

# شبكة يوزين العصبية لتجريب

## التجور الطبية

رسالة مقدمة

الى مجلس كلية العلوم – جامعة بابل كجزء من متطلبات نيل درجة  
الماجستير في علوم الحاسبات

من

فضاء خالدة عيسى الجبوري



ربيع الاول ١٤٢٧ هـ

نيسان ٢٠٠٦ م

# *Bayesian Neural Network For Medical Image Classification*

**A Thesis**

**Submitted to the council of college of science**

**University of Babylon**

**In partial fulfillment of the requirements for the degree of Master  
of Science in Computer Science**

**By**

# *Hedhab Khalid Ubais Al-Jobory*



Apral-٢٠٠٦

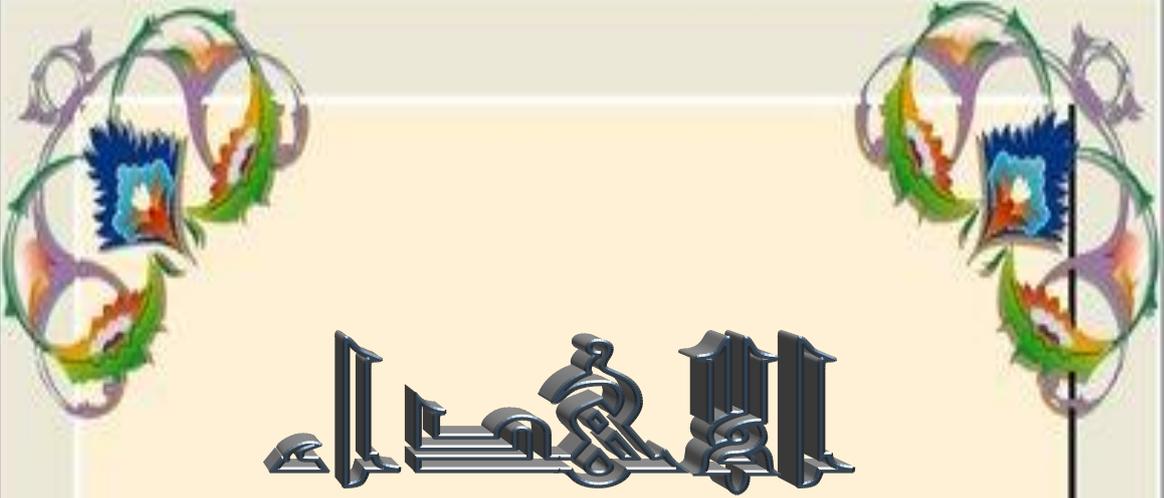
Rabea Al-Awal-١٤٢٧

شكر و تقدير

الحمد لله رب العالمين والصلاة والسلام على اشرف المرسلين محمد وعلى  
اله وصحبه الطيبين الطاهرين. أتقدم بشكري الوافر وجزيل الاعتراف بالجميل  
إلى الأستاذ الدكتور (بيل هاشم كاظم العربي) لمتابعته المستمرة وإرشاده لي  
لإتمام هذه الرسالة جزاه الله عني خير الجزاء.

كما أقدم شكري وامتناني الى رئاسة جامعة بابل وعمادة كلية العلوم وقسم  
علوم الحاسبات رئيساً وأساتذة ومنتسبين لما أبدوه من المساعدة لي.  
ويسعدني ان أتقدم بالامتنان الى الأهل (أبي و أمي وأخوتي وأخواتي) على  
المساعدة الدائمة والدعاء المستمر لي بالتوفيق.

كما أتقدم بالشكر والعرفان إلى كل من قدم لي يد المساعدة او النصيحة



إلى نبع الحنان وبلسم الآلام...

إلى رمز العطاء ومصدر الإلهام...

إلى من جعل الله الجنان وحوورها...



التي علمتني ان الشمعة لا تحترق لتذوب بل تذوب  
لتنير وتتوهج ليرى الآخرون

## شبكة بيزين العصبية لتصنيف الصور الطبية

هضاب خالد عبيس

### الخلاصة

يلعب التطور الحاصل في مجال الحاسوب وتقنياته دوراً مهماً في جميع المجالات العلمية وخصوصاً المجالات الطبية منها، وبما ان الطب الحديث يعتمد على انواع عديدة من الصور الطبية في عملية تشخيص الأمراض فكان من اللازم استخدام الحاسوب في معالجة هذه الصور، ونظراً للتعقيد الكبير الذي تتصف به الصور الطبية وخاصة صور الرنين المغناطيسي (MRI) والصور المقطعية (CT) تم العمل على هذه الانواع من الصور.

تعاملت الرسالة مع مشكلة تصنيف الصور الطبية الخاصة بالاورام، وقد تم التركيز على استخدام مجموعة من التقنيات لغرض حل هذه المشكلة، فقد تم استثمار الخوارزميات الجينية التي تعد خوارزميات بحث عامة تعتمد على تقنيات الاختيار الطبيعي، وتعمل على مجموعة من الحلول بقصد اختيار أفضلها ولقد تم استخدامها لغرض القيام بعملية تجزئة الصور الطبية كنوع من المعالجة الأولية للبحث الحالي. كما تم التعامل في هذه الرسالة مع تحويل الفضاء اللوني و التركيز على الفضائين (RGB) و (HSV) لغرض تهيئة الصور وتسهيل التعامل معها في عملية استخلاص الصفات. تعد مرحلة استخلاص الصفات المرحلة الأساس لتهيئة الصورة لعملية التصنيف و توجد أنواع عديدة من هذه الصفات و لقد انصب الاهتمام في هذه الرسالة على استخلاص صفات التراكيب التي يتم اشتقاقها من مصفوفة الحدود المتزامن ثنائية البعد، اما عملية التصنيف فقد وقع الاختيار على شبكة بيزين العصبية لتقوم بهذه المهمة، وذلك بسبب المشاكل التي تعاني منها الشبكات العصبية التقليدية مثل التعميم والاشباع والتكيف الزائد والوقوع في النهاية الصغرى المحلية وغيرها.

شبكة بيزين العصبية شبكة متعددة الطبقات ذات تغذية امامية تعتمد في تدريبها على قانون بيزين الاحتمالي، أي ان اساس عمل هذه الشبكة هي قوانين الاحتمالية وتركز هذه الشبكة على حل مشكلة التكيف الزائد وقد أثبتت الشبكة قدرتها على حل هذه المشكلة وكذلك حل مشكلة الوقوع في النهاية

الصغرى المحلية، وبعد إدخال صور مجموعة التدريب ومجموعة الاختبار تمكنت الشبكة من التعلم والتعرف على جميع هذه الصور.

## المحتويات

رقم الصفحة	العنوان	التسلسل
	المقدمة	الفصل الاول
١	مقدمة عامة	١-١
٢	الاعمال السابقة	٢-١
٣	هدف البحث	٣-١
٤	هيكل الرسالة	٤-١
	ادبيات عامة	الفصل الثاني
٥	مقدمة عامة	١-٢
٥	تجزئة الصور	٢-٢
٦	التعتيب	١-٢-٢
٦	كشف الحدود	٢-٢-٢
٧	نمو المناطق	٣-٢-٢
٧	شطر ودمج المناطق	٤-٢-٢
٧	تقنيات العنقدة	٥-٢-٢
٩	تقنية الاوساط المتعددة	١-٥-٢-٢
١٠	تقنية شطر المناطق التداخلي	١-٥-٢-٢
١٢	تقيم اداء تقنيات التجزئة	٦-٢-٢
١٥	الخوارزميات الجينية	٣-٢
١٥	عناصر الخوارزمية الجينية	٤-٢
١٥	المجتمع	١-٤-٢
١٥	التقييم	٢-٤-٢
١٦	التشفير	٣-٤-٢
١٦	الانتقاء	٤-٤-٢
١٨	التزاوج	٥-٤-٢
١٩	الطفرة	٦-٤-٢

رقم الصفحة	العنوان	التسلسل
١٩	الاحلال	٧-٤-٢
٢٠	مقاييس التوقف	٨-٤-٢
٢١	صيغ الخوارزميات الجينية	٥-٢
٢٣	الفضاء اللوني	٦-٢
٢٣	الفضاء اللوني (RGB)	١-٦-٢
٢٤	الفضاء اللوني (HSV)	٢-٦-٢
٢٦	الشبكات العصبية	٧-٢
٢٦	انواع الشبكات العصبية	١-٧-٢
٢٧	شبكات التغذية الامامية	١-١-٧-٢
٢٧	شبكات التغذية العكسية	٢-١-٧-٢
٢٨	شبكات التغذية التنافسية	٣-١-٧-٢
٢٩	التعلم في الشبكات العصبية	٢-٧-٢
٣٠	دوال التنشيط	٣-٧-٢
٣٠	دوال التنشيط العامة	١-٣-٧-٢
٣١	دوال التنشيط المحلية	٢-٣-٧-٢
٣٢	مشاكل الشبكات العصبية متعددة الطبقات	٨-٢
٣٤	شبكة بيزين العصبية	٩-٢
٣٥	حل بيزين	١-٩-٢
٣٧	تقريب كاوس	٢-٩-٢
٣٨	المعرفة المسبقة	١٠-٢
	<b>تصميم وبناء النظام المقترح</b>	<b>الفصل الثالث</b>
٤٠	تنفيذ النظام المقترح	١-٣
٤٠	ادوات البرمجة	٢-٣
٤٠	الهيكل العام لتنفيذ النظام المقترح	٣-٣
٤١	الصورة RGB	١-٣-٣
٤٢	بيانات الصورة	٢-٣-٣
٤٣	الخوارزمية الجينية	٣-٣-٣
٤٩	الصورة المجزأة	٤-٣-٣
٤٩	تحويل الفضاء اللوني	٥-٣-٣
٥٠	الصورة ممثلة بالفضاء اللوني HSV	٦-٣-٣
٥١	استخلاص الصفات	٧-٣-٣
٥١	صفات التراكيب	٨-٣-٣
٥٤	شبكة بيزين العصبية	٩-٣-٣
	<b>اداء النظام المقترح</b>	<b>الفصل الرابع</b>
٥٩	اداء النظام المقترح	١-٤

رقم الصفحة	العنوان	التسلسل
٥٩	التجربة الاولى	٢-٤
٦٠	التجربة الثانية	٣-٤
٦٣	التجربة الثالثة	٤-٤
٦٨	التجربة الرابعة	٥-٤
٧٣	التجربة الخامسة	٦-٤
٨٠	الاستنتاجات	٧-٤
٨٣	الاعمال المستقبلية	٨-٤

## الفصل الأول

### المقدمة والاعمال السابقة

#### ١-١-١ المقدمة

نالت الشبكات العصبية الاصطناعية (Artificial Neural Network) ANNs اهتماماً واسعاً من الباحثين كأحد موضوعات العصر المهمة التي حققت التحدي الذي يسعى اليه باحثو الذكاء الاصطناعي (Artificial Intelligence) AI في تصميم أنظمة ذات سلوك يحاكي سلوك العقل البشري في عملية اتخاذ القرار وحل المشاكل [١]، فظهرت الشبكات العصبية الاصطناعية لمحاكاة الشبكات العصبية البيولوجية التي تعد بالأساس الرياضي (Mathematical Models) نماذج لمعالجة المعلومات.

هناك انواع عديدة من الشبكات العصبية ولكل منها ميزات تمكنها من حل المشاكل وتأدية العمل المراد منها ولكن لكل من هذه الشبكات عيوب ومشاكل تصاحب عمل هذه الشبكات من هذه المشاكل هي التعميم، و التقارب، والوقوع في النهاية الصغرى المحلية، التكييف الزائد عن الحد، فظهرت العديد من البحوث التي تحاول حل هذه المشاكل ومنها اضافة حد التعميم (Momentum Term) الى معادلة تعديل

الأوزان لزيادة التقارب والهروب من الوقوع في النهاية الصغرى المحلية [٢][٣]، واستخدام الخوارزميات الجينية في إيجاد أفضل متجه اوزان، واستعمال الشبكات العصبية في نظام هجين مع التحويل المويجي، ومن البحوث الأخرى هي استخدام شبكة بيزين العصبية في حل مشكلة التكييف الزائد (Over Fitting).

من اللحة الأولى للعنوان والذي يضم الأسلوبين ( الشبكات العصبية (Neural Network) وطريقة بيزين الإحصائية (Bayesian Statistical Method)) قد تعطي انطباعاً بان هذين الأسلوبين لا يمكن ان يلتقيا في موضوع واحد، فالشبكات العصبية هي عبارة عن حسابات متوازية غير خطية (Non Linear) تحاكي هيكل الدماغ، مثال على الشبكات شبكة انسياب الخطأ خلفاً قدرة على التعلم بواسطة الأمثلة وبذلك تستطيع حل مشاكل التصنيف والتنبؤ (Classification, Predication). ويمكن وصف الشبكة العصبية من الجانب الأول بالصندوق الاسود (black box) حيث تتلاطم المعاملات داخل هذا الصندوق ويتم الحصول على الحل بصورة غير مفهومة، وبالمقارنة مع الجانب الثاني وهو طريقة بيزين الإحصائية والتي تقوم باصدار استنتاج مفهوم يعتمد على بديهية معروفة [٤].

من خلال التوضيح السابق يمكن ان تكون الشبكة العصبية طريقة معاكسة لطريقة بيزين الإحصائية في نمذجة البيانات. على كل حال هناك موضوع يضم الطريقتين، فكلتا الطريقتين تهدفان إلى إيجاد نموذج يطابق البيانات بصورة جيدة (well-match)، تمثل الشبكات العصبية تقنيات تقليدية مرنة هذه المرونة تمكنها من حل المشاكل، ولأنها مرنة جداً (غير خطية non linear) تكون قادرة على التكيف مع البيانات بصورة جيدة. ان المشكلة في الشبكات العصبية هذا التكيف عندما يزيد عن الحد المعقول (over fitting) والذي يمكن ان يخدع في اكتشاف هياكل بيانات غير موجودة في انماط التدريب، هنا تأتي طريقة بيزين الإحصائية والتي تؤدي دوراً مكماً للشبكة العصبية، وذلك من خلال إيجاد توزيع احتمالي (probability distribution) مناسب يمكن من خلاله السيطرة على معاملات الشبكة العصبية، تقدم طريقة بيزين الاحصائية تخميناً مناسباً للاوزان weights، معاملات السيطرة control parameters، عدد الطبقات المخفية no. of hidden layer، وعدد العقد المخفية في كل طبقة no. of hidden neurons.

تعد الشبكات العصبية من اشهر الطرائق المستخدمة في حل المشاكل وذلك بسبب مزاياها المتعددة فهي مرنة في التعامل مع البيانات وتستطيع حل المشاكل عندما لا توجد معرفة كافية تمكننا من بناء نموذج مناسب، وبنفس الوقت تعاني الشبكات العصبية من عدد من المشاكل حاول الباحثون على مر السنين ايجاد حلول لهذه المشاكل. تعد شبكة بيزين العصبية حلاً لاحدى المشاكل التي تعاني منها الشبكات العصبية التقليدية و قد قدم الباحثون اعمالاً متعددة في هذا المجال منها:

قدم *Toussaint* و *Gori* و *Dose* في العام (٢٠٠٤) شبكة بيزين العصبية والتي اوجد لها توزيعاً احتمالياً يمكنه من تخمين عدد العقد المخفية في الطبقة المخفية بشرط وجود البيانات، وقد استخدم الشبكة في ازالة الضوضاء من صورة ثنائية تحتوي على نسبة عالية من الضوضاء لغرض التخلص من هذه الضوضاء، قام بتقديم تخمين اذا كان العنصر اللوني ذا قيمة (١) او قيمة (٠) [٥].

كذلك قدم ماثيو كوبنسكي ورفاقه (*Matthew A. Kupinski et al*) في العام (٢٠٠١) نموذجاً لشبكة بيزين العصبية استخدمها في تصنيف الصور الطبية تم ادخال متجه الصفات الى الشبكة وكانت نتيجة التصنيف اما الحالة الطبيعية (غير مصاب) او الحالة الغير طبيعية (حالة الإصابة) [٧].

اما *Jouko Lampinen* و *Aki Vehtari* فقد استخدم طريقة *Markov chain Monte Carlo* لغرض تخمين متجه الاوزان ومعامل السيطرة ( $\alpha$ ) وقد استخدم هذه الشبكة لغرض تمييز الاشجار وتحديدها في صور الغابات وذلك في العام (٢٠٠٠) [٨].

قدم *de Fritas* و *M. Nairanjan* في العام (١٩٩٨) نموذجين لشبكة بيزين العصبية من خلال تطبيق طريقة *Markov chain Monte Carlo* هي سلسلة اخذ العينات المهمة واعادة اخذ العينات (*sampling importance resampling*) ونموذج (*SIR*) ونموذج (*sampling importance resampling*) *HySIR* (Hybrid) [٩].

كما قدم *Jan C. Bioch* و *Onno van der Meer* و *Rob Pattharst* شبكة بيزين العصبية في العام (١٩٩٨) تستخدم توزيعاً احتمالياً لغرض تخمين متجه الاوزان واستخدم طريقة *Markov chain Monte Carlo* لغرض حل التكامل المتعدد الحدود واستخدم الشبكة في تصنيف بعض الحالات الطبية [٦].

## ٣-١- أهداف البحث

يهدف البحث الحالي الى استثمار الإمكانية الموجودة في قوانين الاحتمالية وخصوصاً قاعدة بيزين والتي بإمكانها توفير صيغة يمكن من خلالها السيطرة على المعاملات المسبقة (متجه الأوزان)، وكذلك تقديم دالة احتمالية يمكن اشتقاقها واستخدامها لغرض حساب الخطأ الحاصل في اخراج الشبكة وأيضا تقديم توزيع لاحق للشبكة يمكنها من التنبؤ بحالة الإخراج.

تم استخدام كل هذه العوامل التي توفرها قاعدة بيزين في داخل الشبكة العصبية متعددة الطبقات ذات التغذية الأمامية لغرض بناء شبكة بيزين العصبية المعتمدة على قوانين الاحتمالية في عملية التدريب. تم استخدام هذه الشبكة في عملية تصنيف الصور وكانت الصور المستخدمة هي صور طبية تمثل اورام الكبد و أورام الغدة الكظرية، عند البداية كان من اللازم معالجة الصور الطبية لغرض الوصول إلى احسن هيئة يمكن من خلالها الوصول الى نتائج جيدة في عملية التصنيف، حيث تم معالجة الصور معالجة اولية وذلك بإجراء عملية العنقدة على الصور وكانت الخوارزميات الجينية هي الوسيلة لاتمام هذه المهمة، ومن ثم اخذ متجه من الصفات التي يمكن بواسطتها تصنيف تلك الصور ولقد تم اختيار صفات التراكيب التي يتم اشتقاقها من مصفوفة الحدوث المتزامن هي الصفات المناسبة لوصف الصور الطبية. تتمكن شبكة بيزين العصبية من تجاوز مشكلة التكيف الزائد والوصول الى نتائج جيدة في عملية التدريب وتقليل قيمة الخطأ الحاصل في عملية التصنيف.

## ١-٤- هيكـل الرسالة

يتكون الهيكل العام للرسالة من أربعة فصول، توزعت على الواقع الاتي

اذ تضمن الفصل الأول زيادة على المقدمة العامة نبذة مختصرة عن البحوث والدراسات السابقة وكذلك توضيح الهدف من البحث وأخيراً هيكل الرسالة.

اما فيما يخص الفصل الثاني فقد كان يتناول توضيحاً للأسس النظرية لعملية تجزئة الصور والطرائق المستخدمة في هذه العملية وكان التركيز على عملية العقدة الخاصة بالصور، ومن ثم بيان وبشكل مركز ومختصر للخوارزمية الجينية وعناصرها وأنواع هذه العناصر مع التركيز على العناصر المستخدمة في العمل الحالي، وبعدها تم الانتقال إلى ما يخص الفضاء اللوني وأنواعه وكان التركيز على الفضاء اللوني المستخدم في العمل، اما ما تبقى من الفصل الثاني فقد كان يهتم بالشبكات العصبية أنواعها ودوال التنشيط التي تستخدمها، ومن ثم توضيح المشاكل التي تعاني منها هذه الشبكات وكان التركيز على حل مشكلة التكيف الزائد وبعدها تم إعطاء مقدمة عن شبكة بيزين العصبية وتوضيح لتقريب كاوس وبيان المفهوم العام للمعرفة المسبقة وأنواعها.

وعند الوصول إلى الفصل الثالث ستجد تنفيذاً للطريقة المقترحة حيث تم توضيح عمل الخوارزمية الجينية المستخدمة في عملية عقدة الصور الملونة يتلوها توضيح لخوارزمية التحويل اللوني (HSV) لكي يتم الانتقال إلى استخلاص الصفات وتوضيح هذه العملية والتركيز على صفات التراكيب ومصفوفة الحدوث المتزامن لكي يكون الختام بتوضيح لعملية التدريب الخاصة بشبكة بيزين العصبية.

أما الفصل الرابع فيبين النتائج التي تم التوصل إليها والاستنتاجات لتلك النتائج زيادة على الأعمال المستقبلية.

## الفصل الثاني

# البيانات هامة

## ٢-١- معالجة الصور

يعد حقل معالجة الصور الرقمية (*digital image processing*) من الحقول المهمة التي لاقت نجاحاً واهتماماً كبيرين في العديد من التطبيقات وفي مجالات مختلفة منها الطبية والعسكرية والصناعية بالإضافة الى مجال الفضاء والاتصالات. يختص هذا الحقل بالتعامل مع صور ثنائية البعد من خلال الحاسبة [١٠].

وبصورة عامة هناك غرضان من تطبيقات معالجة الصور كافة، حيث يتمثل الغرض الأول بتحسين الصور (*image enhancement*) بطريقة ما لتسهيل تفسيرها من الناس فضلاً عن دعمها لخطوات المعالجة اللاحقة. اما الغرض الثاني فيختص بتحليل الصور (*image analysis*) لاستخلاص معلومات معينة منها بهدف فهمها وتفسيرها من قبل الحاسوب [١١][١٠].

## ٢-٢- تجزئة الصور (Image Segmentation)

تعد التجزئة الخطوة الاولى على طريق تفسير بيانات الصورة حيث تؤدي مهمة تجزئة الصورة الى عدد من المناطق المختلفة كل منها يمتلك نفس الخواص (مثلا المستوى الرمادي (*gray level*))، اللون (*color*) والنسيج (*texture*) [١٠].

وبصورة عامة يتم صياغة مسألة التجزئة رياضياً على النحو الآتي [١١].

إذا كانت  $R$  تمثل منطقة الصورة بكاملها، فإن عملية التجزئة تقسم هذه المنطقة إلى  $n$  من المناطق الجزئية  $R_1, R_2, \dots, R_n$  بحيث تحقق هذه المناطق الشروط الآتية:

$$R = \bigcup_{i=1}^n R_i \quad -1$$

$$R_i \text{ منطقة متصلة لكل } i=1, 2, \dots, n \quad -2$$

$$R_i \cap R_j = \emptyset \text{ لكل } i, j \text{ بحيث } i \neq j \quad -3$$

$$p(R_i) = \text{true} \text{ لكل } i=1, 2, \dots, n \quad -4$$

٥-  $p(R_i \cup R_j) = \text{false}$  لكل  $i \neq j$

يدل الشرط الاول على وجوب كمالية التجزئة، وهذا يعني ضم كل عنصر صورة الى منطقة ما في الصورة. في حين يتطلب الشرط الثاني ان تكون كل منطقة متصلة. اما الشرط الثالث فيدل على ضرورة ان تكون المناطق غير متداخلة (*disjoint*). يتعامل لشرط الرابع مع الخواص التي يجب توافرها في كل عنصر صورة داخل المنطقة الواحدة، مثلاً اذا كان  $p(R_i) = \text{true}$  فهذا يعني امتلاك كل عناصر الصورة التابعة للمنطقة  $R_i$  الشدة اللونية نفسها. واخيراً يحرص الشرط الخامس على ان تكون المناطق  $R_i$  و  $R_j$  مختلفة. وفي ما ياتي توضيح لأكثر الطرائق شيوعاً في عملية التجزئة:

## ٢-٢-١- التعتيب (Thresholding)

احدى طرائق تجزئة الصورة، عند احتواء الصورة على مساحات متباينة اللمعان، مثلاً المؤلفة من اجسام فاتحة (*light object*) وعلى خلفية عاتمة (*dark background*) وتكون عناصر الاجسام والخلفية ذات مستويات رمادية متباينة تتضح بشكل خطين (*two modes*) متباينين في المدرج التكراري للمستويات الرمادية. ان احدى الطرائق الواضحة في استخلاص الاجسام من الخلفية هي اختيار عتبة (*threshold*) تفصل بين هذين الخطين [١٢] ويعتمد اختيار العتبة على اساس المدرج التكراري للصورة أي اختيار قيمة المستوى الرمادي التي تفصل بين هاتين المنطقتين المتباينتين. تمثل القمم العالية (*maximum peaks*) مناطق متميزة في الصورة الرقمية وعملية التجزئة تعتمد على اختيار القيم الفاصلة بين القمم العالية وهذه القيم تتمثل بقيم العتبة [١٣]. الصورة التي تحتوي على عدة مناطق غير متجانسة ومتداخلة تكون قممها غير واضحة في المدرج التكراري، وهنا تكمن صعوبة تأسيس عتبات تفصل بين القمم بشكل فعال، يؤدي التداخل بين مناطق المدرج التكراري الى تكوين مدرج تكراري احادي النمط (*uni model*) عندها تتوقف عملية التعتيب [١٤] ان اغلب الصور الطبية هي صور ذات مدرج تكراري احادي النمط لذا تتوقف طريقة التعتيب في الصور الطبية

## ٢-٢-٢- كشف الحدود (Edge Detection)

تحتوي حواف الصورة على معلومات دقيقة ومفيدة في تحليل الصورة. ان وظيفة عوامل الحواف (*edges operators*) هي تخطيط مكونات الصورة بزيادة اللمعان (*brightness*) باتجاه معين اعتماداً على نوع متجه العامل المستخدم في تحديد حواف الصورة [١٥]. وبصورة

عامة تقوم هذه التقنية بعملها على مرحلتين، ففي الاولى تستخدم تقنيات كشف الحافة (*edge-detection*) لتحديد عناصر الصورة المنتمية الى حافة وتلك التي لا تنتمي الى حافة. في حين تتضمن المرحلة الثانية عملية دمج تلك الحواف وذلك لتشكيل الحدود المغلقة للكائنات [١٦][١٧][١١]. وتوجد العديد من تقنيات كشف الحواف منها:-

- عامل الميل (*gradient operator*): تعد هذه الطريقة من ابسط الطرائق والتي يتم فيها استخدام عامل الميل الذي يقيس معدل التغير في الشدة اللونية لعنصر صورة ما واتجاهه ايضاً [١٥].

### ٢-٢-٣- نمو المناطق (Region Growing)

تعتمد هذه التقنية في عملها على مبدأ من الاسفل الى الاعلى (*bottom-up*) [١٧]. وكما واضح من اسم هذه التقنية، تقوم بتجميع عناصر الصورة او مناطق جزئية فيها لتكوين مناطق اكبر [١٨][١١].

توجد العديد من الطرائق لاجراء عملية النمو ولمزيد من التفصيل يمكن الرجوع الى [١٩].

ولعل الطريقة الابسط لانجاز ذلك تتمثل باختيار عناصر صورة معينة تدعى البذور (*seeds*) ومن ثم توليد المناطق المجزئة باضافة العناصر المجاورة للبذور التي تتشابه معها في الخواص (المستوى الرمادي، اللون) الى المناطق التي تمثلها البذور [١١].

### ٢-٢-٤- شطر و دمج المناطق (Region Splitting And Merging)

وهي من الطرق الشائعة حالياً، حيث اثبتت نجاحاً في اغلب مسائل تجزئة الصور، تمتاز هذه الطريقة بكفاءتها الحاسوبية العالية مقارنة مع الطريقة السابقة، حيث تتعامل هذه الطريقة مع منطقة كاملة وليس عنصراً- عنصراً [٢٠].

تعتمد هذه الطريقة في عملها على مبدأ من الأعلى الى الأسفل (*top-down*) وعلى النقيض من الطريقة السابقة التي تبدأ بعنصر صورة واحد، تعد هذه الطريقة الصورة ككل منطقة واحدة [١٩]، ثم تقوم بتقسيم هذه المنطقة الى عدد من المناطق الجزئية بعد تطبيق اختبار التجانس (*homogeneity test*) في كل مرحلة من التقسيم، اذا لم يتم اجتياز هذا الاختبار تقسم تلك المناطق بدورها الى مناطق

جزئية اخرى وتستمر هذه العملية مكونة تمثيلاً يدعى الشجرة الرباعية (*quad tree*). بعد اكمال عملية تقسيم الصورة يتم دمج المنطق المجاورة التي تحقق معيار التجانس (*homogeneity measure*) [١٦].

## ٢-٢-٥- تقنيات العنقدة (Clustering Techniques)

تعد العنقدة واحدة من التقنيات البسيطة والمستعملة بصورة واسعة في مجال تجزئة الصور [٢١]، حيث يرجع استعمالها الى الستينيات. تقوم هذه التقنية بتجميع عناصر الصورة الى مناطق معينة.

وعلى أي حال، وقبل الدخول في كيفية استخدام هذه التقنية في عملية التجزئة، يتم تسليط الضوء على بعض المفاهيم الخاصة بالعنقدة.

في البداية تعرف العنقدة على انها طريقة تصنيف غير موجهه (*unsupervised classification*) هدفها تقسيم مجموعة من الانماط التي تدعى متجهات الصفات (*feature vectors*) الى عدد محدد من المجاميع الجزئية تدعى عنقايد (*clusters*). وعليه اذا كانت لدينا المجموعة  $Q = \{x^{(i)}, i=1, 2, \dots, M\}$  بحيث ان  $x^{(i)} = x_1^{(i)}, x_2^{(i)}, \dots, x_k^{(i)}$  فان العنقدة تقوم بتقسيم هذه المجموعة الى  $M$  من المجاميع الجزئية  $\pi = \{C_1, C_2, \dots, C_M\}$  والتي تمتلك الخواص الاتية [٢٢][٢٣]:

$$أ- \emptyset \neq C_i \text{ لكل } i=1, 2, \dots, M$$

$$ب- \emptyset = C_i \cap C_j \text{ لكل } i \neq j$$

$$ج- Q = \bigcup_{i=1}^M C_i$$

بصورة عامة تتضمن مهمة العنقدة العناصر الاتية [٢٤]:

١- تمثيل الانماط (*Pattern Representation*):- يشير تمثل الانماط الى تحديد عدد العناقيد، عدد المتجهات المتوافرة اضافة الى عدد الصفات في متجه الصفات.

٢- **انتقاء الصفات (Feature Selection)**:- يدل هذا العنصر على تعريف مجموعة جزئية من الصفات لاستعمالها في عملية العنقدة. فبالنسبة للصور يمكن ان تاخذ هذه الصفات قيماً مثل المستوى الرمادي، قيمة الميل (*gradient magnitude*)، زاوية الميل (*gradient phase*) اضافة الى اللون (*color*) و/ او صفات اخرى [٢٥].

٣- **الاستخلاص البياني (Data Abstraction)**:- يقصد بالاستخلاص هنا عملية ايجاد تمثيل بسيط للمجاميع العنقودية، حيث يوجد عدد من التمثيلات ولعل اكثرها شيوعاً تلك التي تقوم بتمثيل العنقود من خلال مركزه فمثلاً اذا كان لدينا العنقود  $C_i$  الذي يتكون من  $S_i$  من المتجهات، فيمكن بعد ذلك حساب مركز ذلك العنقود على النحو الاتي [٢٣]:

$$Z^{(i)} = \frac{\sum_{X \in C_i} X}{S_i} \quad (1.1)$$

٤- **مقاييس التنسيب (Assignment Measure)**:- الذي يدل على كيفية ضم متجهات الصفات المختارة الى احد العناقيد المتوافرة. يوجد نوعان من المقاييس هما [١٦]:

أ- **مقاييس التباعد (Distance Measures)**:- ان الشكل الأبسط والأكثر شيوعاً لهذا النوع من المقاييس هو مسافة اقليدس (*Euclidean distance*) التي تعكس مقدار الاختلاف بين متجهين، فمثلاً اذا كان  $x^{(g)}, x^{(i)}$  متجهين في فضاء متكون من  $k$  من الابعاد فان مسافة اقليدس بينهما تحسب على النحو الاتي:-

$$d(x^{(i)}, x^{(g)}) = \sqrt{\sum_{k=1}^K (x_k^{(i)} - x_k^{(g)})^2} \quad (2.1)$$

تعطي القيمة الكبيرة لهذه المسافة مؤشراً على وجود اختلاف كبير بين المتجهين اما القيمة الصغيرة فتدل على وجود تشابه كبير بينهما.

ب- **مقاييس التشابه (Similarity Measures)**:- ان الهيئات الشائعة من هذا النوع هي الضرب الداخلي للمتجه (*vector inner product*). حيث يتم تنسيب متجه الصفات الى العنقود الذي يمتلك مع مركزه قيمة اكبر نسبة الى عملية الضرب المتجه على النحو الاتي:-

$$\sum_{k=1}^K X_k^{(i)} \cdot X_k^{(j)} = (X_1^{(i)} \cdot X_1^{(j)} + X_2^{(i)} \cdot X_2^{(j)} + \dots + X_k^{(i)} \cdot X_k^{(j)}) \quad (3.1)$$

بعد توضيح هذه المفاهيم يمكن توضيح مسألة التجزئة كمسألة عنقدة، حيث يتم تحويل الصورة من المجال المكاني (*spatial domain*) الى فضاء الصفات (*feature space*) وبذلك يصبح كل عنصر في الصورة ممثلاً من خلال متجه صفات معينة في ذلك الفضاء. وعليه تصبح مسألة التجزئة عبارة عن مسألة ايجاد العناقيد في هذا الفضاء، حيث يمثل كل عنقود كياناً ما في الصورة. وبعد ايجاد تلك العناقيد يتم انجاز التجزئة من خلال مقابلة (*mapping*) تلك العناقيد رجوعاً الى المجال المكاني للصورة [19][10].

بصورة عامة يعتمد نجاح استخدام العنقدة في تجزئة الصور بصورة كبيرة على انتقاء الصفات المناسبة، حيث ان العناقيد المكتشفة في فضاء ما قد يكون من السهل اكتشافها في فضاء اخر [25].  
توجد العديد من تقنيات المستخدمة لحل مسألة العنقدة وفيما ياتي اكثر الطرائق شيوعاً فيها:

## ٢-٥-٢-١ تقنية الاوساط المتعددة (K-means)

وهي واحدة من التقنيات البسيطة والشائعة التي تم اقتراحها من قبل العالم McQueen في العام ١٩٦٧ حيث تستخدم هذه التقنية مربعات الخطأ (*squared errors*) معياراً لتوجيه تقاربها [24]. يرجع شيوع هذه الطريقة الى سهولة تنفيذها والى تعقيدها البسيطة من حيث الوقت.

تهدف هذه التقنية الى تصغير (*minimizing*) مجموع المسافات المربعة بين المتجهات التابعة لعنقود ومركزه. ويمكن تلخيص خطوات عمل هذه التقنية على النحو الاتي [26][27]:-

١- اختيار  $M$  من مراكز العناقيد العشوائية  $Z^{(1)}(1), Z^{(2)}(1), \dots, Z^{(M)}(1)$ .

٢- تنسيب متجهات الصفات في الخطوة  $k$  الى  $M$  من العناقيد باستعمال العناقيد

على النحو الاتي:-

$$x \in C_j(k) \text{ if } \|x - z_j(k)\| < \|x - z_i(k)\| \quad (4.1)$$

لكل  $i=1,2,\dots,M$  ,  $i \neq j$  ,  $C_j(t)$  : عنقود مركزه  $Z^{(i)}(t)$

٣- حساب مراكز عناقيد جديدة  $Z^{(i)}(t+1)$  لكل  $j=1,2,\dots,M$  بحيث تصغر المسافات المربعة لكل المتجهات في العنقود  $C_j(t)$  بالنسبة لمركز العنقود الجديد، وببساطة فان متوسط المتجهات التابعة للعنقود  $C_j(t)$  هو المقياس الذي يقوم بالتصغير وعليه يمكن حساب العنقود الجديد كالتالي:-

$$Z^{(j)}(t+1) = \frac{1}{S_j} \sum_{x \in C_j(t)} x, \quad j = 1, 2, \dots, M \quad (5.1)$$

$S_j$  : - عدد المتجهات التابعة للعنقود  $C_j(t)$

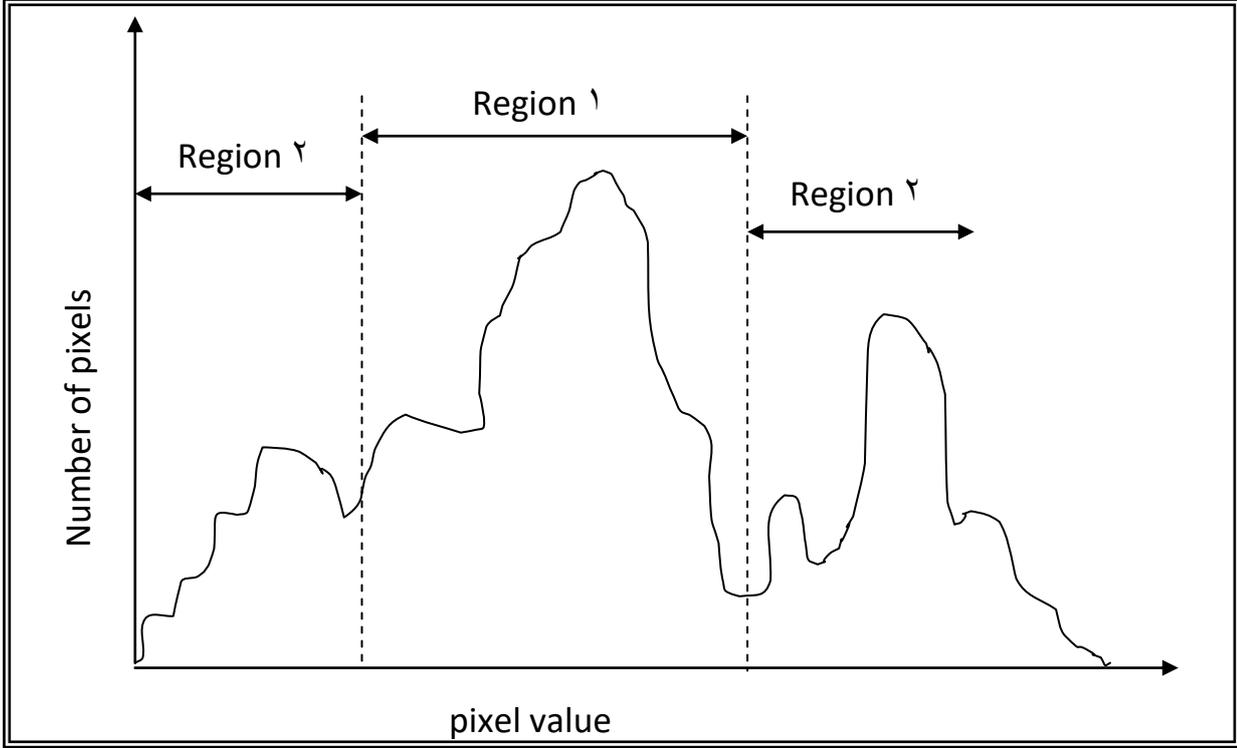
٤- اذا كان  $Z^{(i)}(t+1) = Z^{(i)}(t)$

لكل  $j=1,2,\dots,M$  ، فهذا يعني تقارب الخوارزمية، حيث يتم التوقف وبخلافه يتم الذهاب الى الخطوة (٢).

ومن المشاكل التي تواجه هذه التقنية هي حساسيتها لاختيار مراكز العناقيد الابتدائية حيث يعتمد نوع الحل الذي نحصل عليه على مراكز العناقيد الابتدائية المختارة ونتيجة لذلك تعاني هذه التقنية من مشكلة النهاية الصغرى المحلية (*local minima*).

## ٢-٢-٥-٢-٢ تقنية شطر المناطق التداخلي (Recursive Region Splitting)

اصبحت هذه التقنية طريقة قياسية لانجاز مهمة العنقدة، حيث تستعمل هذه التقنية طريقة عتبية المدرج التكراري لتجزئة الصور وكما موضح في الشكل (٢-١)



شكل (١-٢) لايجاد قمة المدرج التكراري

وفيما يلي تلخيص لخطوات هذه التقنية [١٦]

١- اعتبار الصورة منطقة واحدة ومن ثم حساب المدرج التكراري لكل عنصر من عناصر متجه الوصفات.

٢- تطبيق اختيار إيجاد القمة (*peak*) لكل مدرج تكراري وبعد ذلك اختيار القمة الأفضل واعتبار القيم الواقعة على جانبي القمة قيماً للعتبات ومن ثم تجزأ الصورة إلى منطقتين بالاعتماد على هذه القمة.

٣- تنعيم (*smoothing*) الصورة الثانية الناتجة من العتبة.

٤- يتم تكرار الخطوات من ١-٣ لكل منطقة حتى لا يكون بالامكان توليد مناطق جزئية جديدة وهذا يعني عدم احتواء المدرج التكراري على قمم بارزة.

تعاني هذه الطريقة من مشكلة تحديد اختيار إيجاد القمة المناسبة بالإضافة الى تحديد قيم العتبات.

بصورة عامة تعاني طرائق التجزئة المعتمدة على استخدام تقنيات العنقدة من مشاكل تحديد عدد عناقيد الصورة المرغوبة اضافة الى ان الصفات المستخدمة في متجه الصفات تعتمد على الصورة ولا توجد طريقة عامة لتعريف الصفات المرغوبة للحصول على نتائج تجزئة جيدة [١٥].

## ٢-٢-٦- تقييم اداء تقنيات التجزئة

يعتمد اداء تقنيات التجزئة على مدى واسع من العوامل المتضمنة نوعية الصورة التي يتم معالجتها، حاجات التطبيق الذي يستعمل المناطق والحواف الناتجة، اضافة الى ذلك قد تكون السرعة عاملاً مهماً في تطبيقات الوقت الحقيقي (*real-time application*) لهذا السبب من المهم تقييم اداء عدة تقنيات لايجاد التقنية المثلى لتطبيق ما [١٧]

تتميز تجارب تقييم الاداء المثلى لتطبيق على النحو الاتي [١٧] :

١- مقارنة التقنية الحالية مع عدد من تقنيات التجزئة الشائعة.

٢- تقييم كل تقنية باستعمال العديد من الصور ومن مختلف التطبيقات ودرجات تعقيد مختلفة ايضاً (مع التاكيد على المجال الحالي).

٣- استعمال مقاييس تقييم عديدة لاجل المقارنة.

يعد الفحص المرئي من البشر الطريقة الايسر لتقييم الاداء. اضافة الى ذلك يمكن مكنة عملية تقييم تقنية ما اذا كان هناك منطق كيانات و/ او حدود كيانات معروفة، حيث ان احدي الطرائق للحصول على مثل هذه المعلومات هي توليد صور اصطناعية (*synthetic image*) حيث تكون كيانات الصورة معروفة مسبقاً [١٧].

يوجد بالاضافة الى المقياس السابق عدد من المقاييس الاحصائية التي يمكن تقسيمها الى صنفين هما المخالفة التجريبية (*empirical discrepancy*) والجودة التجريبية (*empirical goodness*) [٢٨].

### ❖ المخالفة التجريبية

تعتمد مقاييس هذا الصنف على استخدام صورة مرجعية مجزأة يدوياً ومن ثم مقارنة الصورة الناتجة من تطبيق تقنية التجزئة مع هذه الصورة المرجعية. تتم هذه العملية من خلال مقارنة تجزيئين للصورة، حيث ان احد هذين التجزيئين منتج من قبل المستعمل ويمثل الى

كيانات الصورة المراد اختيارها. بعد ذلك يتم استعمال مقياس التباعد (*distance measure*) ثنائي البعد لقياس الاختلاف بين الاثنتين، وبذلك يوفر تخميناً لخطأ التجزئة المنتج من قبل تقنية التجزئة نسبة الى التجزئة المجهزة من قبل المستعمل [٢٩].

توجد ايضاً طريقة اخرى ضمن هذا الصنف تقوم بحساب عدد عناصر الصورة المصنفة بصورة صحيحة C وعدد عناصر الصورة المصنفة بصورة خاطئة E ومن ثم احتساب النسبة  $(C-E)/(C+E)$  كمقياس للداء [١٧].

### ❖ الجودة التجريبية

تعتمد عملية التقييم ضمن هذا الصنف على مقياس بديهي للجودة، مثلاً انتظام الشدة اللونية ضمن المناطق المجزأة او التضاد اللوني للشدة اللونية بين مناطق الصورة المختلفة، حيث يوجد مقياسان للداء هما [٢٨]:

#### أ- انتظام المناطق (*Region Uniformity*) [٢٩]

يتناسب انتظام خاصية ما في منطقة عكسياً مع تباين قيم تلك الخاصية المحسوبة لعناصر الصورة التابعة لتلك المنطقة، حيث تعني القيمة صفر للتباين ان كل العناصر التابعة لتلك المنطقة تمتلك بالضبط نفس قيم الخاصية، بينما تؤشر القيم الكبيرة للتباين التشتت بعيداً عن متوسط الخاصية عبر المنطقة، لنفترض ان قيمة الخاصية في كل عنصر صورة  $(x,y)$  للمنطقة  $R_j$  يكون  $f(x,y)$ ، فعليه يتم حساب متوسط تلك القيم كما موضح في العلاقة (٧.١)

$$U = \overline{f_j} - \left( \sum_{R_j \in \alpha} \frac{w_j \sigma_j^2}{B} \right) \quad (6.1)$$

: تباين المنطقة  $j$ .

: وزن يتناسب قيمته مع مساحة المنطقة  $w_j$ .

يمثل B في العلاقة اعلاه عامل تقييس مصمم لجعل القيمة العظمى للمقياس مساوية الى واحد.

$$B = \left( \sum_{R_j \in \alpha} w_j \right) \frac{(f_{\max} - f_{\min})^2}{2} \quad (7.1)$$

القيمة العظمى للخاصية المختارة في الصورة.

القيمة الصغرى للخاصية المختارة في الصورة.

## ب- التضاد اللوني للمناطق (Region Contrast) [٢٩]

ياخذ المقياس السابق بنظر الاعتبار الانتظامية داخل كل منطقة بغض النظر عن المناطق المتصلة والمحيطة بها، اما المقياس الحالي فيقوم بحساب التضاد اللوني بين المناطق المتصلة وبافتراض

$$C_{ij} = \frac{\left| \frac{f_i}{f_j} - \frac{f_j}{f_i} \right|}{f_i + f_j} \quad (8.1)$$

تمتلك هذه العلاقة القيمة (صفر) كقيمة دنيا والقيمة (واحد) كقيمة عظمى.

يكون مقياس التضاد اللوني لمنطقة ما مساوياً الى المجموع الموزون للتضاد اللوني لتلك المنطقة مع كل جيرانها المتصلين بها تساهم كل منطقة مجاورة  $R_i$  بهذا المجموع من خلال قيمة تتناسب الى الاتصال بينها وبين المنطقة  $R_j$  التي يتم حساب المقياس لها. لنفترض ان هذه القيمة تكون  $P_{ij}$  كما معرفة في [٣٠]، يصبح مقياس التضاد اللوني للمنطقة  $R_j$  كالآتي:

$$C_j = \sum_{R_j \text{ Adj } R_i}^{n-1} P_{ij} C_{ij} \quad (9.1)$$

يلاحظ ان مجموع قيم الاتصال  $p_{ij}$  لجميع المنطق  $R_i$  متصلة مع المنطقة  $R_j$  يساوي واحداً. ومن اجل الحصول على مقياس تضاد لوني واحد للصور ككل نحتاج الى حساب المجموع الموزون للاسهامات كل منطقة في الصورة. بصورة عامة يعرف مقياس التضاد اللوني للصورة  $a$  على النحو الآتي:

$$C_a = \sum_{R_j \in \alpha} \frac{v_j C_j}{\sum_{R_j \in \alpha} v_j} \quad (10.1)$$

حيث يمثل  $V_j$  الوزن المخصص للمنطقة  $R_j$  والذي يتناسب ايضا مع مساحة المنطقه ولكن ليس بصورة خطية وانما كداله بهيئة كاوس والموضحة في العلاقه التاليه:

$$v_j = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(A_j - \mu)^2}{\sigma^2}\right) \quad (11.1)$$

حيث يمثل كل من  $\mu$  و  $\sigma$  المتوسط الحسابي والانحراف المعياري على الترتيب.

يوجد بالاضافة الى المقاييس المذكورة مقياس يعتمد بصورة كبيرة على التطبيق الذي صممت لاجله خوارزمية التجزئة فمثلاً في تطبيقات تمييز الكيانات (object recognition)، من الاعتيادي استعمال تقنية تجزئة (التي يمكن ان تكون معتمدة على الحواف او معتمدة على المنطقة) لتجزئة الصورة الى عدد من الاجزاء التي يتم استعمالها بعد ذلك لاغراض التمييز.

في هذه الحالة بدلاً من ان يكون الكائن البشري او المقاييس المذكورة سابقاً هي الافضل لتقييم نتائج التجزئة، يصبح التطبيق هو الحكم الافضل للتقييم والتقنية التي تعمل جيداً لتطبيق ما تصبح هي الافضل لذلك التطبيق بغض النظر عما يتصوره الخبير البشري حول نوعية نتائج التجزئة [28].

## ٢-٣- الخوارزميات الجينية (Genetic Algorithm)

تعاني اغلب طرائق البحث التقليدية لحل مسائل الامثلية (*optimization problems*) من عدد من المشاكل والصعوبات وخاصة عند استعمالها لحل المسائل المعقدة، ومن هذه المشاكل مثلاً ميول اغلب الخوارزميات الى امثلية محلية (*local optima*)، عدم كفاءة الطرائق التقليدية عند التعامل مع المسائل ذات المتغيرات المتقطعة (*discrete variables*)، واعتماد التقارب الى الحل المثالي على الحل الابتدائي [31].

ونتيجة للاسباب السابقة فقد استخدم الباحثون الخوارزميات الجينية كطريقة حل لمسائل الامثلية، حيث تبدء هذه الخوارزمية بمجتمع عشوائي ابتدائي يمثل الحل وتقوم بمجموعة من الخطوات لحين وصول الخوارزمية الى افضل حل ممكن في فراغ المشكلة.

## ٢-٤- عناصر الخوارزمية الجينية (Elements Of Genetic Algorithm)

تتألف الخوارزمية الجينية من عدد من العناصر وفيما يأتي توضيح لها:-

## ٢-٤-١- المجتمع (Population)

يتكون المجتمع من  $N_{pop}$  من الافراد، حيث تحدد قيمة  $N_{pop}$  تجريبياً من مصمم الخوارزمية (عادةً من ٢٥ الى ٥٠) فرداً. لكل فرد كروموسوم (*chromosome*) يتكون من  $L$  من الجينات، حيث يمثل هذا الكروموسوم المستوى الجيني (*genotype*) للفرد الممثل للمستوى التركيبي (*phenotype*) تسمى قيمة الجينة (*allele*). ويصنف التدوين الاتي هيئة كروموسوم [٣٢]:-

$$\text{Chromosom}_i = \text{Gene}_1, \text{Gene}_2, \dots, \text{Gene}_L, \quad 1 \leq i \leq N_{pop}$$

و عند استعمال التشفير الثنائي على سبيل المثال فان :

$$\text{gene}_{1 \leq j \leq L} \in \{0, 1\}$$

بعد ان يتم تحديد حجم المجتمع و طول الكروموسوم ،يتم توليد قيم عشوائية (بالاعتماد على نوع التشفير المستخدم ) لتمثل القيم الابتدائية لجينات كل الافراد ،حيث يمثل هؤلاء نقاط البداية في فراغ البحث للخوارزمية الجينية [٣١]. وبعد توليد هؤلاء الافراد تحسب صلاحياتهم وكما موضح في الفقرة الاتية.

## ٢-٤-٢- التقييم (Evaluation)

في الخوارزمية الجينية يتم تخصيص قيمة صلاحية (*fitness value*) لكل فرد سواء كان مولداً في المجتمع الابتدائي او خلال الاجيال اللاحقة، وترتبط هذه القيمة بقيمة دالة الهدف (*objective function*) [٣٢][٣٣][٣١]. فمثلاً تكون قيمة الصلاحية لمسائل التعظيم (*maximization problem*) مساوية لقيمة دالة الهدف. اما لمسائل التصغير

(*minimization*) فان الهدف هو ايجاد الحل ذي القيمة الدنيا لدالة الهدف، وبذلك تحصل الحلول ذات القيم الاصغر لدوال الهدف على قيمة اكبر للصلاحية، وعادةً يتم استخدام التحويل الاتي لدالة الهدف بالنسبة لهذا النوع من المسائل [٣٢]:

f(...): دالة الهدف

D : عدد متغيرات القرار في دالة الهدف

## ٢-٤-٣- التشفير (Encoding)

يقصد بالتشفير عملية ايجاد تمثيل مناسب للحل، حيث يعد التشفير عامل نجاح اساسياً للخوارزمية الجينية [٣٤] ويعتمد بصورة كبيرة على المسألة المراد حلها.

توجد العديد من انواع التشفير منه التشفير الثنائي (*Binary Encoding*) والتشفير الصحيح (*Integer Encoding*) والتشفير الحقيقي (*Real Encoding*) وفيما ياتي توضيح للتشفير المستخدم في النظام:-

### - التشفير الصحيح (Integer Encoding)

يتكون الكروموسوم هنا من خيط اعداد صحيحة. بالنظر الى عدم احتياج هذا النوع من التشفير الى عملية تفسير فان التشفير الصحيح يسرع من عملية محاكاة الخوارزمية الجينية [٣١].

## ٢-٤-٤- الانتقاء (Selection)

يقصد بالانتقاء عملية اختيار الالباء من المجتمع لاجل التزاوج وانتاج اطفال جدد، بعد اختيارنا لطريقة التشفير المناسبة يصبح القرار الاتي الواجب اتخاذه هو كيفية اجراء الانتقاء [٣٤]. وبصورة عامة وطبقاً لنظرية دارون التي تنص على مبدأ البقاء للأصلح (*survival of fittest*) يحصل الافراد ذوو الصلاحية العالية على فرصة اكبر للعيش والتزاوج من الافراد ذوي الصلاحية الواطئة [٣٣]، وعلى أي حال، تتمايز جميع طرائق الانتقاء من خلال عامل يدعى ثقل الانتقاء (*selection pressure*) الذي يمثل عدد النسخ التي يحصل

عليها الفرد الافضل في اثناء اجراء عملية الانتقاء، وعليه فان طرائق الانتقاء ذات ثقل الانتقاء الكبير يحصل فيها الفرد الافضل على عدد اكبر من النسخ وبالتالي يؤدي مشاكل التقارب المبكر (*premature convergence*) والانتهاء البطيء (*slow finishing*) (التي سيرد توضيحها لاحقاً) لذلك يجب الحفاظ على هذا العامل متوازناً نسبياً [٣٢].

توجد العديد من طرائق الانتقاء المستخدمة والانواع الشائعة منه هي على النحو الاتي:

- انتقاء عجلة الروليت (Roulette Wheel Selection (RWS)

- انتقاء النخبة (Elitism Selection)

- انتقاء الرتب (Rank Selection)

- انتقاء العينات الشاملة التصادفية (Stochastic Universal Sampling (SUS)

- انتقاء المجموعات (Tournament Selection)

تم استخدام انتقاء المجموعات الثنائية و فيما ياتي شرح لهذه الطريقة

### -انتقاء المجموعات ( Tournament Selection )

يوجد العديد من الانواع الخاصة بهذا الانتقاء واشهرها هو انتقاء المجموعات الثنائية، تكون عملية الانتقاء في هذا النوع باختيار فردين بطريقة عشوائية من المجتمع، والفرد الافضل منهما يتم اختياره من الاثنين. اذا تم تنفيذ طريقة المجموعات الثنائية بدون احلال فان الفردين اللذين تم اختيارهما يوضعان جانباً ولا يدخلان في عملية الانتقاء التالية ولا يتم احلالهما في المجتمع، بسبب اخراج الفردين من المجتمع في كل عملية انتقاء والافراد المتبقون في المجتمع يدخلون في عملية الانتقاء الاتية، فان المجتمع الجديد يصبح نصف ممتلئ، لذلك فان الفرد الافضل سوف يتم اختياره مرتين والفرد الاسوء سوف لا يتم اختياره ابداً. في انتقاء المجموعات الثنائية مع الاحلال يتم احلال الفردين المنتقين حالاً في المجتمع لغرض اجراء عملية الانتقاء التالية [٣٣].

اما فيما يخص مفهوم التقارب المبكر والانتهاء البطيء فالشرح الاتي يوضح هذين المفهومين

- **التقارب المبكر (Premature Convergence):** - في بداية محاكاة الخوارزمية الجينية، قد يوجد فرد له صلاحية تفوق كثيراً صلاحيات الآخرين. يسود هذا الفرد المتفوق كل المجتمع (تقارباً مبكراً) حيث يتم انتقاؤه غالباً [٣٥].

- **الانتهاء البطئ (Slow Finishing):** - في نهاية محاكاة الخوارزمية الجينية، ربما يوجد الكثير من الافراد الذين لديهم نفس الصلاحية تقريباً مما يجعل التمييز بين مختلف الحلول للانتقاء افضلها عملية صعبة [٣٥] [٣١].

## ٢-٤-٥- التزاوج (Crossover)

يعد التزاوج الخاصية التي ميزت الخوارزمية الجينية عن بقية خوارزميات التطور (استراتيجية التطور و البرمجة التطورية) [٣١]. وهو عملية مبادلة جينات الابوين لانتاج طفلين يحملان جينات من كلا الابوين.

بصورة عامة، يوجد غرضان لطرق التزاوج كافة احدهما يمثل البحث في فضاء المعاملات (*parameters space*) اما الاخر فيتعلق بحاجة البحث على طريقة للحفاظ على المعلومات المخزونة في كروموسومات الأبوين بأقصى ما يمكن وذلك لاعتبار هذه الكروموسومات امثلة للكروموسومات الجيدة المختارة بعملية الانتقاء [٣٢].

تعتمد طرائق التزاوج المستخدمة على نوع التشفير المستخدم والمسألة المراد حلها وطرائق التزاوج المعروفة هي:

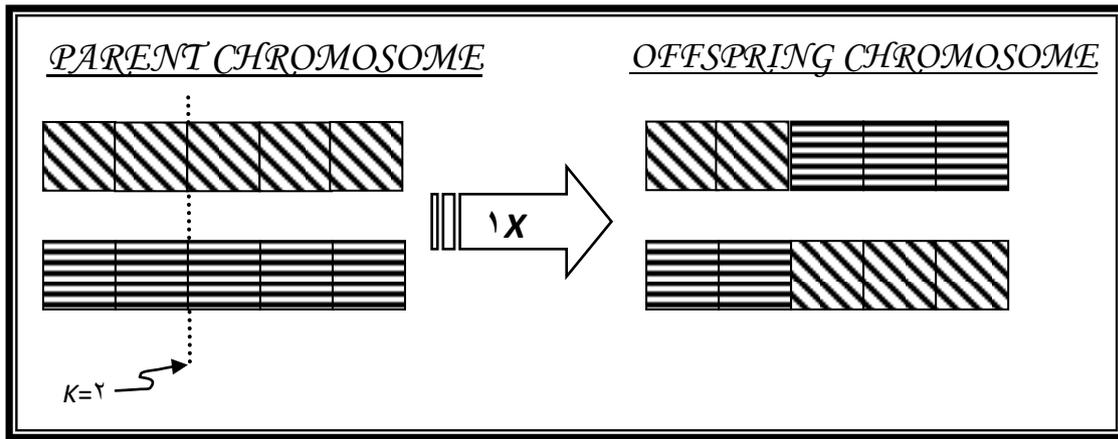
- التزاوج ذو نقطة القطع الواحدة ( $1x$ ) Single Point Crossover

- التزاوج ذو نقطتي القطع ( $2x$ ) Two Point Crossover

- التزاوج المنتظم (Uniform Crossover  $Ux$ )

**التزاوج ذو نقطة القطع الواحدة ( $1x$ ) Single Point Crossover**

تمثل الطريقة الايسر للتزاوج وقد تم استعمالها في SGA، حيث تتم باحتمالية معينة  $pc$  حيث ( $0.6 < pc < 0.9$ ) وذلك باختيار موضع عشوائي  $k$  حيث ( $k \in \{1, 2, \dots, n-1\}$ ) و انتاج كروموسومين جديدين بتوحيد جينات من الابوين كما في الشكل الاتي [٣١] [٣٣].

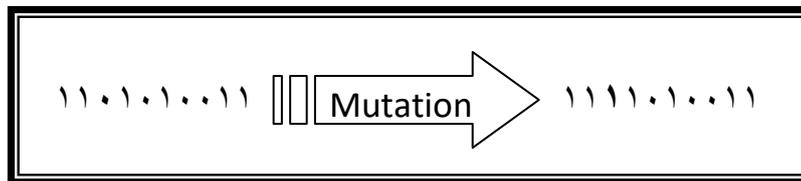


شكل (٢-٢) التزاوج ١x

## ٢-٤-٦- الطفرة (Mutation)

هي التغيير العشوائي لجينة او اكثر في الكروموسوم، وتتمثل الحاجة الى هذا العامل لزيادة التنوعية في المجتمع من خلال توليد فرد جديد لا يماثل أياً من الافراد الموجودين وبذلك يوفر بحثاً اكتشافياً (*exploration*) للخوارزمية الجينية فهي تكتشف جزءاً مجهولاً في فراغ البحث [٣١][٣٢]. اضافة الى امكانيته في التخلص من مشكلة النهاية الصغرى المحلية (*local minima*).

ينجز هذا العامل وباحتمالية معينة من خلال مسح الكروموسوم جينة- جينة وملاحظة مدى حصول التغيير وفقاً للاحتمالية المحددة. وتوجد عدة طرائق لاجراء هذا العامل اعتماداً على التشفير المستخدم والمسألة المراد حلها فمثلاً يقوم هذا العامل في حالة استخدام التشفير الثنائي بقلب قيمة الجينة (٠ الى ١ ، ١ الى ٠) [٣٣][٣٤][٣١] وكما موضح في الشكل (٣-١)



شكل (٣-١) الطفرة

بعد الانتهاء من اجراء عمليات التزاوج والطفرة والتقييم على مجموعة الأفراد المنتقاة يصبح القرار التالي الذي يجب اتخاذه هو كيفية إدخال الفرد الجديد الى المجتمع من خلال استخدام عامل الاحلال.

## ٢-٤-٧- الإحلال (Replacement)

يخرج الإحلال أفراداً قدامى لهم صلاحية واطئة ليحل محلهم أفراد جدد بصلاحية أفضل وفيما يأتي نوعان من طرائق الإحلال [٣١]:

-إحلال المجموعات الثنائية (Binary Tournament Replacement)

- إحلال المجموعات الثلاثية (Triple Tournament Replacement)

### - إحلال المجموعات الثنائية ( Binary Tournament Replacement )

تمثل طريقة الإحلال هذه طريقة انتقاء المجموعات الثنائية الموضحة في سابقاً حيث يتم إحلال الطفل الجديد المقيم الناتج من التزاوج والطفرة محل أسوأ فردين يتم انتقاؤهم عشوائياً من المجتمع الصيغة الرياضية الآتية توضح هذا النوع من الإحلال [٣١].

$$Replace_n = \begin{cases} Ind_i & \text{if } F(ind_i) < F(ind_j) \end{cases} \quad (١٣.١)$$

For  $n=\{1, 2\}$ , random number  $i, j \in \{1, 2, \dots, Npop\}$ ,  $i \neq j$

$Replace_n$ : الفرد  $n$  المراد إحلاله.

$F(ind_i)$ : صلاحية الفرد  $i$ .

$F(ind_j)$ : صلاحية الفرد  $j$ .

يحافظ هذا النوع من طرائق الاحلال على الفرد الافضل دائماً وبحجم نخبة يساوي واحداً على الاقل.

## ٢-٤-٨- مقاييس التوقف (Stopping Criterion)

وهي المؤشرات او المقاييس الاحصائية التي تحدد مدى التقارب الحاصل في الخوارزمية الجينية، يوجد العديد من هذه المقاييس منها:

❖ الانجازية المتصلة (*on-line performance*): تمثل الانجازية المتصلة مقياساً للاداء المتوسط للخوارزمية الجينية بالاعتماد على دالة الصلاحية والصيغة الرياضية الآتية توضح ذلك [٣١]:

$$on - line(T) = \frac{1}{T} \sum_{t=1}^T F(t) \quad (14.1)$$

T: العدد الكلي لمرات إيجاد قيم دالة الصلاحية

F(t): التقييم التائي للصلاحيات

في أثناء تطور الخوارزمية الجينية تتقارب قيمة (*on-line* (T) باتجاه قيمة ثابتة، وعند استمرارها بالثبوت لعدد كاف من الدورات المحددة مسبقاً يتم إيقاف المحاكاة للخوارزمية الجينية. بالإضافة إلى الانجازية المتصلة، قد يكون مقياس التوقف واحداً أو أكثر من المقاييس الآتية:

- ❖ أكمل الخوارزمية لعدد أفرادها المحددين في بدء العمل [٣٣].
- ❖ اذا وصلت الخوارزمية إلى أحسن صلاحية وكان الفرق بين الصلاحيات لعدد من الدورات فرقاً قليلاً [٣٤].
- ❖ تماثل جميع افراد المجتمع في الصلاحيات.
- ❖ قد يحصل التوقف حال حصول فرد واحد او اكثر على قيمة صلاحية تفوق قيمة عتبة معينة.
- ❖ اقتراب متوسط الصلاحيات من أحسن صلاحية. [٣٦].

## ٢-٥- صيغ الخوارزميات الجينية (Forms Of Genetic Algorithms):

توجد صيغتان رئيستان للخوارزميات الجينية هما الخوارزمية الجينية البسيطة والخوارزمية الجينية لحالة الاستقرار.

### - الخوارزمية الجينية لحالة الاستقرار

#### Steady State Genetic Algorithm (ssGA)

هي أسلوب اخر للخوارزمية الجينية حيث يتغير المجتمع تدريجياً بتوليد الأفراد الجدد واحداً تلو الآخر، ثم يتم إحلال عدد قليل من الأفراد كل جيل (مجتمعات متداخلة) [٣٤][٣١][٣٧].

#### ssGA algorithm:

*Initialization (population);*

*Evaluation (population);*

*Gen ← ٠;*

*Do*

*Selection (population, selected-parents);*

*Crossover (selected-parents, created-offspring, crossover prob.);*

*Mutation (created-offspring, mutation prob.);*

*Population ← created-offspring;*

*Evaluation (population);*

*Replacement (population, created-offspring);*

*Gen ← Gen+ ١;*

*While (not stop\_ criteria);*

## End ssGA

في هذه الخوارزمية يتم إحلال عدد قليل من الأفراد (عادة واحد او اثنان) محل أفراد غير مرغوب فيهم في المجتمع وهذا ما يقصد بتداخل الاجيال في هذه الصيغة من صيغ الخورزميات الجينية.

### ٢-٦- الفضاء اللوني (Color Space) [٣٨]

ان الغاية من وراء استخدام الفضاء اللوني او ما يسمى بالنموذج اللوني (*color model*) او النظام اللوني (*color system*) هي لتسهيل وصف الالوان في بعض المقاييس، ان حقيقة الفضاء اللوني هو وصف النظام الاحداثي (*coordinate system*) للون وهو فضاء فرعي داخل الفضاء اللوني.

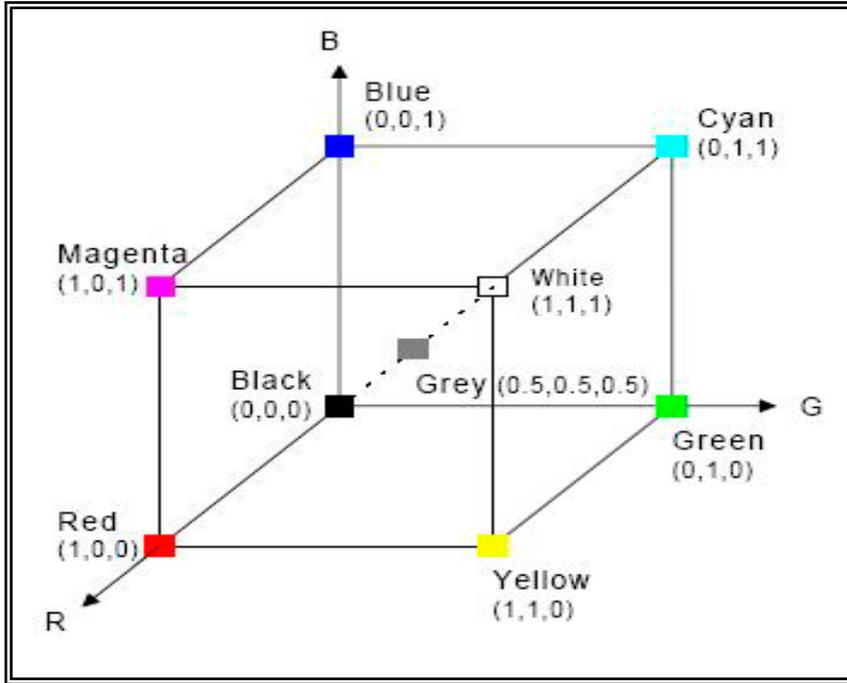
يمكن تعريف الفضاء اللوني انه تمثيل رياضي لمجموعة الألوان، من اشهر الفضاءات اللونية هي الفضاء اللوني (RGB) المستخدم في الرسومات الحاسوبية وأغراض العرض على الشاشات الملونة والفضاء (YUV) و (YCbCr) التي تستخدم في الأنظمة الفديوية والفضاء (CMY) المستخدم للاغراض الطباعية، وهناك فضاء لوني خاص بالضغط هو (YIQ)، اما الفضاء اللوني الخاص باغراض التمييز والتصنيف فهو الفضاء (HSV) هناك فضاءات لونية مشابه لهذا الفضاء هي (HIS) و (HSL).

### ٢-٦-١- الفضاء اللوني RGB (RGB Color Space) [٣٩]

اسم الفضاء مختصر لـ (*Red, Green, Blue*) يمثل هذا الفضاء الألوان الاحمر، الاخضر، والازرق يستخدم في الشاشات الملونة (CRT)، يمثل هذا الفضاء بمكعب الوحدة حيث الألوان الاحمر والاخضر والازرق هي الزوايا ( $255, 0, 0$ ) و ( $0, 255, 0$ ) و ( $0, 0, 255$ ) على التوالي كما يوضح ذلك الشكل (٢-٤) اما اللون الاسود فيكون على الزاوية ( $0, 0, 0$ ) والتدرجات اللونية تكون على طول قطر المكعب، واللون الابيض عند الزاوية ( $255, 255, 255$ ).

يتم مزج الالوان الاولية لهذا الفضاء للحصول على الألوان جديدة، فمثلاً للحصول على اللون الازرق المخضر يتم اضافة اللون الخضر الى الازرق ( $0, 255, 255$ ) اما لغرض الحصول على اللون البنفسجي فيتم مزج اللون الاحمر مع اللون الازرق ( $255, 0, 255$ ) واللون الاصفر يكون باضافة اللون

الاحمر الى اللون الاخضر (٢٥٥,٢٥٥,٠)، الاحمر هو اللون المكمل للون الازرق المخضر، الاخضر هو مكمل اللون البنفسجي والاصفر هو مكمل اللون الازرق.



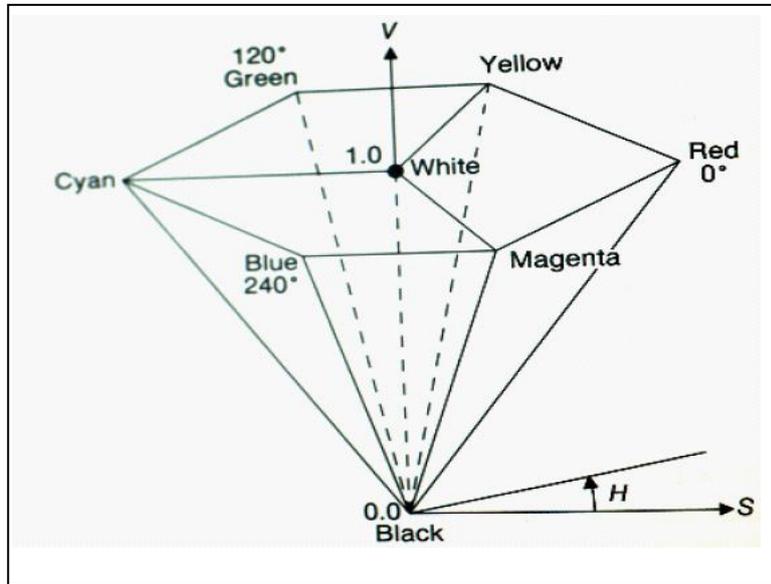
الشكل (٢-٤) مكعب يمثل الفضاء اللوني RGB

الصورة الممثلة بواسطة الفضاء اللوني (RGB) تتألف من ثلاثة عناصر (صور) صورة واحدة تمثل كل لون اولي، عندما ترسل هذه الصور الثلاث الى الشاشة الملونة يتم دمجها للحصول على الصورة الملونة التي تعرض على الشاشة. ان عدد البتات التي تمثل كل عنصر صورة (pixel) في فضاء الـ (RGB) تسمى عمق عنصر الصورة (pixel depth). أي ان كل صورة تمثل لوناً اولياً يكون تمثيلها بثمانية بتات، تحت هذه الشروط كل عنصر صورة في هذا الفضاء يمتلك عمقاً لونياً مقداره (٢٤-bit). ان المصطلح صورة ممثلة لونياً (full-color image) يتم الاشارة اليها بـ (٢٤-bit).

## ٢-٦-٢- الفضاء اللوني HSV (HSV Color Space) [٤٠]

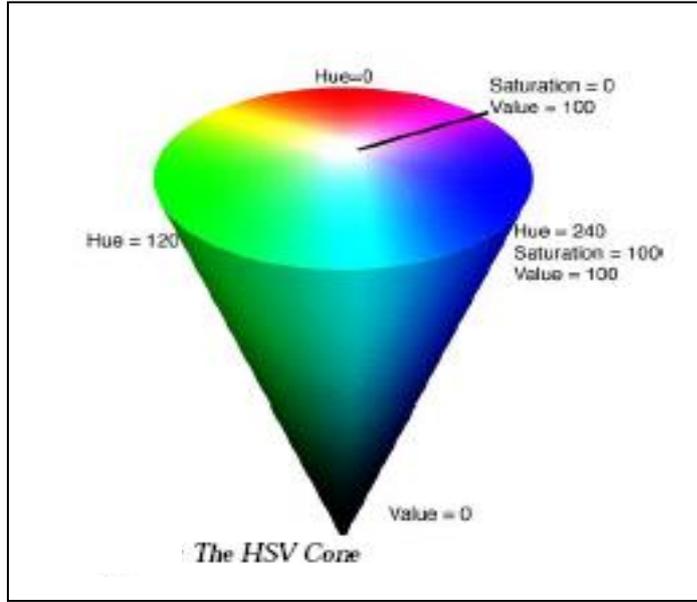
اسم الفضاء مختصر لـ (Hue, Saturation, Value) يمثل الشكل والاشباع والسطوع هذا الفضاء اقرب ما يكون الى نموذج مزج الالوان لدى الفنان، الفضاء يعرف بواسطة مخروط (cone) او هرم سداسي الجوانب (six-sided pyramid)، تمثل قاعدة (قمة) المخروط القيمة  $v=1$  وتتضمن الالوان الاكثر سطوعاً، اما رأس المخروط فيمثل اللون الاسود. الشكل (hue) يقاس بواسطة زوايا تكون

حول المحور العمودي للمخروط (Red = 0°, Green = 120°, Blue = 240°)، اما الاشباع (saturation) هو قيمة بين المديين الصفر والواحد على المحور v على اوجه المخروط. قمة او قاعدة المخروط تمثل اسقاطاً للقطر الرئيسي الخاص بمكعب الوحدة الذي يمثل الفضاء RGB. التحويل بين الفضاء RGB و الفضاء HSV يمثل تحويلاً لا خطياً، القيمة تحدد اكبر عنصر من عناصر الفضاء RGB اما الاشباع فيتعلق بمدى القيم في الفضاء و الشكل يتعلق بزوايا الازاحة عن اكبر عناصر الفضاء RGB كما في الشكل (٥-٢).



شكل (٥-٢) مخطط المخروط الممثل للـ HSV

ومما تجدر الاشارة اليه ان الفضاء RGB يستخدم بشكل واسع لكن الفضاء HSV يفضل في بعض الاحيان على الـ RGB. الشكل يمثل مواصفات اللون الحقيقية، الاشباع يصف مدى نقاء اللون، اما العنصر الثالث في هذا الفضاء فيحدد مدى سطوع اللون كما موضح في الشكل (٦-٢)



الشكل (٦-٢) يمثل المخروط الممثل للـ HSV

## ٧-٢- الشبكات العصبية (Neural Networks)

عند ظهور الشبكات العصبية في مطلع الثمانينات جذبت الاهتمام إليها حيث انتشر استعمال هذه الشبكات وذلك لأنها إحدى تطبيقات الذكاء الاصطناعي، ولأن الباحثين يحاولون معرفة كيفية حزن المعلومات داخل خلايا الدماغ وقابلية الإنسان على التعلم ازداد الاهتمام بهذا الحقل من حقول خوارزميات حل المشاكل (*problem solving algorithms*). ومن المزايا التي ميزت الشبكات العصبية على باقي الخوارزميات هي:

❖ قابلية التعلم (*The Generalization Capacity*)

❖ التوازي (*Parallelism*)

❖ الذاكرة الموزعة (*Distributed Memory*)

❖ السلوك الذكي (*Intelligent Behavior*)

❖ التعلم وليس البرمجة (*Learning Not Programming*)

تعرف الشبكة العصبية بانها نظام لمعالجة المعلومات بشكل متوازٍ، حيث تتكون من مجموعة من الخلايا تسمى (*neurons*) او مجموعة من العقد (*nods*) ترتبط مع بعضها البعض بواسطة مجموعة موصلات عصبية (*connections*) او مجموعة أوزان (*weights*). تمتلك كل خلية حالة خاصة بها تدعى نشاط الخلية (*activation*)، ناتجة من تطبيق دالة نشاط (*activation function*) مناسبة على مدخلاتها للحصول على اخراج تلك الخلية [٤١][٤٢][٤٣].

حققت الشبكات العصبية نجاحاً في العديد من التطبيقات، ومن هذه التطبيقات معالجة الإشارات (*signal processing*)، وتمييز الانماط (*patterns recognition*) ومسائل الامثلية (*optimization problem*) وغيرها من التطبيقات. ان من اهم ما يميز الشبكات العصبية هي امكانيتها العالية في اجراء المعالجة المتوازية وعدم احتياجها الى علاقات معقدة في عملها، وانما تحتاج الى مجموعة من الأمثلة لغرض تعلمها وبالنتيجة سهولة الإجابة عن الامثلة المقاربة والمحتوية على نسبة من ضوضاء وهو ما يعرف بقابلية التعميم (*generalization capability*) [٣].

## ٢-٧-١ - أنواع الشبكات العصبية (*Types of Neural Networks*)

تتنظم الشبكات العصبية بشكل طبقات (*layers*)، وتعالج خلايا الطبقة الواحدة المعلومات بطريقة مشابهة. يحدد سلوك أي خلية عصبية بدالة نشاطها ونمط الموصلات العصبية الموزونة (*weighted connections*) التي ترسل وتتسلم الإشارات. يدعى ترتيب الخلايا في الطبقات وانماط الاتصال العصبية ضمن وبين الطبقات بمعمارية الشبكة (*net architecture*) [٤١].

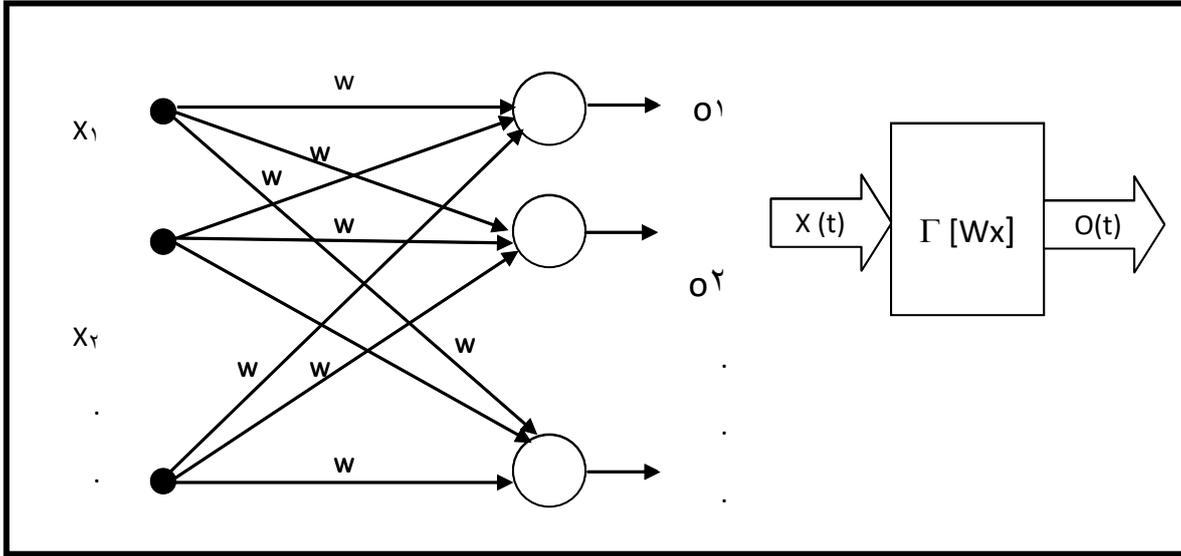
تصنف معمارية الشبكات العصبية بالاعتماد على هيكلها العام على ثلاثة اصناف وهي كالآتي:

### ٢-٧-١-١ - شبكات التغذية الأمامية

#### [٣][٤٥] (*Feed forward Networks*)

تتكون شبكات التغذية الأمامية من طبقة واحدة أو أكثر من وحدات معالجة أساسية غير خطية (*nonlinear processing elements*) أو خلايا عصبية، ترتبط الخلايا الموجودة في طبقة معينة بخلايا الطبقة المجاورة من خلال مجموعة من الموصلات العصبية، تنساب

المعلومات في هذا النوع من الشبكات باتجاه واحد من طبقة الادخال الى طبقة الاخراج كما في الشكل (٧-١)، ونوع التعلم في هذه الشبكات هو التعلم المشرف عليه ( *supervised learning* )، اشهر انواع هذه الشبكات واكثرها شيوعاً واستعمالاً هي شبكة انسياب الخطأ خلفاً.

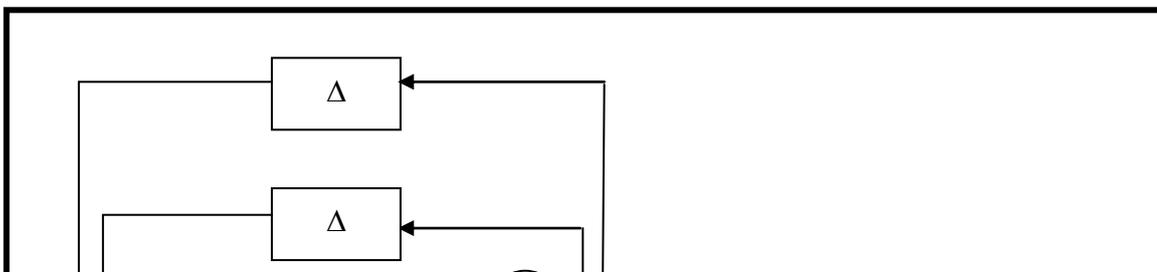


شكل (٧-٢) شبكات التغذية الامامية

## ٧-٢-١-٢- شبكات التغذية العكسية

### [٣][٤٥] (Feedback Networks)

ترتبط خلايا هذا النوع مع بعضها البعض، اذ يرتبط اخراج كل خلية مع مدخلات الخلايا الاخرى في 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 هوب فيلد (*hopfiled network*).



## ٢-٧-١-٣- شبكات التغذية التنافسية (Competitive Networks) [٣]

تسمى أحيانا شبكات تجميع (*clustering nets*)، يقوم هذا النوع من الشبكات باكتشاف علاقات بين أنماط التدريب من خلال إجراء عملية تجميع أنماط التدريب إلى تجمعات متشابهة الأنماط، تمثل كل وحدة إخراج تجمع (*cluster*)، وينسب النمط إلى التجمع الأقرب إليه من خلال قياس المسافة (*distance*) بين نمط ومراكز التجمعات المختلفة وتنتج الشبكة متجهاً نموذجاً أو مثلاً (*representative vector*) كل تجمع يمثل مركز الفئة. إن التعلم في هذه الشبكات غير مشرف عليه (*unsupervised*) ولذلك تسمى بالشبكات ذاتية التنظيم (*self-organization network*) من الأنواع المشهورة لهذه الشبكات خرائط الصفات ذاتية التنظيم (*self-organization features map*) لكوهنلين عام ١٩٨٨ وشبكة اكتشاف التجمع (*clustering discovery network*) المطورة من كارينتر وجروسبيرج عام ١٩٨٨ والمسماة ايضاً بنظرية التناغم التاقلمي (*adaptive resonance theory*).

## (Learning In Neural Networks)

يعرف التعلم بأنه عملية اكتساب الشبكة العصبية القدرة على تنفيذ وظائف معينة باعطاء صورة تقريبية عن المشكلة بواسطة تعديل معاملاته الداخلية (الاوزان)، وفقاً لقاعدة تعلم معينة، وتنجز عملية التعلم باستعمال الامثلة (examples).

تعد قاعدة التعلم جوهر خوارزمية تعلم الشبكة العصبية فهي تحدد كيفية تغيير اوزان الموصلات العصبية، ومن قواعد التعلم الاكثر شيوعاً هي قاعدة تعلم دلتا (*delta rule*) وقاعدة هيب (*hebbian rule*) وقاعدة التعلم التنافسي (*the competitive learning rule*) [٣].

ينقسم التعلم في الشبكات العصبية الى نوعين اساسيين:

١- **التعلم المشرف عليه (Supervised):** يعتمد هذا النوع من التعلم على موازنة مباشرة بين الاخراج الفعلي (*actual output*) للشبكة العصبية والايخراج المرغوب (*desired output*) لها واعتماداً على المسافة بينهما، يتم قياس الخطأ الناتج ليستعمل في عملية تعديل (تصحيح) الاوزان للشبكة ومن الشبكات التي تستخدم هذا النوع من التعلم هي شبكة المدرك وشبكة انسياب الخطأ خلفاً [٤٢][٣][٤٧].

٢- **تعلم غير المشرف عليه (Unsupervised):** يكون الاخراج الهدف في هذا النوع من التعلم غير معروف وبذلك لا توجد معلومات معروفة عن الخطأ يمكن ان تستعمل في عملية تصحيح الاوزان، ويعتمد على ايجاد علاقات بين بيانات الادخال، الهدف منه تعديل الاوزان تلقائياً (*autonomously*) للوصول الى حالة التوازن (*equilibrium state*) ، ومن الشبكات التي تستعمل هذا النوع من التعلم شبكة هوبفيلد [٣].

تعتمد فكرة بناء الشبكات العصبية على المعلومات المتوافرة عن الشبكات العصبية في الدماغ البشري، وكما هو معروف فإن الخلية العصبية في الدماغ البشري لا تقوم بإنجاز معالجة خطية (*linear*) على مدخلاتها، بل إنها تتسلم مجموعة من المدخلات التي تقوم على أساسها بإنجاز فعل معين، ولذلك تمت عملية محاكاة لهذا السلوك بواسطة مجموعة من الدوال اللاخطية (*nonlinear function*) [٤١][٣].

هناك انواع من الدوال التي تم استخدامها في الشبكات العصبية حسب نوع الشبكة ونوع التطبيق وهي الاتي:-

## ٢-٧-٣-١ - دوال التنشيط العامة (activation function)

تتميز هذه الدوال بانها تقسم مدخلاتها على مناطق غير محددة (*infinite regions*) ومن امثلتها:-

### ١ - دالة الإشارة (Sign Function)

تعتمد مخرجات هذه الدالة على اشارة المدخلات، وتعد من الدوال البسيطة ولكنها غير قابلة للاشتقاق، لذلك فان اكثر خوارزميات التعلم المعتمدة على المشتقة لا تستطيع استعمال هذه الدالة، تقسم هذه الدالة الى نوعين [٤١][٣][٤٨]:

#### أ- الدالة احادية القطب (Unipolar Binary Function)

تكون مخرجات هذه الدالة هي القيم الثنائية (٠) او (١) وصيغتها هي

$$F(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq 0 \end{cases} \quad (١٥.١)$$

#### ب- الدالة الثنائية ثنائية القطب (Bipolar Binary Function)

تكون مخرجات هذه الدالة هي القيم الثنائية (-١) أو (+١) وصيغتها العامة هي:-

$$F(\text{net}) = \begin{cases} +1 & \text{if } \text{net} \geq 0 \\ -1 & \text{if } \text{net} < 0 \end{cases} \quad (16.1)$$

## ٢- الدالة السيجماوية (Sigmoidal Function)

هي من الدوال الشائعة الاستعمال في العديد من خوارزميات التعلم [٢]، لأنها من الدوال اللاخطية والقابلة للاشتقاق، وسميت بالدالة السيجماوية وذلك لان شكلها يشبه الحرف S [٤١] [٢]، وتقسم إلى دالة أحادية وثنائية القطب وعلى ما يأتي [٤١] [٣] [٤٨]:

### أ- الدالة السيجماوية أحادية القطب (Uni Polar Sigmoid Function)

تكون قيم مخرجات هذه الدالة قيماً مستمرة وتقع ضمن الفترة [٠, ١] والصيغة العامة لها هي:

$$f(\text{net}) = \frac{1}{1 + e^{-\lambda \text{net}}} \quad (17.1) \quad \text{حيث ان}$$

Net: هي مجموع المدخلات إلى الخلية.

$\lambda$ : عبارة عن قيمة موجبة تحدد ميل (انحدار) الدالة بالقرب من القيمة  $\text{net}=0$ ، وإذا كانت قيمة  $\lambda$  عالية أي  $\lambda \rightarrow \infty$  فان الدالة تقترب من دالة الخطوة (step function) [٣] وتسمى هذه الدالة بالدالة المنطقية أيضاً (logic function) [٤١] [٤٨].

### ب- الدالة السيجماوية ثنائية القطب (Bipolar Sigmoid Function)

يكون الإخراج في هذه الدالة ضمن الفترة [-١, +١] وصيغتها العامة على النحو الآتي:

$$f(\text{net}) = \frac{2}{1 + e^{-\lambda \text{net}}} - 1 \quad (18.1)$$

## ٢-٣-٧-٢- دوال التنشيط المحلية (Local Activation Function)

تعد هذه الدوال بديلاً عن الدوال السابقة وتطبقاً على حقل محلي من الإدخال وهناك نوعان من

هذه الدوال [٤٩]:

## ١- دالة النبضة (Pulse Function):

هي دالة اشارة ثنائية *binary function* وتأخذ هذه الدالة القيم (٠, ١) والصيغة العامة لها هي

$$F(\text{net}) = \begin{cases} 1 & \text{if } a \leq \text{net} \leq b \end{cases} \quad (19.1)$$

اذ تمثل  $a, b$  الحد الأدنى والحد الأعلى للفترة التي تقع ضمنها مدخلات الخلية ( $\text{net}$ ) ومن مشاكلها انها غير قابلة للاشتقاق

## ٢- دالة كاوس (Gaussian Function)

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

$$f(\text{net}) \propto \exp\left(\frac{-(\text{net} - c)^2}{2\sigma^2}\right) \quad (20.1)$$

تمثل  $\text{net}$  المدخلات لدالة كاوس و  $\sigma$  يمثل الانتشار ( $\text{spread}$ ) للدالة،  $c$  تمثل نقطة المنتصف ( $\text{center point}$ )

## ٢-٧-٤- 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 ( $\text{modifiable intermediate connections}$ ) [٤٨]، وتكمن أهميتها بقدرتها على أنجاز عملية التعلم تحت أي تعقيد، واعتمادها على تقويم متكرر لأمثلة التدريب وكما في الشبكات ذات الطبقة الواحدة [٣]،

## ٢-٨-١- مشاكل الشبكات العصبية متعددة الطبقات

لقد أثبتت الشبكات العصبية متعددة الطبقات كفاءة عالية في حل العديد من المسائل ولكن هناك بعض المشاكل أو محددات التي تواجه هذه الشبكات أهمها.

### ٢-٨-١- التكيف الزائد عن الحد (Over-Fitting) [٥٢]

ان مسألة تطوير التعميم في الشبكات العصبية مسألة حرجة جداً. ان السؤال الممكن طرحه هو كيفية إعطاء الشبكة تنبؤات لحالات غير موجودة ضمن مجموعة التدريب؟ أن الشبكات العصبية مثلها مثل بقية طرائق التقدير غير الخطية المرنة والتي من الممكن أن تعاني من التكيف القليل أو التكيف الزائد. فمثلاً الشبكة غير المعقدة بشكل كافٍ يمكن أن تفشل في تحديد الإشارة بالكامل في مجموعة بيانات معقدة، هذه الحالة تعود إلى حالة التكيف القليل (*under-fitting*). إما الشبكة المعقدة جداً ممكن أن تتعرف على الضوضاء كما تتعرف على الإشارة ضمن بيانات التدريب وهذا يؤدي إلى التكيف الزائد (*over-fitting*) التكيف الزائد حالة خطيرة بالنسبة للشبكات العصبية وذلك لأنها يمكن أن تعطي وبسهولة تنبؤات بعيدة عن مدى بيانات مجموعة التدريب وهذه الحالة يمكن أن تحدث في أشهر أنواع الشبكات العصبية.

عندما يتم تدريب الشبكة على مجموعة بيانات وعندما تصبح الشبكة مرنة جداً سوف تقوم باكتشاف أصناف أو تحديد صنف بيانات إدخال غير موجود في مجموعة التدريب، هذه المرونة تعطي تكيفاً جيداً للشبكة وتعميماً قليلاً لها هذه المشاكل يسببها التكيف الزائد للشبكة، لذلك اتجه الباحثون إلى اكتشاف حل لهذه المشكلة من خلال استخدام قوانين الاحتمال.

### ٢-٨-٢- المشكلة التصميمية (Design Problem)

لا توجد قواعد محددة يتم عن طريقها تحديد التصميم المناسب للشبكة واللازم لحل مشكلة معينة، ويقصد بالتصميم المناسب هو تحديد الطبقات المخفية وعدد العقد المخفية في كل طبقة فضلاً عن تحديد التوصيلات بين الخلايا المخفية وتحديد التوصيلات العامة للشبكة، غالباً ما يتم استعمال طريقة التجربة والخطأ (*trail and error*) أو استعمال الطريقة التخمينية من خلال استعمال الطرائق الاحتمالية.

### ٢-٨-٣- التقارب (Convergence)

لا تعد عملية تدريب الشبكة وتقليل الخطأ وصولاً إلى أقل خطأ ممكن بالمهمة السهلة لان مجال دالة الكلفة يحتوي على مواصفات (*features*) تمنع الخوارزمية من التقارب ومنها وجود نهايات صغرى محلية متعددة (*Many local minima*) [٥٣][٢]، يمتلك معامل التعلم (*Learning rate*) تأثيراً كبيراً على سرعة التقارب للتخلص من مشكلة النهاية الصغرى المحلية التي تؤثر في سرعة تقارب الشبكة العصبية.

## ٢-٨-٤ - 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 أنظمة التصنيف [٥٤].

## ٢-٨-٥ - الإشباع المبكر (*Premature Saturation*)

تظهر هذه المشكلة نتيجة لاختيار أوزان ابتدائية عالية تجعل عقد الشبكة غير قادرة على التعلم، تنمو الأوزان التي لها علاقة بالعقدة المقصودة بشكل مستمر وتصبح قيمها عالية مما يجعل مخرجات العقدة بعد تطبيق دالة التنشيط قيم عالية جداً مما يؤدي إلى بقاء قيمة الخطأ عالية وتصبح العقد في حالة الإشباع (*saturation*) [٥٥].

## ٢-٩ - شبكة بيزين العصبية (*Bayesian Neural Network*)

من أوائل الباحثين الذين قاموا بالبحث في مجال شبكة بيزين العصبية هما الباحثان (*Radford Neel*) و الذي قام بتقديم نموذج للشبكة تقوم بعملية التصنيف (*classification*) و الباحث (*David Mackay*) والذي قدم نموذجاً للتصنيف وتردد الدالة (*classification, regression*).

أن الفكرة من وراء شبكة بيزين العصبية هي إيجاد مجموعة واحدة من الأوزان (*weight set*) للشبكة والتي تعطي أعلى تكيف للشبكة مع بيانات التدريب وهذه المجموعة من الأوزان ربما يتم تعديلها وذلك للحصول على أفضل مجموعة أوزان ممكنة تستطيع الشبكة بواسطتها أن تمنع التكيف الزائد (*over-fitting*) [٩].

أن مدرسة بيزين الإحصائية تستند على فكرة مختلفة وهي ماذا يمكن أن تتعلم من البيانات، في هذه المدرسة تستخدم الاحتمالية لتمثيل الغموض أو عدم التأكد (*uncertainty*) بعلاقة تكون معلومة، قبل

مشاهدة أي بيانات فان الرأى المسبق (*prior opinion*) عن ما هي العلاقة الصحيحة التي تمثل أوزان الشبكة يمكن أن توصف بتوزيع احتمالي (*probability distribution*) على أوزان الشبكة، أما بعد مشاهدة البيانات (او بعد أعطاء البيانات إلى البرنامج) سوف ترتفع احتمالية الرأى وذلك بأخذ توزيع لاحق (*posterior distribution*) على أوزان الشبكة. أن مجموعة أوزان الشبكة التي بدأت بشكل معقول قبل مشاهدة البيانات ولكنها لم تتعرف على البيانات بشكل جيد سوف تقل احتمالياتها أما قيم الأوزان التي تتعرف على البيانات فسوف تزداد احتمالياتها مما يؤدي إلى زيادة تكيف الشبكة [٤].

بصورة نموذجية، ان الغرض من التدريب هو جعل التنبوءات للحالات المستقبلية لمداخلات الشبكة فقط تكون معروفة، أن نتيجة التدريب التقليدي للشبكات هو مجموعة من الأوزان التي يمكن أن تستخدم لعمل تنبوءات الشبكة بالمقارنة مع شبكة بيزين العصبية فان نتيجة التدريب في هذه الشبكة هو توزيع لاحق (*posterior distribution*) على أوزان الشبكة، فإذا كان إدخال الشبكة هي قيم لبعض الحالات الجديدة فان التوزيع اللاحق على أوزان الشبكة سوف يعطي رفاعاً للتوزيع على إخراج الشبكة وهذا التوزيع يعرف بالتوزيع التنبؤي (*predictive distribution*) للحالة الجديدة. اذا كنا بحاجة لتنبوء ذي قيمة واحدة فيمكن استعمال الوسط الحسابي (mean) أما إذا أخذنا التوزيع التنبؤي بالكامل فانه سوف يخبرنا عن تنبوء الحالة الغامضة [٥٦].

تقدم شبكة بيزين العصبية حلاً للحالات الآتية:-

١- كيفية الحكم على تنبوءات الغموض (*uncertainty*) هذه الحالة يمكن أن تحل بالتعامل مع التوزيع تنبؤي (*predictive distribution*).

٢- كيفية اختيار الهيكل المناسب للشبكة مثل (عدد الطبقات المخفية و عدد العقد المخفية في كل طبقة).

٣- كيفية تكيف الشبكة لصفات البيانات مثل (صقل الدالة *the smoothness of function* و درجة ارتباط المداخلات المختلفة) [٥٦].

## ٢-٩-١- حل بيزين (The Bayesian Solution)

عرفت الشبكات العصبية بقدرتها على حل المشاكل بصورة مرنة خصوصاً عندما لا تكون هنالك معرفة كافية يمكن بواسطتها اختيار نموذج الحل الامثل، ومن الجهة المقابلة فان مرونتها هذه يمكن ان تسبب حالة التكيف الزائد (*over-fitting*) مما يؤثر في حالة التعميم (*generalization*) في الشبكات العصبية. تمتلك الشبكات العصبية عدة ميزات منها انها تعد اداة مفيدة في كونها دالة تقريب جيدة، ولها القدرة على التصنيف، وقابلية التنبؤ، ان التدريب في الشبكات العصبية يهدف الى ايجاد الهيكل المناسب للشبكة وايجاد افضل مجموعة اوزان في فضاء الاوزان. تعتمد الشبكات العصبية على مشاهدات دالة الخطأ التقليدية للشبكة العصبية، في حين ان شبكة بيزين العصبية فان دالة الخطأ هذه تترجم الى لوغارتم الدالة الاحتمالية (*log-likelihood*) والتوزيع الاحتمالي (*probability distribution*) يترجم عملية الامثلية او اختيار الحل الامثل في الشبكات العصبية [٥٧].

تمتلك شبكة بيزين العصبية جانبين يمكن استخدامهما للتقليل من مشاكل التكيف الزائد، يشمل الجانب الاول وصف التوزيع الاحتمالي السابق (*prior probability distribution*) لمتغيرات الشبكة (وهي في هذا البحث تركز على متجه الاوزان) وهذه القيم يتم اختيارها بدءاً ويتم تغييرها خلال البيانات باستخدام الدالة الاحتمالية (*likelihood function*) لاعطاء التوزيع الاحتمالي اللاحق (*posterior probability distribution*) لمتغيرات الشبكة، اما الجانب الثاني فيتم فيه بناء التنبؤ (*predication*) للقيم المحتملة لمعاملات الشبكة [٥٨].

لنكن المدخلات للشبكة هي متجه الادخال  $x$  ولكل قيمة ادخال هناك قيمة اخراج مرتبطة بها  $y$  أي ان بيانات الشبكة هي

$D = \{(x_1, y_1), \dots, (x_n, y_n)\}$   
ان التوزيع الاحتمالي السابق (*prior probability distribution*) لمتجه الاوزان هو  $p(w)$ ، ان الدالة الاحتمالية (*likelihood function*) والتي تمثل دالة قياس الخطأ هي  $p(y/x, w)$  اما الاحتمال اللاحق لمتجه الاوزان فيتم تمثيله بقاعدة بيزين على النحو الاتي [٥٨]

$$p(w/(x_1, y_1), \dots, (x_n, y_n)) = \frac{p(w)p((x_1, y_1), \dots, (x_n, y_n) / w)}{p((x_1, y_1), \dots, (x_n, y_n))} \quad (21.1)$$

$$= \frac{p(w)p(y_1, \dots, y_n / x_1, \dots, x_n, w)}{p(y_1, \dots, y_n / x_1, \dots, x_n)} \quad (22.1)$$

$$= \frac{p(w) \prod_{i=1}^n p(y_i / x_i, w)}{p(y_1, \dots, y_n / x_1, \dots, x_n)} \quad (23.1)$$

ان طريقة بيزين للتنبؤ لا تستخدم مجموعة واحدة من الاوزان المثالية فقط بل تستخدم التكامل لغرض التنبؤ بمتجهات الاوزان الممكنة على التوزيع الاحتمالي اللاحق للاوزان. والتي تجمع المعلومات من البيانات والتوزيع لسابق للحصول على الاوزان. وعلى فرض ان  $x_{n+1}$  تمثل الادخال الاضافي فان  $y_{n+1}$  تمثل الاخراج المطلوب والذي يعبر عنه بالمعادلة التالية

$$y_{n+1} = \int_{R^N} f(x_{n+1}, w) p(w/(x_1, y_1), \dots, (x_n, y_n)) dw \quad (24.1)$$

ان التوزيع اللاحق (*prior distribution*) والتوزيع التنبؤي (*predictive distribution*) المتمثل بالعلاقة اعلاه يقدمان الحل الامثل لمشكلة الشبكات العصبية، لكن لسوء الحظ هذه التقنية تتضمن تكاملات متعددة الابعاد (*multi-dimensional integrations*) أو تكاملات متعددة الحدود (*multivariate integration*) هذا النوع من التكاملات تمثل أساس أكثر الصعوبات العملية الموجودة في طريقة بيزين الخاصة في الكثير من التطبيقات.

يمثل التدريب مشكلة الشبكات العصبية ويمثل التكامل المتعدد الحدود مشكلة شبكة بيزين العصبية، ان الحلول التحليلية غير ممكنة ولذلك نحن بحاجة الى البحث عن طرائق بديلة لحل مثل هذه التكاملات ومن هذه الطرائق [٩]:

❖ التكامل العددي المباشر (*Direct Numerical Integration*)

❖ محاكاة مونت كارلو (*Monte Carlo Simulation*)

❖ تقريب كاوس (*Gaussian Approximation*)

٢-٩-٢- طريقة تقريب كاوس (*Gaussian Approximation*)

تم وضع تقريب كاوس للدالة الاحتمالية المستخدم في الشبكات العصبية من الباحث (Mackay) وذلك لغرض التغلب على مشكلة التكامل متعدد الحدود الذي يمثل المشكلة الاصبغ في استخدام قاعدة بيزين الاحصائية لتدريب الشبكات العصبية، سوف يتم الحديث هنا عن الشبكات العصبية متعددة الطبقات ذات التغذية الامامية والتي تقوم بمهمة التصنيف، فعلى فرض وجود مجموعة مستقلة (n) من نماذج التدريب (training set) هي  $(x_1, y_1), \dots, (x_n, y_n)$ ، لكل متجه ادخال (input vector) هنالك متجه اخراج (output vector) يكون متصل به. اما متجه الادخال الاضافي وهو متجه الاختبار (test set)، فهو  $(x_{n+1})$ ، مهمة الشبكة هي التنبؤ بمتجه الاخراج (output vector)  $(y_{n+1})$  الذي يمكن ان يمثل متجه الادخال الخاص بالاختبار [٥٧].

ان الشبكة العصبية مثله ببعض الهياكل والتي تمتلك متجه اوزان يطابق متجه الادخال (x) للتنبؤ بمتجه الاخراج (y) يمكن تعريفه بالمعادلة الاتية

$$y = f(x, w) \quad (25.1)$$

ولغرض افتراض نموذج لتوزيع كاوس (Gaussian model) فان التوزيع الاحتمالي المشروط لمتجه الاخراج بشرط وجود متجه الادخال وبالاعتماد على دالة المطابقة سوف يكون كالتالي

$$p(y / x, w) = (2\pi\sigma^2)^{-\frac{N}{2}} \exp\left(-\frac{|y - f(x, w)|^2}{2\sigma^2}\right) \quad (26.1)$$

حيث ان

y: تمثل متجه الاخراج المرغوب (desired output)

f(x,y): تمثل الاخراج الحقيقي للشبكة (actual output)

N: تمثل بعد متجه الاخراج (dimension of the output vector)

$\sigma$ : تمثل مقدار الضوضاء في الاخراج (the noise in output)

ان الطريقة التقليدية في تدريب الشبكات العصبية لغرض لتعظيم الاحتمالية ( *maximum likelihood* ) هي استخدام خوارزمية تعتمد على المشتقة لغرض إيجاد متجه الاوزان الامثل والذي يعطي افضل مطابقة للبيانات لغرض إعطاء أفضل إخراج، يمكن تمثيله بلوغاريتم دالة الاحتمالية (*log-likelihood*) والذي يعرف من خلال المعادلة الآتية:

$$L(w) = \sum \log p(y_i / x_i, w) = -\sum_{i=1}^N \frac{\|y_i - f(x_i, w)\|^2}{2\sigma^2} + C \quad (27.1)$$

حيث ان C لا تعتمد على w. مقدار مستوى الضوضاء ( $\sigma$ ) يمكن اختيار من خلال التدريب.

ان اشتقاق المعادلة (27.1) يمثل تعظيم تخمين الاحتمالية والذي تمثله المعادلة الآتية:

$$L'(w) = -\frac{\|w\|^2}{2\omega^2} - \sum_{i=1}^N \frac{\|y_i - f(x_i, w)\|^2}{2\sigma^2} \quad (28.1)$$

هنا الثابت ( $\omega$ ) يمثل تقبيلاً للاوزان والذي يمكن ان يوضع من قبل مصمم النظام.

في شبكة بيزين العصبية فان المعادلة اعلاه تمثل مقدار الخطأ الحاصل بين الاخراج الفعلي للشبكة والخراج المرغوب بطريقة توزيع كاوس الاحتمالي تستخدم هذه المعادلة لغرض تعديل اوزان الشبكة العصبية والوصول الى متجه الاوزان المثالي.

الشبكة بحاجة الى تحديد توزيع احتمالي مسبق (*prior distribution*) لكي يكتمل تمثيل هيئة بيزين الاحصائية، ولغرض تحديد متجه الاوزان المسبق يتم اخذ عينات عشوائية ومن ثم ايجاد التوزيع الاحتمالي والذي يتم تمثيله بتوزيع كاوس والمعادلة الآتية توضح هذا التوزيع

$$p(w) = (2\pi\omega^2)^{-\frac{N}{2}} \exp\left(-\frac{\|w\|^2}{2\omega^2}\right) \quad (29.1) \quad \text{المعرفة المسبقة (Prior Knowledge)}$$

تبقى المعرفة المسبقة (*prior knowledge*) المستخدمة في الصندوق الاسود (*black box*) المستخدم للتصنيف مشكلة مفتوحة، تتمثل المعرفة المسبقة للشبكات العصبية بمعرفة متجه الاوزان الابتدائية، وعدد العقد المخفية، وعدد الطبقات المخفية. ولغرض الشروع بعملية هيكلة الشبكة فهناك نوعان من المعرفة المسبقة وهي المعرفة المسبقة المعلومة (*informative prior knowledge*) والمعرفة المسبقة المجهولة (*non informative prior knowledge*).

### ❖ المعرفة المسبقة المعلومة (*Informative Prior Knowledge*)

يمكن تعريف المعرفة المسبقة بانها عدد من المشاهدات الحقيقية للبيانات او المعاملات المطلوبة للشبكة. ويمكن تمثيل التوزيع الاحتمالي المسبق من خلال مشاهدات مكتملة، فمثلا يمكن استخدام شبكة بيزين للصدق (*Bayesian belief network*) لغرض اعطاء بيانات كاملة للشبكة، وهذا النوع من المعرفة يتطلب تطبيق شبكة بيزين للصدق لغرض تحويل مجال المعرفة الى توزيع احتمالي مسبق معروف (*informative prior distribution*) [٥٩].

### ❖ المعرفة المسبقة المجهولة (*Non Informative Knowledge*)

ان من غير الممكن تحديد معاملات الشبكة العصبية (متجه الاوزان الابتدائي، عدد الطبقات المخفية، وعدد العقد المخفية، ... الخ) منذ البداية، في حين يمكن تحديد معرفة مسبقة لنموذج الشبكة وذلك بالتحديد المباشر للتوزيع الاحتمالي المسبق (*prior distribution*) الخاص بهذه المعاملات [٧].

عملياً يستخدم التوزيع الاحتمالي المسبق للتقليل من التعقيد الذي يحصل في نموذج الشبكة، يمكن استخدام توزيع كاوس المسبق (*Gaussian prior distribution*) لايجاد المعاملات المسبقة للشبكة وذلك باخذ عينات عشوائية (*random samples*) واستخدام التوزيع الاحتمالي المسبق لها [٥٩]. بالامكان السيطرة على تعقيد الشبكة وذلك بالسيطرة على حجم الأوزان في متجه الاوزان [٦].

## الفصل الثالث

### تصميم وبناء النظام المقترح

#### ٣-١- تنفيذ النظام المقترح

الأسس النظرية الموضوعة لتصميم نظام يعتمد على طريقة بيزين الإحصائية في تدريب الشبكة العصبية والتي يتم استخدامها لغرض تصنيف الصور الطبية حيث يمكن لهذه الشبكة استخدام قوانين الإحصاء لغرض القيام بعملية التدريب وتعديل اوزان الشبكة مما يساعد على حل بعض المشاكل التي تعاني منها الشبكات العصبية التقليدية. وكذلك الخطوات التي تسبق عملية التصنيف تم مناقشتها في الفصل السابق، والفصل الحالي سيوضح الخطوات العملية التي يتم إتباعها لغرض تنفيذ النظام المقترح، تم العمل على صور الرنين المغناطيسي (MRI) وصور الأشعة المقطعية (CT) والتي مثلت صور أورام الكبد وصور أورام الغدة الكظرية، كانت مجموعة الصور المستخدمة في العمل هي (١٢) صورة، تمثل هذه الصور مجموعة التدريب وتضمنت نوعين من الأورام التي تخص الكبد و نوعين تخص الغدة الكظرية توزعت هذه الصور بواقع (٣) صور لكل نوع من هذه الأنواع.

#### ٣-٢- أدوات البرمجة:

نفذ النظام المقترح على حاسب الآلي من نوع بنتيوم ٤ (Pentium IV)، استخدمت لغة البرمجة (Visual Basic) حيث توفر هذه اللغة إمكانيات التعامل مع الصور وباقي الملفات بطريقة سهلة و مرنة وتتمتع باحتوائها على أدوات ودوال تسهل عمل مصمم النظام.

#### ٣-٣- الهيكل العام لتنفيذ النظام المقترح

الشكل أدناه يوضح مخططاً للخطوات اللازمة لإتمام عمل النظام والأدوات والخوارزميات التي تم استخدامها لإنجاز عمل النظام المقترح

### ٣-٣-١ - الصورة RGB:

الصورة التي سوف يتم التعامل معها في النظام المقترح تمثل صوراً طبية مأخوذة من خلال جهاز الرنين المغناطيسي وتسمى هذه الصورة (MRI) (*Magnetic Resonance Imaging*) تعد

الصور المستحصلة باستخدام جهاز الرنين المغناطيسي من أحدث التطورات في مجال التصوير الطبي والتشخيص، التصوير باستخدام الرنين المغناطيسي هو من أهم وأحدث تقنيات مجال التصوير الطبي بعد استخدام التصوير بالأشعة المقطعية بالحاسب الآلي والأشعة الصوتية. ويتميز هذا النوع من الفحوص الإشعاعية بأنه لا يستخدم الأشعة السينية المعروفة (*X-ray*) لذلك فليس له مضار معروفة، كذلك يتميز هذا النوع من التصوير بقدرته على التفريق الدقيق بين مختلف الأنسجة في جسم الإنسان ولذلك فهو يعطي صوراً دقيقة غاية في الدقة والوضوح. وكذلك تم استخدام الصور الطبية المعروفة بالأشعة المقطعية بالحاسب الآلي (CT). تم تجميع هذه الصور من مواقع طبية على صفحات الانترنت وتمثل هذه الصور أنواعاً مختلفة من أورام الكبد والغدة الكظرية لكي يتم معالجة هذه الصور وأجراء عملية التصنيف عليها، تكون هذه الصورة من نوع (RGB).

### ٣-٣-٢- بيانات الصورة:

بعد مرحلة تهيئة الصور لا بد من قراءة ملف هذه الصور من أجل إجراء عمليات معالجة عليها، تعتمد عملية قراءة ملف الصورة على هيئته (*image format*)، إذ توجد العديد من الهيئات المستخدمة لتمثيل الصور منها (TIF, JPIC, BMP وغيرها) وقع الاختيار على ملف الصورة من نوع (*Bit Map Format*) BMP [١١].

هناك عدد من أنواع الملفات التي تعود إلى الملف من نوع (BMP) والتي تعتمد في تصنيفها على عدد البتات المستخدمة في تمثيل عنصر الصورة فهناك طريق الخزن (*٨-bit, ١٦-bit, ٢٤-bit*) الصورة المستخدمة في النظام المقترح هي صورة من نوع (*٢٤-bit*) أو (RGB). يتكون ملف الصورة في هذا النوع من جزئين جزء يمثل الصديرة (*Header*) والذي يحتل (*٥٤ Bytes*) والجزء الثاني يمثل بيانات الصورة تتوزع بمعدل (*٣-bytes*) لكل عنصر صورة (*pixel*).

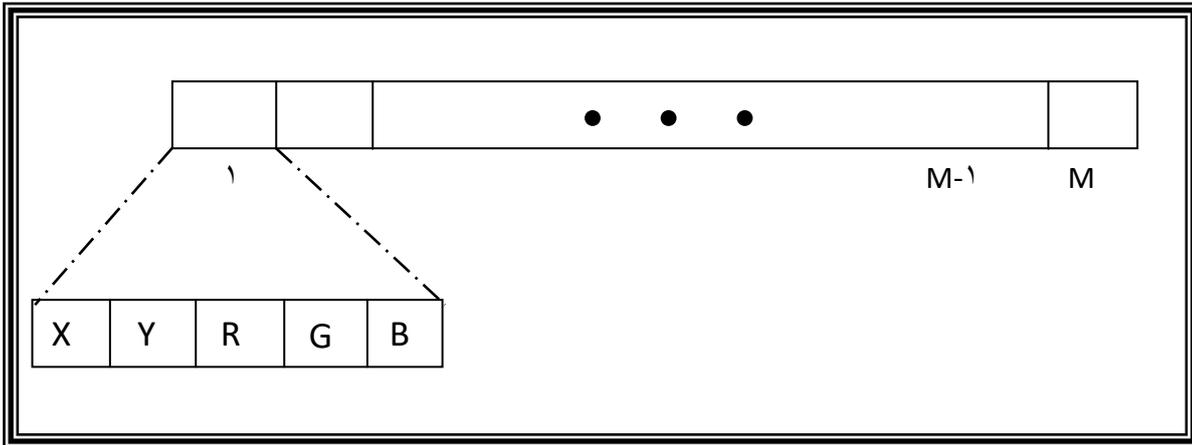
### ٣-٣-٣- الخوارزمية الجينية:

من خلال استخدام الخوارزمية الجينية لحالة الاستقرار والتي تم توضيحها في الفقرة (٢-٩-٢) يتم في الطريقة المقترحة القيام بمهمة تجزئة الصورة، هنالك العديد من طرائق تجزئة الصور وكما تم توضيحها في الفصل السابق وتعد التقنيات التي تعتمد على عملية العنقدة من التقنيات البسيطة والشائعة، إلا إنها تعاني من مشكلة النهاية الصغرى المحلية كما في طريقة الأوساط المتعددة (*K-means*) ويعود السبب في وقوعها في هذه المشكلة إلى كونها تبدأ بحل واحد مما يزيد من احتمالية حصول هذه المشكلة [٢٤].

في الجانب الآخر تعد الخوارزميات الجينية واحدة من الطرائق المستخدمة في حل مشكلة النهاية الصغرى المحلية، حيث تبدأ هذه الطريقة بأكثر من حل مما يزيد من احتمالية تجنبها الوقوع في هذه المشكلة. وعلية تم استخدام الخوارزميات الجينية لحل مسألة العقدة وتطبيقها في تجزئة الصور [٦٠].

#### ◀ تمثيل الكر وموسوم:

إن إحدى المهام الأساسية التي تواجه مصمم الخوارزميات الجينية هي اختيار تمثيل مناسب للكر موسوم الذي سيمثل الحل للمشكلة. في الطريقة المقترحة تم استخدام التمثيل الموضح في الشكل (٢-٣) فعند استخدام الصور الملونة والممثلة بالفضاء اللوني (RGB) (في هذا الفضاء اللوني يكون العنصر اللوني ممثل ب (٢٤-bit))، يتكون الكروموسوم من خمسة عناصر ثلاثة منها تمثل الألوان الخاصة بالعنصر اللوني (الأحمر، الأخضر، الأزرق) والعنصران الآخران يمثلان الإحداثيات (x,y) والتي تمثل موقع العنصر اللوني.



شكل (٢-٣) تمثيل الكر موسوم المستخدم في الطريقة المقترحة

#### ◀ نوع التشفير:

يتم التعامل مع عنصر الصورة والذي يكون ممثلاً بقيم التدرجات اللونية (٠-٢٥٦) فيكون التشفير المناسب للحل في هذه الحالة هو التشفير الصحيح حيث انه يمثل المشكلة بطريقة سهلة ولا تحتاج الى عملية تفسير [٦٠].

#### ◀ قراءة المعاملات المطلوبة:

يتم في البدء قراءة المعاملات الضرورية لعمل الخوارزمية الجينية والتي تمثل احتمالية التزاوج ( $Pc = 0.9$ )، احتمالية الطفرة ( $Pm = 0.09$ )، حجم المجتمع ( $popsiz$ )، عدد العناقيد المرغوبة أي طول الكروموسوم ( $chlen$ )، إضافة إلى عدد الدورات القصوى ( $genlen$ ).

#### ◀ تمهيد مجتمع ابتدائي عشوائي من الأفراد:

تحتاج الخوارزمية الجينية الى مجتمع ابتدائي يتم العمل عليه، في هذه الخطوة يتم ملء الكروموسوم بمراكز العناقيد والممثلة بخمسة عناصر يتم اختيارها بصورة عشوائية من المصفوفات التي تمثل الصورة المراد تجزئتها.

#### ◀ تقييم أفراد المجتمع:

بعد أن تم تكوين المجتمع الابتدائي، سيتم تقييم أفراده من خلال تطبيق دالة الصلاحية والتي تمثل مسافة اقليدس

$$d(X, Z^{(i)}) = \sum_{k=1}^K w_k \left| \frac{(X_k - Z_k^{(i)})}{r_k} \right|, \quad k = 1, 2, \dots, K \quad (1.2)$$

حيث تمثل:-

$X$ : متجه الصفات المراد تنسيبه.

$Z^{(i)}$ : مركز العنقود  $i$ .

$K$ : عدد الصفات في متجه الصفات.

$W_k$ : وزن الصفة  $k$  ( $0 < w_k \leq 1$ ).

$r_k$ : مدى قيم الصفات  $k$ .

تناسب قيم وزن الصفة مع أهميتها حيث يعطى وزناً كبيراً للون الخاص بعنصر الصورة ووزن اقل للصفات الخاصة بالإحداثيات  $x, y$ .

و بعد أن تم تحديد تلك المتجهات، يتم حساب مقدار اختلاف المتجهات التابعة لكل عنقود وعلى النحو الآتي:-

$$distortion = \frac{1}{W \times H \times K} \sum_{i=1}^M \sum_{x \in c_i} d(X, Z^{(i)}) \quad (2.2)$$

حيث تمثل

$d(X, Z^{(i)})$ : تمثل مسافة اقلديس.

$W$ : تمثل عرض الصورة.

$H$ : تمثل ارتفاع الصورة.

$K$ : تمثل عدد الصفات (طول الكروموسوم)

المخطط الانسيابي الذي يمثل سير خطوات الخوارزمية الجينية لحالة الاستقرار على النحو الاتي



يمثل دالة

وبما إن هدفنا هو شكل (٣-٣) مخطط انسابي يمثل خطوات الخوارزمية الجينية الهدف، لذلك يتم استخدام العلافه (٢٥.١) كداله صلاحية للطريقه المقترحه [٦٠].

## ← انتقاء فردين للتزاوج

من خلال استخدام طريقة انتقاء المجموعات الثنائية (BTS) والموضحة في الفقرة (١-٢-٤-٥) يتم انتقاء فردين للتزاوج والخوارزمية الآتية توضح عمل الطريقة:

### **Algorithm BTS**

Select two different individuals randomly (par ١, par ٢);

If (fitness (par ١) > fitness (par ٢)) then

Select (par ١);

Else

Select (par ٢);

Endif

### **End BTS**

## ← طريقة التزاوج

لغرض إنتاج أطفال جدد في المجتمع يتم التزاوج بين الفردين اللذين تم انتقاؤهما من خلال تطبيق عملية التزاوج ذات نقطة القطع الواحدة (١x)، تم استخدام هذا النوع من التزاوج لغرض الحفاظ على الكروموسوم من التمزق الذي يمكن ان يحصل خلال عملية التزاوج وتوضح هذه الطريقة للتزاوج الخوارزمية الآتية:

### **Algorithm ١x**

If  $(\text{rnd}() \leq P_c)$  then

Select random cut point  $K$  within the chromosome such that

$$K \in \{1, 2, \dots, l-1\}$$

Else

$$K \leftarrow l;$$

Endif

For  $i \leftarrow 1$  to  $K$  do

$$\text{Child } 1[i] \leftarrow \text{parent } 1[i];$$

$$\text{Child } 2[i] \leftarrow \text{parent } 2[i];$$

Endfor

If  $(K \neq l)$  then

For  $j \leftarrow k+1$  to  $l$  do

$$\text{Child } 1[j] \leftarrow \text{parent } 2[j];$$

$$\text{Child } 2[j] \leftarrow \text{parent } 1[j];$$

Endfor

Endif

**End**  $x$

يتم تطبيق الطفرة على كلا الطفلين المنتجين من خلال عملية التزاوج السابقة، تطبق الطفرة من خلال مسح الكوموسوم جينة جينة واجراء الطفرة عليها باحتمالية محددة (Pm)، حيث يتم استبدال تلك الجينة بمتجه صفات يتم انتقاؤه عشوائياً من مصفوفة البيانات ليكون مركز عنقود جديد ويشترط في عملية انتقاء هذا المتجه ان يكون مختلفاً عن بقية المراكز المحتواة في الكوموسوم، والخوارزمية الاتية توضح الطفرة:

### **Algorithm Mutation**

For  $l \leftarrow 1$  to  $l$  do

If  $(\text{rnd}() \leq Pm)$  then

Do

Select feature vector randomly from feature space;

While (the selected vector resembles any gene presented in the child chromosome);

Childk [i]  $\leftarrow$  newgen

Endif

Endfor

### **End Mutation**

← عملية الاحلال:

تمثل عملية الاحلال الخطوة التي يتم فيها ادخال الاطفال الجدد الى المجتمع في الطريقة المقترحة تم اختيار الطفل الاعلى صلاحية بين الطفلين واحلاله مكان اسوء طفل في المجتمع، الخوارزمية الاتية تمثل عملية الاحلال:

### **Algorithm replacement**

Select the best child from the two children

*If fitness (Ind[k]) < fitness (child [ ١])*

*ind[k]= child[ ١]*

*Else*

*ind[k]=child[ ٢]*

*Else ignore the new child;*

*endif*

**end replacement**

◀ معيار التوقف:

معيار التوقف المستخدم هنا هو الوصول الى الحد الاقصى من عدد الدورات الجينية او عند حصول تقارب في صلاحيات الافراد أي لا يوجد فرق كبير في صلاحيات افراد المجتمع.

◀ انتقاء الحل الافضل:

يمثل الحل الافضل الفرد الذي يمتلك اعلى صلاحية وبالتالي هو يمثل الصورة المجزأة.

**٣-٣-٤- الصورة المجزأة:**

الصورة المجزئة هي نتيجة تطبيق الخوارزمية الجينية بالصورة التي تم توضيحها بالفقرات السابقة، يتم اختبار نتيجة التجزئة من خلال تطبيق مقياس معدل الخطأ النسبي ( *Mean Relative Error*) لكل عنصر صورة، والعلاقة الاتية تمثل مقياس الخطأ النسبي [١٦]:

$$MRE = \frac{\sum_{x=1}^W \sum_{y=1}^H \frac{|f(x, y) - g(x, y)|}{f(x, y)}}{W \times H} \quad (3.2)$$

في هذه العلاقة فان  $f(x,y)$  تمثل عنصر الصورة الخاص بالصورة الاصلية و  $g(x,y)$  تمثل عنصر الصورة الخاص بالصورة المجزءة،  $W,H$  يمثلان ابعاد الصورة.

### ٣-٣-٥ - تحويل الفضاء اللوني:

كما ذكرنا سابقاً فان الصورة التي تدخل الى النظام هي صورة من نوع (RGB) ولكي تتم تهيئة الصورة الى المرحلة الاتية من الطريقة المقترحة نحتاج الى تحويل الصورة من الفضاء اللوني (RGB) الى الفضاء اللوني (HSV) وذلك لان الصفات التي سيتم استخلاصها من الصورة هي صفات التراكيب التي يتم اشتقاقها من مصفوفة الحدود المتزامن ذات التدرجات الرمادية والذي تم توضيحه في الفقرة (١-٣-٢)، والخوارزمية الاتية تبين كيفية تحويل الصورة من الفضاء (RGB) الى الفضاء (HSV):

### RGB to HSV conversion algorithm

Input:  $c=(r, g, b) \in [0, M]^r$

RGB are the red, green, blue primary color (0-1)

Output: (H, S, V)

H is the hue (0-360°) red at 0°

S is the saturation (0-1)

V is the value (0-1)

Determine the value

$$V = \text{Max}(R, G, B)$$

Determine saturation

$$\text{Temp} = \text{Min}(R, G, B)$$

$$\text{If } V = 0 \text{ then } S = 0$$

$$\text{Else } S = (V - \text{Temp}) / V$$

Endif

Determine the hue

$$\text{If } S = 0 \text{ then } H = \text{Undefined}$$

Else

$$Cr = (V - R) / (V - \text{Temp})$$

$$Cg = (V - G) / (V - \text{Temp})$$

$$Cb = (V - B) / (V - \text{Temp})$$

If  $R = V$  then  $H = Cb - Cg$  "The color between yellow and magenta"

If  $G=V$  then  $H= \gamma+Cr-Cb$  "The color between cyan and yellow"

If  $B=V$  then  $H= \xi+Cg-Cr$  "The color between magenta and cyan"

$H= \gamma * H$  "Convert to degrees"

If  $H < 0$  then "Prevent negative value"

$H=H+ 360$

End if

**Finish**

### ٣-٣-٦- الصورة ممثلة بالفضاء اللوني HSV:

عند تطبيق الخوارزمية أعلاه سوف نحصل على ثلاثة مكونات كل منه يعطي صورة أي ان (H component) تعطي صورة، والـ (S component) تعطي صورة والـ (V component) تعطي صورة كل من هذه الصور تمثل الصورة المجزئة الناتجة من عملية العنقدة، تم اخذ صورة مكونات القيمة (V component) لغرض استخراج الصفات منها والتي تمثل الصورة من نوع (gray level) الخاصة بالصورة المجزئة.

### ٣-٣-٧- استخراج الصفات:

بعد إتمام مرحلة تجزئة الصور تكون عملية استخراج الصفات هي المرحلة الآتية من عملية التصنيف.

مرحلة استخراج الصفات هي المرحلة التي يتم فيها إعطاء وصف أو قياس للكائنات الموجودة داخل الصورة. هذا الوصف أو القياس (measurement) هو قيمة تمثل بعض خواص الكائنات القابلة للقياس، أما الخواص (features) فهي دالة خاصة بصفة واحدة أو أكثر، تحسب وتحدد بعض الخواص الهامة بالكائن [٦١].

عملية استخلاص الصفات تنتج مجموعة من الخواص التي تأخذ مع بعضها البعض والتي تكون متجه الصفات (*features vector*), تقلل مرحلة استخلاص الصفات وبصورة كبيرة كمية المعلومات التي يمكن ان تمثل المعرفة التي بواسطتها يتم اتخاذ قرارات التصنيف وتستند هذه القرارات بصورة أساسية على هذه المعلومات [١٢].

### ٣-٣-٨- صفات التراكيب:

ان احدى الطرائق المهمة لوصف المناطق هي قياس محتوى تركيبها وعلى الرغم من انه لا يوجد تعريف شكلي (*formal identification*) للتراكيب (*texture*), فانه ينظر اليه على انه يضمن قياس لصفات النعومة (*smoothness*) و الخشونة (*coarseness*) [٢٥].

ان مصطلح التراكيب (*texture*) يشير الى تكرار عناصر التراكيب وهو مجموعة من عناصر الصورة (*pixels*) عادة تكون التراكيب الاعتيادية، تراكيب عشوائية تتصف بكونها (غير منتظمة، خشنة، متموجة)، تؤدي صفات التراكيب دوراً رئيساً في التعرف على الانماط والتشخيص الطبي [١١].

تصنف تقنيات وصف التراكيب الى ثلاث تقنيات هي (الاحصائية *statistical*، الهيكلية *structural* والطيفية *spectrum*), توفر الطريقة الاحصائية وصفاً لتراكيب النعومة والخشونة، اما الطريقة الهيكلية فانها تتعامل مع بدائيات الصورة (*primitives image*) مثل وصف الصورة بناءً على الخطوط المتوازية والمتباعدة بانتظام، اما الطريقة الطيفية فانها تعتمد على صفات التحويل فوريير (*Fourier transform*) [١٦]، ينصب الاهتمام في هذا البحث على الطريقة الاحصائية لوصف صفات التراكيب حيث ان الكثير من صفات التراكيب للطريقة تشتق من مصفوفة الحدوث المتزامن للمستويات الرمادية (*co-occurrence gray-level matrix*) تعد صفات التراكيب صفات المدرج التكراري للمستويات الرمادية ذات المرتبة الثانية (*second-order histogram*) (*features*)، أي إنها تؤمن تميزاً كمياً اضافياً لمحتوى التراكيب، ان صفات المدرج التكراري للمستويات الرمادية ذات المرتبة الاولى تعاني من المحدودية لكونها لا تعمل على معلومات تتعلق بمواضع العناصر لكن صفات التراكيب (صفات المدرج التكراري للمستويات الرمادية ذات المرتبة الثانية) لها القدرة على ادخال معلومات الى عملية تحليل التراكيب (*texture analysis*) فهي لا تأخذ بالحسبان توزيع مستويات الرمادية فقط بل الى مواقع العناصر ذات تدرج رمادي متساوٍ.

## ◀ وصف مصفوفة الحدوث المتزامن ثنائية البعد

### (Description of two dimensional co-occurrence matrix)

لقد تم اقتراح مصفوفة التزامن للتدرجات الرمادية من قبل (Haralick) في العام ١٩٧٣، هذه المصفوفة تستخدم لتحليل تراكيب الصورة لأنها تستطيع ان تعطي وصفاً مكانياً يعتمد على قيم المستويات الرمادية داخل الصورة.

لتكن مصفوفة الحدوث المتزامن ثنائية البعد (p) ذات حجم (n x n) حيث ان n تمثل عدد التدرجات الرمادية داخل الصورة. لأسباب حسابية يتم تقليل عدد التدرجات الرمادية أي استخدام التدرجات الموجودة داخل الصورة فقط، وبذلك يقل حجم المصفوفة. تمثل المصفوفة مرمك لـ (p[i,j]) تجمع عدد ازواج عناصر الصورة التي تمتلك الكثافة اللونية او القيمة اللونية (z, i). ازواج عناصر الصورة تعرف بواسطة مسافة (d)distance واتجاه direction (θ) والتي يمكن ان تمثل بواسطة متجه إزاحة هو (Z ∈ Zx, Zy) حيث Zx تمثل عدد العناصر على الاتجاه (X-axis) و Zy تمثل عدد عناصر الصورة بالاتجاه (Y-axis)، مصفوفة الحدوث المتزامن ثنائية البعد نستخدم اربعة اتجاهات حسب الزوايا (٠°, ٤٥°, ٩٠°, ١٣٥°) وقيمة الإزاحة هي d=١, بعد حساب مصفوفات التزامن الخاصة بكل اتجاه يتم حساب ثمان صفات من كل مصفوفة .

وهذه الصفات تحسب حسب المعادلات الآتية [٦٥].

#### ▪ Entropy

$$\sum_{i,j} P_{\phi,d}(i,j) \log_2 P_{\phi,d}(i,j) \quad (4.2)$$

#### ▪ Energy or angular second moment:

$$\sum_{i,j} P_{\phi,d}^2(i,j) \quad (5.2)$$

- **Maximum Probability:**

$$\max_{i,j} P_{\phi,d}(i, j) \quad (6.2)$$

- **Inverse Difference moment:  $\kappa=2, \lambda=1$**

$$\sum_{i,j;i \neq j} \frac{P_{\phi,d}^{\lambda}(i, j)}{|i - j|^{\kappa}} \quad (7.2)$$

- **Contrast:**

$$\sum_{i,j} |i - j|^{\kappa} P_{\phi,d}^{\lambda}(i, j) \quad (8.2)$$

- **Homogeneity:**

$$\sum_i \sum_j \frac{1}{1 + (i - j)^2} P_{\phi,d}(i, j) \quad (9.2)$$

- **Inertia or variance:**

$$\sum_i \sum_j (i - j)^2 P_{\phi,d}(i, j) \quad (10.2)$$

- **Correlation:** 
$$= \frac{\sum_{i,j} [(ij)P_{\phi,d}(i, j)] - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (11.2)$$

$$\mu_x = \sum_i i \sum_j P_{\phi,d}(i, j)$$

$$\mu_y = \sum_j j \sum_i P_{\phi,d}(i, j)$$

$$\sigma_x = \sum_i (i - \mu_x)^2 \sum_j P_{\phi,d}(i, j)$$

### ٣-٣-٩-شبكة بيزين العصبية (Bayesian Neural Network)

عند الوصول إلى شبكة بيزين العصبية هذا يعني إننا قد وصلنا إلى المرحلة الأخيرة من النظام المقترح وهي بناء شبكة عصبية تقوم بمهمة التصنيف لغرض بناء هذه الشبكة نحتاج الى معرفة التوزيع الطبيعي او (توزيع كاوس) اذ يعتمد تعليم الشبكة على هذا التوزيع.

#### تدريب شبكة بيزين العصبية:

ان مواصفات الشبكة في النظام المقترح هي شبكة متعددة الطبقات (*multi layers*) ذات تغذية أمامية (*feedforward*)، أي ان هذه الشبكة تتكون من عدة طبقات هي طبقة الإدخال (*input layer*) والطبقة المخفية (*hidden layer*) وطبقة الإخراج (*output layer*)، وبما ان الشبكة ذات تغذية أمامية فهذا يعني إن تغذية الشبكة تكون باتجاه واحد حيث تتغذى مجموعة الطبقة المخفية من مجموعة طبقة الإدخال، وتتغذى مجموعة طبقة الإخراج من مجموعة الطبقة المخفية، اما الموصلات التي تربط طبقة بالطبقة التي تليها فهي أوزان تلك الطبقة. تمثل الأوزان التي تربط طبقة الإدخال (*i*) بالطبقة المخفية (*j*) و  $w_{jk}$  هي الأوزان التي تربط الطبقة المخفية بطبقة الإخراج (*k*). تتسلم كل عقدة مخفية إدخالها من جميع عقد الإدخال مع أوزانها المستقلة اما عقد الإخراج فتتسلم إدخالها من العقد المخفية مع أوزانها المستقلة كما في المعادلات الآتية [٣]:

$$h_j = f \left[ \sum_{i=1}^n w_{ij} x_i \right] \quad (12.2)$$

$$y_k = f \left[ \sum_{j=1}^m w_{jk} h_j \right] \quad (13.2)$$

حيث ان

$h_j$ : تمثل اخراج العقدة المخفية

$y_k$ : تمثل اخراج عقدة الاخراج

$f(\cdot)$ : تمثل دالة لا خطية مستمرة (*nonlinear*) تتزايد على وتيرة واحدة (*increasing*)  
(*monotonically*) مستمرة قابلة للاشتقاق (*differential contentious*) والتي تسمى دالة التحفيز  
(*activation function*) وقد تم اختيار الدالة السجماوية (*sigmoid function*) وتمثلها المعادلة  
الآتية:

$$f(x) = \frac{1}{1 + \exp(-s)} \quad (14.2)$$

حيث ان  $s$  تمثل

$$s = \sum_{i=1}^n x_i w_{ij} \quad (15.2)$$

$$s = \sum_{j=1}^m h_j w_{jk} \quad (16.2)$$

وعند إضافة العتبة (*threshold*) إلى الشبكة والتي تصبح جزءاً من أجزاء العقد الموجودة في كل طبقة  
من طبقات الشبكة ما عدا طبقة الإخراج ويرمز للعتبة ( $\lambda$ ) فتكون المعادلتان السابقتان على ما يأتي:

$$h_j = f \left[ \sum_{i=1}^N w_{ij} x_i + \lambda_j \right] \quad (17.2)$$

$$y_k = f \left[ \sum_{j=1}^M w_{jk} h_j + \lambda_k \right] \quad (18.2)$$

### - تحديد الاوزان الابتدائية للشبكة

في البداية يتم تحديد اوزان عشوائية للشبكة بين (0-1) لطبقة الاخراج والطبقة المخفية، بعدها يتم حساب الاوزان من خلال التوزيع الاحتمالي السابق (*prior distribution*) والذي يمثل تقريب كاوس (*Gaussian approximation*) والمعادلة الاتية توضح هذا التوزيع:

$$p(w_{ij}) = (2\pi\omega^2)^{-\frac{M}{2}} \exp\left(-\frac{w_{ij}^2}{2\omega^2}\right) \quad (19.2)$$

$$p(w_{jk}) = (2\pi\omega^2)^{-\frac{M}{2}} \exp\left(-\frac{w_{jk}^2}{2\omega^2}\right) \quad (20.2)$$

حيث ان

M: عدد عقد الاخراج

$\omega$ : هو تقييس مناسب لمتجه الاوزان.

- بما ان شبكة بيزين العصبية هي شبكة تغذية أمامية فهذا يعني انها تحتاج إلى الإخراج المرغوبة (*desired output*) هذه القيم تستخدم في تعليم الشبكة وذلك بحساب مقدار الفرق بين الإخراج الفعلي للشبكة (*actual output*) والإخراج المرغوب (*desired output*)، وكما مر ذكره سابقاً فان شبكة بيزين تعتمد على حساب الاحتمالية في عملها فيجب حساب دالة التوزيع الاحتمالي المشروط واشتقاقها، حيث تمثل مشتقة الدالة الاحتمالية تعظيم مقدار الأوزان التي تعطي أفضل إخراج للشبكة والمعادلة الاتية تمثل اشتقاق تقريب كاوس للدالة الاحتمالية (*likelihood function*):

$$l'_k(d_k/x_k, w_{jk}) = -\frac{w_{jk}^2}{2\omega^2} - \frac{[d_k - f(x_k, w_{jk})]^2}{2\sigma^2} \quad (21.2)$$

حيث

$d_k$ : هو عبارة عن الإخراج المرغوب

$f(x_k, w_{jk})$ : يمثل الإخراج الفعلي للشبكة

$\sigma$ : هو مستوى الضوضاء في الإخراج.

تستخدم الدالة الاحتمالية في حساب الخطأ الحاصل في طبقة الإخراج لكل عقدة، أما الخطأ الحاصل في الطبقة المخفية فإن القيمة المطلوبة في العقدة المخفية غير معلومة لذا يستخدم الخطأ الموجود في عقدة الإخراج كما في المعادلة الآتية:

$$l'_j = h_j(1 - h_j) \sum_k (l'_k * w_{jk}) \quad (22.2)$$

ولحساب مقدار التحديث في أوزان طبقة الإدخال والطبقة المخفية فيكون على ما يأتي

$$\Delta w_{ij} = \eta l'_j x_i + \alpha \Delta w'_{ij} \quad (23.2)$$

حيث

$\Delta w_{ij}$ : يمثل مقدار التغير في أوزان طبقة الإدخال والطبقة المخفية

$\eta$ : عامل التعلم (*learning rate*) ويكون (0.1-0.3)

$\alpha$ : عامل التنعيم أو الزخم (*momentum rate*)

$\Delta w'_{ij}$ : يمثل مقدار الفرق بين الوزن الحالي والوزن السابق

: مقدار الخطأ عند العقدة  $j$

فيكون الوزن الجديد

$$w_{ij} = \Delta w'_{ij} + w''_{ij} \quad (24.2)$$

حيث ان  $w''_{ij}$  يمثل الوزن السابق

اما فيما يخص حساب مقدار التغير بين أوزان الطبقة المخفية وطبقة الإخراج فيكون

$$\Delta w_{jk} = \eta l'_k h_j + \alpha \Delta w'_{jk} \quad (25.2)$$

حيث ان

$\Delta w_{jk}$ : يمثل مقدار التغير في أوزان طبقة الإدخال والطبقة المخفية

$\eta$ : عامل التعلم (*learning rate*) ويكون (0.1-0.3)

$\alpha$ : عامل التنعيم او الزخم (*momentum rate*)

$\Delta w'_{jk}$ : يمثل مقدار الفرق بين الوزن الحالي والوزن السابق

$h_j$ : يمثل اخراج العقدة المخفية

: مقدار الخطأ عند العقدة k

ويصبح الوزن الجديد هو:

$$w_{jk} = \Delta w'_{jk} + w''_{jk} \quad (26.2)$$

إن المقياس الأساسي الذي يتم من خلاله معرفة مقدار تعلم الشبكة و الوصول إلى مجموعة الأوزان المثالية هو الحصول على اقل مجموع لمربع الخطأ (*Minimum Sum Squared Error*) SSE أو الوصول إلى قيمة صغيرة مقبولة [٤٦]. يفترض المستخدم في اغلب الخوارزميات القابلة للتكرار قيمة تقريبية تمثل الدقة المطلوبة للحل وعند الوصول الحل الى هذه القيمة تتوقف الخوارزمية وهذا ما يحصل في شبكة بيزين العصبية [٢٦]. والمعادلة الآتية تمثل المقياس الأساسي لقياس الخطأ:

$$SSE = \frac{1}{2} \sum_{i=0}^N \sum_{j=0}^M [d_j(i) - y_j(i)]^2 \quad (27.2)$$

حيث ان

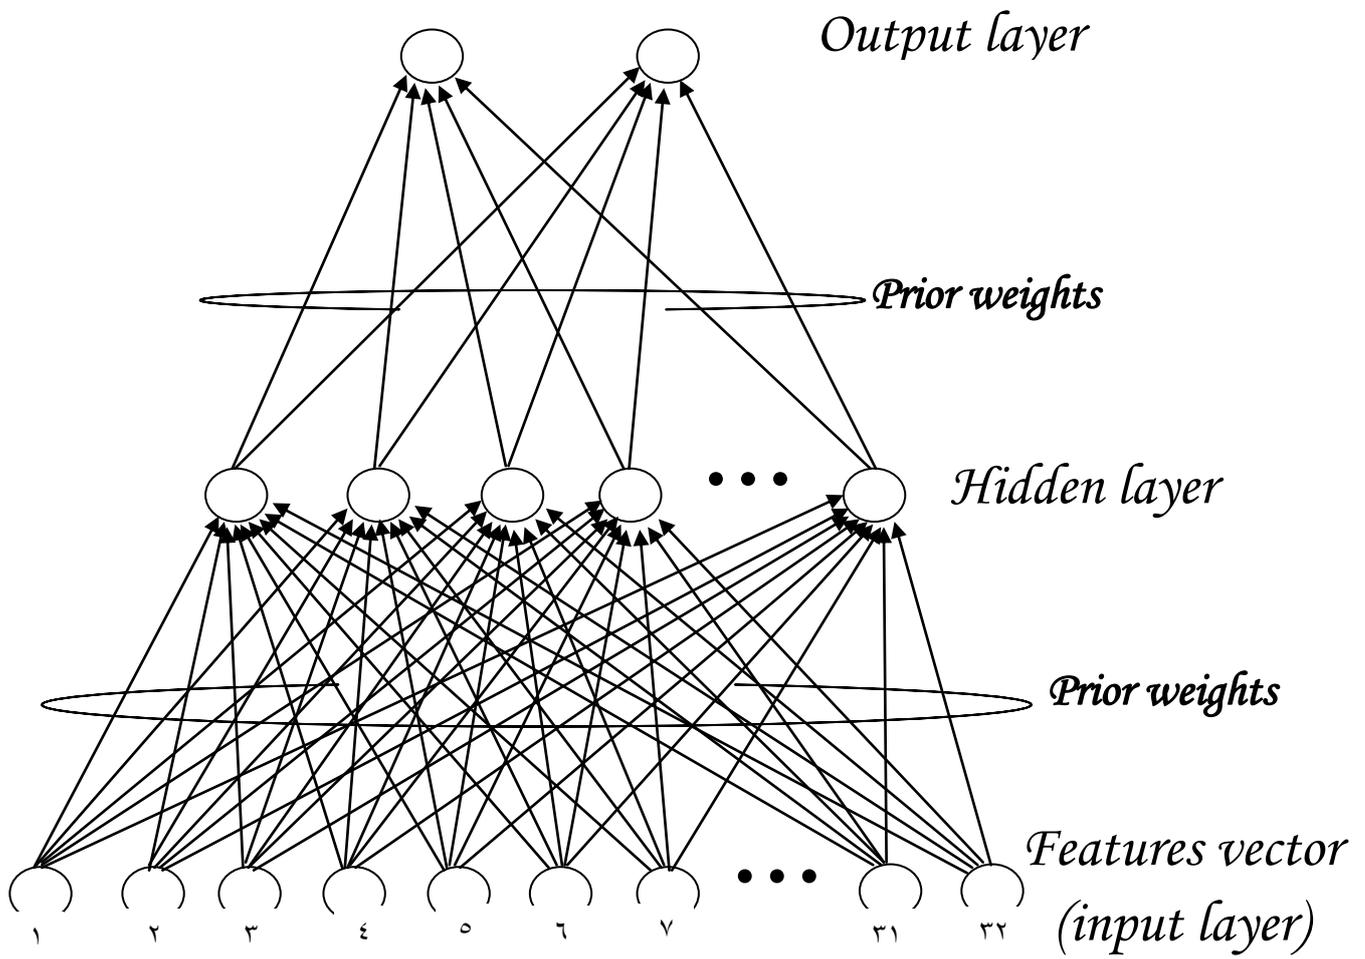
N: عدد انماط التدريب

M: عدد الاصناف

$d_j(i)$ : المخرجات المرغوبة لعقدة الاخراج z في حالة تدريب النمط i

$y_j(i)$ : المخرجات الفعلية لعقدة الاخراج z في حالة تدريب النمط i

## هيكل شبكة بيزين العصبية



شكل رقم (٤-٣) يمثل هيكل شبكة بيزين العصبية