



Distinguish Some Textile Defects by Adopting Image Processing Methods and Intelligence Techniques

Iman Subhi Mohammed

Computer Sciences Department
College of Computer Science and
Mathematics / Mosul University/ Iraq/

ImanSubhi@uomosul.edu.iq

DOI: [10.33899/edusj.1970.163333](https://doi.org/10.33899/edusj.1970.163333)

Israa mohammed khuder

Computer Sciences Department
College of Education for Pure Sciences
Mosul University/ Iraq/

israamoh@uomosul.edu.iq

Received

20 / 06 / 2018

Accepted

30 / 07 / 2018

Abstract

The automatic control of the fabric is one of the important steps in the spinning and weaving industry in order to preserve the quality of the fabric. The manual methods have been used for decades to control the product using human vision. The monitoring process is very strenuous, time consuming and cost effective. To reduce the costs required there arise the needing of automated systems appearance to examine, detect and apply tissue defects.

The aim of the proposed work is to build an efficient system for detecting and classifying textile defects using advanced image processing techniques based on new methods of combining the practical implementation of image segmentation and features extraction, as well as the use of artificial intelligence techniques of neural networks for detection and classification.

The system was built in two phases: the first is the defect detection phase, and the second phase is the classification phase, where live images were collected as a textile database from the textile factory in Mosul as well as the local market. The fabrics were carefully selected and these fabrics are of different types and colors, some of these have no defect at all and some of them have up to fourteen types of defects. 560 images were collected; 280 of which were non defective fabrics, 280 were defective, and there are 20 images for every type of defect, at the defect detection phase, the statistical second-class attributes of the GLCM matrix (energy, variance, correlation, homogeneity) are extracted, while in the classification phase, the statistical first-class attributes, mean and skewness, and the geometric attribute of the total defect size. Two neural networks were used as determinants of detection and classification: the Back Propagation Neural Network (BPNN) and the Elman network. The proposed system showed a 95.7% discrimination rate compared with other similar work in the same field.

Keyword: textile, weft direction defect, warp direction defect, Hole, Stain, statistical approaches, neural-networks, mean, Skewness, median.

تمييز بعض عيوب نسيج القماش باعتماد طرائق معالجة الصور والتقنيات الذكية

إسراء محمد خضر

قسم علوم الحاسوب

كلية التربية للعلوم الصرفة

العراق/ جامعة الموصل

israamoh@uomosul.edu.iq

DOI: [10.33899/edusj.1970.163333](https://doi.org/10.33899/edusj.1970.163333)

إيمان صبحي محمد

قسم علوم الحاسوب

كلية علوم الحاسبات والرياضيات

العراق/ جامعة الموصل

ImanSubhi@uomosul.edu.iq

القبول

2018 / 07 / 30

الاستلام

2018 / 06 / 20

الملخص

تعد مراقبة النسيج بصورة تلقائية من الخطوات المهمة في صناعة الغزل والنسيج؛ وذلك لصيانة جودة القماش ولضمان الجودة ومطابقة المنتجات للقياسات النوعية، واستعملت الطرائق اليدوية لعقود طويلة لمراقبة المنتج وذلك باستعمال الرؤية البشرية، وتعد عملية المراقبة بهذا الأسلوب شاقة جداً ومستهلكة للوقت والكلفة، ولاختزال كل أنواع الكلفة تطلب ظهور أنظمة تلقائية لفحص عيوب النسيج وكشفها وتطبيقها. يهدف العمل المقترح إلى بناء نظام كفاءٍ لكشف عيوب الأقمشة وتصنيفها؛ وذلك باستخدام تقنيات معالجة الصور المتقدمة المعتمدة على طرائق جديدة في الدمج بين التنفيذ العملي لتقطيع الصور واستخلاص الصفات منها، فضلاً عن استعمال تقنيات الذكاء الاصطناعي المتمثلة في الشبكات العصبية للكشف والتصنيف. تم بناء النظام بمرحلتين: الأولى: هي مرحلة كشف العيوب، والمرحلة الثانية: هي مرحلة التصنيف، حيث تم جمع صور حيّة بوصفها قاعدة بيانات لأقمشة من معمل الغزل والنسيج في الموصل فضلاً عن السوق المحلية، تم اختيار صور الأقمشة بعناية وهذه الأقمشة بأنواع وبألوان مختلفة، منها سليمة من العيوب، ومنها متضمنة على أربعة عشر نوعاً من العيوب؛ إذ تم تجميع 560 صورة قماش، 280 منها صور لأقمشة سليمة من العيب، فضلاً عن 280 صورة أخرى لأقمشة معيبة، ولكل صنف من العيوب 20 صورة. في مرحلة اكتشاف العيوب تم استخلاص الصفات الإحصائية من الدرجة الثانية من مصفوفة (GLCM) Gray-Level Co-Occurrence Matrix (الطاقة، التباين، الارتباط، والتجانس)، أما في مرحلة التصنيف فقد تم استخلاص الصفات من الدرجة الأولى المعدل، والميل، والصفة الهندسية المتمثلة بحجم العيب الكلي. وقد استعمل شبكتان عصبيتان بوصفهما محددان للكشف هما شبكة الانتشار العكسي BPNN وشبكة Elman، أوضح النظام المقترح نسبة تمييز 95.7% مقارنة بنتائج أعمال أخرى مقارنة وفي المجال نفسه.

الكلمات المفتاحية: نسيج القماش، عيب باتجاه اللحمة، وعيب باتجاه السداء، الثقب، البقعة، الطرائق الإحصائية، الشبكات العصبية، المعدل، الالتواء، الوسيط .

1. المقدمة

أن أهمية السيطرة النوعية على المنتجات الصناعية تزداد يوماً بعد يوم، وتعرف السيطرة النوعية بأنها "معرفة مدى مطابقة المنتجات للمواصفات القياسية ومعرفة أسباب الانحراف والإجراءات اللازمة لذلك" وتعد صناعة الغزل والنسيج من الصناعات التي تتطلب الجودة لتلبية رغبة المستهلك، وأمست الرقابة عليها أكثر أهمية عند المنتج للوفاء برغبة المستهلك [1]. إن مرور أية كمية غير مطابقة للمواصفات المطلوبة يقلل من سعر القماش بنسبة (45%) - (65)%. [2] لذا فقد أولى الباحثون اهتماماً كبيراً لأنظمة فحص الغزل والنسيج الأوتوماتيكية والتي تختصر الوقت بشكل كبير بالإضافة إلى ما تعطيه من دقة عالية في عملية الفحص [3].

2. الدراسات السابقة

لقد تم إجراء عدد من المحاولات لجعل عملية فحص النسيج آلية وقد تركزت معظمها في الكشف عن العيب وتركز عدد قليل منها على التصنيف [1] [4]. إذ استعملت عدة طرائق للتصنيف وكانت النتائج متفاوتة الكفاءة، وفيما يأتي نبذة لبعض البحوث التي استعملت لغرض كشف وتصنيف عيوب الأقمشة وبالشكل التالي:

- في سنة 2007 قدم الباحثان Wang Jianxia و Zheng Guang [5] طريقة للكشف عن عيوب النسيج تعتمد على تقنيات معالجة الصور وتسمى فرق البعد الحسابي للصورة image distance difference arithmetic ومبدأ الطريقة سهل جداً وذلك بطرح إحدى الصور من الأخرى الأمر الذي يعكس الاختلاف بين الصورتين في اللون والإضاءة والملمس والإطار، وكان معدل دقة تحديد العيب (92)%.
- في سنة 2008 تناول الباحثان K.L.Mak و P. Peng [6] عملية الكشف عن عيوب النسيج بواسطة مرشحات Gabor المثالية. وقد تم اختيار شبكة موجات Gabor كتقنية رئيسية لاستخلاص ميزات النسيج وبالاستناد على هذه الميزات تم تصميم مرشح Gabor المثالي وبالاعتماد على قاعدة بيانات مكونة من 78 صورة متنوعة من عيوب النسيج.
- اقترح P. Peng و آخرون سنة 2009 [7] نظاماً للكشف الآلي عن عيوب الأقمشة يتكون من شبكة Gabor الموجية المتضمنة طبقة مخفية واحدة مع العديد من المرشحات المورفولوجية البسيطة وتم ذلك بالاعتماد على قاعدة بيانات تتكون من 78 صورة نسيج منها 39 صورة خالية من العيوب وبقية الصور تتضمن عيوب متنوعة. وقد أثبتت نتائج الاختبار فعالية الطريقة في الكشف عن العيوب بنسبة (97.4)%.
- قدم الباحث TE-LI SU وآخرون سنة 2010 [8] عملاً يوضح الكشف الأوتوماتيكي لعيوب النسيج باستخدام التحويل الموجي لاستخلاص الصفات ثم تصنيف العيوب باستعمال الشبكة العصبية ذات الانتشار العكسي. وقد تم دمج طريقة تاكوجي (Taguchi method) بالشبكة العصبية مما أعطى سرعة في التصنيف وبمعدل تمييز يصل إلى (96.5)% .
- في سنة 2011 قدم الباحث S.Priya وآخرون [9] طريقة جديدة للكشف عن عيوب النسيج باستعمال الطرائق المورفولوجية البسيطة والبعيدة عن التعقيدات الحسابية. وقد تم الاعتماد على قاعدة بيانات صور (TILDA) وقد كان معدل دقة التصنيف يقدر بـ (90.8)%.

- في سنة 2012 قدم الباحثان M. Rokonuzzaman و Md. Tarek Habib [1] بحثاً بعنوان مجموعة من الصفات الهندسية لتصنيف عيوب النسيج بواسطة الشبكة العصبية. والمتضمن حساب الصفات الهندسية لمنطقة العيب مثل عرض وارتفاع نافذة العيب وعدد المناطق المعيبة والمساحة الكلية للعيب وذلك باستخدام نوع واحد من التراكيب النسيجية وقاما بتصنيف خمسة أنواع من أنواع العيوب بالاعتماد على قاعدة بيانات مكونة من 100 صورة 33 منها صور سليمة من العيب و كانت دقة التصنيف (98)%.
- وفي السنة نفسها قدم الباحثان Anand H. Kulkarni و Sheetal B. Patil [2] نموذج كشف وتحديد عيوب النسيج الأوتوماتيكي بالاعتماد على صفات النسجة ومقاييس تواجد المستوي الرمادي Gray Level Co-occurrence Matrix (GLCM) والشبكة العصبية الاحتمالية والنموذج المقترح أعطى نتائج دقيقة لتصنيف عيوب النسيج بمجموعة صغيرة من عينات التدريب وهي 10 عينات لكل عيب. وقد كان المعدل الإجمالي لنجاح تحديد النسيج هو (96.6) % ونسبة نجاح الكشف عن العيب هي (91.1) %.
- في سنة 2013 قدم Ali Javed وآخرون [10] مقارنة وتحليلاً لتقنيات مختلفة في كشف عيوب النسيج وقد بينت المقارنة بين طريقة Regular Band (RB) تعد أفضل بكثير من أي تقنيات أخرى ونسبة كشف (99.4) % لأنها تستعمل مفهوماً بسيطاً من الانحراف المعياري والمتوسط المتحرك. وطريقة RB هي إحدى طرائق كشف عيوب النسيج المزخرف بكفاءة وسرعة وتستند إلى منهج الانتظام والدورية بمعنى تكرار وحدة من الزخرفة بانتظام وأي إشارة عدم انتظام في الزخرفة تعد إشارة إلى وجود عيب في الصورة [3]. كما وأوضحت المقارنة بين دقة مرشحات Gabor الموجية تصل إلى (96.0) % وبهذا تعد أفضل تقنية مستعملة لحد الآن.
- أما في عام 2014 فقد عمل الباحث Michael K.Ng وآخرون [11] على تحليل نماذج ورقية و نسيجية من الأقمشة المنقوشة بعدة نقشات منها المنقط والمربعات والمنجم، وقام بفحص وتصوير العيوب في هذه الأقمشة بواسطة خوارزمية التحسين المحدبة، وقد حصل على نسبة كشف تتراوح ما بين (94.9) % - (99.6) %.
- في سنة 2015 اعتمد الباحث Ali Rabhi وآخرون [12] على التجانس المحلي والشبكة العصبية للحكم على وجود العيوب في صور النسيج بعد تطبيق تحويل جيب التمام المتقطع DCT واستخلاص صفات الطاقة من الصور، وقد حصل على نسبة كشف تصل إلى (97.35) %.
- كما قدم الباحث P.Y. Kumbhar وآخرون [13] في عام 2016 طريقة جديدة تعتمد على الخوارزمية الجينية واستخلاص بعض الصفات الهندسية واستعمال آلة المتجه الداعم SVM كمصنف لعيوب النسيج وقد نجح الباحثون في تصنيف (90.0) % من العيوب.
- وفي سنة 2017 اقترح الباحث Sunil Bangare وآخرون [14] طريقة لكشف عيوب النسيج باستعمال RGB وتقنيات HSV واساليب معالجة الصور وكانت دقة الكشف التي حصل عليها (96.15) %.
- وفي سنة 2018 تناول الباحث Shuang Mei وآخرون [15] طريقة جديدة تعتمد على إعادة بناء الصورة بعد تصحيحها باستعمال شبكة التشفير التلقائي لتقليل الضوضاء في Gaussian pyramid، وقد اعتمد كل تصحيح كمؤشر للتنبؤ بالكسل التالي، ومن خلال التقسيم والتجميع للمتبقين من الصورة

المعاد بناؤها وعلى كل مستوى من مستويات الدقة حصل على النتيجة النهائية للفحص، وقد وصلت الدقة الشاملة للفحص الى اكثر من (80.0)%.

3. التراكيب النسيجية


يتكون القماش المنسوج Woven fabric من تشابك مجموعتين من الخيوط بشكل متعامد، المجموعة الأولى تسمى السدى "Warp" وهي الخيوط الطولية، والأخرى تسمى اللحمة أو الحشو "Weft" وهي الخيوط العرضية، يأخذ شكل التشابك بين هاتين المجموعتين من الخيوط أشكالاً متباينة ومتعددة، إلا أنها تتدرج تحت نظام ثابت يعرف بالتركيب النسيجي، وتوجد ثلاثة أنماط للتراكيب النسيجية وهي بالشكل التالي [16]، [17]:

- (1) النسيج العادي أو السادة **plain weave**: يعد أبسط أنواع النسيج وأكثرها انتشاراً. ومن الأمثلة على الأقمشة السادة التفتا، الشيفون، الشاش، الأورجنزا، الجورجيت، التيل، والبولين وكما في الشكل (1).
- (2) النسيج المبرد **twill weave**: يظهر على شكل خيوط مائلة قطرية، وفيه تتعاشق خيوط السداء مع خيوط اللحمة في زوايا 45 درجة [13]. ومن الأمثلة على الأقمشة المبردية الجينز والفانيليا لاحظ الشكل (2).
- (3) نسيج الأطلس **satin weave**: يتميز بصفة عامة بسطح لامع نتيجة لتفرق مواضع تقاطع القتل وللحلمات مما يسمح بزيادة انعكاس الضوء على القماش [18]. والشكل (3) يوضح هذا النوع من النسيج.



4. تحليل العيوب defect analysis

تعتبر عملية تحليل العيوب خطوة مهمة في عملية فحص النسيج الأوتوماتيكي، وهي تعتبر من العمليات الأولية التي تسبق الكثير من خطوات العمل. وان تحليل العيوب يساعد في فهم خصائصها، مما يعطي دلائل على اختيار الصفات المناسبة. ولقد تم التعامل مع أربعة عشر نوعاً من عيوب النسيج والتي اعتمدت في قاعدة بيانات البحث ومن هذه العيوب ما يسببه فقدان جزء من خيوط اللحمة كما في الشكل (4-a)، ومنها سببه تشابك غير صحيح لخيوط اللحمة والسداة شكل (4-b)، والبعض يبدو بشكل قريب من الدائرة كما في الشكل (4-c)، ومن العيوب ما تكون في شكل متناثر من لون مختلف كما في الشكل (4-d) وغيرها [1]، [19].



شكل (4) صور بعض انواع العيوب: (4-a) Missing picks ، (4-b) Float ، (4-c) Hole ، (4-d) Stain

5. أساليب فحص النسيج

تصنف أساليب فحص النسيج إلى ثلاثة أصناف وهي:

* **الاساليب الإحصائية statistical approaches** والتي تعتمد على السلوك الإحصائي الثابت في المناطق الخالية من العيوب. ومن أمثلتها الكشف عن الحواف edge detections والارتباط المتقاطع cross-correlation [20]، [21]، [22].

* **الاساليب الطيفية spectral approaches** وتستعمل عندما تعجز الاساليب الإحصائية في كشف العيوب التي تظهر عند تحولات الكثافة الخفية والدقيقة جداً. ومن أمثلتها مرشحات جابور Gabor filters [20]، [21]، [22].

* **الاساليب المستندة إلى نموذج model-based approaches** [20] وهي اساليب مناسبة لصور النسيج التي تحتوي اختلافات السطح العشوائية كذلك للأقمشة المزخرفة بشكل عشوائي أو النقش اليدوي ويعد نموذج ماركوف كاوس العشوائي Gauss Markov Random Field model إحدى الاساليب في هذا المجال [20]، [21]، [22].

6. التقنيات الذكائية

إن السرعة التي يقوم الحاسب بها في عملياته الرياضية يمكن استعمالها في الكثير من المهام غير الرياضية البحتة أيضاً، فقد تكونت حقول جديدة تقع تحت مظلة الذكاء الاصطناعي كان من بينها حقل للتعرف على الأشكال والصور والنماذج، وقد دخل في تطبيقات عديدة مثل التعرف على المواقع، والتطبيقات العسكرية، والتقيب عن المعادن، والإبحار في المحيطات، وسفن الفضاء وغير ذلك [23]، وقد تم استعمال الشبكات العصبية كإحدى التقنيات الذكائية لغرض الكشف عن العيوب وتصنيفها [24]، ومن الشبكات المستخدمة في البحث ما يلي:

- **الشبكة العصبية ذات الانتشار العكسي (BPNN) Neural Network Back Propagation:**

التي تقوم على التدريب بنمط تصحيح الخطأ، حيث يتم إعادة انتشار الإشارة من الخرج إلى الدخل بشكل عكسي بوصفها إحدى مراحل التعليم ويتم خلالها ضبط أوزان الشبكة وحساب التغيرات فيها وحساب مربع الخطأ Mean (MSE) Square Error والذي ينتج من الاختلاف بين الإخراج الفعلي والإخراج المطلوب، ويستخدم الخطأ في تغيير الأوزان؛ وذلك لتقليل الخطأ تدريجياً، ويتوقف التدريب عند الحصول على أقل نسبة خطأ لكل خلية من خلايا الإخراج، فإذا اعتبر أن إشارة الإدخال e ، إذ $t_i[e]$ يمثل الإخراج المطلوب وإن o_i هو الإخراج الفعلي، فيتم حساب دالة الخطأ كما في المعادلة (1) [25]:

$$E[e] = \frac{1}{2} \sum_i (t_i[e] - o_i)^2 \quad \dots (1)$$

- **شبكة Elman:** وهي إحدى الشبكات العصبية التكرارية recurrent التي تتكون من طبقتين مع وجود تغذية الانتشار العكسي التي تتضح في إعادة إخراج الطبقة الأولى إلى إدخال الطبقة الأولى، وهذه الميزة تعطي إمكانية للشبكة لتصل إلى الحل الأمثل مع سرعة في التدريب وضبط الأوزان. ومن

مميزات شبكة Elman أن لديها ذاكرة ديناميكية قوية؛ لذا فهي تستعمل في مجالات مختلفة كالتصنيف، والتنبؤ، وأنظمة التعريف الديناميكي، والسيطرة الكيفية وغيرها [26].

7. مرشحات Gabor

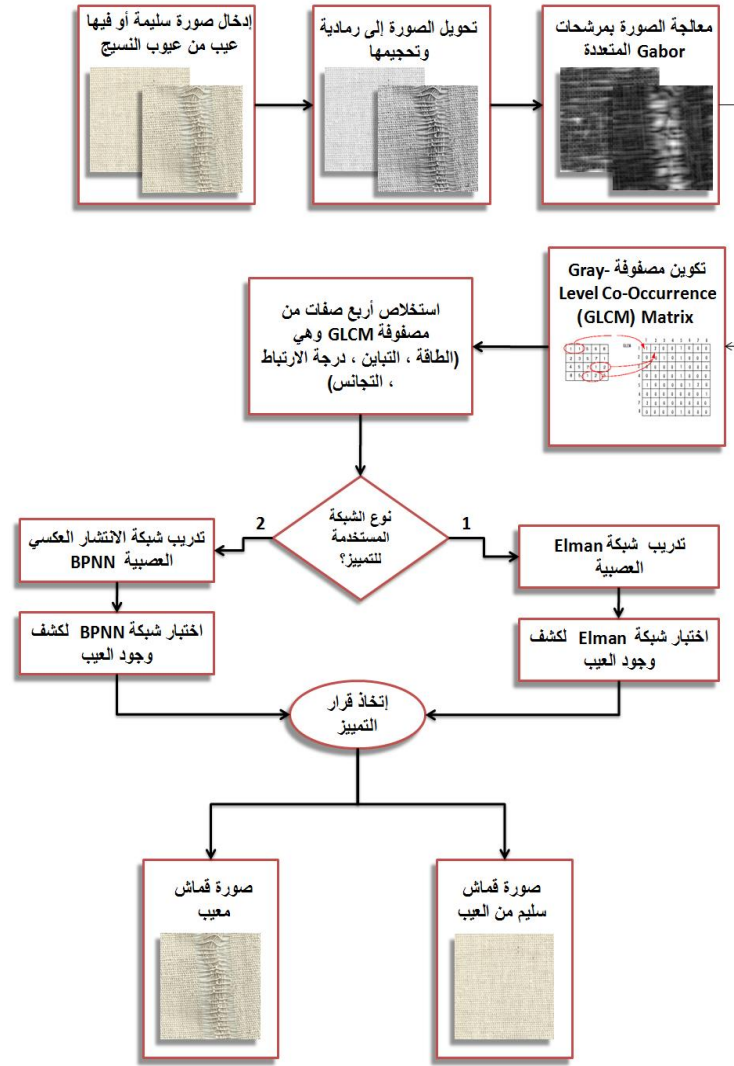
تقلد مرشحات Gabor قدرات العقول البشرية في التعرف على النسيج [27]؛ وذلك لأن دوال Gabor تشابه شبكية العين؛ إذ تحلل الصور إلى العديد من الصور النقية filtered images، وكل منها يحتوي على كثافات متفاوتة على نطاق ضيق من التردد والاتجاه، وتكون مرشحات Gabor ذات البعدين (2-D) في المجال المكاني عبارة عن Gaussian Kernel Function مضمنة بواسطة الموجة الجيبية sinusoidal plane wave، ويمكن تعريف مرشحات Gabor على أنها "مجموعة من الموجات، مع كل موجة تلتقط الطاقة بتردد معين واتجاه معين"، لذا فمرشحات Gabor ذات البعدين لها ميزة وكفاءة في تجميع المعلومات المحلية للصورة بشكل مثالي، فضلاً عن قابليتها في الوصول إلى الحد الأدنى لأوجه التشابه ما بين الحيز المكاني والحيز الترددي للبيانات، وقد استعملت مرشحات Gabor في العديد من تطبيقات تحليل الصور بما في ذلك تجزئة النسيج، وكشف العيوب، وتمييز الوجوه، واسترجاع الصور [28]. والمعادلة رقم (2) تمثل معادلة جابور ذات البعدين 2D-Gabor function [29]:

$$g_{w2D}(x, y) = \frac{1}{\sigma\sqrt{\pi}} e^{-\left(\frac{(x-x_0)^2+(y-y_0)^2}{2\sigma^2}\right)} e^{-j2\pi f_0((x-x_0)\cos(\theta)+(y-y_0)\sin(\theta))} \dots (2)$$

إذ تمثل σ الانحراف المعياري لمغلف كاوزين sigma/ standard deviation of Gaussian envelope ، أما θ فهي زاوية الاتجاه orientation لدالة جابور و (x_0, y_0) هي نقطة قمة الدالة peak of the function.

8. خطوات خوارزمية العمل المقترحة

تضمنت خوارزمية العمل المقترحة مرحلتين المرحلة الأولى هي اكتشاف العيوب وتصنيفها إلى صنفين معيب و غير معيب والمرحلة الثانية هي تصنيف العيوب إلى أربعة عشر صنفاً. في المرحلة الأولى تمت معالجة الصور من حيث تحجيمها ولقد استخدمت خوارزمية التحجيم imresize bilinear لهذا الغرض، ومن ثم معاملتها بمرشحات Gabor المتعددة؛ وذلك لإبراز العيوب الموجودة ومن ثم حساب مصفوفة GLCM واستخلاص الصفات الإحصائية من الدرجة الثانية وهي (الطاقة، التباين، درجة الارتباط و التجانس) من كل صورة لتكوين مصفوفة الإدخال إلى الشبكة العصبية لتقوم بتمييز صنفين من الأقمشة هما صنف أقمشة سليمة وصنف أقمشة معيبة. وقد تم استخدام شبكتين عصبيتين كمصنفين هما Elman أو BPNN وذلك لمقارنة نتائج الشبكتين واعتماد الشبكة الأفضل من حيث زمن التدريب ودقة وسرعة الكشف والشكل (5) يوضح خطوات كشف العيوب .



شكل (5) خوارزمية مرحلة اكتشاف العيوب

أما في المرحلة الثانية فيتم معالجة الصور المعيبة الناتجة من المرحلة الاولى، ومن ثم تقطيع هذه الصور واستخلاص الصفات الإحصائية المناسبة، لتقوم إحدى الشبكتين العصبيتين BPNN او Elman بعملية تصنيف العيوب إلى أصنافها الاربعة عشر .

أ- تكوين قاعدة البيانات وتحجيم الصور

تمت الدراسة بعد الزيارة الميدانية لمعمل الغزل والنسيج في الموصل في كانون الثاني من العام 2014 إذ جمعت صور الأقمشة بصورة حية من خلال التقاطها بكاميرا رقمية نوع (samsung nv lens) وبدقة (8 mega pixel) فضلا عن أخذ عينات من الأقمشة من المعمل ومن السوق المحلية واكتساب الصور منها عن طريق الماسح الضوئي نوع (HP) وبدقة (300 dpi) إذ تم التعرف على أنواع من الأقمشة والعيوب الموجودة فيها فضلا عن صور أخرى سليمة لتتم المقارنة بها. خزنت الصورة بملف ذي امتداد png ، ويشار من خلال [30] إلى أن الصور المخزونة بهذا الامتداد من نوع المضغوطة بلا فقدان للبيانات والتي تدعم الألوان الحقيقية لذلك تعد

الأفضل للتعديل على الصور مقارنة بالصور ذات الامتداد jpg والتي هي من نوع المضغوطة القابلة لفقد البيانات وتقل جودتها مع كثرة الحفظ والتعديل. والشكل (6) يوضح عينات من صور قاعدة البيانات. وتمّ تجميع 560 صورة قماش؛ 280 منها صور سليمة و280 صورة أخرى فيها أنواع العيوب الأربعة عشر، ولكل صنف من العيوب 20 صورة لتتكون قاعدة بيانات حية متضمنة أنواع التركيب النسيجية وأصناف العيوب المختلفة.



شكل (6) صور من قاعدة البيانات

ب- المرحلة الأولى - مرحلة اكتشاف العيوب في الأقمشة

تتمّ في هذه المرحلة معالجة صور القماش المعيبة والسليمة وهي 560 صورة باستعمال خاصية قوة التمييز بين النسيج المعيب والنسيج السليم من العيب؛ وذلك لغرض كشف وجود العيب، وتمييز صور الأقمشة بوساطة الشبكات العصبية إلى فئتين: قماش سليم وقماش معيب. وكما في الخطوات التالية:

(1) المعالجة الأولية: بعد قراءة الصورة يتم تحويلها إلى صورة رمادية، لتقليل العمليات الحسابية إذ يتم تحجيم الصورة واعتماد التدرج الرمادي (gray level) في التعامل مع محتويات الصورة، ثم معاملتها بمرشحات Gabor، وان استعمال هذا النوع الخاص من المرشحات مثل مرشح Gabor أعطى نتائج أفضل في تحسين وإبراز معالم النسجة.

(2) استخلاص الصفات: حيث تستخلص صفات النسجة باعتماد طريقة حساب التبعية المكانية للمستوى الرمادي (Spatial Gray Level Dependence Method (SGLDM)، وتبدأ الطريقة أولاً بحساب مصفوفة مقاييس تواجد المستوى الرمادي (Gray-Level Co-occurrence Matrix (GLCM)، ومن ثم استخلاص الصفات من هذه المصفوفة بالكامل، وتعطي المصفوفة معلومات عن التردد النسبي لمواقع أزواج القيم الرمادية التي تفصلهم المسافة d وبزاوية θ ، وكل قيمة في مصفوفة GLCM يشار إليها بالرمز $P_a^{(i,j)}$ ، وتمثل احتمالية الذهاب من نقطة واحدة one pixel من المستوى الرمادي (i) إلى نقطة أخرى بالمستوى الرمادي (j) بالمسافة d والزاوية θ ، وتستخلص أربع صفات مهمة في النسجة والتي تحسب من مصفوفة GLCM وهي: الطاقة، والتباين، ودرجة الارتباط، والتجانس، توصفها المعادلات من 3 إلى 6 على التوالي [31]:

- الطاقة **Energy**: وهي تقيس مدى اتساق النسجة بمعنى تكرار أزواج محددة من النقاط، وتحدث الطاقة العالية عندما يكون توزيع قيم المستوي الرمادي بشكل ثابت أو دوري، وتوضحها المعادلة (3):

$$Energy = \sum_i \sum_j p_d^2(i, j) \quad \dots (3)$$

- التباين **Contrast**: ويقاس الفرق بين أعلى القيم وأدناها لنقاط المستوي الرمادي للنسجة، وأقل تباين لصفات النسجة يكون في الترددات المكانية القليلة وتحسبها المعادلة (4):

$$Contrast = \sum_i \sum_j (i - j)^2 p(i, j) \quad \dots (4)$$

- الارتباط **Correlation**: ويقاس الاعتمادية المكانية في الصورة، وتدل قيم الارتباط العالية على خطية العلاقات بين المستويات الرمادية وأزواج نقاط الصورة، والمعادلة (5) توضح طريقة قياس صفة الارتباط.

$$Correlation = \frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i, j)}{\sigma_x \sigma_y} \quad \dots (5)$$

إذ إن:

$$\mu_y = \frac{1}{n} \sum_{i=1}^n j \sum_{j=1}^n p_d(i, j) \quad \text{و} \quad \mu_x = \frac{1}{n} \sum_{i=1}^n i \sum_{j=1}^n p_d(i, j)$$

$$\sigma_y = \sum_{j=1}^n (j - \mu_y)^2 \sum_{i=1}^n p(i, j) \quad \text{و} \quad \sigma_x = \sum_{i=1}^n (i - \mu_x)^2 \sum_{j=1}^n p(i, j)$$

- زاوية العزم الثاني **Angular Second Moment**: وتقيس تجانس النسجة Homogeneity بإعطاء قيمة تمثل قرب توزيع عناصر مصفوفة GLCM من قطر المصفوفة، وتحسب هذه القيمة بواسطة المعادلة (6):

$$AngularSecondMoment = \sum_i \sum_j \frac{p(i, j)}{1 + |i - j|} \quad \dots (6)$$

ثم يتم تنسيب normalization قيم الصفات المستخلصة التنسيب الطبيعي القياسي normal standard normalization؛ وذلك بطرح المعدل μ_i من كل منها والقسمة على الانحراف المعياري σ_i باعتماد المعادلة (7) [31]؛ وذلك للتخلص من الفروقات الكبيرة ما بين القيم وحصر القيم بين الصفر والواحد، ثم يتم وضع القيم الناتجة في متجهات تمثل صفات الصور، ومن ثم تنتج مصفوفة عبارة عن $(K \times M)$ ، إذ إن K : عدد الصور و M : عدد الصفات، ليكون لدينا مصفوفة الإدخال للشبكة العصبية.

$$x_{i_{normalized}} = \frac{x_i - \mu_i}{\sigma_i} \quad \dots (7)$$

إذ تمثل x_i متجه قيم الصفات قبل التنسيب، في حين يمثل $x_{i_{normalized}}$ متجه قيم الصفات بعد التنسيب.

3) كشف العيب : يتم في هذه المرحلة التعامل مع صور الفحص لغرض تحديد وكشف وجود العيب من عدم وجوده في هذه الصور وذلك باستعمال الشبكات العصبية التي يكون التعليم فيها بواسطة معلم Supervised Learning وبذلك تكون فئة التدريب عبارة عن زوج مكون من متجه الإدخال input والمتجه المستهدف target، وهذه المرحلة تمر بطورين هما طور التدريب لتدريب الشبكة على صفات كل صورة والإخراج المتوقع لها، وقد خصصت في هذه المرحلة 420 صورة كعينة للتدريب، وطور الاختبار ليتم من خلاله اختبار الشبكة على صور جديدة لم تتعلم عليها الشبكة تسمى صور الاختبار وقد تم تهيئة 140 صورة كعينة للاختبار. في طور التدريب يتم تدريب الشبكة على متجهات صفات الصور والتي تم تكوينها بعد استخلاص الصفات من الصور. وذلك لغرض تعليم الشبكة لتتمكن من الكشف عن وجود العيب وتصنيف كل صورة إما إلى صورة معيبة أو سليمة من العيب، بغض النظر عن نوعية العيب والنتيجة بالنظام الثنائي بمعنى إذا كان الإخراج "0" فهي صورة خالية من العيب إما إذا كان الإخراج "1" فالصورة معيبة. في طور الاختبار يتم اختبار الشبكة العصبية لكشف العيب وتتبع نفس خطوات المعالجة الأولية واستخلاص الصفات لغاية الحصول على متجه صفات الصورة المدخلة، يدخل هذا المتجه إلى الشبكة العصبية للتعرف على نوع الصورة فإذا كان الإخراج "0" فإن صورة الاختبار تنتمي إلى الصنف الأول وتمثل صورة نسيج خالية من العيب إما إذا كان الإخراج "1" فإن صورة النسيج تنتمي إلى الصنف الثاني وتمثل صورة نسيج فيه عيب.

ج- المرحلة الثانية- تصنيف عيوب النسيج

ويتم في هذه المرحلة معالجة صور النسيج المعيبة فقط وهي 280 صورة وتصنيفها بواسطة الشبكات العصبية BPNN و Elman إلى أربع عشرة فئة تمثل أصناف العيوب. وكما في الخطوات الآتية:

1) المعالجة الأولية و قطع منطقة العيب (ROI- Region Of Interest) من الصور: بعد قراءة صورة النسيج المعيبة وتحجيمها يتم معاملتها بمرشحات Gabor، وذلك لإبراز وتحديد العيوب الموجودة في الصورة. بعدها يتم تحويل الصورة الرمادية الناتجة من Gabor إلى صورة ثنائية، وذلك بتحويل كل بكسل في الصورة الرمادية والمشار له $x_i \in [0,1]$ إلى بكسل في الصورة الثنائية المقابلة والذي يتمثل بـ $b_i \in \{0,1\}$ حيث أن "0" يشير إلى "أسود" ويشير "1" إلى "أبيض" وتدعى هذه العملية بعملية Binarization. وهناك عدة أساليب لتنفيذ عملية Binarization منها Global fixed threshold وهي المستعملة هنا، إذ يتم استعمال حد عتبة ثابتة كالآتي [32]:

$$b_i = 1 \quad \text{if} \quad x_i \geq 0.5 \quad \& \quad b_i = 0 \quad \text{if} \quad x_i < 0.5$$

وبتطبيق مرشح المعدل Averageing (7*7) يتم إزالة الشوائب من الصورة الثنائية الناتجة وتحسين الصورة. ثم يتم قطع منطقة العيب ROI وهي عملية مهمة لتمييز العيب إذ أنها تمنع تكرار الصفات المستخلصة وهذا التكرار يحصل إذا تم أخذ صفات الصورة بالكامل بالإضافة إلى أنها تقلل من أبعاد مصفوفة الإدخال إلى الشبكة العصبية لاحقاً. وقد تم بناء خوارزمية تقوم بالتقطيع الآلي لمنطقة العيب. وفي هذه الخوارزمية يتم تمرير المصفوفة الثنائية الممثلة للصورة الثنائية إلى خوارزمية التقطيع (Icroped) التي تم بناؤها

لتقوم بالتقطيع الآلي على خطوتين متتاليتين في الخطوة الأولى: يتم التقطيع باتجاه الأعمدة لقطع الأسطر غير التابعة للمنطقة البيضاء وهي منطقة العيب، وفي الخطوة الثانية: يتم التقطيع باتجاه الأسطر لغرض قطع الأعمدة المحيطة بمنطقة العيب، وبهذا يكتمل استقطاع الجزء المهم من صورة النسيج وهو جزء العيب.

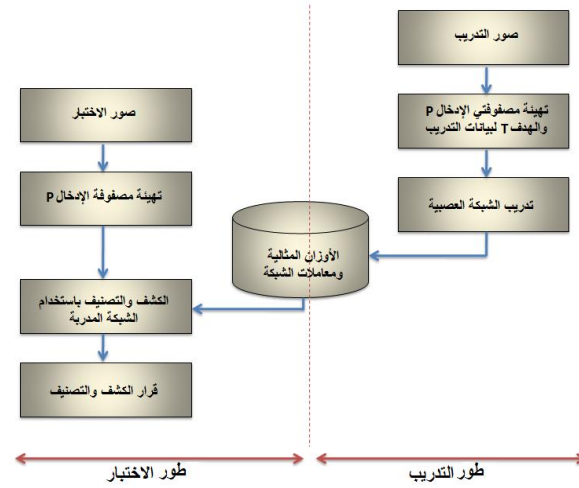
(2) استخلاص الصفات و تصنيف العيوب: يتم حساب الحجم الكلي لمنطقة العيب واعتبارها كإحدى الصفات الهندسية للصورة. ثم يحدد محيط منطقة العيب بعامل كاني لكشف الحواف Canny operators. يليه تقطيع الصورة إلى 9 خلايا (3*3) ومن كل خلية يتم استخلاص صفتين هما معدل الترددات (mean) و الميل (Skewness) ليكون لدينا (2*9) 18 صفة إحصائية وبإضافة الصفة الهندسية المحسوبة قبل التقطيع وهي الحجم الكلي لمنطقة العيب فيكون مجموع الصفات المستخلصة من الصورة 19 صفة. يتم ترتيب صفات صور العيوب في مصفوفة ثنائية عدد صفوفها يمثل عدد الصور وعدد أعمدها يمثل عدد الصفات وهكذا تتكون مصفوفة الإدخال إلى الشبكة العصبية لغرض تصنيف أنواع العيوب. ويمكن حساب العزم الثالث المتمثل بالميل (Skewness) عن طريق المعادلة (8) الآتية [33]:

$$skewness = \frac{1}{N} \left(\frac{\sum_{i=1}^N (X_i - \bar{X})^3}{\sigma^3} \right) \quad \dots\dots(8)$$

ثم تصنف العيوب إلى أصنافها الأربعة عشر وذلك باستخدام إحدى الشبكات العصبية، شبكة الانتشار العكسي BPNN وشبكة Elman وقد تم تخصيص 210 صور كعينة للتدريب في هذه المرحلة وتخصيص 70 صورة أخرى كعينة اختبار. أما هيكلية الشبكة العصبية المستعملة هنا فتتكون من طبقتين مخفيتين الأولى تتضمن 120 وحدة معالجة، والثانية تتكون من 100 وحدة معالجة أما طبقة الإخراج فتتكون من 14 وحدة معالجة لتعطي أربعة عشر خرجا تمثل اصناف العيوب فإذا كان أول إخراج قيمته "1" والبقية أصفارا هذا دليل على أن هذا المخرج تابع للعيوب الأول أما إذا كان الإخراج الثاني هو "1" والبقية أصفارا فهو إخراج يندرج تحت العيب الثاني وهكذا بقية العيوب.

الطور الأول- تدريب الشبكة العصبية: يتم تدريب الشبكة على متجهات صفات الصور المعيبة والتي تم تكوينها بعد استخلاص الصفات من تلك الصور. وذلك لغرض تعليم الشبكة لتتمكن من تصنيف العيوب. كل متجه إدخال يتكون من 19 قيمة والتي تمثل معدل الترددات (mean) الموجودة في كل خلية، والعزم الثالث المتمثل بالميل (Skewness) لكل خلية، بالإضافة إلى صفة حجم منطقة العيب وبعد تنسيب (normalization) هذه الصفات بالنسبة لأعلى قيمة وواقع 9 مناطق لكل صورة.

الطور الثاني- اختبار الشبكة العصبية لتصنيف الصور: وتتبع نفس خطوات المعالجة الأولية واستخلاص الصفات لغاية الحصول على متجه صفات الصورة المدخلة، ثم يتم إدخال هذا المتجه إلى الشبكة العصبية للتعرف على نوع الصورة وشكل العيب وارجاعه الى صنفه الذي ينتمي اليه. الشكل (7) يوضح كيف تتم عملية تدريب الشبكة العصبية وخرن معاملاتها والاوزان المثالية في طور التدريب ومن ثم استرجاعها في طور الاختبار لفحص الصور غير المدربة على الشبكة مسبقا.



شكل (7) المخطط الصندوقي لطوري التدريب والاختبار في الشبكة العصبية

9. النتائج ومناقشتها

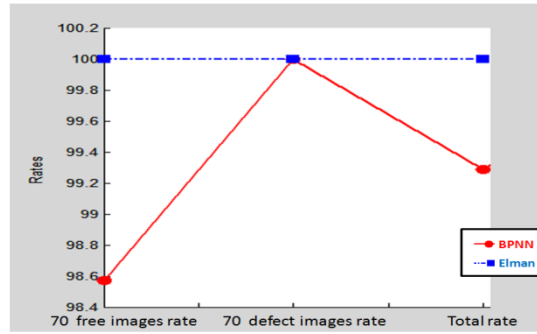
أ- من خلال التطبيق العملي للخوارزمية المقترحة تم تدريب شبكة Elman العصبية لاكتشاف العيب بعد تغذيتها بالصفات الاحصائية من الدرجة الثانية المستخلصة من مصفوفات التبعية المكانية GLCM, تعد هذه الطريقة في استخلاص الصفات مميزة من حيث قلة عدد الصفات المستخلصة بالإضافة إلى جودتها والتي قللت العبء الحسابي المتكرر عن الشبكة العصبية ما أدى إلى سرعة في عملية التمييز .

ب- تم تدريب الشبكات العصبية على 420 صورة منها 210 صورة نسيج طبيعي سليم من العيوب 210 صورة لنسيج يحوي على عيوب النسيج المختلفة وتم تهيئة 140 صورة غير مدربة على الشبكة العصبية منها 70 صورة من صور النسيج السليمة من العيوب و 70 أخرى فيها عيوب مختلفة وبعد اختبار الشبكات العصبية كانت النتيجة متقاربة جداً بالنسبة للشبكتين مع تميز شبكة Elman بأعلى نسبة تمييز وهي (100)%. والجدول (1) يوضح نتائج الشبكتين BPNN و Elman في مرحلة اكتشاف العيب:

جدول (1) نتائج فحص صور الاختبار على شبكة BPNN و Elman


نوع الشبكة	نسبة اختبار 70 صورة قماش سليم	نسبة اختبار 70 صورة قماش معيب	النسبة الكلية	الوقت بالثواني لاختبار 140 صورة
Elman	100%	100%	100%	105.5570
BPNN	98.5714%	100%	99.2857%	113.4430

الشكل رقم (8) يوضح نتائج اختبار الصور غير المدربة على شبكة BPNN و Elman الاعتماد على جدول (1)



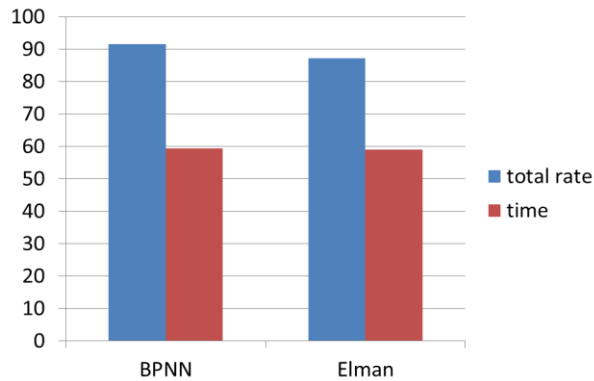
شكل (8) نتائج عملية كشف وجود العيب في صور الاختبار على شبكتي Elman و BPNN

والشكل (9) يوضح نسبة التمييز الكلية لكل من الشبكتين فضلا عن مقدار الوقت المستنفذ لاختبار 140 صورة من الصور غير المدرية والمعدة لغرض فحص كفاءة الشبكتين في التمييز, بالاعتماد على جدول (1).



شكل (9) نتائج عملية كشف وجود العيب في صور الاختبار على شبكتي Elman و BPNN

ج - تم اختبار 70 صورة من الصور المعيبة بواقع 5 صور من كل نوع من العيوب الأربعة عشر على الشبكتين العصبيتين وكانت دقة التصنيف (91.4286%) بالنسبة لشبكة الانتشار العكسي BPNN وقد احتاجت الى 59.4360 ثانية لفحص 70 صورة من صور الاختبار, أما شبكة Elman فقد اعطت دقة تصنيف تصل الى (87.1429%) وكان الوقت اللازم لفحص 70 صورة يساوي 59.0150 ثانية. والشكل (10) يعطي مخططا توضيحيا عن النسبة الكلية للتصنيف في كلا الشبكتين بالإضافة الى الوقت بالثواني اللازم لتصنيف 70 صورة من صور الاختبار.



شكل (10) نتائج عملية تصنيف العيوب في صور الاختبار على شبكتي Elman و BPNN

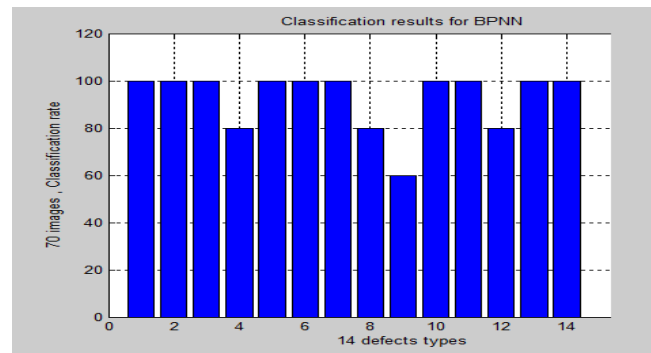
تمييز بعض عيوب نسيج القماش باعتماد طرائق معالجة الصور والتقنيات الذكائية

والجدول (2) يوضح نتائج الشبكات العصبية BPNN و Elman في مرحلة تصنيف العيوب.

جدول (2) نتائج عملية تصنيف العيوب لبيانات التدريب والاختبار على الشبكتين

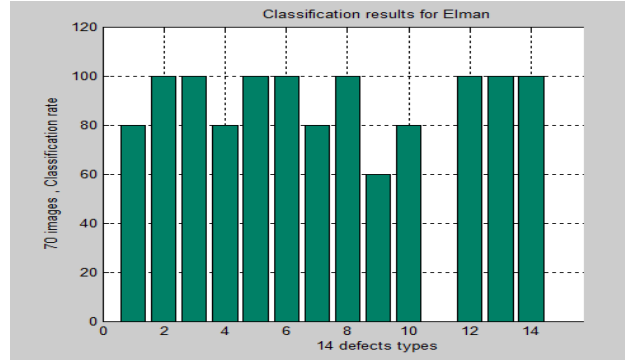
صور الاختبار				صور التدريب		أصناف العيوب
اختبار 70 صورة غير مدربة على شبكة BPNN		اختبار 70 صورة غير مدربة على شبكة Elman		دقة التصنيف 210 صورة مدربة على BPNN	دقة التصنيف 210 صورة مدربة على Elman	
نسبة الخطأ	دقة التصنيف	نسبة الخطأ	دقة التصنيف			
0%	100%	20%	80%	100%	100%	العيوب 1 (Broken ends)
0%	100%	0%	100%	100%	100%	العيوب 2 (Broken pattern)
0%	100%	0%	100%	100%	100%	العيوب 3 (coloured flecks)
20%	80%	20%	80%	100%	100%	العيوب 4 (Cut & tear)
0%	100%	0%	100%	100%	100%	العيوب 5 (Double ends)
0%	100%	0%	100%	100%	100%	العيوب 6 (Float)
0%	100%	20%	80%	100%	100%	العيوب 7 (Hole)
20%	80%	0%	100%	100%	100%	العيوب 8 (Knots)
40%	60%	40%	60%	100%	80%	العيوب 9 (Missing picks)
0%	100%	20%	80%	100%	100%	العيوب 10 (Reed Marks)
0%	100%	100%	0%	100%	13.3333%	العيوب 11 (Slub)
20%	80%	0%	100%	93.333%	100%	العيوب 12 (Stain)
0%	100%	0%	100%	100%	100%	العيوب 13 (Untrimmed Loose threads)
0%	100%	0%	100%	100%	100%	العيوب 14 (Weft Bar)
8.5714%	91.4286%	12.8571%	87.1429%	99.5238%	93.8095%	النسبة الكلية

والشكل رقم (11) يوضح نتائج تصنيف عيوب نسيج القماش على شبكة BPNN بالاعتماد على جدول رقم (2):




شكل (11) نتائج تصنيف عيوب نسيج القماش بشبكة BPNN

والشكل رقم (12) يوضح نتائج تصنيف عيوب نسيج القماش على شبكة Elman بالاعتماد على جدول رقم (2):



شكل (12) نتائج تصنيف عيوب نسيج القماش بشبكة Elman

والشكل (13) يمثل نسب التصنيف الكلية لبيانات التدريب وبيانات الاختبار ومعدل الخطأ لكل من الشبكتين العصبيتين BPNN و Elman



شبكية Elman

شكل (13) نتائج تصنيف عيوب نسيج القماش

10. الاستنتاجات

بعد المطالعة النظرية للعمل المقترح والتطبيق العملي الذي تم فيه دمج طرائق معالجة الصور من خلال استعمال مرشحات Gabor واستخلاص الصفات من مصفوفة التبعية المكانية GLCM مع التقنيات الذكائية باستعمال الشبكة العصبية المتمثلة بشبكة Elman للكشف عن العيوب والشبكة العصبية ذات الانتشار العكسي BPNN لتصنيف العيوب في صور نسيج القماش. تم الحصول على نسبة تمييز تصل إلى 95.7% وهذه النسبة تعتبر ممتازة مقارنة بنسب أخرى في بحوث المجال نفسه، إلا أن العمل لا يمكن أن يصل الكمال لأن لكل أسلوب محاسنه ومساوئه والمتمثلة هنا بصعوبة الحصول على صور الأقمشة والعيوب من قواعد بيانات عالمية وصعوبة تمييز بعض العيوب الدقيقة جداً. كما وقد وضح أسلوب استخلاص صفات النسجة من الدرجة الثانية بعد حساب مصفوفة مقاييس تواجد المستوى الرمادي (GLCM) Gray-Level Co-occurrence Matrix المتمثل بخوارزمية حساب التبعية المكانية للمستوى الرمادي (SGLDM) Spatial Gray Level Dependence Method والتي أدت إلى اختزال حجم الصفات وحجم البيانات الكبير الذي تطلبه مثل هذا العمل. وقد تم اعتماد صور حية من الأقمشة السليمة من العيوب والأقمشة المعيبة لتناسب العمل المقترح والتي أعطت نتائج جيدة. والجدول (3) يوضح مقارنة مع عدداً من الدراسات السابقة في مجال اكتشاف عيوب الأقمشة وتصنيفها والطرائق المستخدمة مع نسبة التمييز.

تمييز بعض عيوب نسيج القماش باعتماد طرائق معالجة الصور والتقنيات الذكائية

جدول رقم (3) مقارنة مع الدراسات السابقة

نسبة التمييز الكلية	قاعدة البيانات	السنة	الطريقة المستخدمة	أسماء الباحثين	ت
96.7 %	78 صورة 39 صورة قماش خالية من العيوب 39 صورة قماش فيها 32 نوعاً من العيوب.	2008	مرشحات Gabor المثالية + شبكة موجات Gabor (GWE)	& K.L.Mak P. Peng	1
96.5 %	200 صورة قماش فيها 4 أنواع من العيوب 50 صورة من كل نوع	2010	التحويل المويجي + شبكة الانتشار العكسي BPNN	TE-LI SU وآخرون	2
98 %	100 صورة قماش منها 33 صورة خالية من العيوب والبقية فيها 5 أنواع من العيوب	2012	شبكة الانتشار العكسي BPNN	& Md. Tarek M. Habib Rokonuzzaman	3
91.1%	150 صورة قماش منها 30 صورة قماش خالية من العيوب و 120 صورة قماش فيها 4 أنواع من العيوب.	2012	GLCM+ الشبكة العصبية PNN الاحتمالية	Anand H. & Kulkarni Sheetal B. Patil	4
96 %	78 صورة قماش 39 صورة قماش خالية من العيوب 39 صورة قماش فيها 32 نوعاً من العيوب .	2013	Regular Band	Ali Javed وآخرون	5
90.0 %	-----	2016	الخوارزمية الجينية وآلة المتجه الداعم SVM	P.Y. Kumbhar وآخرون	5
96.15 %	26 صورة قماش خالية من العيوب 26 صورة قماش فيها عيوب	2017	RGB وتقنيات HSV واساليب معالجة الصور	Sunil Bangare وآخرون	7
80.0 %	TELDA database	2018	شبكة التشفير التلقائي + Gaussian pyramid	Shuang Mei وآخرون	8
95.7 %	560 صورة قماش منها 280 سليمة من العيوب والباقي صور لأقمشة فيها 14 نوعاً من العيوب	2018	مرشحات Gabor + GLCM+ شبكة الانتشار العكسي BPNN + شبكة Elman ايلمان	إيمان صبحي محمد & د. إسراء محمد خضر	9

المصادر

- [1] Tarek Habib MD. and Rokonuzzaman M., ISRN Artificial Intelligence, 2012:1-16 (2012).
- [2] Anand H. K. and Sheetal B. P., (IJLTET), (2012).
- [3] Rao Ananthavaram R. K. , Srinivasa O. Rao and Krishna Prasad MHM, (IJCA), (2012).
- [4] Dewan R. and Aggarwal M. , (AMIERJ), (2012).
- [5] Guang Z. and Jianxil W. , China (ICEMI), (2007).
- [6] Mak K.L. and Peng P., (WASET), (2008).
- [7] Mak K.L. ,Peng P. and Yiu K.F.C., Image Vis Comput. , 27:1585–1592, (2009).
- [8] Te-Li Su, Hua-Wei Chen, Gui-Bing Hong and Chih-Ming Ma, International Conference on Wavelet Analysis and Pattern Recognition , (2010).

- [9] Priya S., Ashok kumar T. and Varghese Paul Dean, International Conference on Signal Processing, Communication Computing and Networking Technologies (ICSCCN) , (2011).
- [10] Javed A., Ahsan Ullah M., and Ur-Rehman A. , (IJIGSP), 40-45 (2013).
- [11] Michael K. Ng, Henry Y. T. Ngan, Senior Member, Xiaoming Yuan, and Wenxing Zhang, IEEE Trans on Autom Sci and Eng, (2014).
- [12] Rebhi A. , Benmhammed I., Abid S. and Fnaiech F., IEEE Photonics J, (2015).
- [13] Kumbhar P. Y. , Mathpati T. , Kamaraddi R. and Kshirsagar N. , (IJREST), 3:3 (2016).
- [14] Bangare S. L., Dhawas N. B., Taware V. S., Dighe S. K., Bagmare P. S., (IJRAT), 5:6 (2017).
- [15] Shuang Mei , Yudan Wang , and Guojun Wen , 18:1064 (2018).
- [16] Salah Hassan Naji., Journal of University of Babylon, 20:1:174-182 (2012). (In Arabic)
- [17] Peng Pai R., Ph.D. Dissertation, The HKU Scholars, University of Hong Kong, (2006).
- [18] Zalat A. El-S. , El-Gamal M. A. , Ibrahim N. H., (QERJ) ,18 (2010). (In Arabic)
- [19] Maroš Tunák, Aleš Linka and Petr Volf ,Quality & Productivity Research Conference,(2009).
- [20] Kumar A. and Khas H. , IEEE Transactions on Industrial Electronics, 55:1:348-363, (2008).
- [21] Mahajan P.M. , Mahajan J.T. and Patil P.M, Advances in Computational Research, 1:2:18-29, (2009).
- [22] Priyanka M. Shanbhag, Manish P. Deshmukh and Shekhar R. ,(GJEDT), 1:2:s2-46, (2012).
- [23] HOGGARS. G., "*Mathematics of Digital Images Creation, Compression, Restoration, Recognition*", Cambridge University Press, New York, (2006).
- [24] Mohammed I.S. , AIP Conference Proceedings 2096,020005- 020005-7 (2019).
- [25] Tom Mitchell, "*Machine Learning*", McGraw Hill, (1997).
- [26] Zhiqiang Zhang, Shangce Gao, Gang Yang, Fangjia Li and Zheng Tang, INT J INNOV COMPUT I, 5:10:2997–3011, (2009).
- [27] Arivazhagan S., Ganesan L., and Bama S., MACH VISION APPL 16:6:356–363, (2006).
- [28] Zhang D. , Wong A. , Indrawan M., Lu G., First IEEE Pacific-Rim Conference on Multimeadia, Australia: 392-395, (2000).
- [29] Mohammed I.S. and khuder I. M. , (KUJSS) , 3:529-555(2017) (In Arabic).
- [30] Mohammed I.S. and Alhamdani I. M. , (IJECE) , v9:i5: 4277-4286(2019).
- [31] Hassan M. Elragal, Proceeding of 23rd National Radio Science Conference (NRSC): 14-16, (2006).
- [32] Maya R. Gupta , Nathaniel P. Jacobson and Eric K. Garcia, ,INT JPATTERN RECOGN 40:389 – 397, (2007).
- [33] Badran A., Jassem M. A. , Mahmoud M. F. and Mohamed M. N., Iraqi Journal of Statistical Sciences, 23:150-167, (2013).