

رسالة مقدمة

الى مجلس كلية العلوم /

وهي جزء من متطلبات نيل درجة الماجستير في علوم الحاسبات

e

﴿نَرْفَعُ دَرَجَاتٍ مِّنْ نَّشَأٍ وَفَوْقَ كُلِّ ذِي عِلْمٍ عَلِيمٌ﴾

بِسْمِ اللَّهِ
الْعَظِيمِ

سورة يوسف (76)

شكر وتقدير

- لايسعني وأنا اكمل هذه الرسالة إلا أن احمد الله سبحانه وتعالى واشكر فضله على ما أمدني به من القوة والصبر والإرادة، وأقدم شكري إلى:
- ◀ رئاسة جامعة بابل وعلى رأسها الأستاذ الدكتور خليل إبراهيم الطيف لتعاونه في تطوير مستوى الدراسات العليا في ثليات وأقسام الجامعة كا .
 - ◀ عمادة كلية العلوم وعلى رأسها الأستاذ الدكتور فلاح حسن حسين لإرشاداته المتواصلة في دعم طلبة الدراسات العليا في كلية العلوم.
 - ◀ أستاذي المشرف الأستاذ الدكتور نبيل هاشم كاغد لملاحظاته القيمة وجهوده المتواصلة في دعم هذه الرسالة.
 - ◀ قسم علوم الحاسبات وعلى رأسه الأستاذ الدكتور نبيل هاشم كاغد لجهوده في توفير كل ما نحتاج إليه من مستلزمات بحثية خلال مدة الدراسة.
 - ◀ طلبة الدراسات العليا ، ولاسيما من في مرحلة البحث لتعاونهم ودعمهم خلال مرحلة البحث.
 - ◀ عائلتي لصبرهم طيلة مدة البحث ، والى كل من ساهم في هذا البحث.

الباحث

قرار لجنة المناقشة

نحن أعضاء لجنة المناقشة ، نشهد إننا قد اطلعنا على الرسالة الموسومة بـ (نظام هجين باستعمال تحويل الموجة في الشبكات العلتصنيف الصور) . وقد ناقشنا الطالب ((صلاح مهدي صالح)) في محتوياتها وفيما له علاقة بها وذلك بتاريخ 2003/ 10 / 8 ووجدنا إنها جرة بالقبول بدرجة (امتياز) لنيل درجة الماجستير في علوم الحاسبات .

التوقيع:

عضو اللجنة: د. عبد المنعم صالح أبو طيبيخ
المرتبة العلمية: أستاذ مساعد
العنوان: كلية الرشيد للهندسة والعلوم
التاريخ: / /

التوقيع:

رئيس اللجنة: د. هلال محمد يوسف
المرتبة العلمية: أستاذ
العنوان: كلية الرافدين للغة
التاريخ: / /

التوقيع:

عضو اللجنة (مشرفاً): د. نبيل هاشم كاغد
المرتبة العلمية: أستاذ
العنوان: جامعة بابل / كلية العلوم
التاريخ: / /

التوقيع:

عضو اللجنة: توفيق عبد الخالق عباس
المرتبة العلمية: أستاذ مساعد
العنوان: جامعة بابل / كلية العلوم
التاريخ: / /

مصادقة عمادة كلية العلوم

أصادق على ماجاء في قرار اللجنة في أعلاه.

التوقيع:

الاسم: عودة مزعل ياسر
المرتبة العلمية: أستاذ مساعد
العنوان: جامعة بابل / كلية العلوم / عميد كلية العلوم
التاريخ: / /

المحتويات

	المقدمة	الفصل الأول
أ	الخلاصة	
ج	المحتويات	
و	قائمة المختصرات	
ز	قائمة المصطلحات	
1.....	مقدمة عامة.....	1-1
4.....	نبذة مختصرة عن البحوث السابقة.....	2-1
8.....	الشبكات العصبية.....	3-1
10.....	أنواع الشبكات العصبية.....	1-3-1
11.....	التعلم في الشبكات العصبية.....	2-3-1
13.....	دوال التنشيط.....	3-3-1
13.....	دوال التنشيط العامة.....	1-3-3-1
17.....	دوال التنشيط المحلية.....	2-3-3-1
18.....	الهيكل العام للموصلات.....	4-3-1
19.....	الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية.....	5-3-1
20.....	شبكة المدرك.....	1-5-3-1
21.....	شبكة انسياب الخطأ خلفاً.....	2-5-3-1
22.....	معمارية الشبكة.....	1-2-5-3-1
23.....	خوارزمية التعلم.....	2-2-5-3-1
27.....	مشاكل الشبكة العصبية متعددة الطبقات.....	3-2-5-3-1
28.....	عامل التعلم.....	4-2-5-3-1
29.....	تحويل الموجة.....	4-1
32.....	الإشارات غير الثابتة.....	1-4-1
33.....	أنواع تحويل الموجة.....	2-4-1
34.....	إطارات الموجة.....	3-4-1
35.....	تحويل الموجة المتقطع.....	4-4-1
36.....	الموجات متعددة الأبعاد.....	5-4-1

37.....	قياس STFT مع تحويل الموجة.....	6-4-1
38.....	الشبكات العصبية وتحويل الموجة.....	5-1
41.....	هدف البحث.....	6-1
42.....	هيكل الرسالة.....	7-1

الفصل الثاني تصميم الطريقة المقترحة

43.....	الطريقة المقترحة.....	1-2
45.....	استحصال الصورة.....	1-1-2
46.....	قراءة ملف الصورة.....	2-1-2
47.....	مرحلة تجزئة الصورة.....	3-1-2
48.....	التعتيب.....	1-3-1-2
48.....	استخلاص الصفات.....	4-1-2
51.....	قراءة معاملات تحويل الموجة.....	5-1-2
53.....	تحديد أوزان موصلات الشبكة الموجية.....	6-1-2
53.....	خوارزمية انسياب الخطأ خلفاً باستعمال تحويل الموجة.....	7-1-2
59.....	اتخاذ القرار.....	8-1-2

الفصل الثالث النتائج، الاستنتاجات، والأعمال المستقبلية

60.....	أداء الشبكة المقترحة.....	1-3
60.....	التجربة الأولى.....	1-1-3
71.....	التجربة الثانية.....	2-1-3
81.....	التجربة الثالثة.....	3-1-3
81.....	الفئة الأولى.....	1-3-1-3
81.....	دالة المشتقة الأولى لدالة كاوس وشبكة EBP التقليدية.....	1-1-3-1-3
82.....	دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية.....	2-1-3-1-3
81.....	الفئة الرابعة.....	2-3-1-3
83.....	دالة المشتقة الأولى لدالة كاوس وشبكة EBP التقليدية.....	1-2-3-1-3
84.....	دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية.....	2-2-3-1-3
84.....	الفئة الذ.....	3-3-1-3
85.....	دالة المشتقة الأولى لدالة كاوس وشبكة EBP التقليدية.....	1-3-3-1-3
85.....	دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية.....	2-3-3-1-3
86.....	التجربة الرابعة.....	4-1-3

88.....	المشتقة الأولى لدالة كاوس كموجة أم	1-4-1-3
89.....	الدالة الناتجة من تجميع ثلاث دوال سيجماوية كموجة أم	2-4-1-3
91.....	الاستنتاجات	2-3
92.....	الأعمال المستقبلية	3-3
94.....	المصادر	
101.....	ملحق 1	
103.....	ملحق 2	
104.....	ملحق 3	

إقرار الأستاذ المشرف

أشهد أنّ إعداد هذه الرسالة الموسومة ب(نظام هجين باستعمال تحويل الموجة في الشبكات العصبية لتصنيف الصور) قد جرى تحت إشرافي في قسم علوم الحاسبات- كلية العلوم - جامعة بابل وهي جزء من متطلبات نيل درجة الماجستير ، علوم الحاسبات.

التوا :

اسم المشرف: د. نبيل هاشم كاغد

المرتبة العلمية: أستاذ

التاريخ: / / 2003

توصية رئيس القسم

إشارة الى التوصية أعلاه المقدمة من قبل الأستاذ المشرف أحيل هذه الرسالة الى لجنة المناقشة لدراستها وبيان الرأي فيها.

التوقيع :

اسم المشرف: د. نبيل هاشم كاغد

المرتبة العلمية: أستاذ

التاريخ: / / 2003

الخلاصة

تعاني الشبكة العصبية ذات التغذية الأمامية المدربة بخوارزمية انسياب الخطأ خلفاً من مجموعة

مشاكل منها: (التقرب البطيء، والوقوع في مشكلة النهاية الصغرى المحلية،... الخ) ، تؤثر هذه

المشاكل على أداء هذه الشبكة وقدرتها في حل المشكلة ، لبحث طرائق عديدة واتجاهات مختلفة

تحاول تجاوز وحل معظم هذه المشاكل والتقليل من تأثيرها على أداء الشبكة، ومنها دمج هذه الشبكة

مع تقنيات أخرى تمتلك مميزات تساعد في التخلص من هذه المشاكل، ومن هذه الاتجاهات أو الطرائق

دمج الشبكات مع تحويل المويطام هجين، إذ يمتلك تحويل المويجة نظرية تقريب شامل

تستعمل في عملية تقريب الدوال.

يقع إطار بحثنا ضمن هذا الاتجاه، إذ استعمل تحويل المويجة بعد اختيار دالة مويجة أم مناسبة

كجزء يقوم بإنجاز وظيفة حسابية داخل الشبكة العصبية كوحدات مخبأة ، ولأن متجه الإدخال مكون

من عدة متغيرات فقد تم إجراء تحويل مويجي متعدد الأبعاد لهذا الغرض وباستعمال التقييس المتعدد ،

فقد استعملت دالتين مختلفتين كمويجة أم هما :

← دالة ناتجة من تجميع ثلاث دوال سيجماوية.

← دالة المشتقة الأولى لدالة كاوس.

تم اختبار كل دالة على حدة داخل الشبكة لمسألة التصنيف على مجموعة من الصور المرسومة

بخط اليد لأشكال مختلفة ذات تدرج رمادي (8) ثنائيات ، هذه الصور مقسمة على ثمان مجموعات،

كل مجموعة تحتوي على (6) صور بتشوهات معينة واستعمل مقياس PSNR وهو أحد مقاييس

وثوقية الهدف لحساب هذه التشوهات.أوضحت نتائج تدريب الشبكة قدرتها على التعامل مع هذه

الصور وتحسين قابلية التعميم للشبكة إذ استطاعت الشبكة التعرف على جميع أنماط الاختبار البالغ

عدها (24) ماعدا التجريبتين الأولى والثامنة في حالة استعمال دالة الموجة الأم الأولى إذ تمكنت

الشبكة من تمييز (23) نمطا من أصل (24).

تم قياس أداء الشبكة الهجينة بشبكة انسياب الخطأ خلفا التقليدية وأوضحت النتائج تفوقها عليها إذ

تمكنت الشبكة الهجينة من الوصول الى الحل بعدد أقل من الدورات قياسا بالشبكة التقليدية.

تضمن البحث أيضا اختبار قابلية الشبكة في التعامل مع الصور الملونة، وأثبتت النتائج كفاءة

الشبكة في عملية التصنيف لهذه الصور.

تم تنفيذ الطريقة المقترحة على حاسب ذي معالج نوبنتيوم 3 وبسرعة معالج 650

هيرتز واستعمال لغة (Visual C++) الإصدار السادس لبرمجتها.

ظهرت الحاسبات الرقمية في بدايتها لحل مسائل حسابية معقدة تستغرق وقتاً طويلاً لحلها يدوياً ،
ولكن التطور الذي شهدته الحاسبات والنجاح الذي حققته في تطبيقات متعددة جعلها أكثر من مجرد آلة
حسابية (**Computing Machine**) الذي كان دافعاً قوياً للعلماء لتطوير وابتكار عدة تقنيات تحاول
استغلال إمكانيات الحاسبة لإنجاز وظائف ذكية (**Intelligent Tasks**) مرتبطة بالسلوك البشري
وتعد سهلة بالنسبة للبشر كمشكلة تمييز الأنماط (**Pattern Recognition**) [1] ، ومنها الأنظمة
الذكية (**Intelligent Systems**)، وتشمل (الأنظمة الخبيرة، والشبكات العصبية، وأنظمة المنطق
المضرب، والخوارزميات الجينية)، التي حاول بها الباحثون محاكاة قدرة الإنسان على التعلم وإدراك
وتمييز الظواهر والأشياء المحيطته على تطوير نفسه . استطاعت هذه الأنظمة إنجاز
نجاحات كبيرة في حلها للمسائل المعقدة ، وازدادت شعبية تلك الأنظمة لصفحتين تميّزت بهما، جميعها
متأثرة بالأنظمة البيولوجية، وجميعها قادرة على حل غير خطية [2] ، فقد رافقت تلك الأنظمة
مجموعة مشاكل قللت من أدائها وكفاءتها ، فظهر إيجاب حديث لدمج تلك التقنيات مع بعضها أو مع
تقنيات أخرى لتعويض بعض المميزات المفقودة في إحدى هذه التقنيات بمميزات تقنية أخرى وإمكانية
خلق نظام كفوء وذكي للتطبيقات العملية عن طريق تكامل نقاط الضعف الموجودة في تقنياته، ويسمى
النظام الناتج نظام هجين (**Hybrid System**) وتسمى التقنيات المستعملة لدمج هذه الأنظمة
تكنولوجيا الخلط (**Fusion Technology**) [3] .

نالت الشبكات العصبية الاصطناعية (**Artificial Neural Networks**) ANNs اهتماماً من
قبل الباحثين كأحد موضوعات العصر المهمة التي حققت التحدي الذي يسعى إليه باحثوا الذكاء
الاصطناعي (**Artificial Intelligence**) AI في تصميم أنظمة ذات سلوك مشابه للسلوك البشري
في عملية اتخاذ القرار وحل المشاكل [4] ، فظهرت الشبكات العصبية الاصطناعية لمحاكاة الشبكات

العصبية البيولوجية التي تُعدُّ بالأساس نماذجاً رياضية (**Mathematical Models**)

المعلومات.

قدم روزنبلات (**Rosenblatt**) في العام 1958 أول نموذج لشبكة عصبية اصطناعية أطلق عليها اسم المدرك (**Perceptron**) وأستعملها لحل المشاكل الخطية [3][5]، أوضح منسكي وبيبرت (**Minsky and Papert**) عام 1969 في كتابهما المسمى (**Perceptrons**) أن شبكة المدرك محددة لحل المشاكل الخطية وغير قادرة على حل المشاكل اللاخطية [1][6]، ونتيجة لذلك توقف الباحثون عن العمل في هذانب حتى عام 1986 عندما قدم روميلهارت ورفاقه (**Rumelhart et al.**) شبكة انسياب الخطأ خلفاً (**Error Back Propagation**) EBP التي أصبحت الانطلاقة الجديدة للشبكات العصبية واستعملت في تطبيقات متعددة [7].

تعدُّ شبكة انسياب الخطأ خلفاً من بين اشهر الشبكات العصبية انتشاراً واستعمالاً إذ لاقت نجاحاً في تطبيقات متعددة ولاسيما مسألة التصنيف (**Classification**). تتكون هذه الشبكة من ثلاثة أنواع من الطبقات (طبقة إدخال ، وطبقة مخبأة واحدة أو أكثر، وطبقة إخراج)، تستعمل هذه الشبكة دالة اقل متوسطات مربعات الخطأ (**Least Mean Square Error**) LMSE كمقياس للتوقف، إذ تستمر هذه الشبكة بالعمل حتى يتم الوصول الى الخطأ المقبول ويعكسه يتم الرجوع عكسياً من طبقة الإخراج الى طبقة الإدخال لتعديل أوزان الشبكة بتحديد مساهمة كل وزن بالخطأ الناتج [1][8].

تعاني هذه الشبكة من مجموعة مشاكل، منها مشكلة التعميم والتقارب والوقوع في النهاية الصغرى المحلية، فظهرت العديد من البحوث الخاصة بحل هذه المشاكل ومنها إضافة حد التعميم (**Momentum Term**) الى معادلة تعديل الأوزان لزيادة سرعة التقارب والهروب من الوقوع في النهاية الصغرى المحلية [7][9]، واستعمال الخوارزميات الجينية [8]، ومن البحوث الأخرى التي حاولت حل هذه المشاكل وتجاوزها هي استعمال تحويل الموجة (**Wavelet Transform**) WT

الشبكات العصبية في نظام هجين.

أثرت نظرية الموجة بشكل عميق على حقل معالجة الإشارة لأنها تقدم وذجاً رياضياً

دقيقاً (Rigorous Mathematical Approach) للتعامل مع التحليل متعدد

التفاصيل (Multiresolution) [10].

تعد دوال الموجة (Wavelet Functions) مقربات عامة (Universal

Approximations) تعطي أساساً نظرياً لاستعمالها ضمن إطار تقريب الدالة

(Function Approximation)، إذ يمكن لأي دالة تنتمي إلى الفضاء $L^2(R)$ أن تقرب إلى دقة

مطلوبة عن طريق جمع عدد محدد من الموجات (Wavelets) تكون عن طريق إجراء عمليات

توسيع (Dilation) ونقل (Translation) على دالة وحيدة (Single Function) تدعى الموجة

الأم (Mother Wavelet) [11].

ظهر تحويل الموجة حديثاً كأداة قوية للتقريب، ويمتلك هذا التقريب هيكل مشابه للشبكة العصبية

واحتوائه على قواعد موجة متعامدة (Orthonormal Wavelet Bases) توفر معدلات

تقارب (Rates of Convergence) لتقريب الدوال بواسطة شبكات معتمدة على الموجات، وكنتم

تستعمل لاختيار دالة النشاط ومعاملات الشبكة [12][13].

يمكن تمييز صنفين لفكرة الجمع بين الشبكات العصبية ونظرية تحويل الموجة في نظام

واحد [10][14]: -

*الصنف الأول: هو استعمال تحويل الموجة كجزء مفصول عن عملية تعلم الشبكة كمرحلة معالجة

أولية (Preprocessing) لاستخلاص الصفات من البيانات، وتغذي معاملات الموجة الناتجة إلى

الشبكة العصبية كمدخلات.

*الصنف الآخر: هو دمج تقني الشبكات العصبية والموجات في هيكل واحد واستعمال الموجات

كدوال نشاط لتحديد نشاط الخلايا المخبأة في الشبكة، وهي الطريقة المتبعة في بحثنا.

2-1 نبذة مختصرة عن البحوث السابقة

في عام 1993 طور باتي وكريشنبراساد (Pati and Krishnaprasad) [15]

عصبية ذات تغذية أمامية، تحويلات الموجة المنقطعة. إذ أظهرنا باستعمال تجميع ملائم من

الحدود إكانية اعتبار الشبكات ذات التغذية الأمامية مع دوال نشاط سيجماوية كمعماريات

تستعمل تحويلات تحليلات الموجة (Wavelet Decomposition of Mapping)، وجاء هذا

الاستنتاج من ملاحظة امتلاك معماريات الشبكة العصبية ذات التغذية الأمامية هيكل

نقل-توسيع (Translation-Dilation Structure) وتطبق كل عقدة نفس دالة النشاط. اقترح

الباحثان تجميع لثلاث دوال سيجماوية كموجة أم، وعلا استعمالها للدالة السيجماوية بأنها يمكن أن

تطبق في دوائر متكاملة متماثلة (Analog Integrated Circuitry)، بجانب ذلك لتوضيح المنهج

العام الذي يمكن أن يطبق في كات العصبية الاصطناعية، واستعمل الباحثان شبكة مكونة من

إدخال واحد وأخراج واحد (Single Input and Single Output)، وركز الباحثان على الموجات

ذات البعد الواحد (Onedimensional Domain) ويمكن تطبيقه في حالة الأبعاد الأعلى

(Higher Dimensional Domain) على شبكات ذات تغذية أمامية مع دوال نشاط سيجماوية.

تمت محاكاة أمثلة بسيطة لاختبار إجراء تركيب الشبكة المقترحة، اختار الباحثان في المثال

الأول دالة محددة النطاق (Bandlimited Function) المؤلف من دالتين جيبيتين عند ترددات

مختلفة وهي $f(x) = \sin(2\pi 5x) + \sin(2\pi 10x)$ ، أملا المثال الآخر وهو أكثر تعقيدا من المثال

الأول، تمت محاكاته عن طريق طيف عشوائي متمركز في التردد وتجزئة الدالة المقابلة لهذا الطيف

إلى عينات في مجال الوقت، واستعمل التقييس الوحيد (Single Dilation) للموجة الأم في كلا

المثالين.

اقترح كونيكازو وتويوشي (Kunikazu and Tuyoshi) في عام [16] 1994 طريقة جديدة

للجمع بين الموجبة والشبكات العصبية، إذ اقترحا خوارزمية تتكون من مرحلتين هما التركيب الذاتي

(Self Construction) وتقليل الأخطاء (Minimization of Errors)، في المرحلة الأولى

يُحدّد هيكل الشبكة المقترحة باستعمال تمويجة، وفي المرحلة الأخرى يُقلّل خطأ

التقريب، واستعملت الموجات لبناء الشبكة المقترحة. في مرحلة بناء الشبكة يتم تحديد عدد

الوحدات المخبأة وتعديل معاملات كل وحدة بواسطة قاعدة كوهنين (Kohonen's Rule)، أما في

مرحلة تقليل الأخطاء فتحدّثات الشبكة باستعمال قاعدة δ إذا كانت نقطة التدريب المختارة

واقعة ضمن نوافذ الوحدات المخبأة، وأطلق عليها اسم خوارزمية التغذية الأراجعة

المتمركة — زة (LBP (Localized Backpropagation)، وأخضعت الدالة

$f(x) = \sin(3x) \cos(5(x - 0.5))$ المعرفة في الفترة $[-1, 1]$ والمقسمة عند معدل تقسيم

$\psi(x) = \frac{x}{x_0} \exp(\frac{x_2}{2x_0^2})$ ، من 8Hz (Sampled rate) لعملية التدريب واستعملا موجة أم هي

مواصفات الشبكة المقترحة: شبكة مثالية، وتقارب سريع، والهروب من الوقوع في النهاية الصغرى

المحلية، ويبيّن أنّ كلفة الشبكة أنت 70% قياسا بشبكة BP التقليدية.

قام كوكراجا (Kugarajah) في العام 1995 بحل المشاكل التي تظهر في حالة تعدد

الأبعاد (Multidimensional) [17] بالاعتماد على نظريات دوشيز (Daubechies Theories)

المتعلقة بإطارات (Frames) الموجبة وأعطى إطار عمل لتحليل التعلم المحلي في الشبكات

العصبية، فطى إجراء لبناء شبكات بالاعتماد على نظرية الموجة، وأوضحت نتائجه ملائمة

استعمال الموجات كدوال في الشبكة في حالات السيطرة المتأقلمة

(Adaptive Control Situations)، واعتمد الباحث على التشابه الموجود بين تحويل الموجة

وشبكة RBFN، لبناء شبكة يكون عملها on-line زيادة على off-line. اختار الباحث نظام

سيطرة متأقلم غير خطي مباشر (**Direct Nonlinear Adaptive Control**) لتوضيح تطبيق الشبكة في سياق التعلم المحلي.

طورَ أيشاوز وفاشتسفانوس (Echaz and Vachtsevanos) [18] إطار عمل للشبكات العصبية الموجية لتجاوز الفجوة بين الشبكات العصبية التقليدية والهيكل المتأقلمة وسلاسل الموجة المخلال استثمار كل من توزيع الزمن-التردد للموجات، وقواعد التعلم للشبكات

العصبية، ونكرا أن الشبكات العصبية الموجية تطابق أو تشابه المماريات القديمة في حلها لمشاكل

التقريب والتصنيف. وضح الباحثان وجود أرضية مشتركة بين التقنيتين، إذ إن إخراج أي خلية عصبية مع وحدات استجابة محلية (**Locally Receptive Units**) يكون أقرب إلى الموجات من التقنيات

الأخرى، واستعملت معاملات التوسيع والنقل كأوزان في الشبكة العصبية على حين كانت الموجة دالة

نشاط غير خطية، ومن ثم تعطي طبقة تقريبات الموجة شبكة عصبية مكوّنة من طبقتين تحتفظ بمستوى التردد-الزمن و التحليل متعدد التفاصيل (**Multiresolution Analysis**) والتقريب

الشامل (**Universal Approximation**) بالنسبة للموجات، والسعة والكفاءة والتطور بالنسبة للشبكة العصبية. اختيرت شبكة (**Radial Basis Function**)، ذات الاستجابة المحلية للحصول على

موجات متعددة الأبعاد متناسقة نصف قطريا (**Radially Symmetric Multidimensional**)

(**Wavelets**)، والنتيجة هي الحصول على فئة جديدة من شبكات RBF يشار إليها بالشبكات العصبية الموجية النصف قطرية (**Radial Wavelet Neural Network**) واستعملت خوارزمية

(**K-mean Clustering**) لتدريب الشبكة، وتم اختيار مثالين لتوضيح أداء الشبكة المقترحة ومقارنته

مع RBF و MLP وهما تقريب دالة جيبية (**Sine Function**) مكونة من دورة ونصف الدورة أحادية البعد والمثال الآية تصنيف بيانات لفتتين ممزوجتين مكونتين من لولين

(**Two-Spiral Data**) (كما في الشكل رقم 4 في المصدر [18]) أوضح أن أداء الشبكة قياساً

RBF و MLP كان الأفضل.

بَحَث شينغ وشين وشياو (CHENG and CHEN and CHIAU) عام 1998 [19]

تطبيق البية لحل مشاكل السيطرة في الأنظمة غير الخطية، وطوروا قوانين سيطرة

متأقلمة، وخوارزميات ملائمة لتحديث المعاملات للأنظمة غير المعروفة للاخطية، وأظهروا أن تأثيرات

أخطاء التقارب والتشويش الخارجي يمكن أن تخفف إلى مستوى معين باستعمال قاعدة السيطرة للشبكة

عصبية المويجية المتأقلمة المقترحة، وطبق هذا التصميم على مثالين لنظام رقص ساعة

معكوس، ونظام أنسان آلي بمفصلين لتوضيح إجراءات التصميم المقترح، وأظهروا أداءه، إذ استعملت

قاعدة التعامد (Orthogonal Basis) لتكوين المويجات.

لم يُحدّد الباحثون طريقة لتحديد عدد مرات التوسيع والنقل للمويجا، بقي الاختيار يعتمد على

الخبرة والتجربة بما له علاقة بخطأ التقريب، واستعمل الباحثون تصميمين لهذه الشبكة هما الأول:

إدخال وحيد وإخراج وحيد (SISO (Single Input and Single Output)، والآخر: إدخال متعدد

وإخراج متعدد (MIMO (Multi Input and Multi Output).

قام ديفيد روفيرسو (David Roverso) عام 2000 [14] بوصف كيفية استعمال الشبكات

العصبية الانعكاسية (Recurrent Neural Networks) والمويجات بشكل يحسن من حل مشكلة

تصنيف الحالات المتغيرة (Transient Classification Problems)، واستطاع النظام المطور

الجديد تحديد أساسيين للأنظمة القديمة، هما مطلب شفافية ذات طول ثابت ومطلب إشارة

القدح (Tigger Signal) التي تشير إلى بداية حالة متغيرة.

استعمل التحليل المويجي كمرحلة معالجة أولية لاستخلاص الصفات من بيانات سلسلة

الوقت (Time-Series Data)، ووضح أن النتائج يمكن الحصول عليها حتى مع مرحلة إستخلاص

صفات موجية مبسطة بشكل كبير، ومثل هذا التبسيط مرغوب فيه بصورة خاصة في تطبيقات On-

line، وكذلك في التطبيقات ذات الأبعاد العالية أي التطبيقات التي تأخذ بنظر الاعتبار عدد متغيرات

المعالجة و/أو الفئات متغيرة الحالة. أجريت اختبارات ناجحة للنظام المقترح على بيانات أخذت من

منشأة نووية بسعة 900MW ، إذ كانت مهمة النظام المقترح التمييز بين سبع فئات مختلفة متغيرة

الحالة، وأوضحت النتائج قدرة النظام المقترح الذي يقدم حالة قوية لتطبيقها في عمليات صناعية

متنوعة (مسائل الوقت الحقيقي (Real Time)).

3-1 الشبكات العصبية (Neural Networks)

ازداد الاهتمام بالشبكات العصبية منذ مطلع الثمانينيات ومن ثم انتشار استعمالها ، فهي إحدى

تطبيقات الذكاء الاصطناعي التي استطاعت تجاوز مشاكل فون نيومان (Von Neuman) والأنظمة

الخبيثة [3][20]، ويعود هذا إلى عدة عوامل، منها رغبة الباحثين في معرفة كيفية تخزين المعلومات

وقابليات التعلم لدى الجهاز العصبي البيولوجي، زيادة على بعض الخصائص القيمة للشبكات العصبية

الاصطناعية التي ميزتها عن خوارزميات أخرى [3][6] :-

1-قابلية التعميم (The Generalization Capacity)

2-التوازي (Parallelism)

3-الذاكرة الموزعة (Distributed Memory)

4-السلوك الذكي (Intelligent Behavior)

5-التعلم وليس البرمجة (Learning not Programming)

تعرف الشبكة العصبية بأنها نظام لمعالجة المعلومات بشكل متوازي، يتكون من مجموعة عناصر

(PEs) (Neurons) أو عقد (Nods) ترتبط مع بعضها البعض بوساطة

مجموعة من الموصلات العصبية (Connections). تمتلك كل خلية حالة خاصة بها تدعى

نشاط (Activation) الخلية، ناتجة من تطبيق دالة نشاط (Activation Function)

مدخلاتها للحصول على إخراج تلك الخلية [5][21][22].

اقترح ماكلوخ وبيترز (McCulloch&Pitts) عام 1943 أول نموذج لخلية عصبية اصطناعية [10]، تضمن استعمال مبدأ عتبة (Threshold) الخلية، أي إن إخراج الخلية يكون ثنائي (Binary) اعتماداً على قياس نشاط الخلية بقيمة معينة [5]. وللحصول على تفاصيل أكثر يمكن مراجعة [5][9][23][26].

وضع العالم دونالد هب (Donald Hebb) في عام 1949 قانونه الخاص بالتعلم في الشبكات العصبية الذي أوضح فيه أن الخبرة تُخزن في الموصلات التي تربط الخلايا العصبية، وذكر هب أن التعلم والتذكر (Learning and Memory) هي ظواهر ناتجة من تقوية الموصلات بين الخلايا العصبية، ويبين أن التحفيز المتكرر لخلايا الشبكة يؤدي إلى تغييرات مستمرة لتقوية تلك الموصلات وصولاً إلى حالة الاستمرار أو ظهور التعلم [6]، وينص هذا القانون [6][9][23] :-

"عندما يكو المحور العصبي للخلية A قريباً بما يكفي لتحفيز الخلية B ويشترك بصورة متكررة في تحفيزها، تحدث عملية نمو أو تغير أيضي (Metabolic Change) في إحدى الخليتين هما بحيث تزداد فعالية الخلية A لأنها إحدى الخلايا المحفزة للخلية B".

شكل هذا القانون الأساس للعديد من قواعد التعلم المستعملة لتدريب الشبكات العصبية

الاصطناعية لتعديل أوزان الموصلات التي تربط الخلايا [1][6].

حققت الشبكات العصبية نجاحاً في العديد من التطبيقات، ومن بينها معالجة الإشارات (Signal Processing)، وتمييز الأنماط (Patterns Recognition) ومسائل الأمثلة (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) [9].

1-3-1 أنواع الشبكات العصبية (Types of Neural Networks)

تتنظم 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 وتستلم الإشارات. يدعى ترتيب الخلايا في الطبقات وأنماط الاتصال العصبية ضمن وبين الطبقات بمعمارية الشبكة (**Net Architecture**) [5].

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

1- شبكات التغذية الأمامية (**Feed Forward Networks**) [8][20]

تتكون شبكات التغذية الأمامية من طبقة واحدة أو أكثر، ووحدة معالجة أساسية غير خطية (**Nonlinear Processing Elements**) أو خلايا عصبية. ترتبط الخلايا الموجودة في طبقة معينة بخلايا الطبقة المجاورة من خلال مجن الموصلات العصبية. تتناسب المعلومات في هذا النوع من الشبكات باتجاه واحد من طبقة الإدخال إلى مخرج، ونوع التعلم في هذه الشبكات هو التعلم المشرف عليه (**Supervised Learning**)، أشهر أنواع هذه الشبكات وأكثرها شيوعاً واستعمالاً هي شبكة انسياب الخطأ خلفاً.

2- شبكات التغذية العكسية (**Feedback Networks**) [8][9][20]

ترتبط الخلايا في هذا النوع مع بعضها البعض، إذ يرتبط إخراج خلية عصبية مع مدخلات الخلايا نفس الطبقة والطبقة المجاورة. 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 هي شبكة هوبفيلد (**Hopfield Network**).

3- الشبكات التنافسية (Competitive Networks)[5][9]

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، مثل كل وحدة إخراج تجمع (Cluster)، وينسب النمط إلى أقرب تجمع إليه من خلال قياس المسافة (Distance) بين النمط ومراكز التجمعات المختلفة وتنتج الشبكة متجها نموذجاً أو مثالا (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 Features Map) لكوهينين عام 1988 وشبكة اكتشاف التجمع (Cluster Discovery Network) المطورة من قبل كارينتر وجروسبيرج عام 1988 والمسماة أيضا بنظرية التناغم التأقلمي (ART (Adaptive Resonance Theory).

1-3-2 التعلم في الشبكات العصبية (Learning in Neural Networks)

يعرف التعلم بأنه عملية اكتساب النظام العصبي القدرة على تنفيذ وظائف معينة بإعطاء صورة

تقريبية عن المشكلة بواسطة تعاملاته الداخلية (الأوزان)، وفقا لقاعدة تعلم معينة [17][20]، وتنتج

عملية التعلم باستعمال الأمثلة (Examples) [21] [6][9].

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

(Hebbian Rule) وقاعدة التعلم التنافسي (The Competitive Learning)

(Rule) [21]، وللحصول على تفاصيل أكثر عن قواعد التعلم يمكن الرجوع إلى [9].

تمتلك قواعد التعلم خصائص تميز قاعدة عن أخرى اعتماداً على طبيعة عمل القاعدة في تعديلها

للأوزان، إذا كانت عامة (Global) أو محلية (Local) [17]: -

*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 أقل (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 بالنسبة للجانب الإيجابي، أما الذ السلبية فيحتاج إلى

عدد أكبر من الوحدات، وقابليات تعميم قليلة .

ينقسم التعلم في الشبكات العصبية على نوعين أساسيين [21] [9] [24] :-

1- تعلم مشرف عليه (Supervised): يعتمد هذا النوع من التعلم على موازنة مباشرة بين الإخراج

الفعلي (Actual Output) للشبكة العصبية والإخراج المرغوب (Desired Output) لها واعتماداً

على المسافة بينهما، يتم قياس الخطأ الناتج ليستعمل في عملية تعديل (تصحيح) أوزان الشبكة.

2- تعلم غير المشرف عليه (Unsupervised): يكون الإخراج الهدف في هذا النوع من التعلم غير

معروف وبذلك لا توجد معلومات معروفة عن الخطأ يمكن أن تـ

الأوزان، ويعتمد على إيجاد علاقات بين بيانات الإدخال، الهدف منه تعديل الأوزان

تلقائياً (Autonomously) للوصول إلى حالة التوازن (Equilibrium State)، ومن الشبكات التي

تستعمل هذا النوع من التعلم شبكة هوبفيلد.

ويوجد هناك نوع آخره التعلم يسمى التعلم بالتقوية (**Reinforcement Learning**) الذي هو حالة خاصة من التعلم المشرف عليه [21]، أو حالة وسطية بين التعلم المشرف عليه والتعلم غير المشرف عليه [24]، يعتمد فقط على المعلومات المتوافرة حول الإخراج الفعلي إذا كان صحيحاً أو لا، يصنف الوك استجابة بيئة المشكلة حول الإخراج الفعلي إلى جيدة (١) أو سيئة (يعاقب)، ووفقاً لها يعدل معاملاته، وتستمر عملية التعديل حتى تظهر حالة التوازن، ويحدد الأوزان التي تمنع الأداء السيئ في المستقبل [25]، ويصنف تعلم شبكة التنظيم الذاتي تحت هذا النوع من التعلم.

1-3-3 دوال التنشيط (Activation Functions)

تعتمد فكرة بناء الشبكات العصبية على المعلومات المتوافرة عن الشبكات العصبية في الدماغ البشري، وكما معروف فإن الخلية العصبية في دماغ الإنسان لا تقوم بإنجاز معالجة خطية (**Linear Processing**) على مدخلاتها، بل إنها تستلم مجموعة من المدخلات التي تقوم على أساسها بإنجاز فعل معين، ولذلك تمت عملية محاكاة لهذا السلوك بواسطة مجموعة من الدوال اللاخطية (**Nonlinear Functions**) [5] [8] [9].

إن وجود تلك المجموعة من دوال النشاط واستعمالها ضمن خلايا الشبكة يعتمد على نوع خصوصية الشبكة (**Particular Class of Network**) [48]، وأيضاً على قيم الهدف (**Target Values**) [5].

1-3-3-1 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 ولكنها غير قابلة

للاشتقاق، لذلك فإن أكثر خوارزميات التعلم المعتمدة على المشتقة لا تستطيع استعمال هذه الدالة، تقسم

هذه الدالة على نوعين [5][9][23]:-

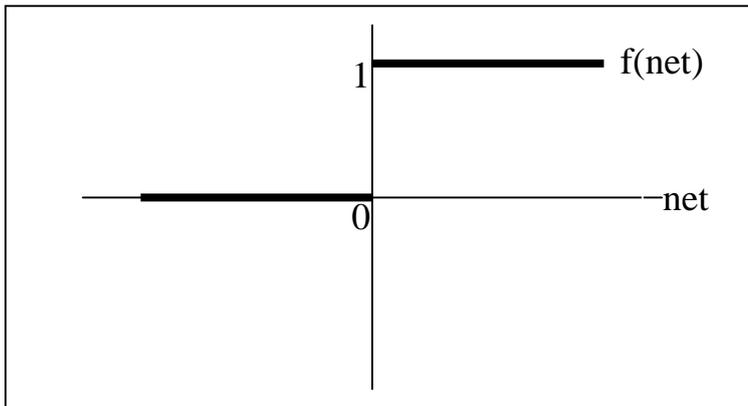
أ- الدالة الثنائية أحادية القطب (Unipolar Binary function)

تكون مخرجات هذه الدالة هي القيم الثنائية (0) أو (1) وصيغتها العامة هي:-

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

ولهذه الدالة اسم آخر هو (Heaviside Function) [23]. الهيكل العام لمخرجات هذه الدالة

يوضحه الشكل (1-1).



شكل (1-1) يبين الدالة الثنائية أحادية القطب

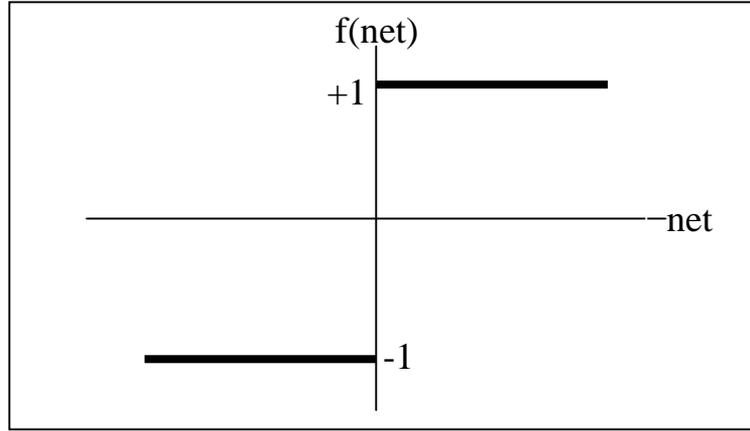
ب- الدالة الثنائية ثنائية القطب (Bipolar Binary Function)

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

$$f(\text{net}) = \begin{cases} +1 & \text{if } \text{net} \geq 0 \\ -1 & \text{if } \text{net} < 0 \end{cases} \quad (1-2)$$

وإحدى المسميات الأخرى لهذه الدالة هي (Signum Function) [24]، والشكل (1-2) يوضح

هذه الدالة.



شكل (1-2) يبين الدالة الثنائية ثنائية القطب

يطلق على دالة الإشارة بشكل عام أحياناً (Hard Limiting Activation Function) [10].

2- الدالة السيجماوية (Sigmoidal Function)

هي من الدوال الشائعة الاستعمال في العديدينوارزميات التعلم [2]، لأنها من الدوال اللاخطية

والقابلة للاشتقاق وسميت كذلك لأن شكلها يشبه الحرف S [5][7]، وتقسّم هذه الدالة على

نوعين [5][9][23]: -

1- الدالة السيجماوية أحادية القطب (Unipolar Sigmoidal Function)

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

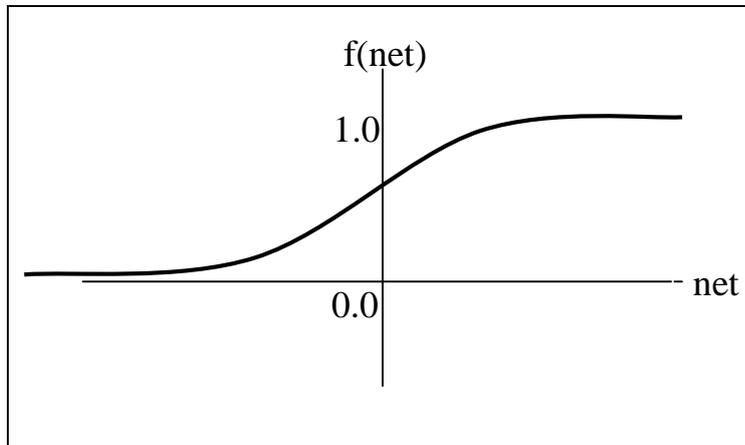
$$f(net) = \frac{1}{1 + e^{-\lambda net}} \quad (1-3)$$

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 $\lambda \rightarrow \infty$ فإن الدالة تقترب من دالة

الخطوة (Step Function) [9] المعرفة بالعلاقة (2 - 1) وتسمى هذه الدالة أحيانا بالدالة

المنطقية (Logistic Function) [5][23]. الشكل (1-3) يوضح هذه الدالة.



شكل (1-3) يوضح دالة سيجماوية أحادية القطب

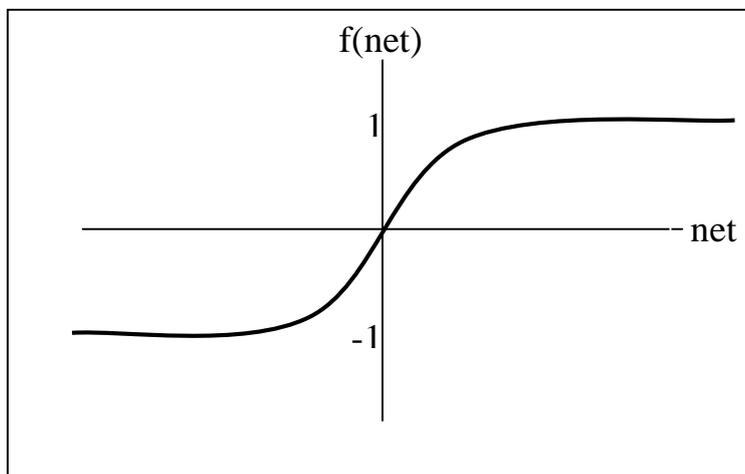
ب- الدالة السيجماوية ثنائية القطب (Bipolar Sigmoid Function)

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

$$f(net) = \frac{2}{1 + e^{-net}} - 1 \quad (1-4)$$

وتسمى هذه الدالة أيضا (Hyperbolic Tangent Function) [1] [9] [26]، هذه الدالة

موضحة في الشكل (1-4).



شكل (1-4) دالة سيجماوية ثنائية القطب

1-3-3-2 دوال التنشيط المحلية (Local Activation Function)

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

الإدخال، وهناك نوعان من هذه الدوال [1] [5] [26] [27]:-

1-دالة النبضة (Pulse Function)

هي دالة إشارة ثنائية (Binary Signal Function) وتأخذ هذه الدالة القيم 0 و 1، الصيغة

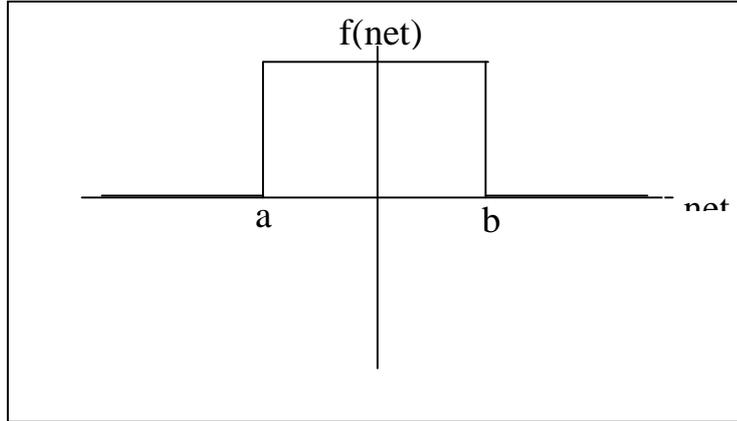
أ :

$$f(\text{net}) = \begin{cases} 1 & \text{if } a \leq \text{net} \leq b \\ 0 & \text{otherwise} \end{cases} \quad (1-5)$$

إذ تمثل a و b الحد الأدنى والأعلى للفترة التي تقع ضمنها مدخلات لخلية (net)، ومن مشاكل هذه

الدالة إنها غير قابلة للاشتقاق ولا يمكن استعمالها في خوارزميات التعلم المعتمدة ع

المشتقة [8]، والشكل (1-5) يوضح هذه الدالة.



شكل (1-5) يبين دالة النبضة

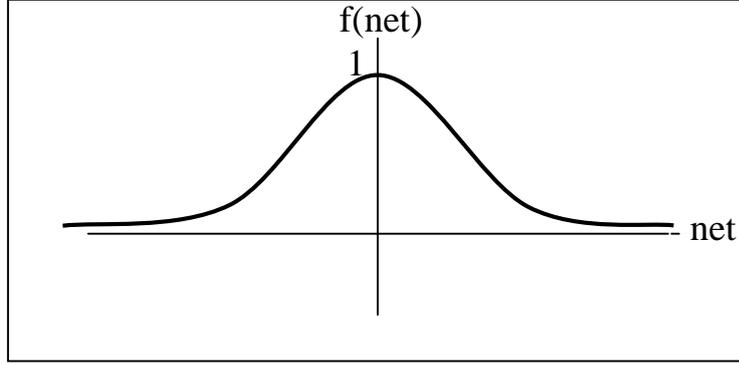
2- دالة كاوس (Gaussian Function)

تمتلك هذه الدالة مشتقة يمكن استعمالها في خوارزميات التعلم المعتمدة على المشتقة، والصيغة

العامة لها هي:-

$$f(\text{net}) = e^{-\frac{(\text{net} - c)^2}{2\sigma^2}} \quad (1-6)$$

net: المدخلات إلى دالة كاوس، σ : تمثل الانتشار (Spread) للدالة، c : نقطة المنتصف (Center Point). الشكل (6-1) يوضح هذه الدالة.



كل (6-1) يبين دالة كاوس

1-3-4 الهيكل العام للموصلات

(The General Structure of Connections)

يمكن تقسيم الشبكات العصبية الاصطناعية اعتماداً على هيكل الشبكة العصبية على نوعين [23]

-:

1- الشبكات الطبقيّة (Layered Networks)

تتكون هذه الشبكات من مجموعة من الطبقات (Layers)، 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 Layer)

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

ب- الطبقة (الطبقات) المخبأة (Hidden Layer(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 Layer)

تكون هذه الطبقة مسؤولة عن بار مخرجات الشبكة. ومن الأمثلة الشائعة لهذه الشبكة هي

شبكة المدرك (Perceptron) وشبكة انسياب الخطأ خلفا (Error Backpropagation

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

2- الشبكات تامة الارتباط (Fully Connected Network)

ترتبط كل خلية عص 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 نفس

الطبقة أو في دو هذا يساعد الشبكة في الوصول إلى حالة الاستقرار، ومن أمثلتها شبكة

هوفيلد [5][6][9].

1-3-5 الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية

(Multilayer Feed Forward Networks)

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) [23]، وتكمن أهميتها بقدرتها على إنجاز عملية التعلم تحت أي تعقيد، واعتمادها على

تقويم متكرر لأمثلة التدريب وكما في ذات الطبقة الواحدة [9]، ولمعرفة الظروف التي أدت

إلى التوجه نحو هذا النوع من الشبكات، سنتناقش النماذج الأولى للشبكات العصبية المكونة من طبقة

واحدة وبالأخص شبكة المدرك (Perceptron) والمحددات على هذه الشبكات التي أدت إلى التفكير بالشبكات متعددة الطبقات.

1-5-3-1 شبكة المدرك (Perceptron Network)

تعدُّ شبكة المدرك المقترحة من قبل روزنبلات (Rosenblatt) عام 1958 أول تصميم لشبكة عصبية تتكون من مجموا بالاعتماد على نموذج ماكلوخ-بيترز للخلية وقانون هيب للموصلات [23] [26]، تتكون هذه الشبكة من طبقة إدخال وطبقة إخراج، ومجموعة من الموصلات بين هاتين الطبقتين؛ أوزانها أثناء عملية تدريب الشبكة. تكون قيمة الإدخال والإخراج للشبكة العصبية (0) أو (1) [23] أو تكون (-1) أو (+1) [28]، وتكون أوزان الموصلات قيم حقيقية. تكون دالة التنشيط في خوارزمية تعلم المدرك هي دالة إشارة (Sign Function). تتعلم المدرك بوساطة قاعدة تعلم مشرف عليه لتصحيح الأخطاء، وتعدل أوزان الشبكة خلال عملية التعلم بحسب المعادلة الآتية [1][5][9][23]:-

$$w_{ij}(new) = w_{ij}(old) + c(d_j - \text{sgn}(\sum_{i=1}^n x_i \cdot w_{ij}(old)))x_i \quad (1-7)$$

w_{ij} : وزن الموصل بين الخلية المصدر i والخلية الهدف j ، c : معامل التعلم، x_i : إدخال الخلية

a_j : قيمة الإخراج المرغوبة للخلية j .

عُدت شبكة المدرك بداية انطلاق الموجة الأولى لنظرية الشبكات العصبية

الحديثة [26]، استطاعت هذه الشبكة حل بعض المشاكل الخطية ولكنها بالمقابل فشلت في حل المشاكل

اللاخطية (Nonlinear Problems) مثل مشكلة الدالة XOR [7][29]، إذ أوضح نلس نلسون

(Nils Nilsson) وآخرين عدم قدرة المدرك على حل هذه المشاكل [1][28]، أوضح مارفن منسكي

وسيمور بيبيرت (Marvin Minsky and Seymour Papert) في كتابهما عدم إمكانية الشبكات

العصبية لحل هذه المشكلة لأن خوارزمية المدرك تعتمد على معرفة الإخراج المرغوب

إخراج وتفترض أن أوزان الموصلات بين طبقة الإدخال وطبقة الإخراج هي الوحيدة التي تجري

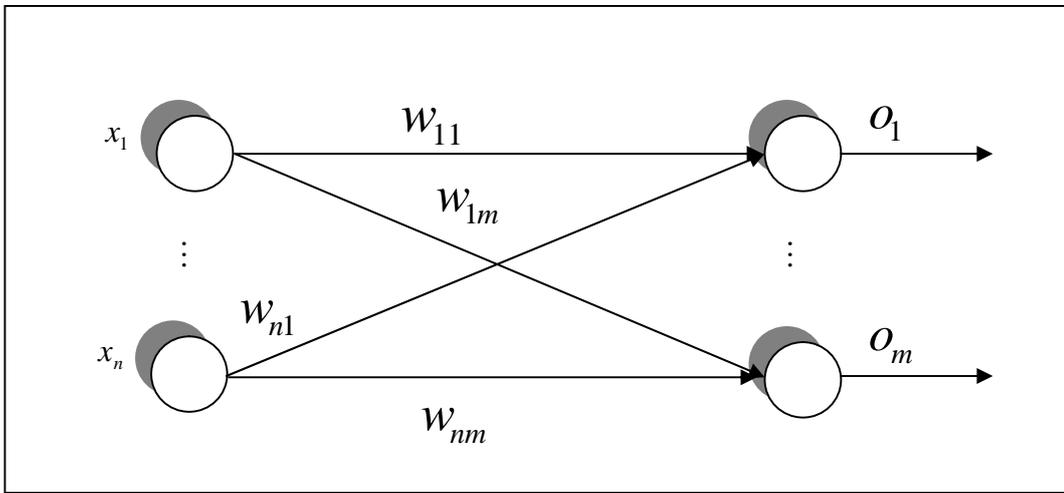
عليها عملية التعلين إضافة طبقة ثالثة (أو أكثر) تسمى الطبقة المخبأة، يجعل من الصعوبة معرفة

الإخراج المررب لخلايا الطبقة (الطبقات) المخبأة، وبذلك انحصرت كفاءة المدرك في حل المشاكل

الخطية [1][5][7][9]، وسجل كتاب منسكي وبيبرت النهائية لموجة شبكة المدرك وتوجه الباحثون نحو

ترك هذا الاتجاه وتحويل الاهتمام إلى تقنيات الذكاء الاصطناعي الأخرى، والشكل (7-1) يوضح

الهيكل العام لشبكة المدرك.



(7-1)

يوضح شبكة مدرك تحتوي على n خلية إدخال و m خلية إخراج [9]

2-5-3-1 شبكة انسياب الخطأ خلفا (Error Backpropagation)

(Network

تعد هذه الشبكة من الشبكات الأكثر شعبية في التطبيق، وهي عبارة عن شبكة تغذية أمامية متعددة

الطبقات مدربة باستعمال خوارزمية انسياب الخطأ خلفا، 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 لمة العتبة (Threshold Function) المستعملة في الشبكات الخطية، وهذه الشبكة قادرة على حل مشاكل التقريب بتعقيدات مخن [5][6][7][9][23].

1-2-5-3-1 معمارية الشبكة (Network Architecture)

تتكون شبكة انسياب الخطأ خلفا من ثلاثة أنواع من الطبقات [6][7][10][23] :-

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 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 واحدة وعدد كافي

من الخلايا المخبأة، مدربة باستعمال خوارزمية انسياب الخطأ خلفا قادرة على تقرب أدالة إلى دقة

معينة وهذا ما يشار إليه بنظرية التقريب الشامل (Universal Approximation

Theorem) [6][7][17][26][30].

3-طبقة الإخراج (Output Layer)

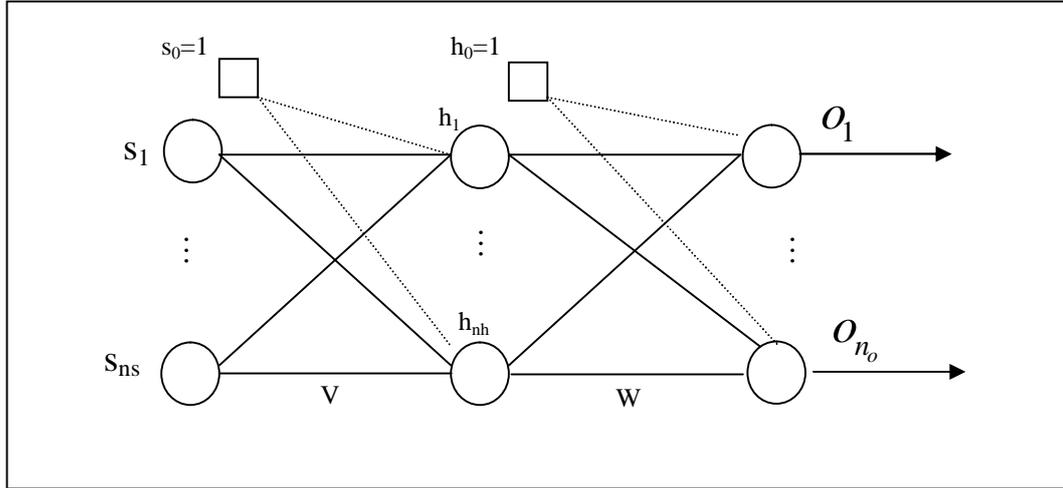
تستلم هذه الطبقة شفرة النمط المحفز (Stimulus Pattern Code) من الطبقة المخبأة وإيجاد

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 الشكل (8-1) يوضح هذه الشبكة.



(8-1)

يبين شبكة انسياب الخطأ خلفا [9]

S_i : مخرجات خلية الإدخال i ، h_k : مخرجات الخلية المخبأة k .

O_j : مخرجات خلية الإخراج j ، V : منظومة أوزان الموصلات بين طبقة الإدخال والطبقة المخبأة.

W : منظومة أوزان الموصلات بين الطبقة المخبأة وطبقة الإخراج.

n_s : عدد خلايا الإدخال، n_h : عدد الخلايا المخبأة، n_o : عدد خلايا الإخراج.

1-3-5-2-2 خوارزمية التعلم (Learning Algorithm)

تعد خوارزمية تعلم شبكة انسياب الخطأ خلفا من الخوارزميات الفعالة وتصنف ضمن

خوارزميات التعلم المشرف عليه (Supervised Learning Algorithms) التي تعتمد على

المشتقة في تعديل الأوزان [1][7][24][31]، وتستعمل هذه الشبكة دالة تنشيط سيجماوية

(Sigmoid Function) لتحديد نشاط خلاياها، وهي دالة قابلة للاشتقاق (كما ذكرنا في الفقرة

(1-3-3-1))، تستعمل هذه الخوارزمية دالة أقل متوسطات مربعات الخطأ

LMSE(Least Mean Square Error) مقياساً يحدد تقارب مخرجات الشبكة باتجاه الحل

المرغوب. توضح المعادلة (1 - 8) صيغة هذه الدالة [1][7][9]:

$$E = \frac{1}{2} \sum_{p=1}^{n_p} \sum_{k=1}^{n_o} (d_{pk} - o_{pk})^2 \quad (1-8)$$

E: الخطأ الكلي للشبكة بعد إدخال كافة الأنماط.

n_o : عدد خلايا الإخراج.

n_p : عدد أنماط التدريب.

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

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

تعمل مشتقة دالة الكلفة أعلاه على تعديل أوزان الشبكة العصبية بالاتجاه الذي يؤدي إلى تقليل قيمة

الخطأ الكلي للشبكة [1][6][9].

تمر خوارزمية التعلم في شبكة انسياب الخطأ خلفاً بمرحلتين أساسيتين [7][23] -:

1-مرحلة التغذية الأمامية (Feed Forward Phase)

يتم في هذه المرحلة إدخال أنماط التدريب إلى الشبكة وينساب النشاط (Activity) الناتج خلال

الشبكة من طبقة الإدخال إلى طبقة الإخراج مراراً بالطبقة (الطبقات) المخبأة، ويتم حساب قيمة

الإخراج بحسب المعادلات الآتية [9]:

$$h_k = f(net_k) = f\left(\sum_{i=0}^{n_z} z_i \cdot v_{ik}\right) \quad (1-9)$$

$$o_j = f(net_j) = f\left(\sum_{k=0}^{n_h} h_k \cdot w_{kj}\right) \quad (1-10)$$

z_i : مخرجات خلية الإدخال i بضمنها خلية العتبة $s_0 = 1$

h_k : مخرجات الخلية المخبأة k بضمنها خلية العتبة $h_0 = 1$

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_z : عدد الخلايا في طبقة الإدخال.

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

لشبكة مقبولة تتوقف عملية التدريب وإلا يتم الانتقال إلى المرحلة الثانية .

2-مرحلة انسياب الخطأ خلفا (Error Backpropagation 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 المرحلتين حتى يتحقق شرط التوقف

الوصول إلى الخطأ المقبول، والشكل (1-9) يوضح عملية التعلم وانسياب المعلومات في

المرحلتين [9].

1-3-5-2-3 مشاكل الشبكة العصبية متعددة الطبقات

لقد أثبتت هذه الشبكات المدربة بخوارزمية انسياب الخطأ خلفاً كفاءة عالية في حل العديد من

المسائل ولكن هناك بعض المشاكل أو المحددات التي تواجه هذه الشبكات أهمها [1][23]:

1- المشكلة التصميمية (Design Problem)

لا توجد قواعد محددة يتم عن طريقها تحديد التصميم المناسب للشبكة واللازم لها

معينة، ويقصد بالتصميم المناسب هو تحديد عدد الطبقات المخبأة وعدد الخلايا المخبأة في كل طبقة

فضلاً عن تحديد التوصيلات بين الخلايا المخبأة وتحديد التوصيلات العامة للشبكة، غالباً ما يتم استعمال

طريقة التجربة والخطأ (Trial and Error) أو استعمال معاملات التحويل المويجي لعملية تحديد التوصيلات.

2- التقارب (Convergence)

لا تعتبر عملية تدريب الشبكة لتقليل الخطأ وصولاً إلى أقل خطأ ممكن بالمهمة السهلة لأن مجال

دالة الكلفة يحتوي على مواصفات (Features) تمنع الخوارزمية من التقارب ومنها وجود نهايات

صغرى محلية متعددة (Many Local Minima) [7][31]، يمتلك معامل التعلم (Learning Rate)

تأثير كبير على سرعة التقارب (سيتم توضيحه في الفقرة (1-3-5-2-4))، للتخلص من مشكلة النهاية

الصغرى المحلية التي تؤثر على سرعة تقارب الشبكة العصبية، يتم استعمال تقنيات تبحث عن الحل

العالمي (الشامل) ومنها استعمال الموجات التي تعتبر مقربات عامة (Universal

Approximators) تعطي تقريب للدالة أو الإشارة المعالجة بالتحليل المويجي.

3- التعميم (Generalization)

يقصد به قدرة الشبكة في التعرف على أنماط جديدة (قليلة الاختلاف) لم تستخدم ضمن مجموعة

أنماط التدريب، وهو من المقاييس المهمة لكفاءة الشبكة، وخاصة تلك التي تستخدم في أنظمة التصنيف.

4-الإشباع المبكر (Premature Saturation)

تظهر هذه المشكلة نتيجة لاختيار أوزان ابتدائية عالية تجعل خلايا الشبكة غير قادرة على

التعلم، تنمو الأوزان التي لها علاقة بالخلية المقصودة بشكل مستمر وتصبح ق

مخرجات الخلية بعد تطبيق دالة نشاطها مقارنة إلى الحد الأعلى أو الأدنى (القيمة 1 والقيمة 0

في حالة الدالة السيجماوية أدية القطب) وتصبح المشتقة $f(\text{net})$ مقارنة إلى الصفر وهذا يجعل

قيمة التعا صفر أيضا وتبقى الأوزان ثابتة وبالتالي بقاء قيمة الخطأ عالية وتصبح الخلايا

في حالة الإشباع (Saturation). من ضمن الحلول لتجاوز هذه المشكلة يتم استعمال معاملات النقل

والتوسيع لتحويل الموجة لتوفير الأوزان الابتدائية لشبكة انسياب الخطأ خلفاً [12].

4-2-5-3-1 عامل التعلم (Learning Factor)

يمثل مقدار الخطوة التي تخطوها خوارزمية التعلم في فضاء المشكلة لتقليل خطأ التدريب، ويعد

ذو تأثير كبير على إنجازية خوارزمية التعلم وتكون قيمته ضمن الفترة [1,0] [1] [6] [9]. تعتمد قيمة

معامل التعلم على المشكلة المراد حلها، إذ لا توجد قيمة ثابتة ملائمة لمشاكل مختنا وهي مشكلة بحد

ذاتها، ومن المهم اختيار القيمة المناسبة لمعامل التعلم، لأن القيمة العالية تؤدي إلى الوقوع في مشكلة

التجاوز (Overshooting)، بينما القيمة الواطئة تتجنب تلك المشكلة لكنها تؤدي إلى تأخير في عملية

التقارب [9] [23]، وبسبب تلك مشاكل 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

[7] [8] [32] حسب المعادلة:-

$$= 0 \cdot \left(1 - \frac{t}{T_{\max}}\right) \quad (1 - 11)$$

η : القيمة الجديدة لمعامل التعلم، η_0 : قيمة معامل التعلم الابتدائية، t : قيمة الدورة (Epoch) الحالية، T_{max} : العدد الأقصى لدورات التعلم.

1-4 تحويل الموجة (WT(Wavelet Transform))

استحوذ موضوع تحويل الموجة على اهتمام علماء الرياضيات والهندسة والحقول الأخرى

المرتبطة بهما على حد سواء، وطبق بشكل ناجح في تحليل الإشارة في مجال التردد- الزمن

(Time-Frequency Signal Analysis)، وتقريب الدوال (Function Approximation)

وتقريب حل المعادلات التفاضلية الجزئية (Approximation in Solving Partial

Differential Equation)، وغيرها من التطبيقات [19][33].

تعود الفكرة الأصلية لهذا التحويل إلى تحويل فوريير (Fourier Transform)، ففي بداية القرن

التاسع عشر وتحديدًا عام 1807 قدم جوزيف فوريير (Joseph Fourier) نظرية في تقريب وتحليل

الدوال التي تعرف اليوم بتحويل فوريير، وأصبح استعمال هذا التحويل شائعًا في تطبيقات عديدة في

حقل تحليل الإشارة، يعطي هذا التحليل معلومات حول محتوى التردد للإشارة لكنه لا يعطي معلومات

حول كيفية تغير تلك الترددات مع الزمن، وبذلك لا يمكن استعمالها لتقريب الإشارات غير

الثابتة [33][34][35].

قام كابور (Gabor) عام 1946 بتطوير وتعديل تحويل فوريير من خلال إضافة نافذة

إمرار (Window Pass)، وهو ما يعرف بتحويل كابور (Gabor Transform)، أو تحويل فوريير

ذي الوقت القصير (Short Time Fourier Transform) STFT، الغرض منه التعامل مع

الترددات المختلفة من خلال تجزئ الإشارة باستعمال نافذة زمن وتطبيق تحويل فوريير على كل

جزء، لكن الحجم الثابت لأجزاء النافذة لم يؤدي إلى الغرض المطلوب [33][36].

كانت بداية ولادة تحويل الموجة في أواخر السبعينات، عندما لاحظ مهندس فيزياء الأرض

الفرنسي مورليت (Morlet) عدم قدرة STFT على تحليل إشارات الزلازل التي كان يرغب في

معالجتها، إذ تميّزت هذه الإشارات بامتلاكها ترددات عالية خلال مدة زمنية قصيرة وترددات واطئة

خلال مدد زمنية طويلة، لذا توصل إلى فكرة بارعة باستعمال نافذة متغيرة الحجم تتعامل مع تلك

الترددات وأطلق على دوال التحويل الجديدة اسم الموجات (Wavelets)، بعد ذلك تضافرت

جهود الباحثين (Grossman and Morlet) لوضع الأسس الرياضية لتحويل الموجة [33][37]

وفي عام 1985 أعطى مالات (Mallat) لتحويل الموجة انطلاقة جديدة من خلال عمله في حقل

معالجة الإشارة الرقمية، إذ كشف العلاقة بين المرشحات الرقمية وتحويل الموجة، فأصبح تمثيل

الموجات بوساطة مرشحات تمثيلاً شائعاً في معظم التطبيقات [35]، وفي ذات الوقت قامت

دوبشيز (Daubechies) بتطوير مفهوم إطارات الموجة (Wavelet Frames) التي تسمح بحرية

أكثر في اختيار الدوال الأساس، ولها الفضل هي ومالات بالانتقال من تحليل الإشارة المستمر إلى

تحليل الإشارة المتقطع. ثم قام مالات عام 1986 بتطوير فكرة التحليل متعدد

المستويات (MRA) (Multiresolution Analysis) لتحويل الموجة المتقطع (Discrete Wavelet

Transform) DWT [33].

تعرف الموجات بأنها دوال مركزة الطاقة في حيز الزمن ذطول محددة (ومن هنا جاء

اسمها)، تستعمل وسائلاً لتحليل الإشت غير الثابتة التي تتغير مع الزمن [38]، تنتج الموجات عن

طريق إجراء عمليتين أساسيتين هما التوسيع (Dilation) والنقل (Translation) لدالة وحيدة تدعى

الموجة الأم (Mother Wavelet)، وتسمى مجموعة الدوال الناتجة من هذه العملية بالموجات

الأساس (Basis Wavelets) التي تعرف بالمعادلة التا [11][16] [39]:-

$$\mathbb{E}_{(a,b)}^x = \frac{1}{\sqrt{a}} \mathbb{E} \left(\frac{x-b}{a} \right) \quad (1-14)$$

إذ إن $\bar{\Psi}(x)$: الموجبة الأم، a : معامل التوسيع، b : معامل النقل.

تتميز هذه الدوال بكونها دوال محددة في حيز الزمن (**Compactly Supported**)، أي إنها

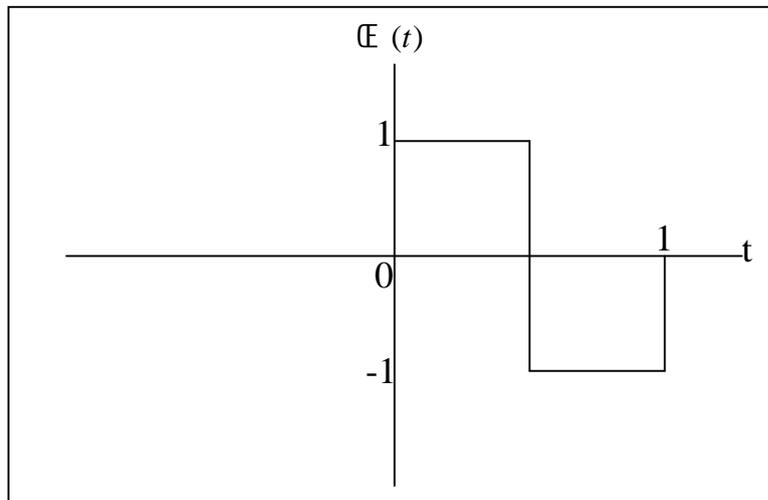
تمتلك قيم خلال مدة معينة وتكون قيمتها صفراً خارج هذه المدة، ومن هذه الدوال التي هي أول

الأنواع التي ظهرت وأبسط موجة هار (**Haar**) المعرفة بالمعادلة التالية [36] [40] [41] :-

$$\mathbb{E}(t) = \begin{cases} 1 & \text{if } 0 \leq t < \frac{1}{2} \\ -1 & \text{if } \frac{1}{2} \leq t < 1 \\ 0 & \text{otherwise} \end{cases} \quad (1-15)$$

يوضح الشكل (10-1) هذه الموجة والمعرفة ضمن الفترة [1,0]، ومن المعادلة (1-15) نلاحظ أن

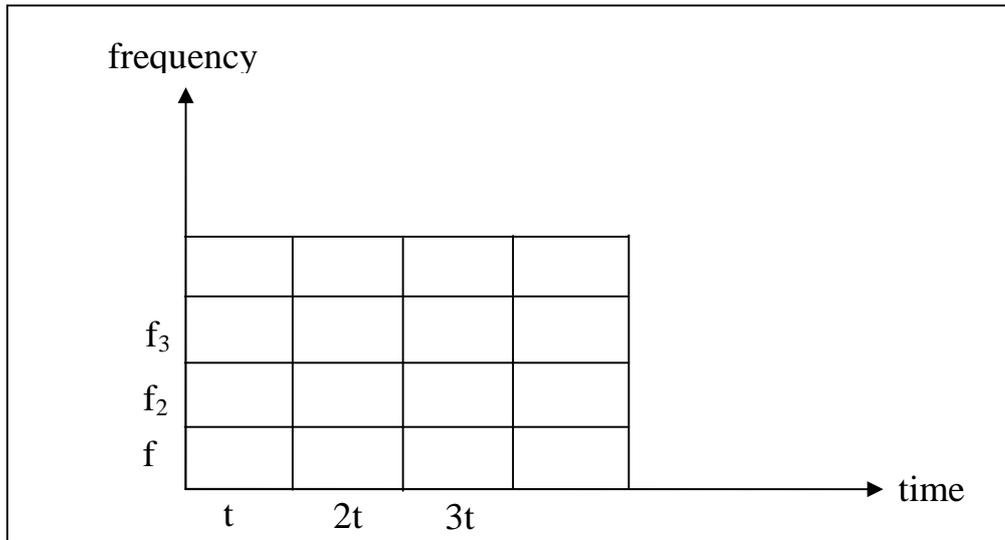
قيمة هذه الموجة صفراً خارج هذه الفترة.



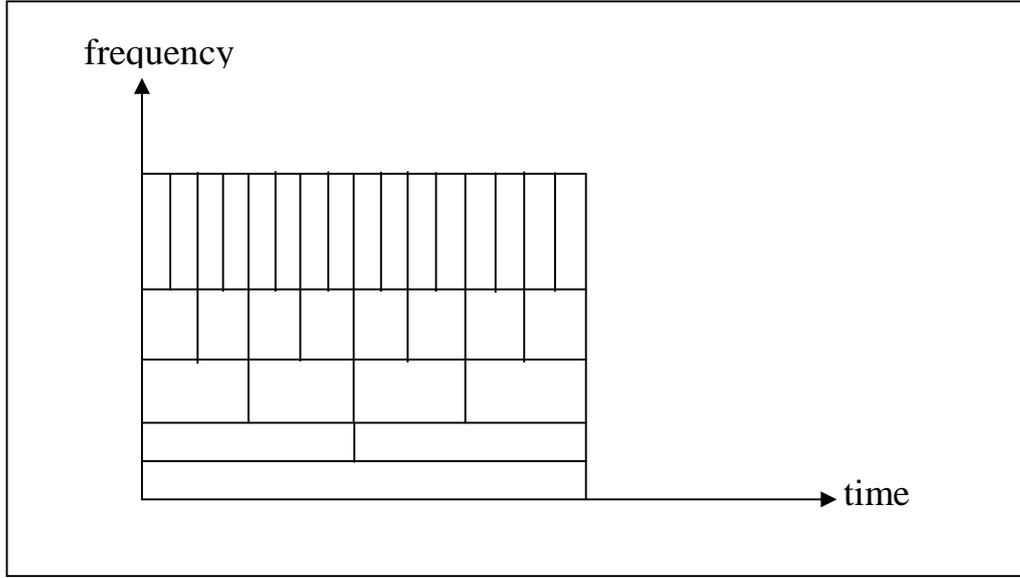
، (10-1) يبين موجة هار (**Haar**)

1-4-1 الإشارات غير الثابتة (Non-Stationary Signal) [36][42][43]

تعرف الإشارات غير الثابتة بأنها الإشارات التي تتغير تردداتها مع الزمن مثل (الموسيقى، الصور، الكلام، ... الخ). لم ينجح تحويل فوريير في معالجة هذه الإشارات، لأنه يتعامل مع الأحداث التي تخاصص لا تتغير مع الزمن (التي تستمر على طول محور الزمن) ويهمل الأحداث العرضية، والحل لهذه المشكلة هو استعمال تحويل STFT (تحويل كيبور)، يملك هذا التحويل نوعين من الدوال هما دالة الجيب (Sine Function) ودالة الجيب تمام (Cosine Function)، وهي دوال دورية (Periodic Function)، يستعمل هذا التحويل نافذة تحليل مربعة بسيطة ذات حجم ثابت لجميع ت، لذا يكون مستوى التردد-الزمن ذا شكل واحد لجميع الترددات وكما موضح في الشكل (11-1)، أما الموجات فتعد وسائل فعالة لتحليل الإشارات غير الثابتة لأنها تستعمل عدد غير محدد من الدوال الأساس، وتستعمل نافذة متغيرة الحجم إذ تختلف هذه النافذة مع الترددات، فتستعمل نافذة ضيقة في الترددات كبيرة في الترددات الواطئة، وبذلك يكون شكل مستوى التردد-الزمن متغير كما موضح في الشكل (12-1).



شكل (11-1) يبين مستوى التردد الزمن لتحويل فوريير



شكل (1-12) يبين مستوى التردد-الزمن لتحويل الموجة

2-4-1 أنواع تحويل الموجة (Types of Wavelet Transform)

ينتمي تحويل الموجة إلى عائلة التحويلات التي تمتلك مجموعة من الدوال الأساس، ويوجد

نوعين من تحويل الموجة [44]: -

CWT(Continuos Wavelet Transform)

*تحويل الموجة المتصل

(Discrete Wavelet Transform)

*تحويل الموجة المنقطع

ترتبط إشارة الإدخال بموجة تحليل متصلة عند استعمال تحويل الموجة المتصل، التي هي عبارة عن

دالة من معاملين هما التقييس والموقع (Scale and Position) بحيث يمكن إعادة تكوين الإشارة من

تحويلها الموجي، في التطبيقات العملية ستستعمل أجزاء من هذا التحويل، بحيث يكون متجه الإدخال

عبارة عن متجه من القيم، ويتم حساب موجات متقطعة، تم التركيز أثناء البحث على تحويل

الموجة المنقطع لأن الشبكة تتعامل مع متجه ذو عدد محدد من القيم.

1-4-3 إطارات الموجة (Wavelet Frames) [11][15][17][39]

توجد مجموعتان من دوال الموجة، الأولى هي موجات متعامدة

(Orthogonal Wavelets)، والمجموعة الثانية هي إطارات الموجة (Wavelet Frames). يرتبط

تحليل الموجة المتعامد مع نظرية التحليل متعدد التفاصيل

(Multiresolution Analysis)، ولا يمكن التعبير عن هذه الموجات في صيغة تقريبية

(Closed Form)، وهذا محدد يجعل من الصعوبة تطبيقها لمسائل تقرب الدوال، بصورة معاكسة

تركب إطارات الموجة عن طريق عمليات بسيطة من النقل والتوسيع على دالة ثابتة وحيدة (Single

Fixed Function) تدعى الموجة الأم (Mother Wavelet) تنتمي إلى الفضاء $L^2(R)$ التي

يجب أن تحقق شروط أقل صرامة (Less Stringent) من شروط التعامد، فالإطارات إذا هي حالة

عامة للقواعد ذات التنسب المتعامد [15].

تشتق الموجة $\bar{\psi}_j$ من موجتها الأم عن طريق العلاقة

$$\mathbb{E}_j(x) = \mathbb{E}_j\left(\frac{x - m_j}{d_j}\right) \quad (1 - 16)$$

إذ أن معامل النقل m_j ومعامل التوسيع d_j هي أعداد حقيقية، لذا يمكن تعريف عائلة الدوال

المولدة من الدالة ψ

$$\Omega_c = \left\{ \frac{1}{\sqrt{d_j}} \mathbb{E}\left(\frac{x - m_j}{d_j}\right), m_j \in R \text{ and } d_j \in R^+ \right\} \quad (1 - 17)$$

يسمى Ω_c (يشير إلى الحالة المستمرة لتحويل الموجة) إطار ضمن الفضاء $L^2(R)$ إذا وجد على

الأقل ثابتان $A > 0$ و $B < +\infty$ ، وأنه $\forall f \in L^2(R)$ وإذا تحققت المتكافئتان التاليتان:

$$A \| f \|^2 \leq \sum_j | \langle \mathbb{E}_j, f \rangle |^2 \leq B \| f \|^2 \quad (1-18)$$

حيث $\| f \|^2$ هي المعيار (Norm) للدالة f <.,.> هو حاصل الضرب الداخلي (Inner Product) في الفضاء $L^2(R)$ ، بالتالي يمكن تمثيل الدالة f بواسطة السلسلة التالية:

$$f(x) = \sum_n C_n \Omega_{cn} \quad (1-19)$$

$$C_n = \int f(x) \Omega_c d_n d_x \quad (1-20)$$

4-4-1 تحويل الموجة المتقطع (Discrete Wavelet Transform)

في معظم التطبيقات العملية يتم التعامل مع الإشارات بعد أخذ عينات (Samples) من تلك الإشارات ثم تطبيق تحويل الموجة عليها. ضمن مفهوم التحويل المتقطع تعرف عائلة الموجات بالعلاقة التالية:

$$\Omega_d = \left\{ r^{\frac{m}{2}} \mathbb{E}(r^m x - n s), (m, n) \in Z^2 \right\} \quad (1-21)$$

إذ أن α و β هي ثوابت تحدّد مع الموجة الام للعائلة Ω_d ، و (n, m) فهرسي التوسيع والنقل لهذا التحويل. في الواقع يمكن اعتبار العلاقة (21 - 1) حالة خاصة من العلاقة (17 - 1) لان:

$$\begin{cases} m_j = n r^{-m} s \\ d_j = r^{-m} \end{cases} \quad (1-22)$$

يعتبر DWT أسرع واكفا في الحساب من CWT واسهل للتطبيق في المجال العملي [45]

وسنقوم بمناقشة الموجات متعددة الأبعاد في الفقرة التالية للحاجة إليها في البحث.

1-4-5 المويجات متعددة الأبعاد (Multidimensional)

[46][17](Wavelets)

ظهرت نظرية المويجات كما نعلم كأداة مهمة في تطبيقات عديدة خاصة في معالجة الإشارات و

التحليل العددي وركزت الدراسات في هذا المجال على المويجات ذات البعد الواحد و البعدين، لان

استخدام التحويل المويجي لأبعاد أعلى يكون مكلف.

يمثل تطور الشبكات العصبية ضمن إطار عمل نظرية المويجات أحد الحالات التي تتطلب

استخدام المويجات متعددة الأبعاد، لذا كانت هناك الحاجة لدراسة هذا النوع من المويجات، وبصورة

خاصة أخذت إطارات الموجة متعددة الأبعاد اهتماما أكثر.

تولد المويجات بعد اختيار مويجم في الفضاء $L^2(R)^n$ بطريقتين، إما باستعمال التقييس

الوحيد (Single Scaling) وفيه يستعمل معامل توسيع مدرج (Scalar Dilation Parameter)

مشترك لكل الأبعاد، فمن خلال العلاقة التالية:

$$(a, b) = \left\{ l, k (x) = a^{\frac{1}{2}l} (a^l x - bk) : l \in \mathbb{Z}, k \in \mathbb{Z}^n \right\} \quad (1 - 23)$$

إذ أن:

l : فهرس التوسيع.

k : فهرس النقل.

a : معامل التوسيع.

b : معامل النقل.

x : تمثل متجه الإدخال متعدد الأبعاد.

لاحظ أن معامل التوسيع المدرج a^l يكون مشترك بين كل أبعاد الموجة للعائلة $\Psi(a, b)$.

باستعمال التقييس المتعدد (Multi Scaling)، (المعتمد عليه في بحثنا لتوليد المويجات)، يوجد

معامل توسيع مدرج مستقل لكل بعد، إذ تتكون لدينا مصفوفتي توسع D ونقل T بالصيغة التالية:

$$D_l = \text{diag} (a^{l_1}, \dots, a^{l_n}),$$

$$T = \text{diag} (b_1, \dots, b_n),$$

إذ أن:

$$l = (l_1, \dots, l_n) \in \mathbb{Z}^n .$$

وبذلك سيكون هناك معامل توسيع مدرج منفصل بعد يمكن أن يستعمل في دوال الموجة، وتصبح

المعادلة (23 - 1) بالصيغة التالية:

$$(a, b) = \left\{ \begin{array}{l} l, k \\ (x) = D_l^{-\frac{1}{2}} (D_l x - T k) : l, k \in \mathbb{Z}^n \end{array} \right\} \quad (1 - 24)$$

تبقى عملية حساب الموجة متعددة الأبعاد بطريقة تؤدي إلى الحصول على إطار، إذ أن المشكلة

هي إيجاد دالة موجة تحقق مجموعة شروط يمكن مراجعتها في [17][46]، من الطرق التي يمكن

بوساطتها حساب إطار موجة متعدد الأبعاد هي استعمال حاصل الضرب الممتد (Tensor

Product) لدوال موجات أحادية البعد:

$$\mathbb{E}(x) = \mathbb{E}(x_1) \cdot \mathbb{E}(x_2) \cdots \mathbb{E}(x_n) \quad (1 - 25)$$

استعملت هذه الطريقة لأن حاصل الضرب الممتد لإطارات موجات أحادية البعد يعطي إطاراً

أيضاً، وتوجد طرق أخرى لحساب إطارات موجة متعددة الأبعاد يمكن مراجعتها في نفس المصادر

أعلاه.

1-4-6 قياس STFT مع تحويل الموجة

1- يستعمل تحويل STFT موجة ذات منحني جيبية (Sinusoid Wave) كدالة أساس، تحتفظ بنفس

التردد خلال فترة زمنية كاملة، بينما بالمقابل يستعمل تحويل الموجة موجة خاصة كدالة أساس، تتغير

مع في الموقع والتردد خلال الفترة الزمنية [35][41].

2- يستعمل STFT نافذة تحليل مفردة، بالمقابل يستعمل تحويل الموجة نافذة وقت قصر عند الترددات

العالية و نافذة وقت طويل عند الترددات الواطئة [36].

3- يتعامل تحويل الموجة مع مستوى التردد-الزمن بصورة أكفأ من STFT لأن الأخير يركز على

التردد فقط.

4- يعد تحويل فورير وحيد (Unique) لكن تحويل الموجة ليس كذلك، إذ يوجد العديد من الموجات

التي يمكن اختيارها لعملية التحليل [44].

5- يعتمد تحليل فورير على معلومات عامة تكون غير كافية لدراسة الأنماط المحلية أو

المحددة (Compact) [44].

6- يمكن تحويل فورير كلفة تعقيد $O(n \log n)$ ، بينما يكون تحويل الموجة أكثر كفاءة إذ له تعقيد

(n) , [44].

5-1 الشبكات العصبية وتحويل الموجة

تعد الشبكات العصبية ونظرية تحويل الموجة أدوات تقريب عامة

(Universal Approximation Tools)، إن الشبكة العصبية هي أداة لتقريب دوال لاخطية

وملاءمتها (Fitting) من بيانات الإدخال/إخراج، بينما ظهر تحويل الموجة كأداة جديدة للتقريب)

ذكر في الفقرات (1-1) و (4-1) [12].

تعاني الشبكات العصبية (خاصة شبكة اتسياب الخطأ خلفا) من مجموعة مشاكل وضحت في

الفقرة (1-3-2-5-3)، لذا ظهرت محاولات لدمج (توحيد) تقنيات جديدة مع الشبكات العصبية لغرض

بناء نظام له القدرة على تجاوز وحل معظم مشاكل الأخيرة [13].

استعملت الموجات بصورة كفاءة في تحليل وتمثيل الصور أحادية البعد وعندما عمت

الموجات إلى أبعاد أعلى أصبح بالإمكان استعمالها كوحدة حساب (Computational Units)

الشبكات العصبية الاصطناعية، واستمر التشابه الموجود بين التقنيين فيسمى بالشبكات

الموجية (Wavelet Networks) [10][18]، وهذا التشابه برز من ملاحظة النتائج التالية [15]:

*امتلاك الشبكات العصبية ذات التغذية الأمامية على هيكل نقل-توسيع.

*تستعمل كل عقدة في الطبقة الواحدة نفس دالة النشاط.

من خلال ملاحظة إخراج شبكة مدرك مكونة من ثلاث طبقات الذي هو:

$$f(x) = \sum_{i=1}^k w_i \cdot s(a_i x + b_i) \quad (1-26)$$

إذ أن k هو عدد الخلايا المخبأة و (b_i, a_i, w_i) هي معاملات الشبكة و $s()$ هي دالة

النشاط، نلاحظ أن المعادلة (1-26) مشابهة لصيغة المعادلة (1-19)، فالشبكة الموجية هي شبكة

عصبية ذات تغذية أمامية مكونة من ثلاث طبقات فيها الدالة $s()$ عبارة عن موجة.

أدت عملية الجمع بين الشبكات العصبية وتحويل البعد إلى إيجاد عدد من التقنيات

الجديدة [10] وهي: (Wavelet Network) و (Wavenet) والموجات ذات المنطق

المضرب (Fuzzy Wavelets). فالنوع الأول هو شبكة عصبية ذات تغذية أمامية تستعمل الموجات

كدالة نشاط وفي هذه الشبكة يتم تعديل قيمة الموقع والتوسيع للموجات زيادة على ازان w أثناء

التعلم، أما في النوع الثاني فإن الموقع والتوسيع يكونان ثابتين ويتم تعديل قيمة الأوزان فقط، أما النوع

الثالث منها فإنه يستعمل الموجات ثنائية التعمد، للمزيد من التفاصيل يمكن الرجوع إلى [10].

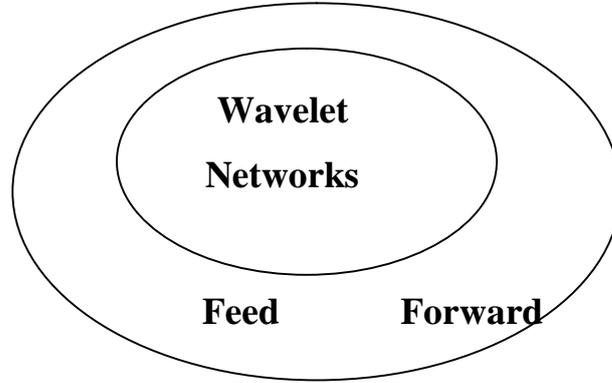
إن أصل الشبكات الموجية يمكن أن نرجعه إلى جهود دوكرمان (Daugman) عام 1988

وكان قد استعمل موجات كابور (Gabor Wavelets) لتصنيف الصور، وأصبحت الشبكات الموجية

أكثر شعبية بعد الجهود التي بذلت من قبل باي (Pati) في الأعوام (1991 و 1992)

وزهانك (Zhang) عام 1992 وسزو (Szu) عام 1992، وقدمت الشبكة الموجية كشبكة عصبية ذات تغذية أمامية خاصة (A Special Feed Forward Neural Network) [10]، والشكل (13-1)

يمثل العلاقة بين الشبكات الموجية والشبكات العصبية التقليدية.



شكل (13-1) يبين علاقة الشبكات الموجية والشبكات العصبية

إستعمل تحويل الموجة مع الشبكات العصبية كجزء مفصول عنها لأجراء المعالجة الأولية

للبيانات الداخلة إلى الشبكة (مستخلص للصفات)، إذ تحلل الإشارة إلى موجة ما وتغذى معاملات تلك

الموجة إلى الشبكة كمدخلات، واستعمل هذا الصنف من الشبكات لمعالجة البيانات المتغيرة مع

الزمن (Time_Series Data) [10][14][18]، أما الصنف الثاني من الشبكات الموجية (وهو اتجاه

بحثنا) فاستعملت الموجات كدوال نشاط ضمن الخلايا العصبية للطبقة المخبأة لتحديد نشاط تلك

الخلايا، ويكون الإخراج الكلي للشبكة عبارة عن عملية جمع لموجات موزنة

(Weighted Combining of Wavelets) حسب الصيغة التالية:

$$\hat{f}(x) = \sum_{i=1}^h w_i \cdot \psi_i(x) \quad (1-27)$$

إذ أن h هو عدد الموجات (عدد الخلايا المخبأة) $\psi_i(x)$ الموجة i و w_i هي أوزان الموصلات بين

الطبقة الباء وطبقة الإخراج و $\hat{f}(x)$ هو القيمة التقريبية للدالة f، وتوفر هذه الدالة مستوىً عاليًا

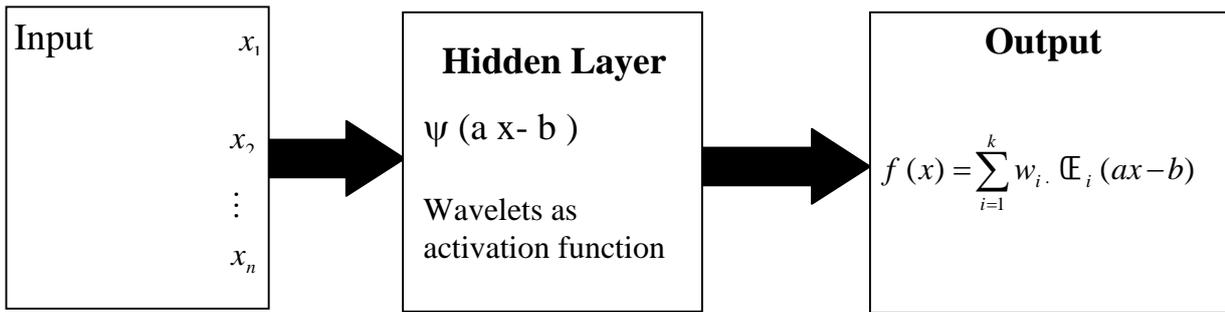
من التعميم (Much Higher Level of Generalization)، ووقت حساب قصير (Shorter Computing time) مقارنة مع شبكة عصبية ذات تغذية أمامية مكونة من ثلاث طبقات [13].

تظهر الشبكة الناتجة ارتباطا ملحوظا بين معاملات الشبكة ومعاملات دالة ريجة (معاملات

التوسيع والنقل)، إذ تستعمل معاملات الدالة قيما ابتدائية جيدة لمعاملات خوارزمية التعلم التي هي

أوزان الشبكة العصبية (خوارزمية انسياب الخطأ خلفا) [10][12][18]، ويوضح الشكل (14-1)

هيكل شبكة موجية ويبين أيضا التشابه بينه وبين شبكة المدرك المكونة من ثلاث طبقات.



شكل (14-1) يبين التشابه بين شبكة الموجة وشبكة المدرك

6-1 هدف البحث

إنّ ازدياد الاهتمام بالشبكات العصبية واستعمالها في حل مسائل مختلفة التعقيد هو قريبا من

طبيعة عمل الجهاز العصبي البشري، لذلك التقنية عدة مشاكل (ووضّحت في الفقرة

(3-2-5-3-1)) أثرت على أدائها وكفاءتها، يهدف العمل الحالي إلى استثمار التشابه الموجود بين

الشبكات العصبية وتحويل الموجة، والاستفادة من إمكانية استعمال الموجات لتقريب النوال لتجاوز

معظم مشاكل الشبكات العصبية، إذ استعمل تحويل الموجة لاختيار دالة النشاط لخلايا الطبقة المخبأة،

، هي عبارة عن دالة تحويل موجي تقوم بإنجاز تحويل موجي متقطع متعدد الأبعاد
(Multidimensional Discrete Wavelet Transform) على متجه البيانات الداخلة إلى

الشبكة، واعتمد على مبدأ التقييس المتعدد لتوليد الموجات ، واستعملت معاملات النقل والتوسيع

لتحويل الموجة المتقطع في عملية تحديد وتهيئة أوزان موصلات الشبكة العصبية من أجل تقليل تأثير

الأوزان العشوائية لهذه الموصلات على سلوك الشبكة ، كما تم الاعتماد على بيانات الإدخال في عملية

تحديد قيمة فهرسي التوسيع والنقل، بخلاف ما كان معمول به سابقاً إذ كانت عملية تحديد قيم هذين

المتغيرين تعتمد على الخبرة والتجربة ، لجعل عملية توسيع الموجة وتزحيفها يقع ضمن مدى بيانات

الإدخال الذي سيجعل عملية التقارب سريعة في الوصول إلى الحل.

7-1 هيكل الرسالة

يتكون الهيكل العام للرسالة من ثلاثة فصول، إذ يتضمن الفصل الأول زيادة على المقدمة العامة

نبذة مختصرة عن البحوث السابقة، وتوضيحاً للجوانب النظرية للشبكات العصبية وتحويل الموجة، إذ

يتضمن نبذة تاريخية عن تطور الشبكات العصبية ، ودوال نشاطها العامة والمحلية ، والتركيز على

شبكة EBP وخوارزميتها للتعلم والمشاكل التي تواجه هذا النوع من الشبكات ، أما فيما يخص تحويل

الموجة فيحتوي على تاريخ تطور هذا النوع من التحويل ومفهوم إطارات الموجة وتوضيحاً للنوع

المتقطع لهذا ، ومقارنته مع تحويل STFT ، مع بيان كيفية استعمال تحويل الموجة في

الشبكات العصبية زيادة على هدف البحث، في حين يعطي الفصل الثاني وصفاً للطريقة المقتر.

التي تتضمن مراحل معالجة أولية على الصورة لاستخلاص الصفات منها ومن ثم يبدأ دور الموجات

في هيكل الشبكة وعملية تدريبها، أما الفصل الثالث فيبين النتائج التي تم التوصل إليها والاستنتاجات

لنتلك النتائج زيادة على الأعمال المستقبلية.

1-2 الطريقة المقترحة

نتيجة للمشاكلني منها شبكات التغذية الأمامية (التقارب، التعميم ، مشكلة الوقوع في

النهاغرى المحلية ، التصميم) التي ذكرت في الفصل الأول ، الفقرة (1-3-5-2-3)، تم

اقتراح طريقة هجينه تجمع مصبببة ذات التغذية الأمامية المدربة بخوارزمية انسياب الخطأ

كما تسمى بشبكة انسياب الخطأ خلفا) ، وتقنية تحويل الموجة في نظام واحد لتجاوز وحل

المشاكل الثالث الأولى على الأقل ، إذ تم الإفاده من كون تحويل الموجة أداة فعالة (Powerful)

جديدة للتقريب [12] ، كذلك إمكانية الاستفاده من معاملات الموجة في عملية تهيئة

(Initialization) أوزان الشبكة العصبية ، وقد استعمل تحويل الموجة في عملية اختيار دالة

التحويل (Mapping Function) ، زيادة على التشابه الموجود بين التقنيتين [10] .

نفا النظام الهجين لحل مشكلة تصنيف صور بال مرسومة بخط اليد ، إذ تجرى عملية

معالجة أولية لاستخلاص الصفات من هذه الأشكال لتمثل كل صورة في متجه من قيم الصفات ، ومن

ثم إدخالها إلى الشبكة الموجية لكي تتعلمها . تقوم كل عقدة أو خلية عصبية في الطبقة المخبأة بأجراء

عملية تحويل موجي متقطع على كل قيمة قادمة لها من طبقة الإدخال (أي إجراء تحويل موجي

متعدد الأبعاد) ، ثم إجراء عملية جمع خطي (Linear Combination) لهذه الموجات لحساب

قيمة الإخراج لهذه الشبكة الهجينة ، وتدرّب هذه الشبكة باستعمال خوارزمية انسياب الخطأ خلفا، من

الجدير بالذكر أنه تم الاعتماد على البيانات الداخلة إلى الشبكة في عملية حساب فهارس معاملي النقل

و التوسيع (n,m) المستعملين في المعادلة (1 - 21) بدلا من تخمين قيم هذين المتغيرين .

يوضح الشكل (1-2) خطوات عمل الطريقة المقترحة .

1-1-2 استحصال الصورة

يتم في هذه المرحلة استحصال الصورة المراد تعليم الشبكة عليها ، أما عن طريق استعمال جهاز الماسح الضوئي (Scanner) للحصول على الشكل المرسوم بخط اليد على قطعة من الورق، أو رسمها باستعمال أحد برامج الرسم التي في جهاز الحاسب (مثل برنامج الرسم Paint Brush)، وتحويلها إلى صورة بهيئة BMP ذات تدرج رمادي (8) ثنائيات، إذ تمّ رقمته (48) صورة تمثّل أشكال ومخططات مرسومة بخط اليد، وهذه المجموعة من الصور مقسّمة على ثمان فئات، كل فئة مكوّنة من ست صور، وهذه الصور الست الممثلة للفئة الواحدة هي صور لشكل أو مخطط واحد

بتشوهات مختلطة استعمال أحد مقاييس الموثوقية الهدف (Object Fidelity Criteria) المستعملة بشكل واسع في قياس مقدار الاختلاف بين الصور، وهي مفيدة في حالة موازنة نسخ مختلفة مع نفس الصورة، إذ تستعمل هذه المقاييس معادلات تساعد على حساب كمية الأخطاء بين صورتين،

ومن هذه المقاييس نسبة قمة الإشارة إلى الضوضاء (PSNR(Peak Signal to Noise Ratio

المعرف بالعلاقة الآتية [48]:

$$\text{PSNR} = 10 \log_{10} \frac{(L-1)^2}{\frac{1}{N * M} \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} [\tilde{I}(x,y) - I(x,y)]^2} \quad (2-1)$$

حيث إنّ:

L: هو عدد المستويات الرمادية.

N,M: أبعاد الصورة.

$\tilde{I}(x,y)$: الصورة المشوهة.

$I(x,y)$: الصورة الأصلية.

وكانت قيم هذا المقياس للفئات الثمان كما يأتي:

- الفئة الأولى بين (16.7,13.6).

- الفئة الثانية بين (17.05,14,71).
- الفئة الثالثة بين (17.4,15.05).
- الفئة الرابعة بين (16.3,15.2).
- الفئة الخامسة بين (16.09,14.4).
- الفئة السادسة بين (13.05,12.12).
- الفئة السابعة بين (17.9,15.9).
- الفئة الثامنة بين (16.7,14.7).

أما بالنسبة لمجموعة صور الاختبار (Testing Image) فقد تم استعمال برنامج الراسم في عملية الحصول على الصور، وفي مرحلة تمّ تخصيص (24) صورة اختبار لكل فئة وإنّ هذه الصور تحتوي على تشوهات مختلفة لاختبار قابلية التعميم للشبكة المقترحة.

2-1-2 قراءة ملف الصورة (Read The Image File)

بعد مرحلة استحصال الصور، يجب قراءة ملف تلك الصورة لأجراء عمليات معالجة

عليها، تعتمد عملية قراءة ملف الصورة على هيئته (Image File Format)، إذ توجد العديد من

الهيئات المستعملة لتمثيل الصور منها BMP JPG TIF ... الخ.

وقد اختير على ملف الصورة من نوع BMP (Bit Map Format)، الذي يعد من أكثر

الملفات شيوعاً وسهولتي الاستعمال [38]، لتوافقه مع نظام windows [48]، يتكون ملف BMP

من ثلاثة أجزاء، هي الصديرة (Header) الذي يحتل (54 Bytes)، يتضمن معلومات تصف الصورة،

التي تشمل عدد البتات لكل عنصر (Pixel)، عرض وطول خارطة عناصر الصورة، نوع خوارزمية

الضغط المستعملة، وغيرها من المعلومات التي تصف الصورة، يمثل الجزء الثاني من ملف الصورة

لوحة الألوان (Color Palette) المتمثل بالشدة اللونية للألوان الأساسية الثلاثة (الأحمر Red، الأخضر

Green، والأزرق Blue)، يعتمد حجم هذا الجزء على عدد البتات المخصصة لكل عنصر صورة، فإذا كان عدد الثنائيات هو (8) لكل عنصر صورة فإن مدى لوحة الألوان يكون من (0 ... 255) وكل عنصر في الصورة يمثل في أحد مداخل لوحة الألوان، أما الجزء الأخير فهو يمثل بيانات الصور [48] [38]، (انظر ملحق 2 الذي يحتوي على خوارزمية قراءة ملف صورة من نوع BMP).

2-1-3 مرحلة تجزئة الصورة (Image Segmentation)

تعد عملية تجزئة الصور أهم مهام عملية تحليل الصور، زيادة على كونها من العمليات الحرجة في تحليل الصورة لأن الخطأ الذي يحصل في هذه المرحلة يؤثر على المراحل الأخرى في عملية معالجة الصورة (استخلاص الصفات، التصنيف) [47][48].

توفر عملية تجزئة الصورة مرونة في استخلاص خصائص منطقة معينة من الصورة الرقمية، فأصبحت إحدى متطلبات عملية استخلاص الخصائص (Feature Extraction) [48].

إن الهدف من عملية التجزئة هو تجزئة الصورة الرقمية إلى كيانات حقيقية وأشباه كيانات، أو إيجاد أجزاء مهمة واستقطاعها من بقية مكونات الصورة، ينظر إلى عملية تجزئة الصورة إلى كيانات بأنها عملية تجزئة إلى مناطق متباينة ذات خواص متجانسة لأعطاء الاهتمام للمنطقة المراد [47].

تعتمد تقنيات التجزئة على خصائص قيم المستويات لمادية (التشابه (Similarity)، والانفصال (Discontinuity))، وبهذا يمكن تصنيفها على صنفين [49]:-

1- صنف يعتمد على تشابه عناصر الصورة مثل التعتیب (Thresholding)، ونمو المناطق (Region Growing).

2-وصنف يعتمد في تجزئة الصورة على التغيرات في المستويات الرمادية لعناصر الصورة

والحصول على نقاط حدود بين المناطق مثل كشف الحواف (Edge Detection).

تم استعمال الصنف الأول في عمل باختيار عتبة معينة، وستوضح هذه التقنية في الفقرة

اللاحقة.

1-3-1-2 التعتيب Thresholding

تعد عملية التعتيب إحدى طرائق تجزئة الصور التي يمكن اعتبارها عملية تصنيف لعنصر

الصورة [50]، تستعمل هذه الطريقة عند احتواء الصورة على مساحات متباينة اللعان [47]، مثلاً في

مجموعة الصور الداخلة في الدراسة، تتألف كل صورة من شكل أو مخطط عاتم اللون (Dark

Object) فية فاتحة (Light Background)، فتكون المستويات الرمادية لعنصر الصورة

والخلفية متباينة تشكل نمطين متباينين في المدرج التكراري (Histogram) للمستويات الرمادية على

شنتين، فإحدى الطرائق الواضحة لفصل هذين النمطين هي اختيار العتبة [47][51].

تعتمد عملية اختيار قيمة العتبة على أساس المدرج التكراري للصورة، واختيار قيمة المستوى

الرمادسل بين المنطقتين المتباينتين [50]، تخصص عناصر الصورة التي تكون قيمها مشابهة

من قيمة العتبة إلى إحدى المناطق وبقية العناصر تخصص إلى المنطقة الثانية (أنظر ملحق 3).

4-1-2 استخلاص الصفات (Feature Extraction)

تعرّف عملية استخلاص الصفات بأنها عملية تقليص أبعاد الصورة عن طريق استخلاص بعض

المقاييس العددية (Numerical Measurements) من بيانات الصورة، من فوائد هذه العملية هو

الحصول على نسبة ضغط عالية (High Compression Ratio) لتقليل وقت الحساب [52]، إذ إنها

تقوم بتحويل الصورة من المستوى الواطئ لتمثيل بيانات الصورة (عناصر الصورة) إلى مستوى عال

من التمثيل (عدد قليل من البيانات)، تحتفظ هذه القيم بمعلومات كافية تتمكن من تصنيف الصور والاستغناء عن وجود العامل البشري في عملية التصنيف [47][48].

تمّ استعمال خصائص المدرج التكراري (Histogram) لقيم المستوى الرمادي (Gray-Level) مقابل عدد عناصر الصورة عند تلك القيمة، إذ يُستعمل هذا المدرج نموذج توزيع احتمالي (Probability Distribution)، ثمّ تستخلص من هذا التوزيع الاحتمالي خصائص إحصائية (Statistically Features) تمثل خصائص المدرج التكراري للمستويات الرمادية ذات المرتبة الأولى (First Order Histogram Features)، تحسب دالة الكثافة الاحتمالية لكل مستوى من المستويات الرمادية حسب العلاقة الآتية [48] :

$$p(g) = \frac{N(g)}{M} \quad (2-2)$$

إذ إنّ $N(g)$ عدد عناصر الصورة في المستوى الرمادي g , M عدد عناصر الصورة (ضرب عدد الأعمدة وعدد الصفوف). من خلال دالة الكثافة الاحتمالية أعلاه يمكن احتساب الخصائص الآتية [47][48]:

1- المتوسط Mean

يتم حساب متوسط المستويات الرمادية للصورة الرقمية بتطبيق المعادلة الآتية :-

$$\bar{g} = \sum_{g=0}^{L-1} g \cdot p(g) \quad (2-3)$$

إذ إنّ L تمثل العدد الكلي للمستويات الرمادية ، لذلك يكون مدى المستوى الرمادي (g) بين 0

إلى $L-1$.

2- الانحراف المعياري Standard Deviation

هو الجذر التربيعي للتباين (Variance)، يزودنا بمعلومات حول شدة التباين بين المستويات

الرمادية، إذ يعطي التباين الكبير دليلاً على أن الصورة تمتلك اختلافات عالية بالعكس. ويحسب بتطبيق

العلاقة الآتية:

$$g = \sqrt{\sum_{g=0}^{L-1} (g - \bar{g})^2 \cdot p(g)} \quad (2-4)$$

3- الالتواء Skewness

يقيس الالتواء مقدار التناظر الموجود في متوسطيات الرمادية للصورة الرقمية.

$$\text{Skew} = \frac{1}{3} \sum_{g=0}^{L-1} (g - \bar{g})^3 \cdot p(g) \quad (2-5)$$

4- الطاقة Energy

يوضح هذا المقياس كيفية توزيع المستويات الرمادية، فإذا كانت قيمة الطاقة عالية يعني أن

عدد المستويات الرمادية في الصورة قليل، علمكبر قيمة لهذا المقياس هي 1.

$$\text{Energy} = \sum_{g=0}^{L-1} [p(g)]^2 \quad (2-6)$$

5- الأنتروبيا Entropy

هي مقياس لعدد البتات المطلوبة لعية الترميز (Coding) وتحسب من خلال العلاقة الآتية:

$$\text{Entropy} = - \sum_{g=0}^{L-1} p(g) \cdot \log_2 [p(g)] \quad (2-7)$$

تزداد قيمة الأنتروبيا إذا كانت قيم عناصر الصورة تتوزع في مدى واسع من المستويات

الرمادية، يتعكس هذا السلوك مع سلوك مقياس الطاقة.

5-1-2 قراءة معاملات تحويل الموجة

يتم في هذه الخطوة قراءة معاملات تحويل الموجة المتقطع وصيغته موضحة في المعادلة

(21-1)، إذ يتم قراءة معامل النقل β ومعامل التوسيع α ، بحيث تكون $\alpha > 1$ و $\beta > 0$ ، انحصرت قيمة α المستعملة في البحث ضمن المدى $1 \leq \alpha \leq 3$ ، وعادة تكون $\alpha=2$ [39]، أما β فقد خصصت لها قيم مختلفة تتراوح ضمن المدى $0 < \beta \leq 1$.

أما بالنسبة لحساب فهرس التوسيع (**Dilation Index**) m أو مستوى التوسيع (**Dilation Level**) [9]، فيتم حسابه بالإفادة من مجالات (**Domains**) بيانات الإدخال بدلا من عملية التخمين لقيم هذين المتغيرين، ليكن لدينا متجه من القيم لفهرس التوسيع بعدد قيم متجه الإدخال، فمن

خلال العلاقة (22-1) لدينا:

$$m_{jk} = n^{-m} \quad (2-8)$$

$$d_{jk} = r^{-m} \quad (2-9)$$

إذ إن m_{jk} و d_{jk} يمثلان معاملي النقل والتوزيع للخلية المخبأة z (التي تقوم بأجراء تحويل

الموجة) لتحويل الموجة المستمر، ومن المعادلة (9-2) يمكن حساب قيمة m ، إذ أن

$$m = -\frac{\log(d_{jk})}{\log(r)} \quad (2-10)$$

بالنسبة لقيمة m_{jk} و d_{jk} فيتم حسابهما بالاعتماد على قيمة بيانات الإدخال، فإذا كان لدينا $[a_k, b_k]$

المجال (**Domains**) الذي يحتوي على قيمة العنصر k في متجه الإدخال لكل الأمثلة الداخلة في

عملية التعلم، فيتم حساب قيمة m_{jk} و d_{jk} من خلال العلاقتين الآتيتين:-

$$m_{jk} = \frac{1}{2}(a_k + b_k) \quad (2-11)$$

$$d_{jk} = 0.2(b_k - a_k) \quad (2-12)$$

وبما أن m يجب أن يكون عددا صحيحا ،لذلك تكون قيمته هي:

$$m = \left\lceil -\frac{\log(d_{jk})}{\log(r)} \right\rceil \quad (2 - 13)$$

إذ يمثل [] عامل الجزء الصحيح .

يتم تحديد عدد m التي يتم تخصيصها لكل قيمة في متجه الإدخال وبذلك يتكون لدينا متجه من قيم m

مختلفة بحيث :

$$\left\{ \left\lceil -\frac{\log(d_{jk})}{\log(r)} \right\rceil + 1, \left\lceil -\frac{\log(d_{jk})}{\log(r)} \right\rceil + 2, \dots \right\} \quad (2 - 14)$$

وكل قيمة لـ m في (2 - 14) تخصص لخلية مخبأة وتكرر هذه المعادلات لكل قيمة في متجه الإدخال.

بعد ذلك يتم حساب قيم n لكل قيمة في المجموعة (2 - 14) للعائلة Ω_d التي تكون عمليات

النقل لها ضمن الفترة $[a_k, b_k]$ ، وهذا يؤدي إلى العلاقة الآتية:

$$a_k \leq 2^{-m} n \leq b_k \quad (2 - 15)$$

سنأخذ في الاعتبار كل قيم n التي تحقق الشرط السابق أي أن :

$$2^m a_k \leq n \leq 2^m b_k \quad (2 - 16)$$

وبما أن n يجب أن تكون عددا صحيحا فإن القيم التي يتم حسابها هي :

$$\{ [2^m a_k] + 1, [2^m a_k] + 2, \dots, [2^m b_k] \} \quad (2 - 17)$$

يعتمد عدد n في المجموعة (2 - 17) على قيمة m ، إذ لا يحتاج المصمم إلى اختيار كم قيمة

يتم حسابها في (2 - 17) (وذلك بخلاف فهرس التوسيع m التي يحدد عددها من قبل المصمم) إذ

يتزايد هذا العدد أسياً (Exponentially) مع m وتكرر هذه المعادلات لكل قيمة في متجه الإدخال

لاستعمال مبدأ التقييس المتعدد (أي يوجد فهرس توسيع مختلف لكل قيمة في متجه الإدخال).

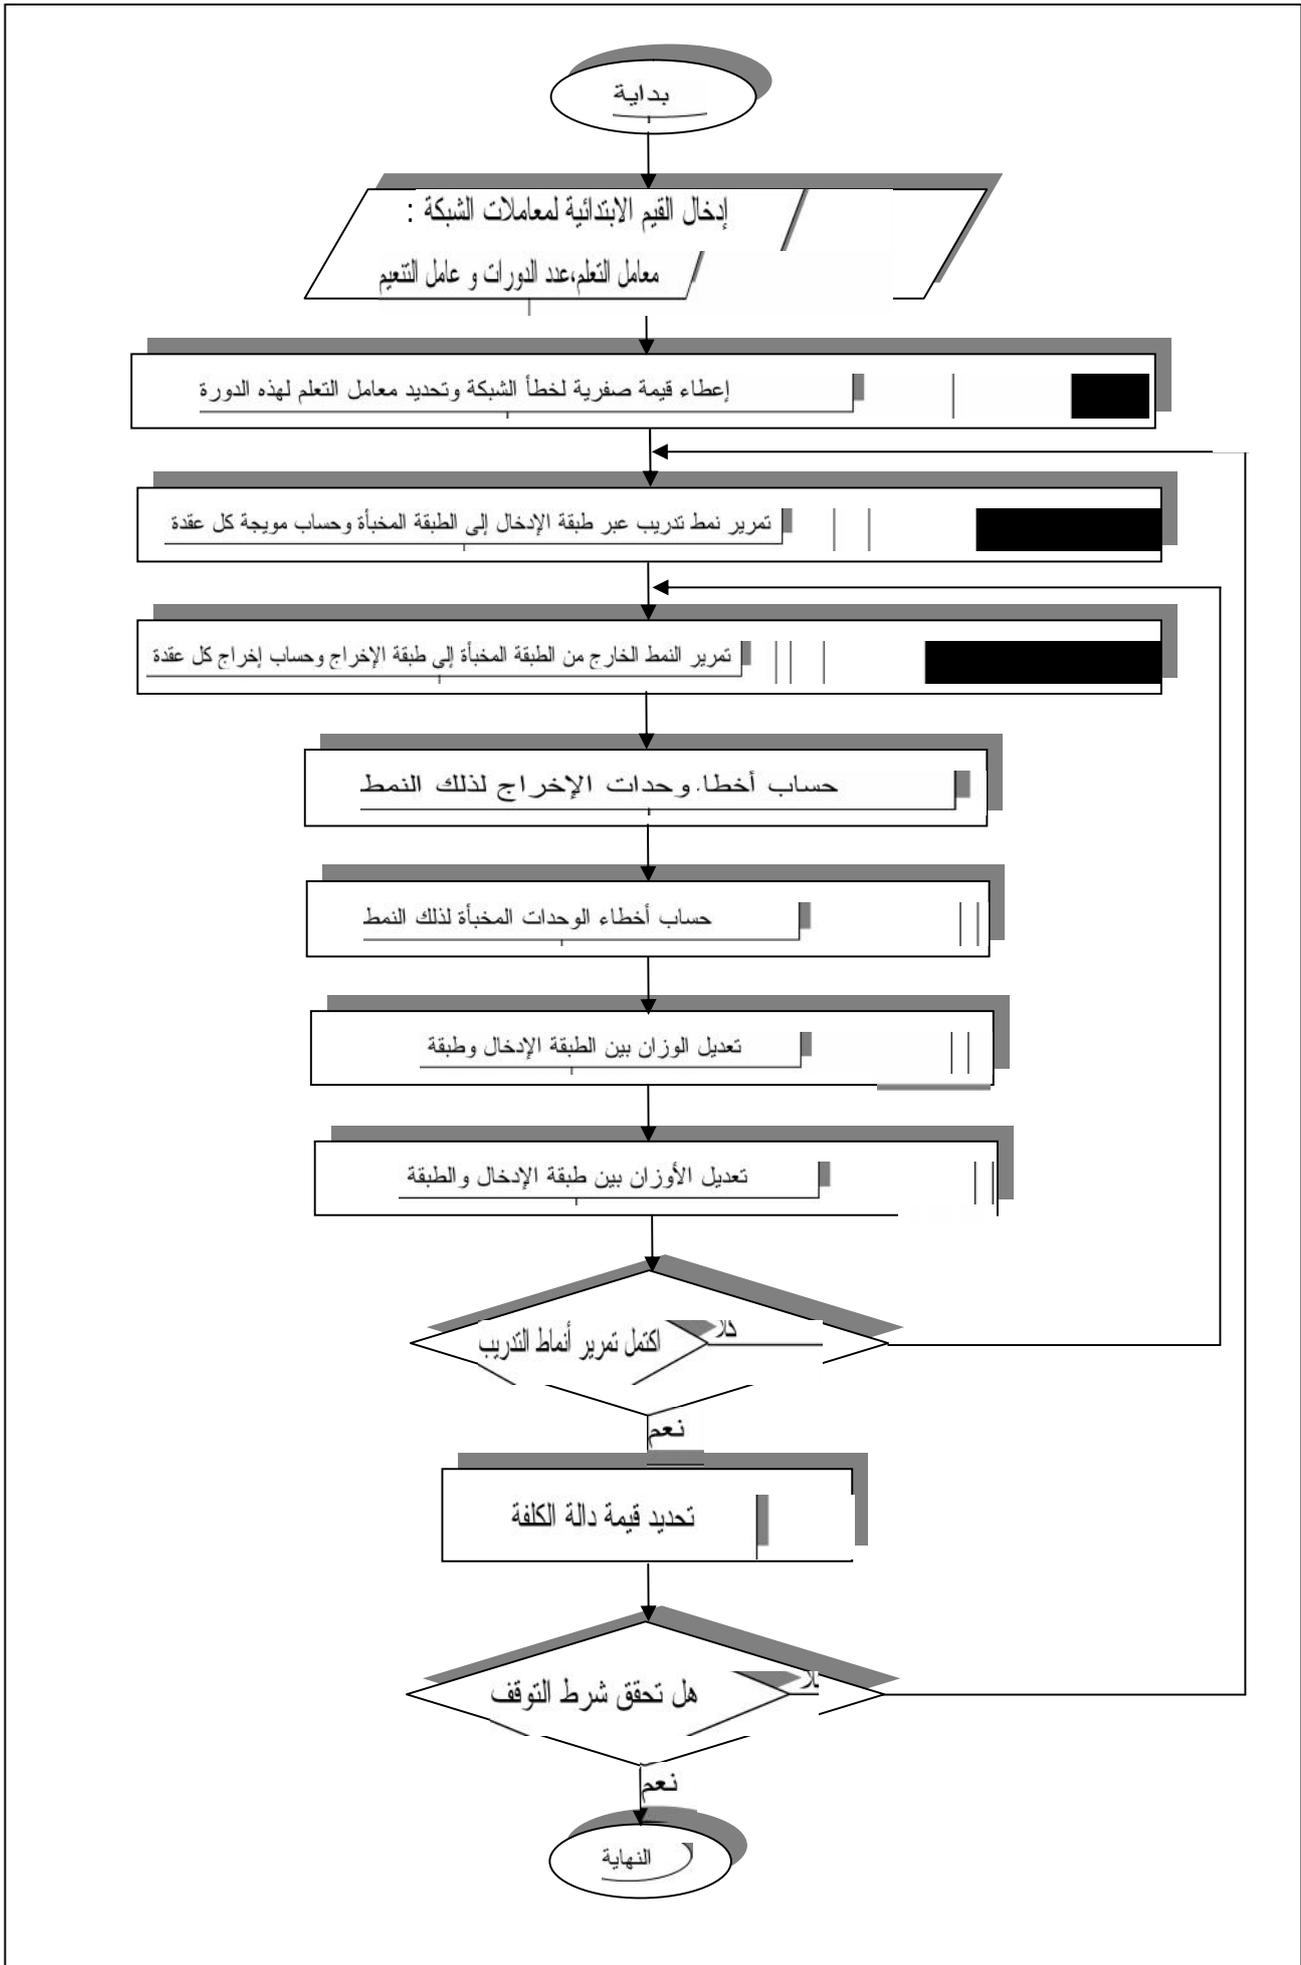
2-1-6 تحديد أوزان موصلات الشبكة المو

تعدّ عملية تحديد أوزان الشبكة المويجية من الأمور المهمة، وكما هو معروف في الشبكات العصبية فإنه ليس من المفضل تخصيص قيم ابتدائية عشوائية لأن ذلك قد يوقع الشبكة في مشكلة النهاية الصغرى المحلية، لذا تستعمل معاملات الموجة السابقة الذكر في هذه الأوزان، ويستعمل معامل التوسيع (α) في تحديد أوزان الموصلات بين طبقة الإدخال والطبقة المخبأة، ويستعمل معامل النقل كمعامل انحياز لخلايا الطبقة المخبأة، أما بالنسبة لأوزان الموصلات بين الطبقة المخبأة وطبقة الإخراج ومعامل انحياز خلايا الإخراج لها قيم عشوائية لأنها أقل خطورة على سلوك

الشبكة [39].

2-1-7 خوارزمية انسياب الخطأ خلفا باستعمال تحويل الموجة

تستلم خوارزمية انسياب الخطأ خلفا الشبكة العصد تحديد هيكلها (أي عدد عقد الإدخال، الإخراج، والعقد المخبأة)، كذلك القيم الابتدائية لأوزان الموصلات التي تحدثنا عنها في الفقرة السابقة، ويوضح الشكل (2-2) المخطط الانسيابي لعملية التعلم في خوارزمية انسياب الخطأ خلفاً وإدخال تحويل الموجة كجزء من هذه الخوارزمية.



شكل (2-2) المخطط الانسيابي لخوارزمية انسياب الخطأ خلفا

وفيما يأتي توضيحاً لخطوات التعلم الموضحة في المخطط أعلاه:-

1- يتم إدخال قيم ابتدائية لمعمل التعلم η_0 ، معامل التنعيم α_{net} ، أكبر خطأ ممكن للشبكة

ERRTOL، وعدد الدورات القصوى لتعلم الشبكة **MAXITER**.

2- نجعل قيمة خطأ الشبكة **MSE** مساوية للصفر وقيمة نمط التدريب الحالي مساوية إلى 1 وتحديد

قيمة معامل التعلم للدورة الحالية اعتماداً على المعادلة (11 - 1) الموضحة في الفصل الأول،

الفقرة (1-3-5-2-4).

3- يتم في هذه الخطوة إدخال أحد أنماط التدريب إلى الشبكة من خلال طبقة الإدخال، تخضع البيانات

الداخلية هنا إلى عملية تقييس (**Normalization**) لتخفيف جهد الحساب ولجعلها ملائمة للشبكة، ويتم

حساب نشاط كل خلية في العدة المخبأة باستعمال دالة تحويل موجي (يجب أن

تكون في الفضاء $L^2(\mathbb{R}^n)$ للحاجة إلى إجراء تحويل موجي متعدد الأبعاد لأن متجه البيانات الداخل

إلى الشبكة مكون من أكثر من قيمة، تم استعمال دالتين مختلفتين ضمن هذا الفضاء، إحداهما دالة

ناتجة من تجميع ثلاث دوال سيجماوية [15] (انظر ملحق 1)، والأخرى هي المشتقة الأولى لدالة

كاوس لأنها تعدُّ نسخة مشتقة من موجة هار الأم، وامتلاكها لصفة التقريب الشامل [11] [39]

موضح في المعادلتين (18 - 2) و (19 - 2) على التوالي.

$$s_1(x) = s(x + 2) - 2s(x) + s(x - 2) \quad (2 - 18)$$

$$s_2(x) = -x e^{-\frac{1}{2}x^2} \quad (2 - 19)$$

إذ إنّ $s(x)$ تمثل الدالة السيجماوية و x تمثل قيمة الإدخال لدالة الموجة خاضع لعملية توسيع

ونقل، ومن ثمّ يتم حساب إخراج خلية مخبأة بحسب المعادلة الآتية:

$$h_j = s_j(x) \quad \text{for } j = 1, \dots, N_w \quad (2 - 20)$$

إذ إن:

$$z_j(x) = \prod_{i=1}^{N_i} (z_{ji}) \quad (2-21)$$

وكذلك

$$z_{ji} = 2^{m_i} x_i - n_i b \quad (2-22)$$

تشير $\Phi(x)$ إلى استعمال تحويل الموجة متعددة الأبعاد (التي نوقشت في الفقرة (1-4-6) الفصل السابق)، و m_i هي مستوى التوسيع للإدخال i .

4-تمرر مخرجات الخلايا المخبا خلايا الإخراج على شكل مدخلات لها، إذ تقوم كل خلية إخراج

بعملية جمع موزّن (Weighted Sum) لموجات الطبقة المخبأة بحسب العلاقة الآتية:

$$y_k = \sum_{j=1}^{N_w} C_{kj} h_j + a_k \quad \text{for } k = 1, 2, \dots, N_o \quad (2-23)$$

حيث أن C_{jk} يمثل الوزن الموصل بين الموجة j و خلية الإخراج k و a_k هو عامل التحيز (Bias Term) لخلية الإخراج k .

عند استعمال الدالة الناتجة من تجميع ثلاث دوال سيجماوية موجة أم تكون قيم أخطاء التقريب

متباعدة، لذلك تم إضافة موصلات عصبية مباشرة (Additional Direct Connections) من

المدخلات الى المخرجات الى معادلة حساب قيمة خلايا الإخراج، بحيث تصبح المعادلة (2-23)

بالصيغة الآتية:

$$y_k = \sum_{j=1}^{N_w} C_{kj} h_j + a_k + \sum_{i=1}^{N_i} a_{ki} x_i, \text{ for } k = 1, 2, \dots, N_o \quad (2-24)$$

إذ إن a_{ki} يمثل الوزن الموصل بين خلية الإدخال i و خلية الإخراج k و x_i هو قيمة خلية الإدخال.

5- حساب قيمة إشارة الخطأ لخلايا إخراج للنمط p بحسب المعادلة الآتية :

$$S_k = (d_k - y_k) \bullet y'_k \quad (2 - 25)$$

بالنسبة لحساب المشتقة y'_k للعناصر الموجودة في المعادلة (2 - 23) يكون :

-لمعامل التحيز a_k

$$\frac{\partial y'_k}{\partial a_k} = 1 \quad (2 - 26)$$

-للأوزان C_{kj}

$$\frac{\partial y_k}{\partial C_{jk}} = h_j(x) \quad \text{for } j=1, \dots, N_w \quad (2 - 27)$$

and for $k=1, \dots, N_o$

بالنسبة لحساب المشتقة y'_k لأوزان الموصلات العصبية المباشرة في المعادلة (2 - 24) يكون :

$$\frac{\partial y_k^p}{\partial a_{ki}} = x_i^p, \text{ for } k=1, \dots, N_o \text{ \& for } i=1, \dots, N_i \quad (2 - 28)$$

إذ إن x_i^p يمثل قيمة خلية الإدخال i للنمط p.

6- حساب قيمة إشارة الخطأ في الخلايا المخبأة اعتمادا على خطأ خلايا الإخراج حسب المعادلة

$$. (2 - 29)$$

$$*_j = \left(\sum_{k=1}^{N_o} k \cdot C_{kj} \right) \cdot ' _j \quad (2 - 29)$$

$$' _j = (z_{j1}^p) (z_{j2}^p) \cdot '(z_{ji}^p) \dots '(z_{jN_i}^p) \quad \text{for } j=1, 2, \dots, N_w \quad (2 - 30)$$

إذ إن $\phi'(z_{ji})$ هي قيمة المشتقة للموجة الام عند النقطة z_{ji} .

7- تعديل الأوزان بين الطبقة المخبأة وطبقة الإخراج، حسب العلاقات الآتية :-

$$c_{kj} = \sum_k y_k + \text{net } c'_{kj} \quad \text{for } j=1,\dots,N_w \quad (2-31)$$

and for $k=1,\dots,N_o$

إذ إن :

Δc_{kj} مقدار التغيير بين أوزان الطبقة المخبأة وطبقة الإخراج.

S_k مقدار الخطأ عند عقدة الإخراج k .

y_k إخراج العقدة k .

$\Delta c'_{kj}$ مقدار الفرق بين الوزن الحالي والوزن السابق.

α_{net} عامل التنعيم.

فيكون الوزن الجديد :-

$$c_{kj} = c_{kj} + c''_{kj} \quad (2-32)$$

إذ إن c''_{kj} يمثل الوزن السابق .

كذلك تعديل عامل التحيز لطبقة الإخراج

$$a_k = \sum_j y_j + \text{net } a'_k \quad (2-33)$$

$$a_k = a_k + a''_k \quad (2-34)$$

8-تعديل قيمة معامل التوسيع α ومعامل النقل β حسب العلاقات التا :

$$j_i = \sum_j h_j + \text{net } j'_i \quad \text{for } j=1,\dots,N_w \quad (2-35)$$

and for $i=1,\dots,N_i$

إذ إن $\Delta \alpha'_{ji}$ يمثل مقدار الفرق بين قيمة معامل التوسيع الحالية والسابقة .

$$j_i = j''_i + j_k \quad (2-36)$$

$$j_i = \sum_j h_j + \text{net } j'_i \quad (2-37)$$

وإن $\Delta \beta'_{ji}$ مقدار الفرق بين قيمة معامل النقل الحالية والسابقة .

$$j_i = j''_i + j_i \quad (2-38)$$

9-زيادة قيمة p بمقدار واحد لإدخال النمط التالي في عملية التعلم، فإذا لم تصل إلى العدد الأقصى

ط التدريب يتم الرجوع إلى الخطوة رقم (3) لتدريب الشبكة على ذلك النمط، وإلا يتم الانتقال إلى

الخطوة رقم (10).

10-حساب قيمة دالة الكلفة، التي هي معادلة متوسط مربع الأخطاء (Mean Square Errors).

$$MSE = \frac{1}{2} \sum_{p=1}^p \sum_{k=1}^{N_o} (d_k^p - y_k^p)^2 \quad (2 - 39)$$

11-يتم في هذه الخطوة فحص شرط التوقف، يتحقق هذا الشرط إذا أصبحت قيمة الخطأ الكلي للشبكة

أقل من الخطأ المقبول لها **ERRTOL**، أو إذا أصبحت قيمة الدورة الحالية **Epoch** اكبر من العدد

الأقصى لدورات التعلم **MAXITER**، وعدا ذلك يتم الرجوع إلى الخطوة رقم (2).

8-1-2 اتخاذ القرار

بعد إنهاء خوارزمية انسياب الخطأ خلفا يكون عملها يتحقق أحد شروط التوقف، هي إما تحقيق

شرط دالة الكلفة وإما تجاوز عدد التكرارات الحد الأقصى لدورات التعلم المسموح به من دون وصول

خطأ الشبكة إلى قيمة أقل من القيمة المطلوبة.

إذا تحقق شرط دالة الكلفة فهذا يعني أن الشبكة استطاعت تدريب نفسها على صورة الشكل

المدخل إليها وتمييزه بحس التي ينتمي إليها ذلك الشكل (أي أن الشبكة نجحت 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 الشكل الداخل لها.

3-1 أداء الشبكة المقترحة

لوقوف على انجازية الشبكة الهجينة المقترحة، فقد تم إجراء مجموعة من التجارب لتحليل

أدائها في عملية التقارب واتخاذ القرار، إذ تضمنت تجارب على صور أشكال مختلفة مرسومة بخط

اليدين مقسمة على ثمان فئات كل فئة مكعبة من (6) صور ذات تشوهات مختلفة كما بينا في الفصل

السابق، هذه الصور ذات تدرج رمادي (8) ثنائيات، تمت عملية التحليل باستعمال الدالتين الآتيتين:

$$\{_1(x) = -x e^{-\frac{1}{2}x^2} \quad -\infty < x < +\infty \quad \text{1- المشتقة الأولى لدالة كاوس}$$

$$\{_2(x) = s(x-2) - 2s(x) + s(x+2) \quad \text{2- الدالة الناتجة من تجميع ثلاث دوال سيجماوية}$$

زيادة على إجراء تجارب الموازنة بين كفاءة الشبكة الهجينة المقترحة وشبكة انسياب الخطأ

خلفا التقليدي من حيث عدد الدورات المطلوبة لاتخاذ القرار الصائب، وتضمنت اختبار قابلية التعميم

لهذه الشبكة، كما شملت أيضاً اختبار أداء الشبكة في حالة كون الصور ملونة.

3-1-1 التجربة الأولى

تتضمن هذه التجربة اختبار عملية تدريب الشبكة الهجينة على فئات الأشكال الثمانية باستعمال

المشتقة الأولى لدالة كاوس موجبة أم، حيث نستخلص من كل شكل خصائص المدرج

التكراري (المتوسط Mean، الانحراف المعياري Standard Deviation، الالتواء Skewness

الأنتروبيا Entropy، الطاقة Energy) لتصبح مدخلات إلى الشبكة بعد أن خضعت لعملية تقييس

لتصبح ملائمة للشبكة، وكان عدد عقد الإخراج هو (8) وعدد عقد الإدخال هو (5).

لقد أجريت تجارب متعددة على كل فئة بتغيير معاملات خوارزمية التعلم، وتم انتقاء مجموعة

منها لتوضح أداء الشبكة المقترحة، ومعاملات خوارزمية التعلم (القيمة الابتدائية لعامل

التعلم، عامل التعميم، قيمة الخطأ المقبول للشبكة، عامل النقل لتحويل الموجة، عامل التوسيع

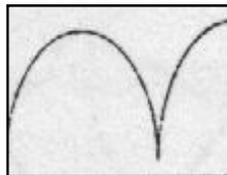
لتحويل الموجة، عدد مستويات التوسيع) قيم عديدة ضمن فترات معينة، وبين الجدول (1-3) قيم هذه المعاملات.

0.01-0.05:	عامل التعلم
0.0005-0.001:	عامل التعيم
400000:	الحد الأقصى لعدد التكرارات
0.01-0.001:	قيمة الخطأ المقبول
1-8:	عدد مستويات التوسيع
1.5-3:	معامل التوسيع لتحويل الموجة
0.6-1:	معامل النقل لتحويل الموجة

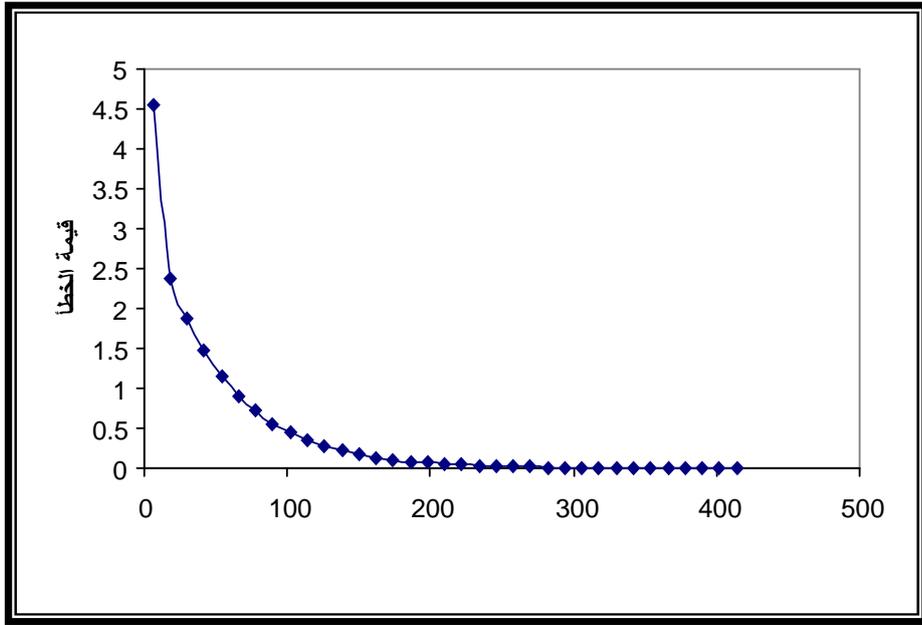
جدول (1-3) يبين المعاملات الأساسية المستخدمة في الشبكة الهجينة باستعمال المشتقة الأولى لدالة كاوس موجية أم

الفئة الأولى:

أجريت عملية التدريب على هذه الفئة الموحدة في الشكل (1-3)، واستعملت الشبكة قيمة ابتدائية لعامل التعلم مقدارها (0.01) وعامل تعيم (0.001)، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (7)، وقيمة الخطأ المقبول للشبكة (0.001)، وعامل التوسيع لتحويل الموجة α هو (2)، وعامل النقل لتحويل الموجة β هو (1)، والشكل (2-3) يبين نتائج عملية التدريب.



ل (1-3) الفئة الأولى



شكل (2-3) يبين نتائج تدريب الشبكة بالنسبة للفئة لأولى

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.000840) بعد (414)

تكرار، ويوضح الشكل (2-3) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية، كما استطاعت

هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (10.73)، وكانت

أقل نسبة للتشوه هي (10%).

يؤثر مقدار التشوهات في الصور المخصصة لاختبار قابلية التعميم للشبكة المقترحة على تلك

القابلية، لأن هذه الصور لها تأثير على حساب نبي النقل والتوسيع. لأننا كما ذكرنا في الفصل

السالى البيانات الداخلة إلى الشبكة في عملية حساب قيمة هذين المتغيرين عوضاً عن

تخمينها، فقد أجريت اختبارات على الشبكة لاثبات ذلك بإضافة صور ذات تشوهات أكثر، فقد

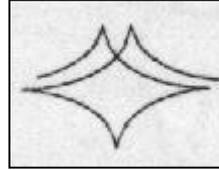
استطاعت الشبكة التعامل مع تشوه بلغت قيمة PSNR له (10.5) وتمكنت من تمييز جميع صور

الاختبار البالغ عددها (24)، أمّا بالنسبة للصور التي كانت قيمة PSNR لها أقل من ذلك فقد أثرت

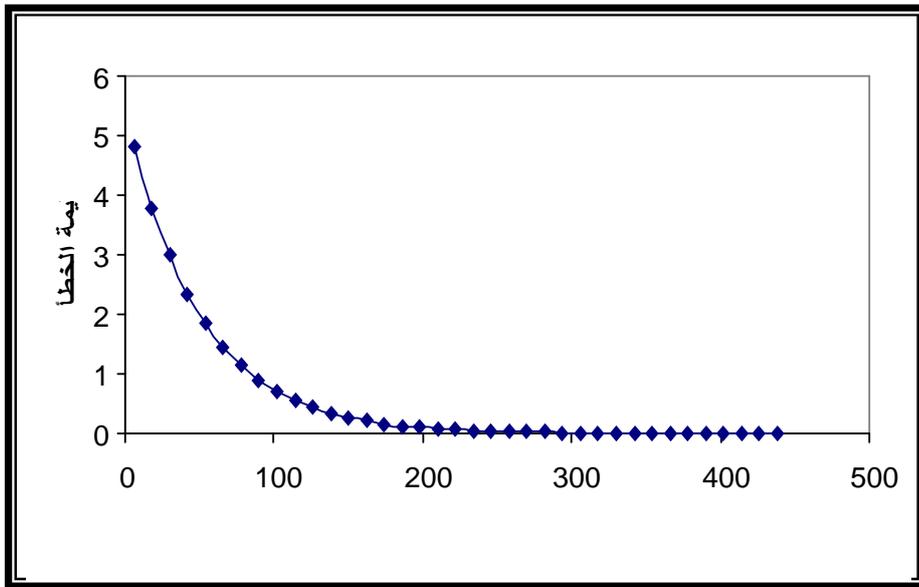
على سلوك قابلية التعميم للشبكة وكانت نسبة التمييز تتراوح بين (8% - 75%).

الفئة الثانية:

أجريت عملية التدريب على هذه الفئة الضحة في الشكل (3-3) باستعمال قيمة ابتدائية لعامل التعلم مقدارها (0.01) وعامل تتعيم (0.0007) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (5) ، وقيمة الخطأ المقبول للشبكة (0.001) ، وعامل التوسيع لتحويل الموجة α هو (2) وعامل النقل لتحويل الموجة β هو (1) ، والشكل (4-3) يبين نتائج عملية التدريب.



شكل (3-3) الفئة الثانية



شكل (4-3) يبين نتائج تدريب الشبكة بالنسبة للفئة الثانية

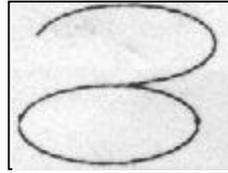
المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.000829) بعد (438) تكرار، ويوضح الشكل (4-3) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية. استطاعت هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عدده (24) ، وتمكنت

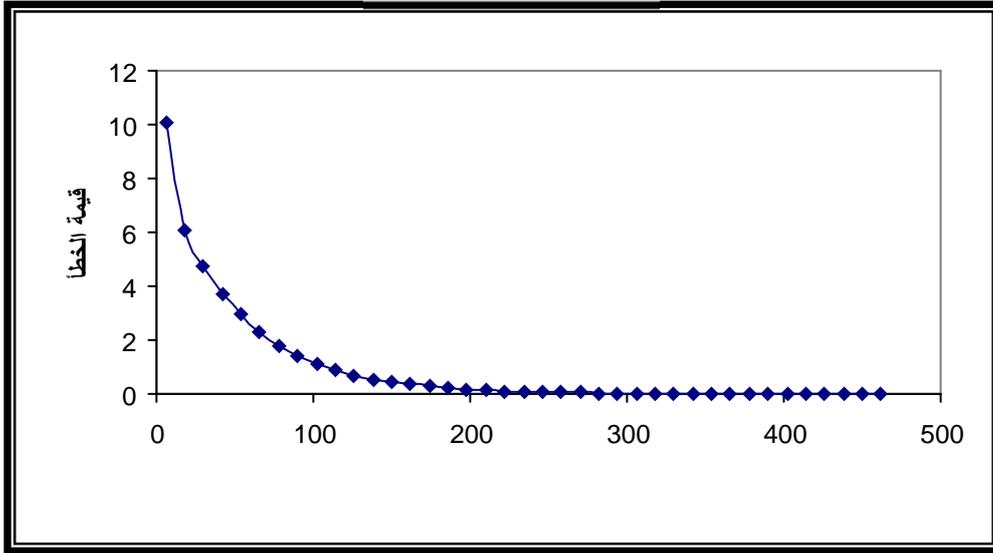
من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (12.6) ونسبة التشوه هي (9.4%).

الفئة الثالثة:

أجريت عملية التدريب على هذه الفئة النحرة في الشكل (3-5) باستعمال قيمة ابتدائية لعامل التعلم مقدارها (0.01) وعامل تنعيم (0.0008) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (6) ، وقيمة الخطأ المقبول للشبكة (0.001) ، وعامل التوسيع لتحويل الموجة α هو (2) وعامل النقل لتحويل الموجة β هو (1) ، الشكل (3-6) يبين نتائج عملية التدريب.



شكل (3-5) الفئة الثالثة



شكل (3-6) يبين نتائج ب الشبكة بالنسبة للفئة الثالثة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.000816) د (462) تكراراً، ويوضح الشكل (3-6) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية. إذ استطاعت هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24) وتمكنت

من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (9.54) ونسبة التشوه هي

(11.1%).

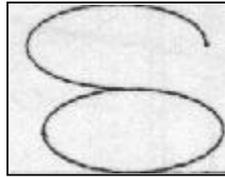
الفئة الرابعة:

أجريت عملية التدريب على هذه الفئة النحفة في الشكل (7-3) باستعمال قيمة ابتدائية لعامل

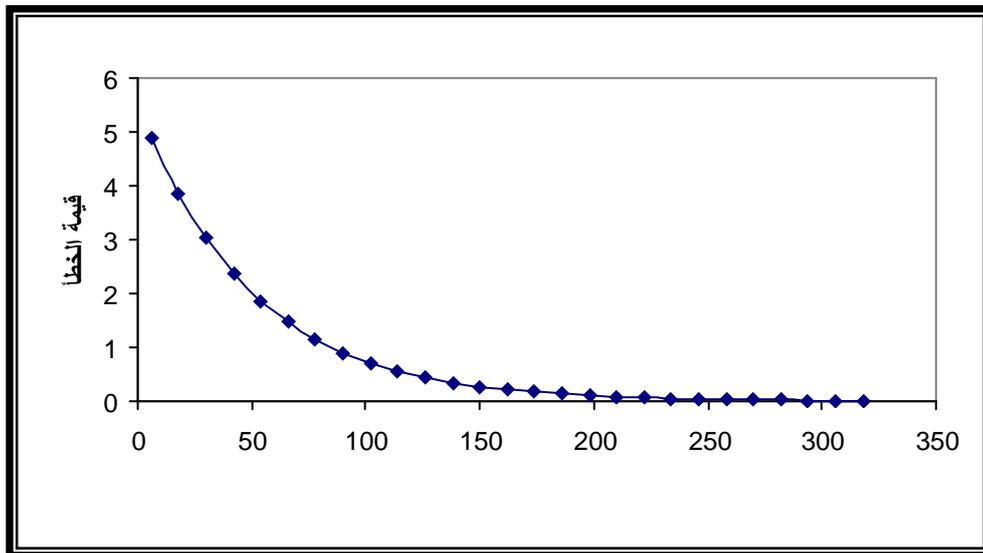
تعلم مقدارها (0.01) وعامل تنعيم (0.001) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع)

(4) ، وقيمة الخطأ المقبول للشبكة (0.01) ، وعامل التوسيع لتحويل الموجة α هو (2)

وعامل النقل لتحويل الموجة β هو (0.9) ، الشكل (8-3) يبين نتائج عملية التدريب.



شكل (7-3) الفئة الرابعة



شكل (8-3) يبين نتائج تدريب الشبكة بالنسبة للفئة الرابعة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008208) بعد (324) تكراراً،

ويوضح الشكل (8-3) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية. إذ استطاعت هذه

الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24) وتمكنت

من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (9.85) ونسبة التشوه هي

(10.35%).

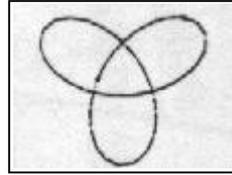
الفئة الـ :

أجريت عملية التدريب على هذه الفئة النحرة في الشكل (3-9) باستعمال قيمة ابتدائية لعامل

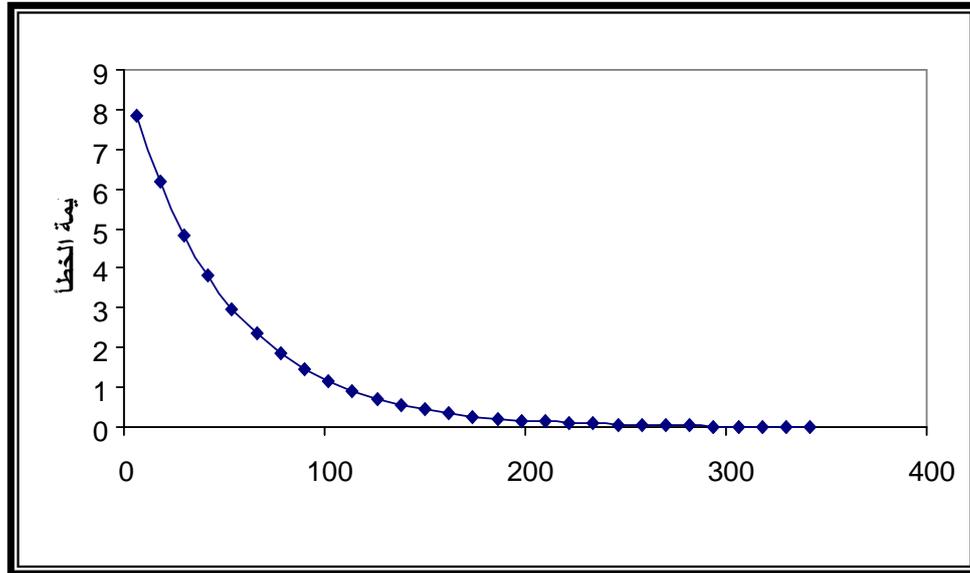
تعلم مقدارها (0.01) وعامل تنعيم (0.0007) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع)

(3) ، وقيمة الخطأ المقبول للشبكة (0.001) ، وعامل التوسيع لتحويل الموجة α هو (2)

وعامل النقل لتحويل الموجة β هو (0.7) ، والشكل (3-10) يبين نتائج عملية التدريب.



شكل (3-9) الفئة الخامسة



شكل (3-10) يبين نتائج تدريب الشبكة بالنسبة للفئة الخامسة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.0008155) بعد (348)

تكراراً، ويوضح الشكل (3-10) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت

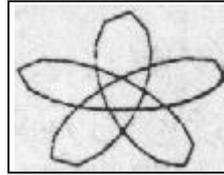
هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (9.87) ونسبة

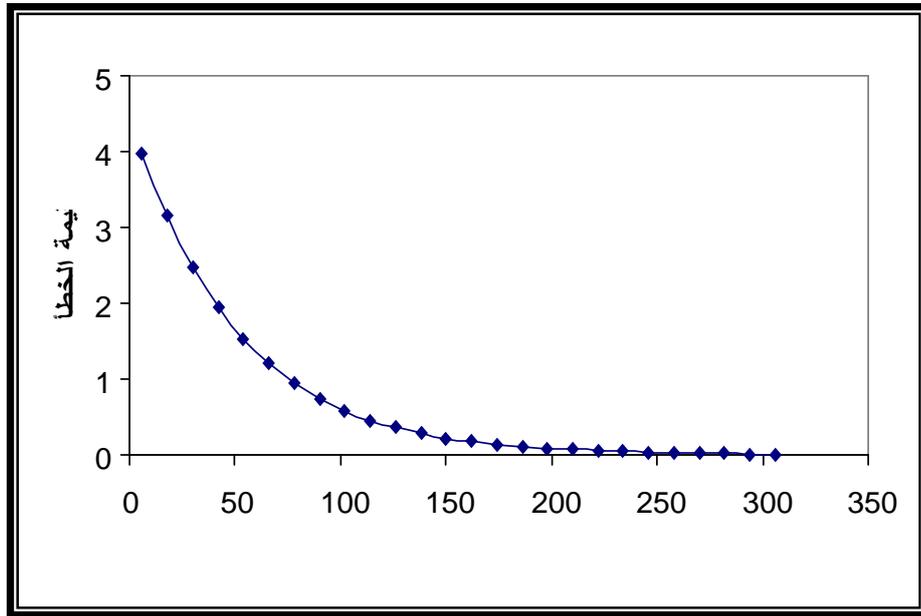
التشوه هي (10.29%).

الفئة السادسة:

أجريت عملية التدريب على هذه الفئة الموضحة في الشكل (3-11) باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01) وعامل تنعيم (0.001) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (4) ، وقيمة الخطأ المقبول للشبكة (0.01) ، وعامل التوسيع لتحويل الموجة α هو (2) ، وعامل النقل لتحويل الموجة β هو (0.9) ، والشكل (3-12) يبين نتائج عملية التدريب.



الشكل (3-11) الفئة السادسة



شكل (3-12) يبين نتائج تدريب الفئة السادسة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008566) بعد (312)

تكراراً، ويوضح الشكل (3-12) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت

هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (8.2) ونسبة

التشوه هي (15.12%).

عند ملاحظة الشكل الذي يمثل هذه الفئة نجد نسبة من التشابه بينه وبين الشكل الذي يمثل الفئة

الخامسة، واتضح هذا التشابه أيضاً في سلوك الشبكة الهجينة عند تعاملها مع هذين الشكلين، إذ كان

سلوك الشبكة متقارب وأحياناً متشابه تماماً في الوصول إلى الحل وكما مبين في الجدول (3-2) الذي

يوضح نتائج تدريب الشبكة عند استعمال دالة كاوس مويجة أم للفئتين ستة والسادسة، عندما كانت

قيمة الخطأ المقبول للشبكة (0.001) وعامل التعلم (0.03) وعامل التنعيم للفئة الخامسة (0.0006)

والفئة السادسة (0.0005).

عدد مستويات التوسيع	عدد التكرارات للفئة	عدد التكرارات للفئة
2	126	126
3	120	120
4	114	114
5	120	120
6	114	120
7	120	120
8	120	108

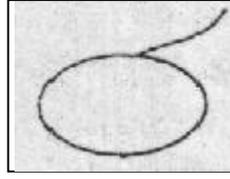
جدول (3-2) عدد التكرارات للفئتين الخامسة والسادسة

الفئة السابعة: دالة التوسيع.

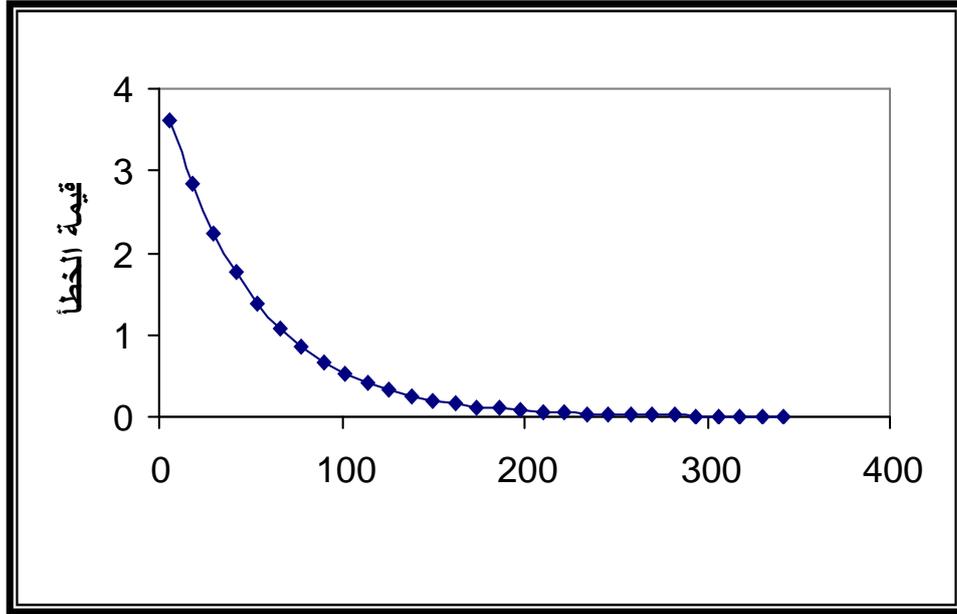
أجريت عملية التدريب على هذه الفئة الموضحة في الشكل (3-13) باستعمال قيمة ابتدائية

لعامل تعلم مقدارها (0.01) وعامل تنعيم (0.0007)، وكان عدد العقد المخبأة (عدد مستويات

التوسيع) (6)، وقيمة الخطأ المقبول للشبكة (0.005) ، وعامل التوسيع لتحويل الموجة α هو (2)، وعامل النقل لتحويل الموجة β هو (0.8)، والشكل (3-14) يبين نتائج عملية التدريب.



ال (3-13) الفئة السابعة



شكل (3-14) يبين نتائج تدريب الفئة السابعة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.004233) بعد (342)

تكراراً، ويوضح الشكل (3-14) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت

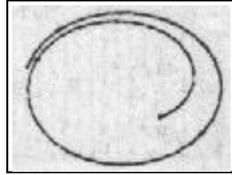
هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (11.115) ونسبة

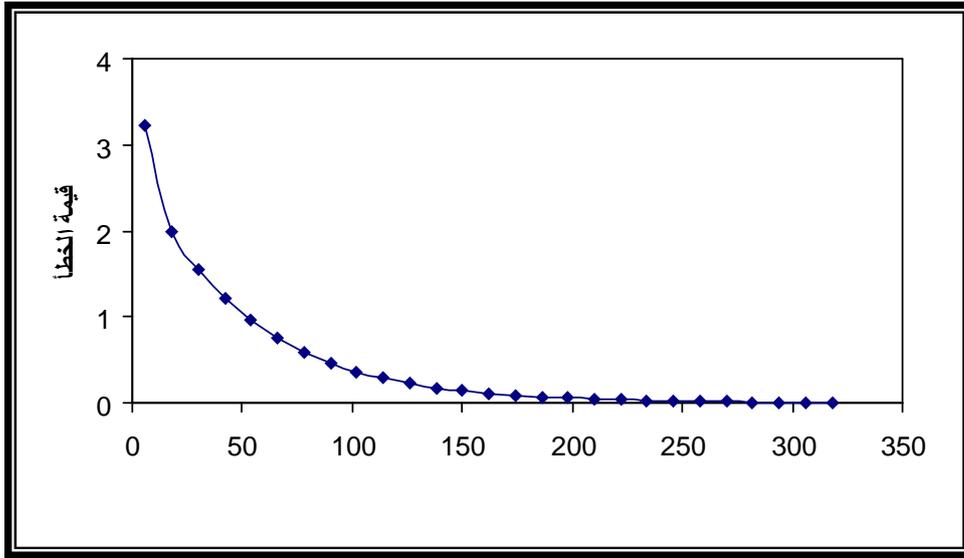
التشوه هي (7.7%).

الفئة الثامنة:

أجريت عملية التدريب على هذه الفئة الموضحة في الشكل (3-15) باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01) وعامل تنعيم (0.00068) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (9) ، وقيمة الخطأ المقبول للشبكة (0.005) ، وعامل التوسيع لتحويل الموجة α هو (2) ، وعامل النقل لتحويل الموجة β هو (1) ، والشكل (3-16) يبين نتائج عملية التدريب.



شكل (3-15) الفئة الثامنة



شكل (3-16) يبين نتائج تدريب الفئة الثامنة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.004235) بعد (324) تكراراً، ويوضح الشكل (3-16) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24) وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (9.55) ونسبة التشوه هي (11%).

ويمكن إدراج نتائج هذه التجربة ولجميع الفئات في الجدول (3-3).

رقم الفئة	عدد التكرارات	قيمة خطأ الشبكة	قيمة الخطأ المقبول	خطأ	عدد مستويات التوسيع
الأولى	414	0.00084	0.001		7
الثانية	438	0.000829	0.001		5
الثالثة	462	0.000816	0.001		6
الرابعة	324	0.0008208	0.001		4
الخامسة	348	0.0008155	0.001		3
السادسة	312	0.008566	0.01		4
السابعة	342	0.004233	0.005		6
الثامنة	324	0.004235	0.005		9

جدول رقم (3-3) نتائج التجربة الأولى

2-1-3 التجربة الثانية

تتضمن هذه التجربة اختبار عملية تدريب الشبكة الهجينة على فئات الأشكال الثمانية باستعمال

الدالة الثانية مويجة أم ، إذ تستخلص من كل شكل خصائص المدرج السراري (المتوسط Mean

الانحراف المعياري Standard Deviation ، الالتواء Skewness ، الأنتروبيا Entropy ، الطاقة

(Energy) لتصبح مدخلات إلى الشبكة بعد أن خضعت لعملية تقييس لتصبح ملائمة للشبكة ، وكان

عدد عقد الإخراج هو (8) وعدد عقد الإدخال هو (5).

لقد أجريت تجارب متعددة على كل فئة بتغيير معاملات خوارزمية التعلم، وتم انتقاء مجموعة

منها لتوضح أداء الشبكة المقترحة، وخصامات خوارزمية التعلم (القيمة الابتدائية لعامل

التعلم ، عامل التنعيم، قيمة الخطأ المقبول للشبكة، عامل النقل لتحويل الموجة، عامل التوسيع

لتحويل الموجة، عدد مستويات التوسيع) قيم متعددة ضمن فترات معينة، وبين الجدول (3-4) قيم هذه المعاملات.

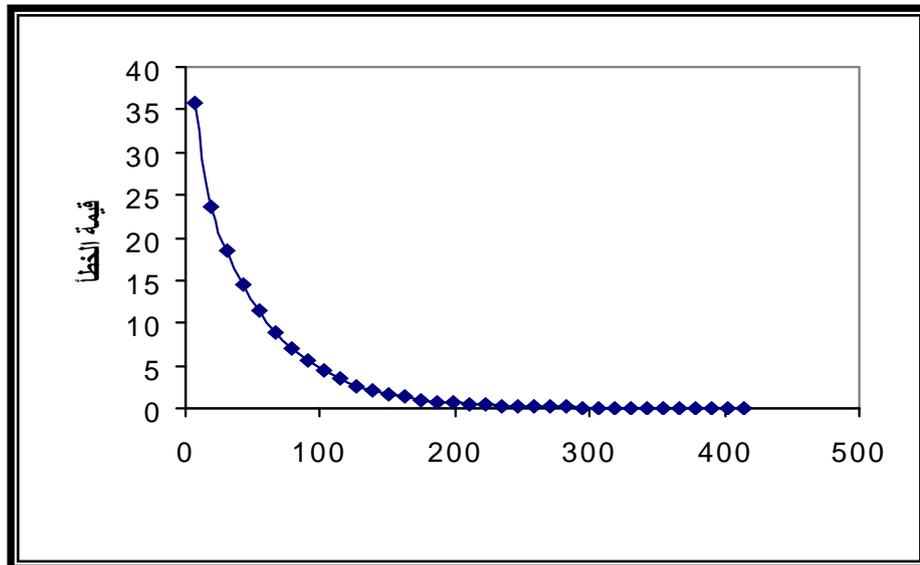
0.005-0.02:	عامل التعلم
0.0007-0.005:	عامل التنعيم
400000:	الحد الأقصى لعدد التكرارات
0.01:	قيمة الخطأ المقبول
1-8:	عدد مستويات التوسيع
1.5-3:	معامل التوسيع لتحويل الموجة
0.6-1:	معامل النقل، لتحويل الموجة

جدول (3-4) يبين المعاملات الأساسية المستعملة في الشبكة الهيئية باستعمال الدالة الثانية موجة أم

الفئة الأولى:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01)

وعامل تنعيم (0.002) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (2) ، و عامل التوسيع لتحويل الموجة α (2) ، و عامل النقل لتحويل الموجة β (1) ، وقيمة الخطأ المقبول للشبكة (0.01) ، و عدد التكرارات والشكل (3-17) يبين نتائج عملية التدريب.



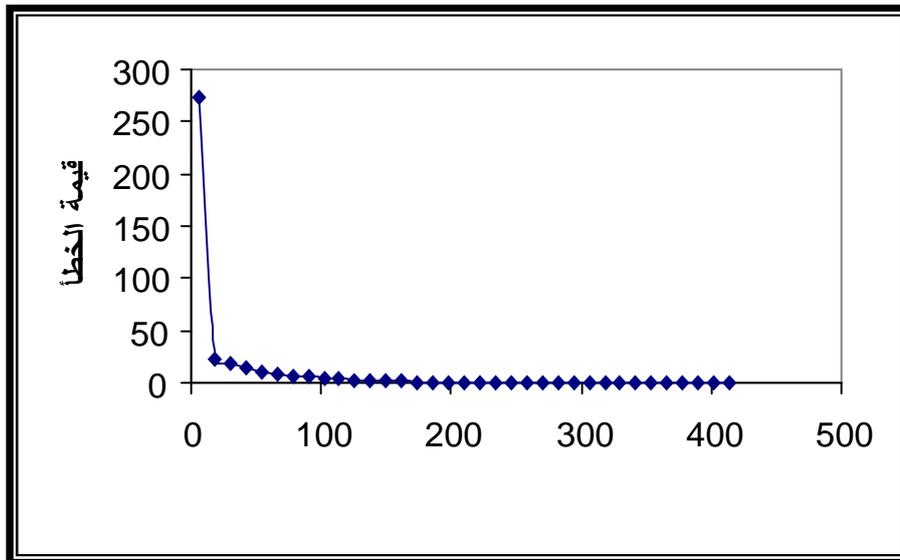
شكل (3-17) يبين نتائج تدريب الفئة الأولى

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008644) بعد (414) تكراراً، ويوضح الشكل (3-17) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية، كما استطاعت هذه الشبكة التعرف على (23) نمطاً من مجموع (24) موجودة ضمن مجموعة التدريب، وتمكنت من التعامل مع أشكال كانت أقل مقداراً للتشوهات في صوها لقيم PSNR (10.73)، وكانت أقل نسبة للتشوه هي (10%).

الفئة الثانية:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01) وعامل تنعيم (0.003)، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (2)، وعامل التوسيع لتحويل الموجة α (2)، وعامل النقل لتحويل الموجة β (1)، وقيمة الخطأ المقبول للشبكة (0.01)، وعدد التكرارات (400000)، والشكل (3-18) يبين نتائج عملية التدريب.



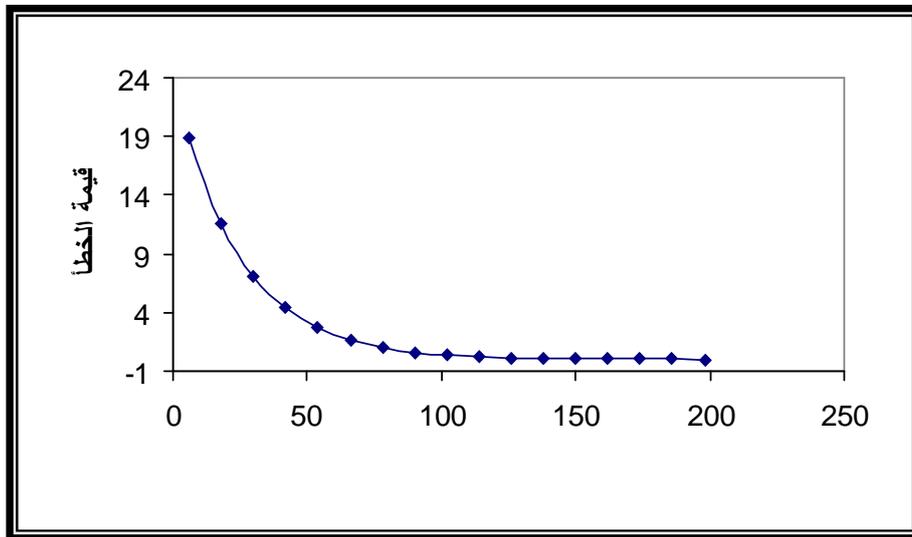
شكل (3-18) يبين نتائج تدريب الفئة الثانية

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008771) بعد (414) تكراراً، ويوضح الشكل (3-18) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية، استطاعت هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24) وتمكنت من التعامل مع أشكال كانت أقل مقدار التشوهات في صورها لقيم PSNR (12.6) ونسبة التشوه هي (9.4%).

الفئة الثالثة:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01) وعامل تتعيم (0.004)، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (8)، وعامل التوسيع لتحويل الموجة α (2)، وعامل النقل لتحويل الموجة β (1)، وقيمة الخطأ المقبول للشبكة (0.01)، وعدد التكرارات (400000)، والشكل (3-19) يبين نتائج عملية التدريب.



شكل (3-19) يبين نتائج تدريب الفئة الثالثة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.007892) بعد (210) تكراراً، ويوضح الشكل (3-19) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية، إذ استطاعت

هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (9.54) ونسبة

التشوه هي (11.1%).

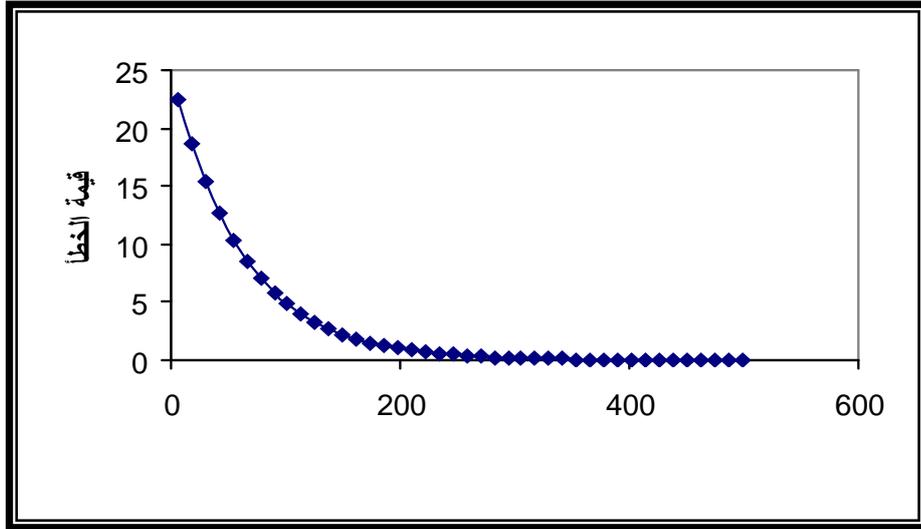
الفئة الرابعة:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.008)

وعامل تنعيم (0.001) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (1) ، وعامل التوسيع

لتحويل الموجة α (2) ، وعامل النقل لتحويل الموجة β (0.6) ، وقيمة الخطأ المقبول للشبكة

(0.01) ، وعدد التكرارات (400000) ، والشكل (3-20) يبين نتائج عملية التدريب.



شكل (3-20) يبين نتائج تدريب الفئة الرابعة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.0008988) بعد (498)

تكراراً، ويوضح الشكل (3-20) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية. إذ استطاعت

هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار التشوهات في صورها لقيم PSNR (9.85) ونسبة

التشوه هي (10.35%).

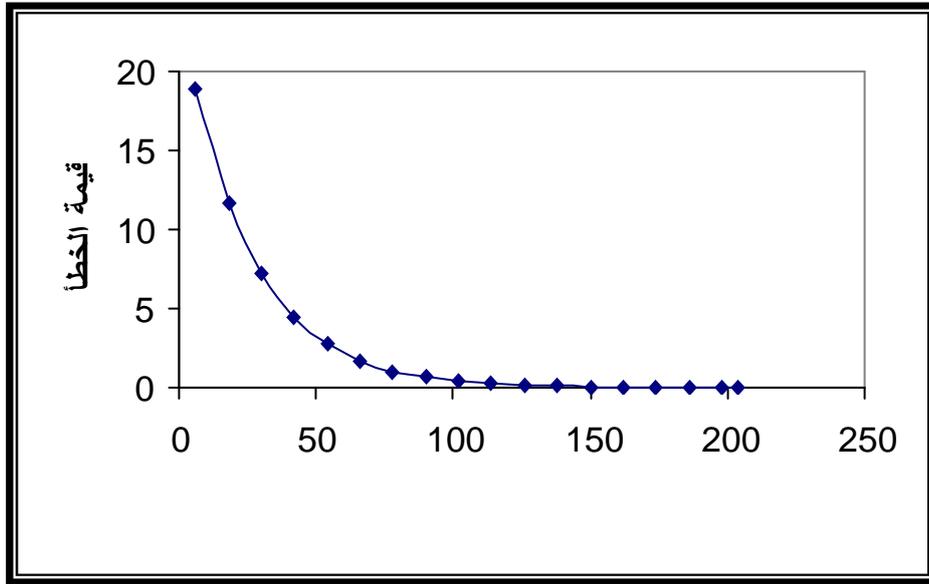
الفئة الخامسة:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدار (0.01)

وعامل تنعيم (0.001)، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (7)، وعامل التوسيع

لتحويل الموجة α (2)، وعامل النقل لتحويل الموجة β (0.7)، وقيمة الخطأ المقبول للشبكة

(0.01)، وعدد التكرارات (400000)، والشكل (3-21) يبين نتائج عملية التدريب.



شكل (3-21) يبين نتائج تدريب الفئة الخامسة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.007212) بعد (204)

تكراراً، ويوضح الشكل (3-21) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية، استطاعت

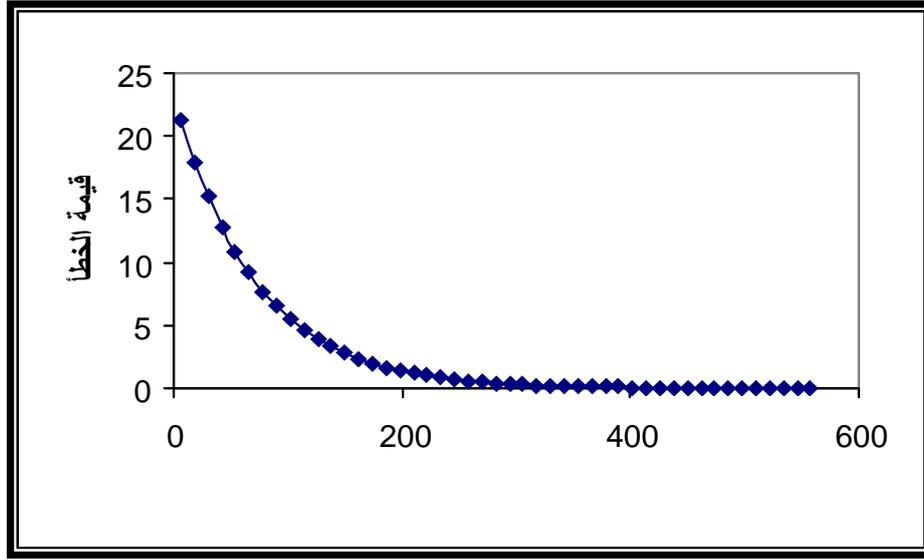
هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار التشوهات في صورها لقيم PSNR (9.87) ونسبة

التشوه هي (10.29%).

الفئة السادسة:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.007) وعامل تنعيم (0.005) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (6) ، وعامل التوسيع لتحويل المويجة α (2) ، وعامل النقل لتحويل المويجة β (0.9) ، وقيمة الخطأ المقبول للشبكة (0.01) ، وعدد التكرارات (400000) ، والشكل (3-22) يبين نتائج عملية التدريب .



شكل (3-22) يبين نتائج تدريب الفئة السادسة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008530) بعد (564) تكرارا، ويوضح الشكل (3-22) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24) وتمكن التعامل مع أشكال كانت أقل مقدار للتشوهات في صورها لقيم PSNR (8.2) ونسبة التشوه هي (15.12 %) .

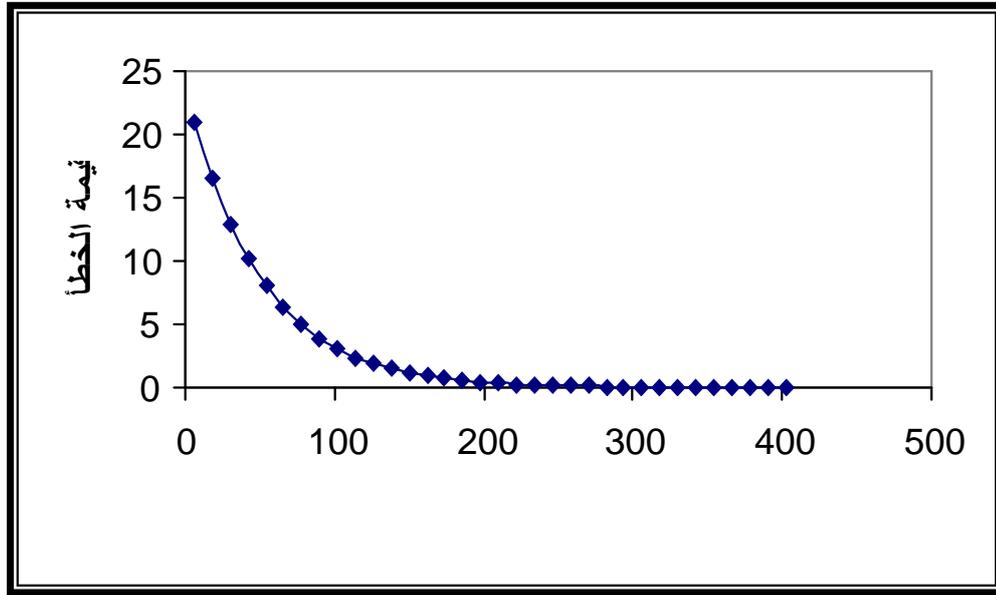
الفئة السابعة:

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01)

وعامل تنعيم (0.004) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (1) ، وعامل التوس

لتحويل الموجة α (2) ، وعامل النقل لتحويل الموجة β (0.8) ، وقيمة الخطأ المقبول للشبكة

(0.01) ، والشكل (3-23) يبين نتائج عملية التدريب.



شكل (3-23) يبين نتائج تدريب الفئة الـ

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.008266) بعد (408)

تكراراً، ويوضح الشكل (3-23) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، استطاعت

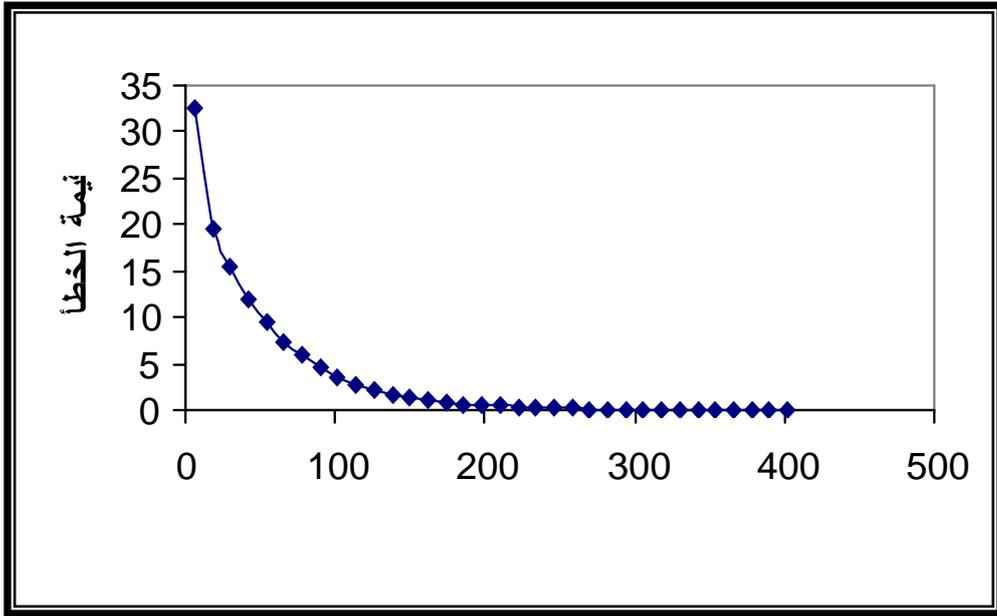
هذه الشبكة التعرف على جميع الأشكال الموجودة ضمن مجموعة التدريب البالغ عددها (24)

وتمكنت من التعامل مع أشكال كانت أقل مقدار التشوهات في صورها لقيم PSNR (11.115) ونسبة

التشوه هي (7.7%).

الفئة ١ :

أجريت عملية التدريب على هذه الفئة باستعمال قيمة ابتدائية لعامل تعلم مقدارها (0.01) وعامل تنعيم (0.002) ، وكان عدد العقد المخبأة (عدد مستويات التوسيع) (3) ، وعامل التوسيع لتحويل الموجة α (2) ، وعامل النقل لتحويل الموجة β (1) ، وقيمة الخطأ المقبول للشبكة (0.01) ، والشكل (24-3) يبين نتائج عملية التدريب.



شكل (24-3) يبين نتائج تدريب الفئة الثامنة

المناقشة:

استطاعت هذه الشبكة الوصول إلى قيمة خطأ مقدارها (0.007920) بعد (408) تكراراً، ويوضح الشكل (24-3) ابتعاد الشبكة من الوقوع في النهاية الصغرى المحلية ، كما استطاعت هذه الشبكة التعرف على (23) نمطا من مجموع (24) موجودة ضمن مجموعة التدريب، وتمكنت من التعامل مع أشكال كانت أقل مقدار التشوهات في صورها لقيم PSNR (11.115) ونسبة التشوه هي (7.7%).

ويمكن إدراج نتائج هذه التجربة ولجميع الفئات في الجدول (3-5)

رقم الفئة	عدد التكرارات	قيمة خطأ الشبكة	قيمة الخطأ المقبول	خطأ التوسيع	عدد مستويات
الأولى	414	0.008644	0.01	2	2
الثانية	414	0.008771	0.01	2	2
الثالثة	210	0.007892	0.01	8	8
الرابعة	498	0.008988	0.01	1	1
الخامسة	204	0.007212	0.01	7	7
السادسة	564	0.008530	0.01	6	6
السابعة	408	0.008266	0.01	1	1
الثامنة	408	0.00792	0.01	3	3

جدول رقم (3-5) نتائج التجربة الثانية

يتضح من خلال مقارنة النتائج الموجودة في الجدول أعلاه مع الجدول (3-3) فيما يخص قيمة

الخطأ المقبول وعدد التكرارات التي تحتاجها الشبكة للوصول إلى ذلك الخطأ، أن سلوك الشبكة كان

أسرع عند استعمال المشد لدالة كاوس مويجة أم منها في حالة استعمال الدالة الناتجة من

تجميع خطي لثلاث دوال سيجماوية، إذ احتاجت الشبكة الهجينة عند استعمال الدالة الثانية إلى تكرارات

مقاربة لتلك المستهلكة في حالة استعمال الدالة الأولى مع العلم أن قيمة الخطأ في التجربة الثانية كانت

(0.01) بينما في التجربة الأولى كانت أقل من ذلك بكثير.

3-1-3 التجربة الثالثة

تهدف هذه التجربة الى موازنة أداء الشبكة الهجينة المقترحة مع شبكة انسياب الخطأ خلفاً

التقليدية (EBP) من حيث عدد التكرارات المطلوبة لاتخاذ القرار الصائب، إذ تم عملية الموازنة

باستعمال كل دالة مويجة أم على حدة، وأجريت تجارب متعددة لهذا الغرض، وفيما يأتي مجموعة من

تلك الاختبارات على أكثر من فئة تمّ انتقاؤها عشوائياً لتوضيح نتائج عملية الموازنة .

1-3-1-3 الفئة الأولى:

يبين الجدول (6-3) قيم المعاملات الأساسية المستعملة في الشبكة الهجينة لكلا الدالتين وشبكة

EBP التقليدية.

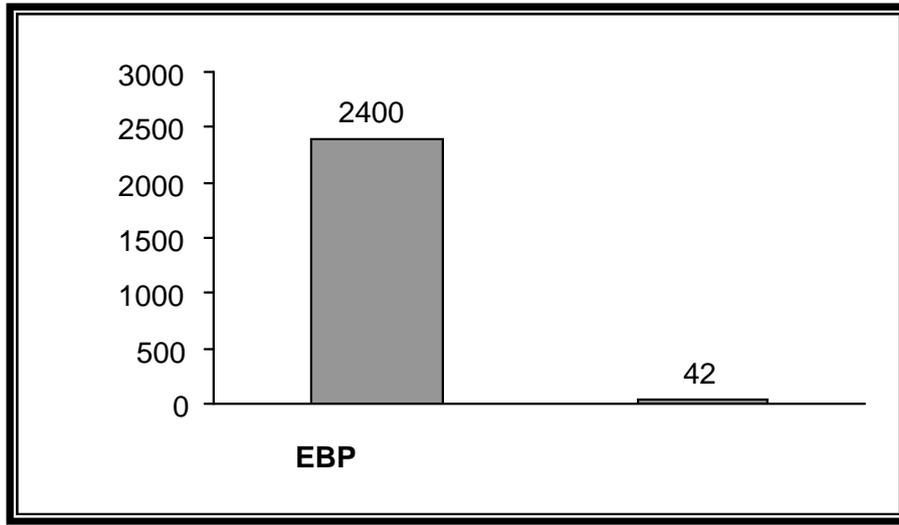
0.1:	عامل التعلم
0.002:	عامل التنعيم
400000:	الحد الأقصى لعدد التكرارات
0.01:	قيمة الخطأ المقبول
8:	عدد الخلايا المخبأة
2:	معامل التوسيع لتحويل المويجة
1:	معامل النقل لتحويل المويجة

جدول (6-3) يبين المعاملات الأساسية المستعملة في الشبكة الهجينة وشبكة EBP التقليدية

1-1-3-1-3 دالة المشتقة الأولى لدالة كاوس وشبكة EBP التقليدية

أجريت عملية الموازنة الضحة في الشكل (3-25) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضّح المخطط سرعة الشبكة المقترحة في اتخاذ القرار .

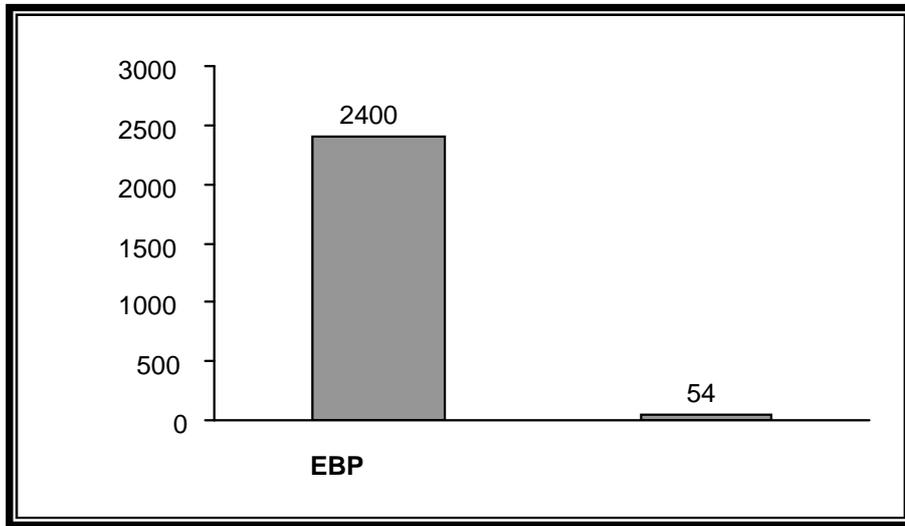


شكل (25-3) يبين موازنة عدد التكرار للشبكة المقترحة وشبكة EBP

2-1-3-1-3 دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية

أجريت عملية الموازنة الضحة في الشكل (26-3) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضح نتائج المخطط سرعة الشبكة المقترحة في اتخاذ القرار.



شكل (26-3) يبين موازنة عدد التكرارات للشبكة المقترحة وشبكة EBP

2-3-1-3 الفئة الرابعة:

يبين الجدول (7-3) قيم المعاملات الأساسية المستعملة في الشبكة الهجينة لكلا الدالتين وشبكة

EBP التقليدية.

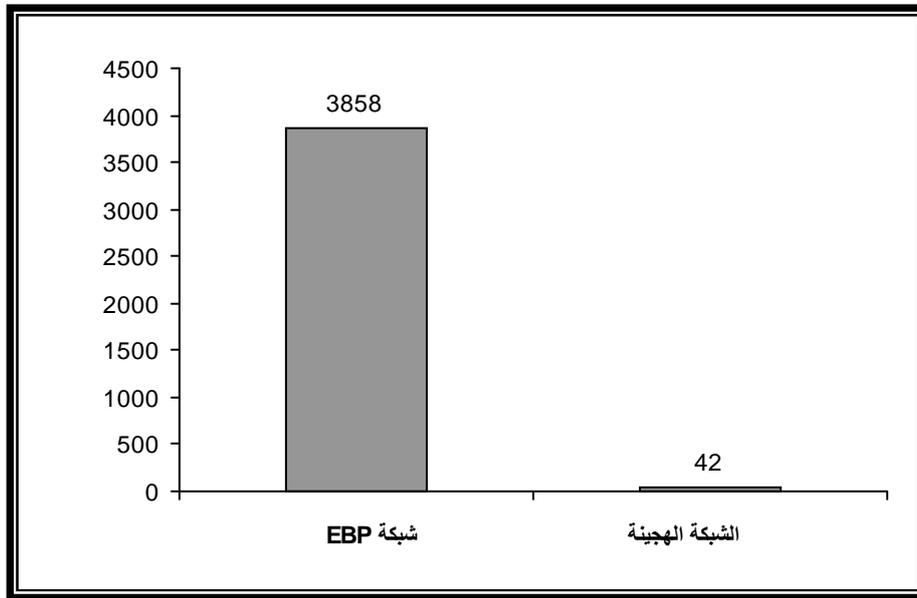
0.1:	عامل التعلم
0.001:	عامل التنعيم
400000:	الحد الأقصى لعدد التكرارات
0.01:	قيمة الخطأ المقبول
6:	عدد الخلايا المخبأة
2:	معامل التوسيع لتحويل الموجة
0.7:	معامل النقل لتحويل الموجة

جدول (3-7) يبين المعاملات الأساسية المستعملة في الشبكة الهجينة وشبكة EBP التقليدية

1-2-3-1-3 دالة المشتقة الأولى لدالة كاوس وشبكة EBP التقليدية

أجريت عملية الموازنة الموضحة في الشكل (3-27) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضيح نتائج المخطط سرعة الشبكة المقترحة في اتخاذ القرار.

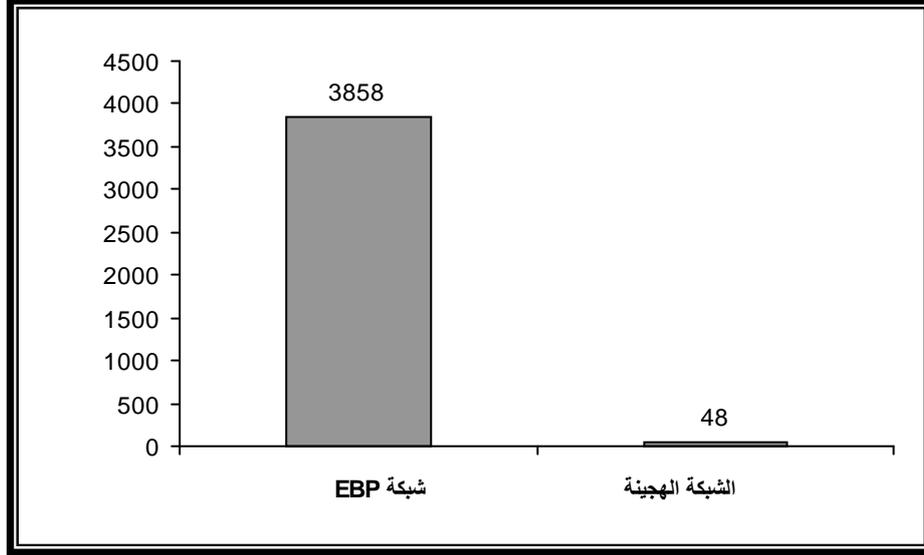


شكل (3-27) يبين موازنة عدد التكرارات للشبكة المقترحة وشبكة EBP

3-1-3-2-2 دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية

أجريت عملية المقارنة المضححة في الشكل (3-28) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضح نتائج المخطط سرعة الشبكة المقترحة في اتخاذ القرار.



شكل (3-28) يبين موازنة عدد التكرارات للشبكة المقترحة وشبكة EBP

3-3-1-3 الفئة الثامنة:

يبين الجدول (3-8) قيم المعاملات الأساسية المستخدمة في الشبكة الهجينة لكلا الدالتين وشبكة

EBP التقليدية.

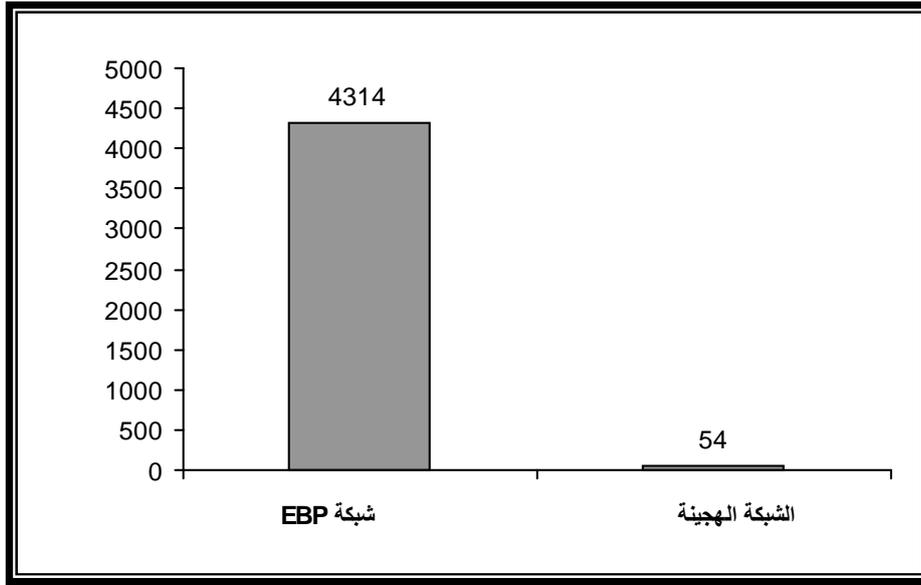
0.08:	عامل التعلم
0.0007:	عامل التنعيم
400000:	الحد الأقصى لعدد التكرارات
0.01:	قيمة الخطأ المقبول
7:	عدد الخلايا المخبأة
2:	امل التوسيع لتحويل الموجة
0.6:	معامل النقل لتحويل الموجة

جدول (3-8) يبين المعاملات الأساسية المستخدمة في الشبكة الهجينة وشبكة EBP التقليدية

1-3-3-1-3 دالة المشتقة الأولى لدالة كاوس و EBP التقليدية

أجريت عملية الموازنة الضحة في الشكل (3-29) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضح نتائج المخطط سرعة الشبكة المقترحة في اتخاذ القرار.

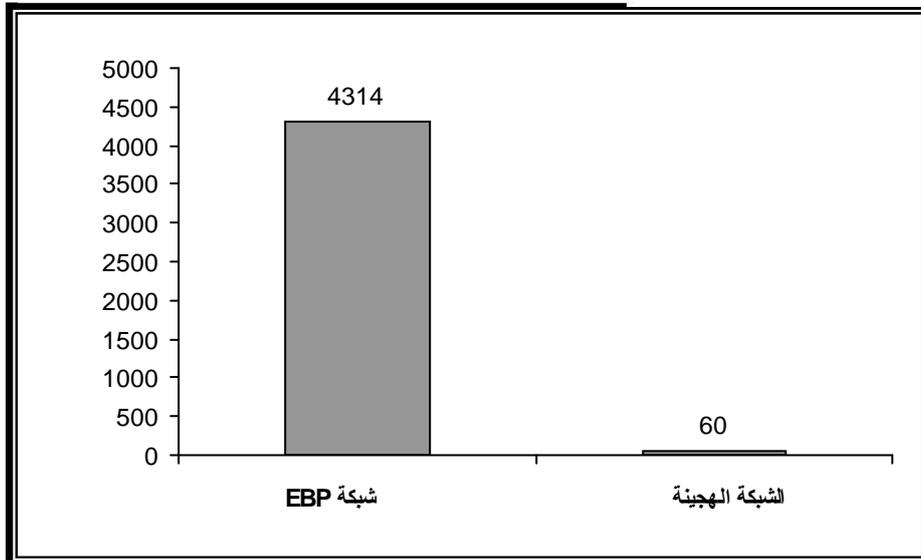


شكل (3-29) يبين موازنة عدد التكرارات للشبكة المقترحة وشبكة EBP

2-3-3-1-3 دالة التجميع السيجماوية الخطية وشبكة EBP التقليدية

أجريت عملية الموازنة الموضحة في الشكل (3-30) من خلال حساب عدد التكرارات المطلوبة

لاتخاذ القرار المناسب، وتوضح نتائج المخطط سرعة الشبكة المقترحة في اتخاذ القرار.



شكل (3-30) يبين موازنة عدد التكرارات للشبكة المقترحة وشبكة EBP

المناقشة:

تبين الاختبارات التي أجريت على ثلاث فئات (الفئة الأولى، والفئة الرابعة، والفئة الثامنة) كفاءة الشبكة الهجينة موازنة مع شبكة EBP التقليدية في الوصول إلى اتخاذ القرار الصائب بعدد أقل من التكرارات، إذ يتضح من الأشكال أعلاه سرعة الوصول إلى حل المشكلة .

وأدرجت نتائج هذه التجربة في الجدول (3-9) لتبيان سلوك الشبكة الهجينة وشبكة EBP

التقليدية.

EBP	عدد التكرارات عند استعمال دالة التجميع السجموية	عدد استعمال مشتقة باوس	عدد التكرارات عند استعمال مشتقة دالة كاوس	رقم الفئة	رقم الفئة
2400	54		42		الأولى
3858	48		42		الرابعة
4314	60		54		الثامنة

جدول (3-9) نتائج التجربة الرابعة

يتضح من الجدول أعلاه أن الشبكة الهجينة احتاجت إلى عدد تكرارات أقل بكثير مما احتاج

EBP التقليدية لأن الشبكة الهجينة تستعمل فهرسي توسيع ونقل تم حسابهما بالاعتماد على بيانات

الادخال وهذا جعل عملية توسيع الدالة وترحيفها يقع ضمن مجال بيانات الادخال وبالتالي الوصول الى

الحل بعدد تكرارات قليلة.

4-1-3 التجربة الرابعة

إنّ الغرض من هذه التجربة هو معرفة قدرة الشبكة المقترحة في التعامل مع صور ذات تدرج

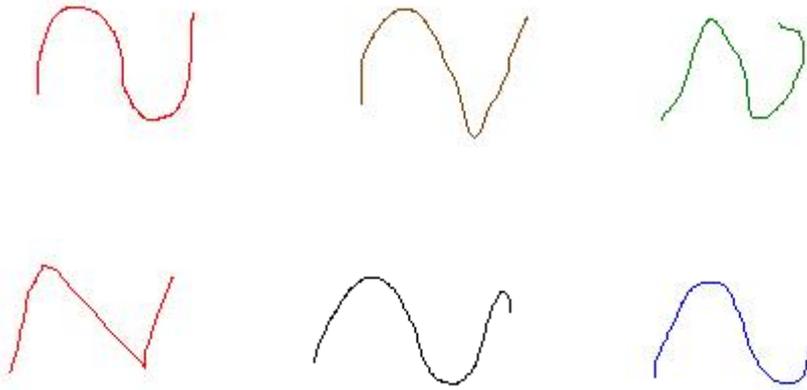
لونى (256) بعد أن ثبت نجاحها في التعامل مع صور ذات تدرج رمادي (8) ثنائيات، وقمنا بإجراء

تجربتين لعملية تدريب فئتين من الفئات الثمانية المذكورة آنفاً، هما الفئة الأولى والفئة الثامنة، باستعمال

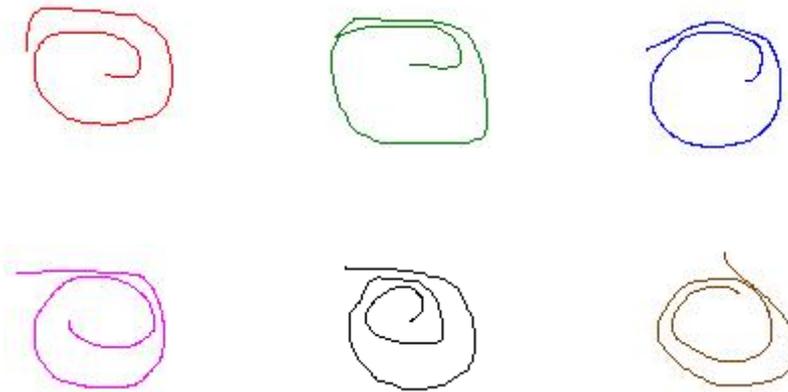
دالتي المويجة الأم (1 و 2) كل على حدة، وتم رسم مجموعة صور كل فئة والموضحة في

الأشكال (31-3) و (32-3) باستعمال أحد برامج الرسم الموجودة في نظام (Windows)، ومجموعة

الصور هذه رسمت بألوان مختلفة.



شكل (31-3) يبين مجموعة الصور الملونة الخاصة بالفئة الأولى



شكل (32-3) يبين مجموعة الصور الملونة الخاصة بالفئة الثامنة

3-1-4-1 المشتقة الأولى لدالة كاوس كموجة أم:

يبين الجدول (3-10) المعاملات الأساسية المستعملة من قبل الشبكة لإجراء عمليات التدريب

للفئتين المذكورتين.

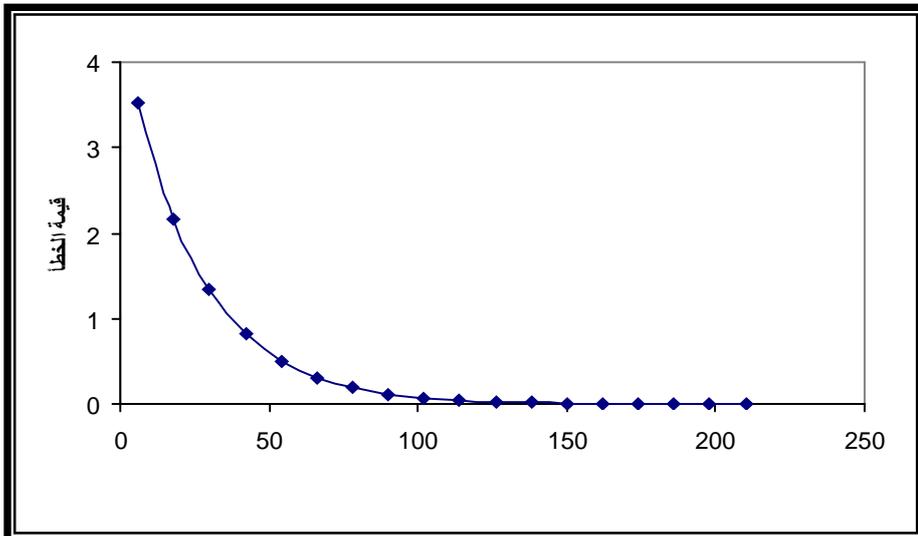
0.02:	عامل التعلم
0.001:	عامل التععيم
400000:	الحد الأقصى لعدد التكرارات
0.001:	قيمة الخطأ المقبول
2:	معامل التوسيع لتحويل الموجة
0.9:	معامل النقل لتحويل الموجة

جدول (3-1) يبين المعاملات الأساسية المستعملة في الشبكة الهجينة

الفئة الأولى:

يبين الشكل (3-33) نتائج عملية تدريب الشبكة الهجينة على مجموعة الصور المخصصة للفئة

الأولى عندما كان عدد الخبا المخبأة (عدد مستويات التوسيع) (4).

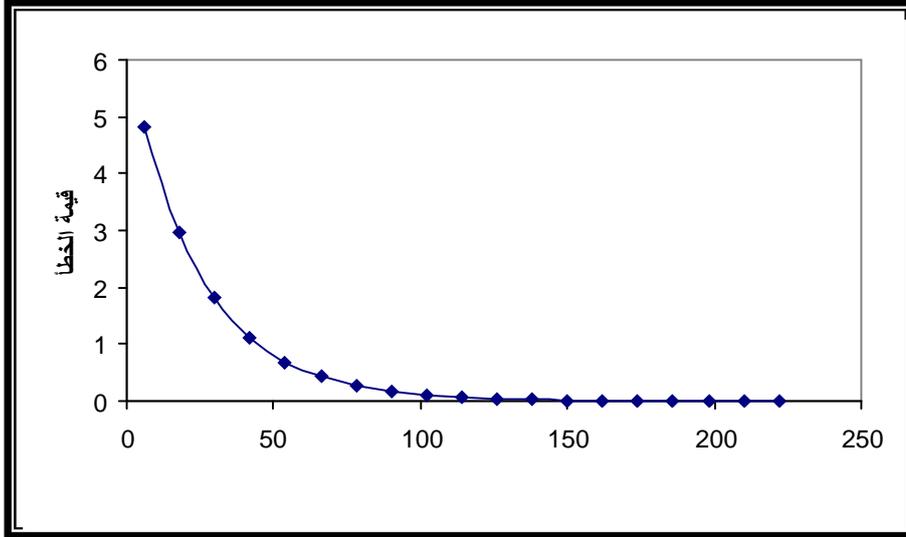


شكل (3-33) يبين نتائج تدريب الصور الملونة الخاصة بالفئة الأولى

الفئة الثامنة:

يبين الشكل (3-34) نتائج عملية تدريب الشبكة الهجينة على مجموعة الصور المخصصة للفئة

الثامنة عندما كان. الخلايا المخبأة (عدد مستويات التوسيع) (6).



شكل (3-34) يبين نتائج تدريب الصور الملونة الخاصة بالفئة الثامنة

2-4-1-3-1 الدالة الناتجة من تجميع ثلاث دوال سيجماوية كموجة أم:

يبين الجدول (3-11) المعاملات الأساسية المستعملة من قبل الشبكة لإجراء عمليات التدريب

للفئتين المذكورتين.

0.01:	عامل التعلم
100000:	الحد الأقصى لعدد التكرارات
2:	أمل التوسيع لتحويل الموجة
6:	عدد العقد المخبأة

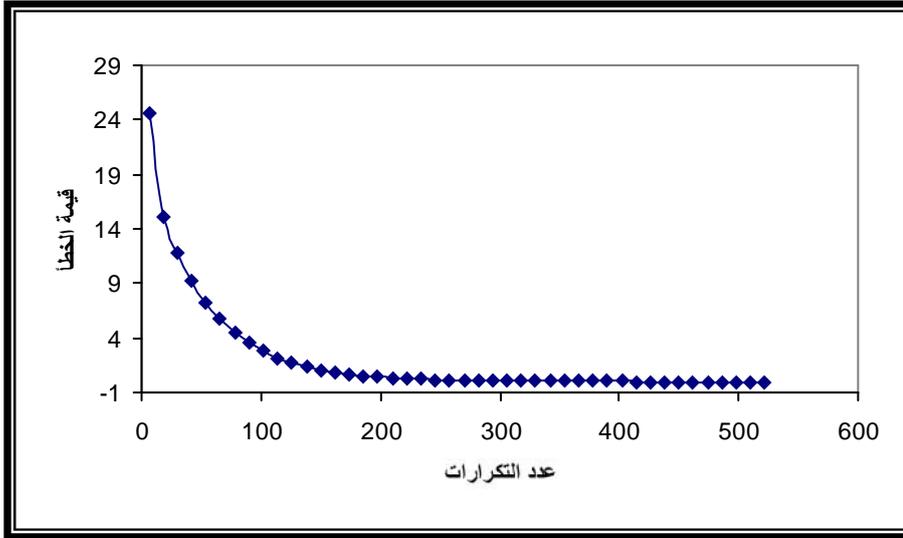
جدول (3-11) يبين المعاملات الأساسية المستعملة في الشبكة الهجينة

الفئة الأولى:

يبين الشكل (3-35) نتائج عملية تدريب الشبكة الهجينة على مجموعة الصور المخصصة للفئة

الأولى عندما كان عامل التعقيم(0.002)، وقيمة معامل النقل (1)، وقيمة الخطأ المقبول للشبكة

(0.001).



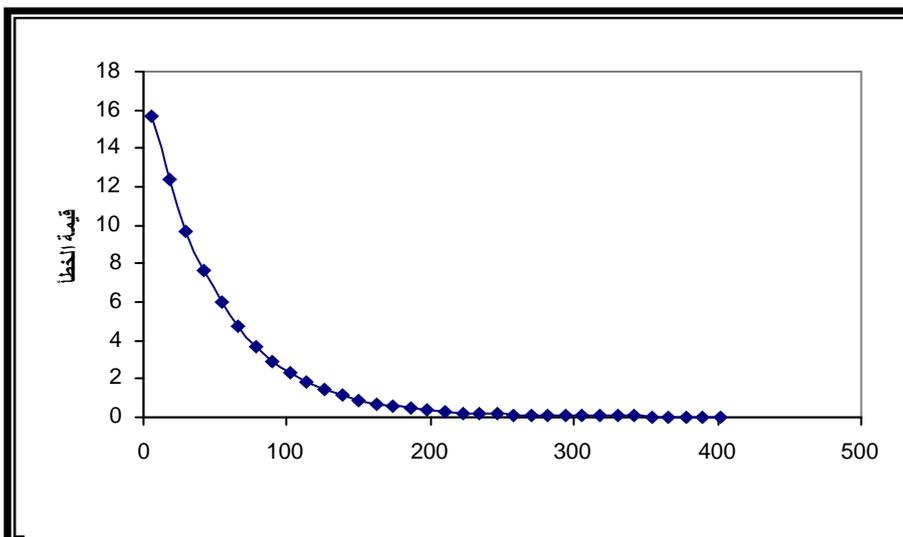
شكل (3-35) يبين نتائج تدريب الصور الملونة الخاصة بالفئة الأولى

الفئة الثامنة:

يبين الشكل (3-36) نتائج عملية تدريب الشبكة الهجينة على مجموعة الصور المخصصة للفئة

الثامنة عندما كان عامل التعقيم(0.001)، وقيمة معامل النقل (0.08)، وقيمة الخطأ المقبول للشبكة

(0.04).



شكل (3-36) يبين نتائج تدريب الصور الملونة الخاصة بالفئة ا

المناقشة:

يتضح من الاختبارات التي أجريت على الصور الملونة نجاح الشبكة في التعامل مع الصور

الملونة، وفضل النتائج قد حصلنا عليها عند استعمال المشتقة الأولى لدالة كائوس موجبة أم قياساً

بالدالة الثانية، إذ تمكنت الشبكة عند الدالة الثانية من التعامل مع قيمة خطأ مقدارها (0.04)

بعكس الشبكة عند استعمال الدالة الأولى إذ استطاعت التعامل مع قيمة خطأ مقدارها (0.001).

2-3 الاستنتاجات

تبين من ملاحظة نتائج التجارب المذكورة أنفاً وأداء الشبكة المقترحة في عملية التصنيف نجاح

الشبكة في حلها لمعظم مشاكل الشبكة العصبية وأيضاً نجاحها في التعامل مع مسألة تصنيف الصور

الذي يعدّ محفزاً جيداً للتشجيع على استعمالها لمشاكل أكثر تعقيداً، ومما تقدم يمكن أن نقف على

الاستنتاجات الآتية:

من الأمور الأولى التي استنتجناها هي سرعة الشبكة الهجينة في الوصول إلى قيمة الخطأ

المقبول وحلها للمشكلة قياساً بأداء شبكة EBP التقليدية.

قدرة الشبكة الهجينة في التعامل مع صور ملونة على الرغم من إجراء عملية الاختبار على

فئتين فقط، إذ أثبتت نتائج التجربة الرابعة نجاح عملية تدريب الشبكة الهجينة على صور ملونة.

تمكنت الشبكة الهجينة من تجنب الوقوع في مشكلة النهاية الصغرى المحلية التي تعدّ من مشاكل

شبكات التغذية الأمامية، وحل هذه المشكلة يعدّ مؤشراً جيداً نحو التوجه إلى استعمالها بشكل أوسع.

قابلية التعميم (Generalization) الممتازة للشبكة في التعرف على الأنماط الموجودة في

مجموعة الاختبار نتيجة لاستعمال تقنيتين تعدّان مقربات عامة وشاملة

(Universal Approximation) معا في نظام واحد لدعم هذه القابلية لأن أحد الأسباب الكامنة

وراء تحسين أداء الشبكة العصبية هو لزيادة قابليتها في التعرف على أنماط غير مطروقة سابقاً.

اتضح من خلال التجارب التي أجريتن أفضل قيمة لمعامل التوسيع α (2)، وكما

تشير إليه الأدبيات الخاصة بموضوع البحث.

إن اعتماد الشبكة الهجينة على بيانات الإدخال في عملية حساب فهرس التوسيع يجعل الموجات

الناجمة تقع ضمن فضاء الإدخال وهذا بدوره يؤدي الى سرعة تقارب الشبكة في الوصول الى الحل.

3-3 الأعمال المستقبلية

1- استعمال الشبكة الهجينة في التعامل مع صور ملونة أكثر تعقيداً.

2- استعمال الشبكة الهجينة في عملية تمييز الكلام (Speech Recognition) لأن إشارة الكلام هي

إشارة غير ثابتة والشبكة الهجينة تحتوي على تحويل موجي يتعامل بنجاح مع هذه الإشارات، إذ

نجحت هذه الشبكة في التعامل مع الصور التي هي أيضاً إشارات غير ثابتة.

3- إن طبيعة الشبكة العصبية في عملية التقليل من حجم البيانات المخزونة، بحيث تحتفظ الشبكة

بأوزان الموصنط التي تكون بحجم أقل (لأن الخبرة تخزن في الموصلات العصبية)، ونجاح

تقنية تحويل الموجة WT في عملية ضغط البيانات والتقليل من حجمها، يشجع على استعمال هاتين

التقنيتين في نظام واحد لضغط البيانات يمكن أن يعطي نتائج أفضل من استعمال كل تقنية على حدة.

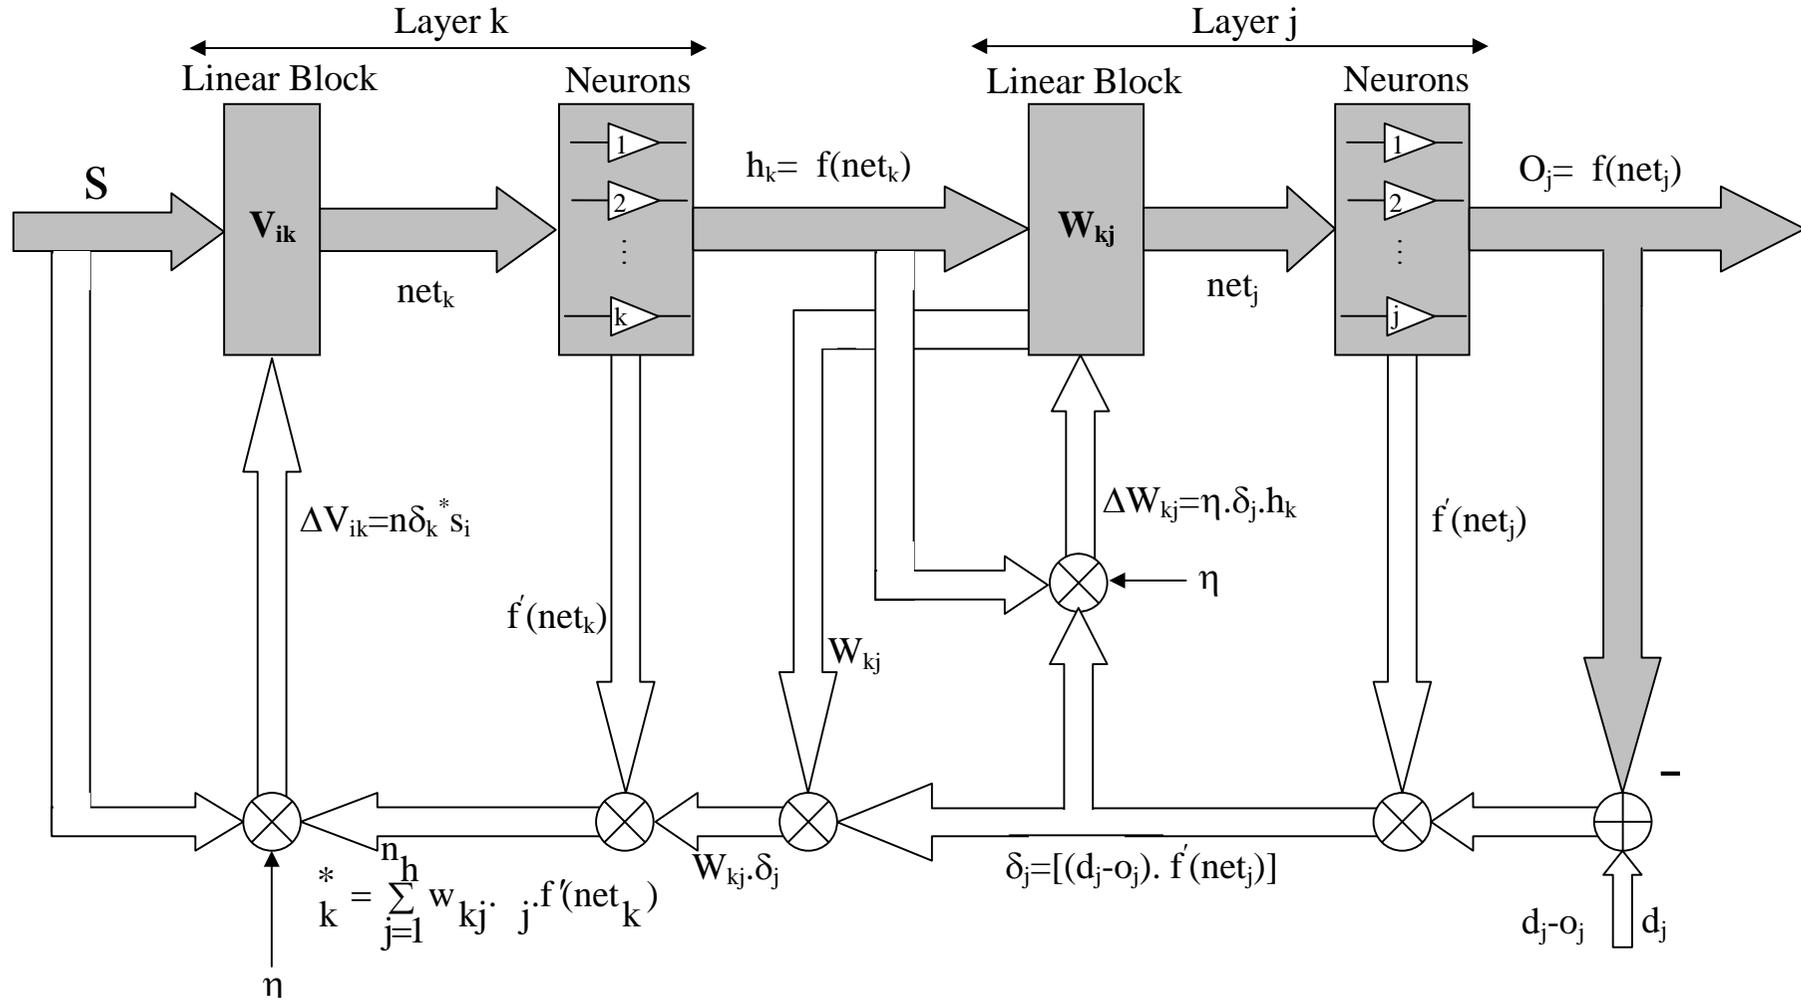
4- استعمال تقنية بحث عامة لاختيار القيمة الأفضل لمعامل إسيع (α) ومعامل النقل (β)

كاستعمال الخوارزميات الجينية.

5- من الممكن استعمال دالة كاوس متعددة المتغيرات موجة أم.

6- استثمر النجاح الذي حققته الشبكة في عملية تصنيف صور أشكال ومخططات مرسومة بخط اليد

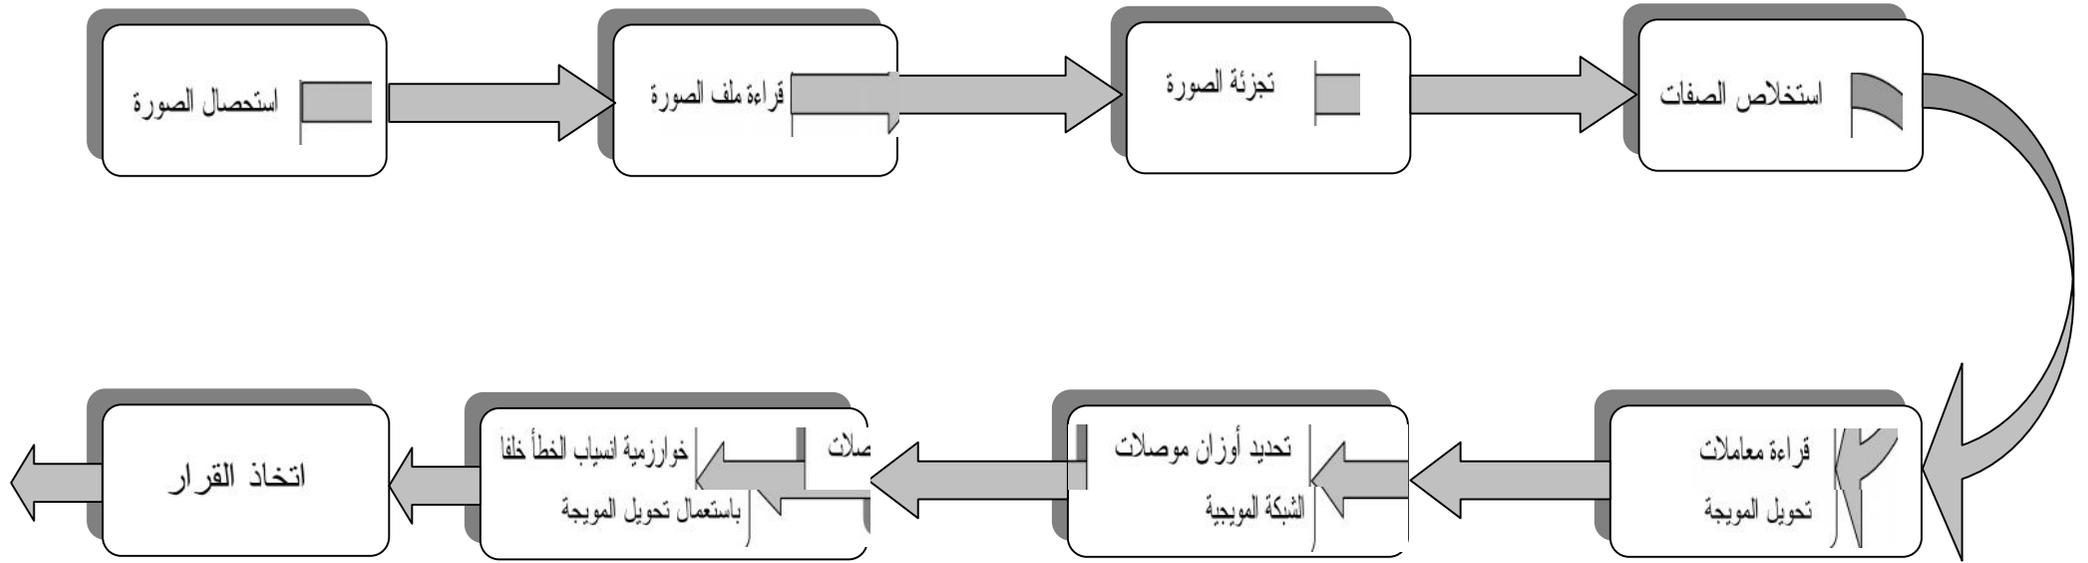
في التعامل مع مسألة تصنيف الكتابة اليدوية (Handwritten).



feed forward phase

Backward phase

شكل (11-1) انسياب المعلومات في شبكة انسياب الخطأ خلفاً



شكل (1-2) يبين خطوات عمل الطريقة المقترحة

المصادر

- [1] S.A.Pandya and B.R.Macy, **Pattern Recognition with Neural Networks in C++**, CRC Press, USA, 1996.
- [2] D.Ruan, **INTELLIGENT HYBRID SYSTEMS: FUZZY LOGIC, NEURAL NETWORKS, AND GENETIC ALGORITHMS**, KLUWER ACADEMIC PUBLISHEIRS, Belgium, 1997.
- [3] L.C.Jain & R.K.Jain, **Hybrid Intelligent Engineering Systems**, Advances in Fuzzy Systems, **11**, Singapore, 1997.
- [4] D.Quagliarella, J. Periaux, C. Poloniand and G. Winter, **Genetic Algorithms and Evolution Strategy in Engineering and Computer Science**, John Wiley and Sons, New Yourk, October, 1998.
- [5] L.Fausett, **Fundamentals of Neural Network: Architectures, algorithms, and Applications**, Prentic-Hall, 1994.
- [6] E.J.Rzempoluck, **Neural Network Data Analysis Using Simulnet**, Springer-Verlag, New York , 1997.
- [7] M.Candill, C.Butler, **Understanding Neural Network**, Vol. 1:Basic Network, sixth printing, 1996.
- [8] هادي، اسعد صباح، طريقة هجينه (GA-BP) لتصميم وتدريب شبكة انسياب الخطأ خلفا معاً تحلل الأوزان ، أطروحة ماجستير، جامعة بابل ، 2000.

- [9] J.M.Zurada, **Introduction to Artificial Neural System**, JAICO publishing House, Bombay, 1997.
- [10] M. Thuillared, **A REVIEW OF WAVELET NETWORKS, WAVELETS, FUZZY WAVELETS AND THEIR APPLICATIONS**, European Symposium On Intelligent Techniques (ESIT), September 14-15, Achen, Germany, (2000).
- [11] Y. OUSSARY and G.DREYFUS, **Initialization by Selection for Wavelet Network Training**, Published in Neurocomputing, **34**, 131, (2000).
- [12] Q. Zhang and A. Benveniste, **Wavelet Networks**, IEEE TRANSACTIONS on Neural Networks, **3**, 6, 889, November, (1992).
- [13] A. Mathur, **Wavelet Self-Organizing Maps and Wavelet Neural Networks: A study**, **4**, 3, 2394, (2001).
- [14] D. Roverso, **MULTIVARIATE TEMPORAL CLASSIFICATION BY WINDOWED WAVELET DECOMPOSITION AND RECURRENT NEURAL NETWORKS**, International Topical Meeting on Nuclear Plant Instrumentation, Control, and Human-Machine Interface Technologies, (NPIC & HMIT 2000), Washington DC, November, (2000).
- [15] Y.C. Pati and P.S. Krishnaprasad, **Analysis and Synthesis of Feedforward Neural Network Using Discrete Affine Wavelet Transformations**, IEEE Trans. On Neural Networks, **4**, 1, 73, January, (1993).

- [16] K. KOBAYASHI and T. TORIOKA, **A WAVELET NEURAL NETWORK FOR FUNCTION APPROXIMATION AND NETWORK OPTIMIZATION**, Proceedings of ANNIE'94, **4**, (1994).
- [17] T. Kugarajah, **Neural Modeling with Wavelets and Application in Adaptive/Learning Control**, Master Thesis, The University of Maryland, U.S.A., 1995.
- [18] J. Echauz and G. Vachtsevanos, **ELLIPTIC AND RADIAL WAVELET NEURAL NETWORKS**, in Proc. Second World Automation Congress (WAC'96), Montpellier, France, May 27-30, TSI Press, **5**, 173, 1996.
- [19] Y. CHENG, B. CHEN AND F. SHIAU, **Adaptive Wavelet Network Control Design for Nonlinear Systems**, Proc. Natl. Sci. Counc. Roc (A), **22**, 6, 783, (1998).
- [20] N.B. Karayiannis and A.N. Venetsanopoulos, **ARTIFICIAL NEURAL NETWORKS: Learning Algorithms, Performance, Evaluation and Applications**, KLUWER ACADEMIC PUBLISHERS, USA, 1992.
- [21] X.Yao, **Evolving Artificial Neural Networks**, Proceedings of the IEEE, **87**, 9, 1423, September, (1999).
- [22] 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).
- [23] E. Davalo and P. Naim, **Neural Networks**, MACMILLAN EDUCATION LTD., Hong Kong, 1991.

- [24] A. Konar, **Artificial Intelligence and Soft Computing: Behavioral and Cognitive Modeling of the Human Brain**, CRC Press, USA, 1999.
- [25] E. Rich and K. Knight, **Artificial Intelligence**, Second Edition, McGraw-Hill Inc., New York 1991.
- [26] B. Kosko, **NEURAL NETWORKS AND FUZZY SYSTEMS**, Prentice Hall International Inc, USA, 1992.
- [27] 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.
- [28] G.F. Luger, and W.A. Stubblefield, **Artificial Intelligence: Structures and Strategies for Complex Problem Solving**, Third Edition, Addison Wesley Longman, USA, 1998.
- [29] V.B. Rao, and H.V. Rao, **C++ Neural Networks and Fuzzy Logic**, MIS Press, New York, 1993.
- [30] F. LUO and R. UNBEHAUEN, **Applied Neural Networks for Signal Processing**, CAMBRIDGE UNIVERSITY PRESS, USA, 1997.
- [31] J. Chen, Z. Chen, S. Xu, Y. Lu, and J. Zhong, **BP algorithm with chaos in MLP neural Networks**, International Conference on Neural Networks and Brain Proceedings (ICNN&B'98), 166, (1998).
- [32] G.Y. Liu, D.Y.Zan, Y.H. Qiu, and J.B. Yu, **A Noval Adaptive Learning Algorithm for BP neural Network**, International Conference on Neural Networks and Brain Proceedings (ICNN&B'98), 197, (1998).

- [33] R. POLIKAR, **The Story of Wavelets**, Appeared in IMACS/IEEE CSCC'99 Proceedings, 5481, (1999).
- [34] D.E. Newland, **An Introduction to Random Vibrations Spectral and Wavelet Analysis**, 3 rd edn, John Wiley and sons, New York, 1994.
- [35] A. Graps, **An Introduction to Wavelets**, IEEE Computational Science and Engineering, **2**, 2, 1, (1995).
- [36] Y.Q. Shi and H. Sun, **IMAGE and VIDEO COMPRESSION for MULTIMEDIA ENGINEERING**, Fundamentals, Algorithms, and Standards, CRC Press LLC, 1999.
- [37] M.J. Haider, **Speech Compression and Recognition Using Wavelet Transform**, MSc. Thesis, University of Baghdad, 1999.
- [38] علي ، سهاد احمد ، ضغط الصور الملونة باستخدام التحويل الوريجي ، أطروحة ماجستير ، جامعة بابل ، 2001.
- [39] Y. Oussar, I. Rivals, L. Personnaz, and G. Dryfus, **Training Wavelet Networks for Nonlinear Dynamic Input-Output Modeling**, Neurocomputing, **20**, (1-3), 173, (1998).
- [40] S.G. MALLAT, **A Theory for Multiresolution Signal Decomposition: The Wavelet Representation**, IEEE Transaction on Pattern Analysis and Machine Intelligence, **11**, 7, 674, July (1989).

- [41] T. Edwards, **Discrete Wavelet Transform: Theory and Implementation**, Technical Report, Stanford University, September 1991.
- [42] C. Torrence and G.P. Compo, **A Practical Guide to Wavelet Analysis**, Bulletin of the American Meteorological Society, **79**, 1, 61, (1998).
- [43] O. RIOUL and M. VETTERLI, **Wavelets and Signal Processing**, IEEE Transaction on Signal Processing, **12**, 6, 14, October, (1991).
- [44] J. L. Strack, F. Multagh and A. Bijaoui, **Image Processing and Data Analysis: The Multiscale Approach**, Cambridge University Press, UK, 1998.
- [45] X. Zhang, L. Tian and Y. Peng, **From the Wavelet Series to the Discrete Wavelet Transform – the Initialization**, Published in IEEE Transaction On Signal Processing, **44**, 1, 129, JANUARY, (1996).
- [46] T. Kugarajah and Q. Zhang, **Multi-Dimensional Wavelet Frames**, Technical Report 95-31 r1, The University of Maryland, 1995.
- [47] S.E. Umbaugh, **Computer Vision and Image Processing**, Prentice Hall PTR, Upper Saddle River, USA, 1998.
- [48] جبار، نهلة إبراهيم، معالجة الصور الطبية لتشخيص بعض الأمراض السرطانية، أطروحة ماجستير، جامعة بابل، 2001.
- [49] سعيد، وفاء محمد، تصميم نظام تجزئة لتمييز أهداف الصور الحرارية، أطروحة ماجستير، جامعة بابل، 2001.

- [50] A. Hamed, **Brain Image Diagnostic System (BIDS)**, Ph.D. Thesis, Saddam University, June 1999.
- [51] R.C. Gonzalez and E.W. Richard, **Digital Image Processing**, Addison-Wesley Publishing Company, USA, 1993.
- [52] V.W. Samawi, **An Investigation into the Use of Neural Networks in Texture Classification**, Ph.D. Thesis, Saddam University, June 1999.

ملحق 1

إذا عُدَّت الدالة السيجماوية $s(x)=(1+e^{-x})^{-1}$ هي الموجبة الأم، وإن $s \in L^2(\mathbb{R})$ ، فلذلك

لا يمكن تكوين إطار باستعمال دوال سيجماوية مفردة كعناصر إطار، سنأخذ الفرق بين دالتين

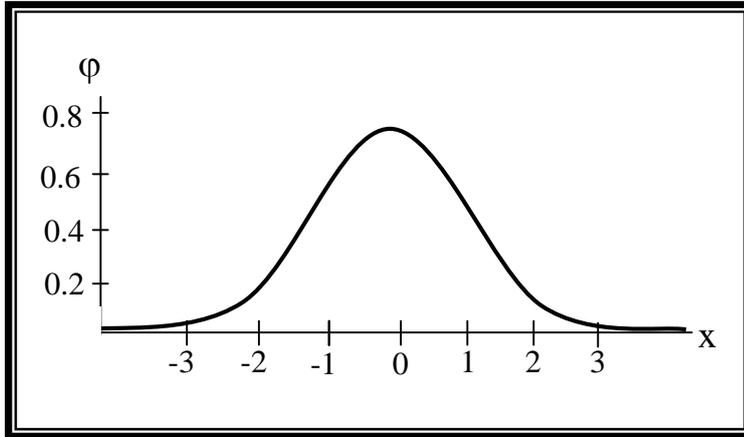
سيجماويتين هو في الفضاء $L^2(\mathbb{R})$ لانتقالات محددة ومن ثمَّ نحصل على:

$$\{ (x) = \sum_{n=1}^M S_{a_n b_n}(x) - \sum_{n=1}^M S_{a_n b_n}(x) \quad (1)$$

إذ إن $M < \infty$ وتمثل عدد عمليات النقل والتوسيع و $S_{ab}(x) = S(ax - b)$ و $a, b \in \infty$ ، وتكون

$\varphi \in L^2(\mathbb{R})$ ، ويصبح بالإمكان تكوين اطارات باستعمال تجميعات من الدوال السيجماوية كما في

المعادلة (1) والشكل الآتي يوضح هذه الدالة:



شكل (1) يبين الدالة $\varphi(x)$

وتصبح هذه الدالة:

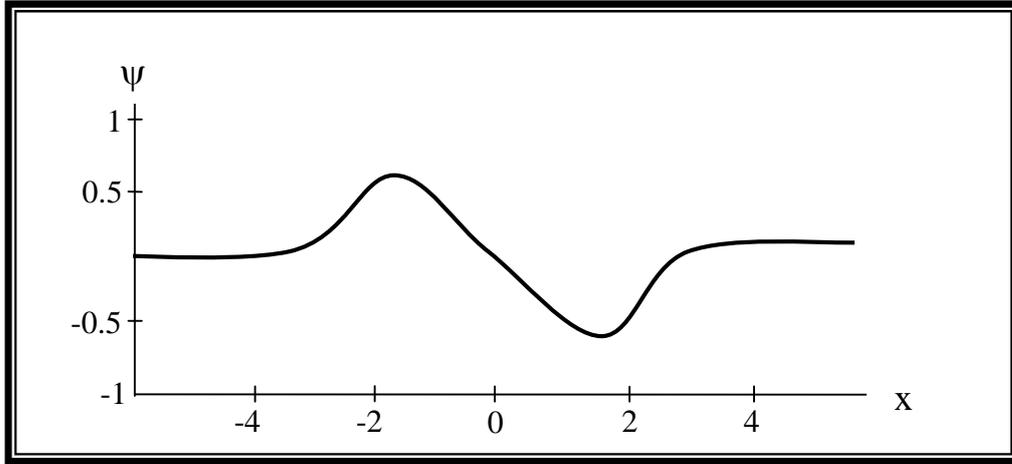
$$\{ (x) = s(x+d) - s(x-d) \quad , 0 < d < \infty \quad (2)$$

نلاحظ من الشكل (1) أن $-\infty < x < +\infty$ ، والدالة أعلاه مستمرة ونحتاج إلى تكوين موجة تقع ضمن

فترة محددة، وتكون قيمتها صفراً خارج تلك الفترة، فإذا فرضنا أن

$$(x) = \{ (x+p) - \{ (x-p) \quad , 0 < p < \infty \quad (3)$$

هي في الفضاء $L^2(\mathbb{R})$ فإن طبيعة هذه الدالة موضحة في الشكل (2).



شكل (2) يبين الدالة ψ

يتبين من علاه أن الدالة لها قيمة ضمن فترة محددة وصفرًا خارج هذه الفترة، فإذا

فرضنا أن $p=1$ و $d=1$ المستعملين في المعادلتين (2) و (3) على التوالي فإن الدالة ψ تكون عبارة

عن موجة أم ناتجة عن تجميع خطي لثلاث دوال سيجماوية [15] بحيث:

$$\psi(x) = s(x+2) - 2s(x) + s(x-2) \quad (4)$$

ملحق 2

فيما يأتي الأجراء الخاص بعملية القراءة لملف صو من نوع BMP التي يكون فيها عدد

الثنائيات لكل عنصر صورة مساوياً إلى (1,4,8,24):-

Algorithm 1-2 {Read BMP File}

Step 1:{Read File Header}

Step 1.1:Get BMP File Header.

Step 1.2:Check The Signature File.

Step 2:Get Global Color Map, Put in Variable Structure "Pallet".

Step 3:Calculat Bitperpixel and Block Data for Each Case Bitno of

1: (bmp.width+7/8).

4: (bmp.width+7/8) shl 2.

8: (((bmp.width+3) div 4)*4).

24: (bmp.width*3).

Step 4:Gets the Offset to Reach the Start of Bitmap Data.

Step 5:Get Block Data Size according to step 3.

Step 6:Put Bitmap Data in Matrix.

ملحق 3

فيما يأتي الأجراء الخاص بعملية تجزئة الصورة اعتمادا على العتبة:-

Algorithm 2.2 { Segment of Image }

Input of Algorithm: The Source Image.

Output of Algorithm: Segmented Image.

Step 1: Read The Image File

Step 2: Calculate the Image Histogram

Step 3: Select The Value of Threshold

Step 4: Split the Image into two Region by Compare each pixel $g(x,y)$
with threshold

If $g(x,y) \geq \text{Threshold}$ Then Region 1

If $g(x,y) < \text{Threshold}$ Then Region 2

قائمة المصطلحات

المصطلح باللغة الإنكليزية	المصطلح باللغة العربية
Artificial Neural Networks	الشبكات العصبية الاصطناعية
Artificial Intelligence	الذكاء الاصطناعي
Activation Function	دالة تنشيط
Basis Wavelets	الموجات الأساس
Compactly Supported Function	دوال محددة في حيز الزمن
Continuos Wavelet Transform	تحويل الموجة المستمر
Classification	التصنيف
Competitive Networks	الشبكات التنافسية
Closed Form	صيغة تقريبية
Dilation	توسيع
Discrete Wavelet Transform	تحويل الموجة المنقطع
Error Backpropagation Network	شبكة انسياب الخطأ خلفاً
Fusion Technology	تكنولوجيا الخلط
Function Approximation	تقريب الدالة
Feature Extraction	استخلاص الصفات
Feed Forward Networks	شبكات التغذية الأمامية
Feedback Networks	شبكات التغذية العكسية
Fuzzy Wavelets	الموجات ذات المنطق المضبب
Generalization Capability	قابلية التعميم
Hybrid System	نظام هجين
Histogram	المدرج التكراري
Intelligent Systems	الأنظمة الذكية
Image Segmentation	تجزئة الصورة
Pattern Recognition	تمييز الأنماط
Least Mean Square Error	أقل متوسطات مربعات الخطأ

المصطلح باللغة الإنكليزية	المصطلح باللغة العربية
Layered Networks	الشبكات الطباقية
Modifiable Intermediate Connections	الموصلات الوسيطة القابلة للتعديل
Mother Wavelet	الموجة الأم
Multiresolution Analysis	التحليل متعدد التفاصيل
Multidimensional Wavelets	الموجبات متعددة الأبعاد
Multi Scaling	التقييس المتعدد
Non-Stationary Signals	الإشارات غير الثابتة
Object Fidelity Criteria	مقاييس الموثوقية الهدف
Pattern Recognition	تمييز الأنماط
Processing Elements	عناصر معالجة
Peak Signal to Noise Ratio	نسبة قمة الإشارة إلى الضوضاء
Reinforcement Learning	التعلم بالتقوية
Radial Basis Function Network	شبكة دالة الأساس نصف القطرية
Short Time Fourier Transform	تحويل فورير ذي الوقت القصير
Signal Scaling	التقييس الوحيد
Scalar Dilation Parameter	معامل توسيع مدرج
Translation	
Time-Frequency Signal Analysis	تحليل الإشارة في مجال التردد-الزمن
Tensor Product	الضرب الممتد
Thresholding	التعتيب
Universal Approximations	مقربات عامة
Wavelet Transform	تحويل الموجة
Wavelet Function	دوال الموجة
Window Pass	نافذة إمرار
Wavelet Frames	إطارات الموجة
Wavelet Networks	الشبكات الموجية

المصطلح باللغة الإنكليزية	ببئة	المصطلح باللغة العربية	
Wavelets		مويجات	
Weighted Connections		الموصلات العصبية الموزنة	

قائمة المختصرات

المصطلح باللغة الإنكليزية	المختصر باللغة الإنكليزية
Artificial Neural Networks	ANNs
Adaptive Resonance Theory	ART
Bit Map Format	BMP
Error Backprobagation	EBP
Least Mean Square Error	LMSE
Multiresolution Analysis	MRA
Peak Signal to Noise Ratio	PSNR
Short Time Fourier Transform	STFT
Wavelet Transform	WT

Abstract

The feed forward neural networks trained by error backpropagation algorithm suffers many problems such as (premature convergence, local minima,...,etc) , these problems effect on the efficiency of that network . Many methods and directions were suggested to overcome these problems. One of these techniques the hybridization. One of these hybridization techniques in the neural networks with the wavelet transform methodology, which has universal approximation theory to be used in the functional approximation process.

In this research the wavelet transform has been used after choosing a suitable mother wavelet as a part doing functional accounting inside the NN as a hidden units. Since the input is vector of multivariate, so a multi-dimensional wavelet transform has been used using multi-standardization. Two functions have been used as a mother wavelet: -

- 1- A function as a collection of three sigmoidal functions.
- 2- The first derivative of Gaussian function.

Each function has been tested inside the network inorder to classify a collection of different hand-drown gray scale images (8) bits, these images subdivided to eight groups, each group contains (6) images with different distortions. The PSNR was used to calculate such distortions.

The training results showed the hybrid network has the ability to deal with such images and the ability to generalize the results by recognizing all the patterns as total of (24) images except the first and the eight experiment when the first function is the wavelet was used to recognize (23) patterns of (24) one.

A comparison between the proposed network an error backpropagation network was given which shows the efficiency of the proposed one is better. Also, the research take into account the color images and its given an efficient classification process for such images.

The proposed method is executed on Pentium III computer with processor speed 650 MHz and using visual C++ version 6 to programming it.

Hybrid System by Using
Wavelet Transform in Neural
Networks for Image
Classification

Athesis

**Submitted to the Council of the Science
College of Babylon University in Partial
Fulfillment of the Requirements for the
Degree of Master of Science in
Computer Science**

By

Salah Mahdi Saleh Al-Obbaidi

October 2003