	0.0003	0.0007
12	0.0007	0.0014	0.0000	0.0000	0.0001
13	0.0000	0.0000	0.0000	0.0000	0.0000

14	0.0015	0.0000	0.0001	0.0010	0.0000
15	0.0010	0.0000	0.0005	0.0000	0.0000
16	0.0017	0.0009	0.0000	0.0007	0.0000
17	0.0000	0.0001	0.0000	0.0001	0.0005
18	0.0000	0.0020	0.0600	0.0004	0.0000
19	0.0000	0.0000	0.0002	0.0000	0.0000
20	0.0000	0.0000	0.0000	0.0000	0.0008
21	0.0000	0.0000	0.0000	0.0000	0.0002
22	0.0000	0.0000	0.0000	0.0015	0.0000
23	0.0001	0.0000	0.2104	0.0000	0.0000
24	0.0000	0.0016	0.0001	0.0000	0.0011
25	0.9975	0.0003	0.0000	0.0000	0.0000
26	0.0011	0.9966	0.0003	0.0000	0.0000
27	0.0000	0.0002	0.9784	0.0000	0.0000
28	0.0000	0.0000	0.0000	0.9974	0.0012
29	0.0000	0.0000	0.0000	0.0002	0.9963
	مطابق	مطابق	مطابق	مطابق	مطابق

جدول (10.4) نتائج اختبار كلمة "لندن"

2.4 التجربة الأولى :

تم في هذه التجربة تطبيق تقنية ترميز التنبؤ الخطي Linear Predication Coding (LPC) في عملية استخلاص صفات الإشارات الصوتية ومن ثم إدخالها على الشبكة العصبية، وذلك للمقارنة مع تقنية التحويل المويجي المستخدمة في البحث المقترح. تم تحليل الإشارات الصوتية لـ (29) متكلماً ولكل متكلم خمس كلمات (ياسين، صباح، مساء، الخير ، وفي)، تم اخذ الرتبة (9)، بعدها يتم إدخال المعاملات إلى الشبكة العصبية، ليتم تدريبها وتكوين النماذج المرجعية، كما موضح في الشكل (2.4).

إن معاملات الشبكة العصبية في هذه التجربة هي كالآتي :

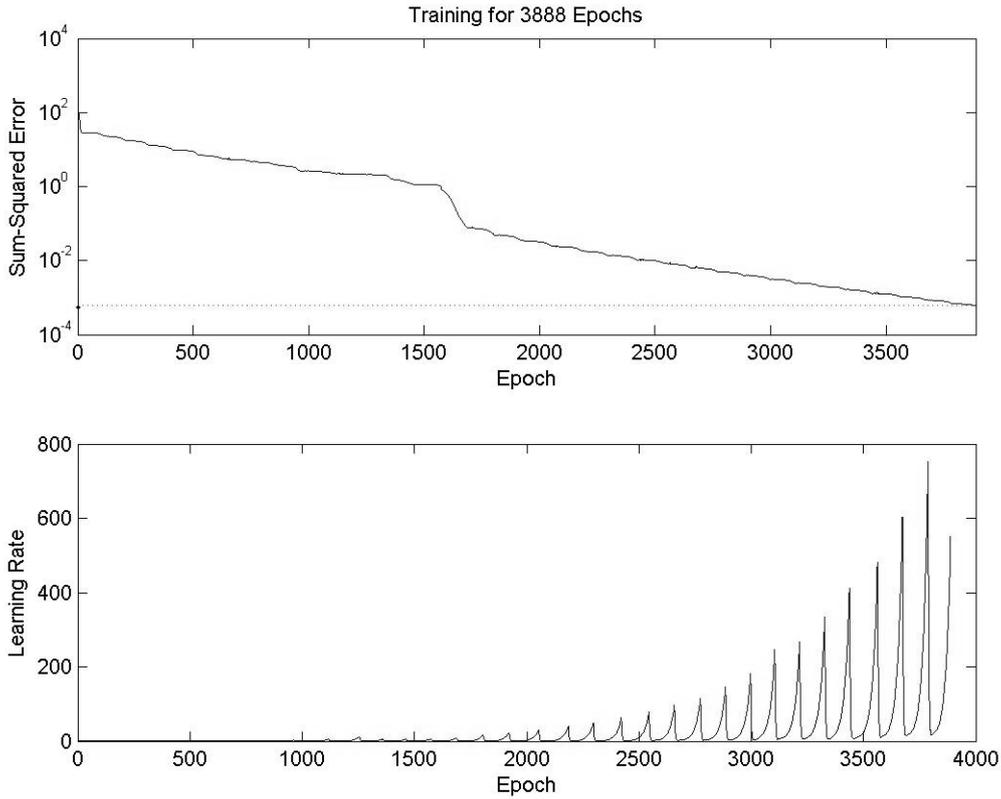
عامل التعلم = 0.02

عامل التنعيم = 0.01

أقصى عدد للتكرارات = 30000

قيمة الخطأ المقبول = 0.0006

استطاعت الشبكة العصبية في هذه التجربة من التعرف على 23 نموذجاً مدخلاً من أصل 29، بالنسبة للنماذج غير المعروفة مسبقاً. أما النماذج المعروفة فقد كانت نسبة التمييز 100%. فقد استغرقت عملية تدريب الشبكة العصبية 3888 دورة.



يمكن أن نلاحظ من خلال التجربة السابقة أرجحية استعمال التحويل المويجي في عملية استخلاص الصفات، وتفضيل تقنية التحويل المويجي على تقنية ترميز التنبؤ الخطي بسبب زيادة فترة تدريب الشبكة العصبية عن ما هو عليه الحال في حالة استخدام تقنية التحويل المويجي الذي استغرق فيه تدريب الشبكة 1595 دورة.

كما إن عدد الأنماط التي تعرفت عليها الشبكة باستخدام تحليل المويجة هو أكثر عدداً من عدد الأنماط التي تم التعرف عليها باستخدام تقنية ترميز التنبؤ الخطي.

3.4 التجربة الثانية :

تم إجراء محاولات عدة في هذه التجربة، وذلك بتغيير الكلمات التي يتم تحليلها باستخدام التحويل المويجي ومن ثم إدخالها إلى الشبكة العصبية، فقد تم اختيار الكلمات (لندن، يمين، وفي، صباح) ليتم تدريب الشبكة العصبية عليها وتكوين النماذج المرجعية. شكل (3.4).

في هذه التجربة تم استخدام تقنية التحويل المويجي في عملية التحليل وبالمعاملات نفسها المستخدمة في النظام المقترح وكذلك نفس معاملات الشبكة العصبية. أما الكلمات المستخدمة في طور الاختبار فهي الكلمات (ياسين، مساء) .

ان معاملات الشبكة العصبية في هذه التجربة هي كالآتي :

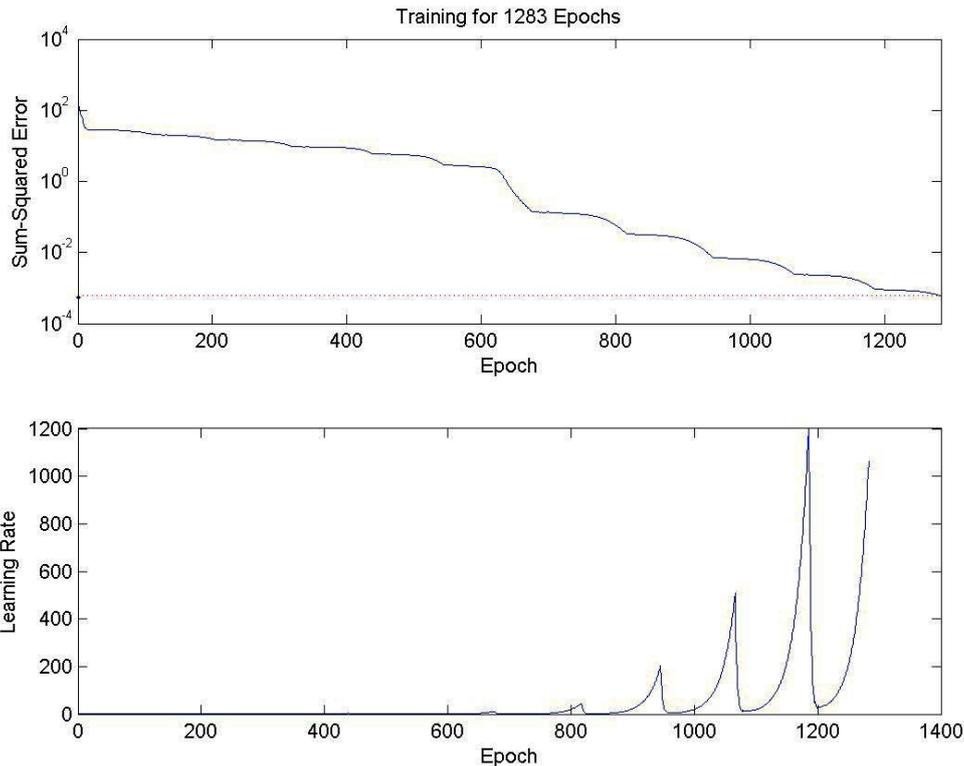
$$\text{عامل التعلم} = 0.02$$

$$\text{عامل التنعيم} = 0.01$$

$$\text{أقصى عدد للتكرارات} = 30000$$

$$\text{قيمة الخطأ المقبول} = 0.0006$$

استطاعت الشبكة العصبية في هذه التجربة من معرفة 26 نموذجاً مدخلاً من اصل 29، بالنسبة للنماذج غير المعرفة مسبقاً . أما النماذج المعروفة فقد كانت نسبة التمييز 100%. وقد استغرقت عملية تدريب الشبكة العصبية 1283 دورة . وكما موضح في الشكل (3.4).



المناقشة :

يمكن أن نلاحظ من خلال التجربة السابقة انه كلما ازداد عدد الكلمات التي يتم تدريبها في الشبكة العصبية، ازدادت قابلية الشبكة في التعرف على الأنماط الجديدة غير المعروفة في الشبكة، أي انه تزداد كفاءة الشبكة العصبية لكن على حساب وقت التدريب، بمعنى انه كلما قل عدد الكلمات التي تم تدريبها ازدادت سرعة تدريب الشبكة العصبية.

كما نلاحظ عندما استخدمت خمس كلمات في التدريب كانت نسبة التمييز هي 93 % في حين كان عدد الدورات 1595 دورةً. وعندما استخدمت أربع كلمات كانت نسبة تمييز الشبكة العصبية تقارب 90 % في حين استغرقت الشبكة العصبية 1283 دورة لتدريب النماذج.

4.4 الاستنتاجات :Conclusions

من ملاحظة أداء الشبكة العصبية المقترحة في عملية التصنيف، والتجربة التي تم إجراءها، يتبين لنا نجاح الشبكة في حلها لهذه المشكلة، مما يشجع استعمال هذه الشبكة لمشاكل أكثر تعقيداً ، ومما تقدم يمكن تحديد الاستنتاجات الآتية :

1. من أهم المشاكل التي تواجه عملية تمييز المتكلم هو عدم ثبوتية الإشارة، لان طبيعة الكلام الناتج عن المتكلم تتغير مع الزمن ومع الحالة النفسية للشخص المتكلم.
2. سرعة الشبكة العصبية في الوصول إلى قيمة الخطأ المقبول، ونجاحها في عملية التمييز.
3. استخدام تقنية محول المويجة في عملية استخلاص الصفات، الذي يعد من المقربات العامة والشاملة (Universal Approximation)، مما حسن من قابلية الشبكة في التعرف على الأنماط غير المعروفة، أن التحويل المويجي يعطي تفاصيل دقيقة يصعب الحصول عليها بشكل مباشر أو باستخدام الطرائق التقليدية، وذلك لأنه يوفر معلومات عن الإشارة في كل من الزمن والتردد في آن واحد.
- كما أن العمل مع التحويل المويجي يمتاز بالمرونة لان عدد معاملات التحليل غير ثابت أي بمعنى آخر أنه يكون متغيراً وفقاً لعمق الشجرة ونوع التحويل المويجي المستخدم. ففي حالة عدم الوصول إلى النتائج المرغوبة يمكن تغيير نوع التحويل المويجي.
4. استخدام مرشح db5 يُعد الأكثر ملائمة للتعامل مع الإشارة الكلامية بعد مقارنته مع بقية العوائل.
5. استخدام تقنية التحويل المويجي WT أكثر ملائمة للتعامل مع الإشارات الكلامية من تقنية ترميز التنبؤ الخطي LPC .

6. كلما ازداد عدد الكلمات التي يتم تدريبها تزداد قابلية الشبكة في معرفة النماذج الجديدة، وكلما قل عدد الكلمات المدربة قلت كفاءة الشبكة في تمييز الأنماط.

5.4 الأعمال المستقبلية Future Works :

1. يمكن التعديل على النظام وزيادة عدد المتكلمين بعد إجراء بعض التعديلات على الشبكة العصبية.
2. يمكن استخدام الخوارزميات الجينية Genetic Algorithms في عملية التصنيف بدلا من الشبكات العصبية.
3. يمكن استعمال طرائق هجينة في عملية التصنيف Classification، ويمكن استعمال المنطق المضبب Fuzzy Logic مع الشبكات العصبية، أو استعمال تقنية Wavnet، التي تعني تهجين تقنية التحويل المويجي مع الشبكات العصبية.
4. إمكانية العمل على اختبار جملة معينة للمتكلمين بدلا من لفظ كلمة واحدة.

المصادر

- [1] الجودة ، نجاح رشيد ، تمييز الكلام باستخدام التحويل المويجي ، رسالة ماجستير ، جامعة بابل ، 2001 .
- [2] صالح، صلاح مهدي، نظام هجين باستعمال التحويل المويجي في الشبكات العصبية لتصنيف الصور، رسالة ماجستير، جامعة بابل، 2003 .
- [3] صكبان، إيمان صالح، تمييز المتكلم باستخدام تقنية المتجه الكمي، رسالة ماجستير ، جامعة بابل، 2001.
- [4] محمد، هند رستم، تعريف المتكلم باستخدام الشبكات العصبية متعددة الطبقات، رسالة ماجستير، جامعة بابل، 2000 .
- [5] المعموري ، هدى ناجي نواف ، تمييز أصوات المحركات الصاروخية باستخدام محول الموجة ، رسالة ماجستير، جامعة بابل ، 2001 .
- [6] هادي ، اسعد صباح ، طريقة جينية هجينة (GA-BP) لتصحيح وتدريب شبكة انسياب الخطأ خلفا مع مبدأ تحلل الأوزان ، رسالة ماجستير ، جامعة بابل ، 2000 .
- [7] A. Cohen and J. Kovacevic, proceeding of the IEEE, 84, 4, 514, 1996.
- [8] A. Graps, "An Introduction to wavelets", IEEE computational Science and Engineering , 2,2,1, 1995 .
- [9] A. H. Cromer, Physics for the life Science , 2nd edn. McGraw – Hill New York, 1977 .
- [10] A. K. Soman and P.P. Vaidnathan , IEEE transactions on Signal processing , 41, 3, 1, 170 , 1993 .
- [11] A. Konar, Artificial Intelligence and Soft computing : Behavioral and Cognitive Modeling of the Human Brain, CRC press, USA, 1999.
- [12] A. Waston , Y.G. Yang, A.J. Soloman and J. Villasennor, IEEE , 6,9, 1997.
- [13] B. Kosko, Neural Networks and Fuzzy systems prentice Hall International Inc., USA , 1992.
- [14] B. S. Atal, Proc. IEEE, 64, 460 ,1976.

- [15] Bridle, J.S., Brown, M. D. & Chamberlain, R.M., " Continuous connected word recognition using whole word templates" , the Radio and electronic engineer, vol.53, No.4, 1983, pp.167-175.
- [16] C.S. Burrus, R.A. Gopinath and H. Guo, Introduction to wavelets and wavelet transform , prentice – Hall, New York , 1998 .
- [17] C. W. Kim and C.W. Lee , Signal processing Image communication, 11, 199 , 1998 .
- [18] D. E. Newland , “ An Introduction to Random Vibrations spectral and wavelet Analysis , 3rd edn., John Wiley and Sons, New York , 1994.
- [19] D. Ruan, Intelligent Hybrid systems : Fuzzy logic , ?Neural Networks, and Genetic algorithms , Kluwer Academic publishers, , Belgium , 1997 .
- [20] E. Davalo and P. Naim , Neural Networks, Mac Millan Education Ltd., Hong Kong , 1991 .
- [21] E.J. Rzempoluck, Neural Network Data Analysis using Simulnet springer- Verlag, New York , 1997 .
- [22] E. Rich and K. Knight , Artificial Intelligence second Edition , McGraw-Hill Inc. , New York, 1991 .
- [23] F. Luo and R. Unbehauen , “ Applied Neural Networks for Signal processing , Cambridge University press, USA , 1997 .
- [24] G.F. Luger , and Stubble field , Artificial Intelligence : structures and strategies for complex problem solving , Third edition, Addison Wesley Longman, USA, 1998 .
- [25] J. Chen, Z. Chen , S. Xu, Y. Lu, and J. Zhang , BP Algorithm with chaos in MLP neural Networks, International conference on Neural Networks and Brain Proceeding (ICNN & B'98) , 166, 1998.
- [26] J.M. Zurada, Introduction to Artificial Neural system, JAICO publishing House , Bombay , 1997 .

- [27] J.S. Walker, Notices of the AMS , 44, 6, 658 , 1997.
- [28] J.S. , Bridle Brown , M.D. & Chamberlain , R.M. , “ Continuous connected word Recognition using whole word templates “ , The Radio and Electronic engineer, Vol. 53, No. 4 , April, pp.167-175, 1983.
- [29] L.C. Jain & R.K. Jain , “ Hybrid Intelligent Engineering systems, Advances in Fuzzy systems, 11, Singapore, 1997.
- [30] Levinson, S.E. , " A perspective on speech recognition", IEEE communication magazine, January, 1990, pp. 28-34.
- [31] L. Fausett, Fundamentals of Neural Network: Architectures , algorithms , and Applications , prentice , 1994 .
- [32] Markowitz, J., " Talking to machines", Byte, December, pp. 97-103, 1995.
- [33] M. Candill, C. Butler , Understanding Neral Network, Vol. 1: Basic Network, Sixth printing, 1996.
- [34] M. G. Strintzis, Signal processing , 58, 255, 1997.
- [35] M.J. Haider, “ Speech compression and Recognition using wavelet transform “ , M.Sc. thesis , university of Baghdad, Electrical Engineering dept. , 1999.
- [36] M. Vetterli and J. Kovacevic, Wavelets and Subband coding , Prentice Hall, New Jersey , 1995 .
- [37] N.B. Karayiannis and A.N. Venetsanopoulos, Artificial Neural Networks : Learning Algorithms, performance , Evaluation and Applications , Kluwer Academic Publishers, USA, 1992 .
- [38] N.H. Nielston and M.V. Widkerhauser , proceeding of the IEEE, 84, 4, 523,1996 .
- [39] O. Rioul and M. Vetterli , IEEE signal processing , 12, 6, 14, 1991.
- [40] P.M. Bentley and J. T. McDonnell, Electronics and communications Engineering Journal , 6,3,175, 1994 .

- [41] R.A. Devore, B. Jawerth and V. Popov, IEEE , 38, 2, 719, 1992.
- [42] R.C. Eberhart and Y. Shi, “ Evolving Artificial Neural Network, International conference on Neural Networks and Brain Proceedings , ICNN&B’98 , Oct. 27-30 , Beijing , China , 1998 .
- [43] R.L. Kennedy, Y. Lee, B. Vanroy, C.D. Reed, and R.P. Lippman , Solving data mining problems through pattern recognition, Prentice Hall , USA, 1998 .
- [44] Rovella, S., Ridella, S. & Zunin, R. , " Circular back propagation networks for classification", IEEE transaction on neural networks, vol.8, No.1, January, pp. 84-87.
- [45] R. Polikar , The story of wavelets, Appeared in IMACS/IEEE CSCC’99 proceedings , 5481, 1999 .
- [46] S. Abdulrahman, “ Speaker verification and Identification Using Bank filter “ , M. Sc. thesis, college of Engineering , university of Baghdad , Baghdad , 1988.
- [47] S. Furui, Elsvir, " Recent Advances in speaker Recognition", Pattern recognition letters , Vol. 18, pp. 859, 1997.
- [48] S.A. Pandya and B.R. Macy, “ Pattern recognition with Neural Networks in C++ , CRC press, USA , 1996 .
- [49] Sadaoki, F. , " Digital speech processing , synthesis and recognition", Jaban, 1989.
- [50] S.D. AL-Sudani, “ Speaker Recognition system “ , M.Sc. thesis , Computer dept. , The university of Technology , Baghdad , 1997.
- [51] Sejnowski, T.J. Goldstein , M. H. & Yuhas, B.P. , 1989 , “ Integration of acoustic and Visual speech signals using neural networks”, IEEE communication Magazine , Vol. 27, No. 11, November, pp. 65-71.

- [52] T. Kugarajah, Neural Modeling with wavelets and Application in Adaptive / Learning control, Master thesis , The University of Maryland, U.S.A., 1995 .
- [53] V. B. Rao, and H.V. Rao, “ C++ Neural Networks and Fuzzy logic, MIS press, New York, 1993 .
- [54] W.A. Mahmood , “ Quantization Techniques for the classification and Recognition of speech signals “ , Ph.D. thesis , university of Swansea , England, 1988 .
- [55] W. Youshou, Networks and Brain Proceedings , Publishing House of Electronics Industry, China, 1993 .
- [56] X. Yao, Evolving Artificial Neural Networks, proceedings of the IEEE , 87,9,1423, September, 1999 .
- [57] Y. Hao, X. Zhu, " A new Feature in speech recognition based on wavelet transform", Proc. ICASSP, 2001.
- [58] Y. Q. Shi and H. Sun , “ Image and Video Compression for multimedia engineering, fundamentals, Algorithms , and standards, CRC press LLC, 1999 .

Abstract

The aim of the research is to build a system for speaker recognition of the Arabic words , by using the discrete wavelet transform and neural networks.

It has been benefited from the wavelet transform properties; where it has able to deal with non stationary signals and signal approximation, for getting on features from sound file of speaker and it has produced features vectors; later it has used in the neural network. Features vectors have used as input patterns to the neural network; and neural network has been trained on them.

It has chosen error back propagation algorithm for classification. In this suggested research; it has used a sample consists of 29 speakers (15 male and 14 female); each speaker pronounces the following words (Yaseen, Yameen, Wafi, Sabah, Mesaa, Al-Khair, and London), these words have important letters that could be used in the distinguish process one speaker on another.

It has been doing many experiments, one of them using the linear predictive coding technique in the decomposition and features extraction, in order to compare with wavelet transform in the process of features extraction. The wavelet transform has been prove the efficiency in dealing with speech signals.

The results of network training has shown its able to deal with these speech samples and improve the ability of network

generalization; where it able to recognize on the all test types in the text dependent, speaker recognition, such the recognition ratio is 100%, while the words has been not trained in the neural network has the ratio between (90-93%).

The suggested method has executed on the computer Pentium 4, Process (1.4) GHz, and by using Matlab 6.5 system.