

## الكشف عن عيوب القماش باستخدام معالجة الصورة

د. عمار علي زقزوق

أستاذ في قسم هندسة التحكم الآلي والحواسيب

كلية الهندسة الميكانيكية والكهربائية - جامعة البعث

### ملخص البحث

مجال المنسوجات واحد من الأعمال التجارية الكبرى في جميع أنحاء العالم. يرتبط سعر المنتج والقدرة التنافسية له ارتباطاً مباشراً بجودة المنتج. فقط المنتجات ذات الجودة الجيدة يمكنها البقاء في المنافسة الشرسة في السوق. لكن عيوب النسيج تعد أهم نقاط ضعف هذا المجال، فهي تؤدي إلى رداءة جودة المنتج، وكما تؤثر أيضاً على النمو الاقتصادي للصناعة. يعتبر فحص النسيج أمراً مهماً للغاية، ولكن الأساليب القديمة المستخدمة لاكتشاف الأخطاء مثل الفحص البصري البشري مرهقة وتستغرق وقتاً طويلاً. لذا، لتقليل الوقت والضغط وزيادة الإنتاجية، فقد تم في هذه الدراسة اقتراح استخدام آلية للكشف عن هذه العيوب. يتكون برنامج النظام من خوارزمية الكشف عن العيوب، والتصنيف تم تطبيقه عبر واجهة مستخدم تم إعدادها باستخدام برنامج MATLAB. يعتمد نهج تصنيف العيب على مصفوفة التواجد ذات المستوى الرمادي (Gray Level Co-occurrence Matrix: GLCM)، وأما التصنيف فيتم باستخدام شبكة عصبونية تلافيفية (Convolution Neural Network). تم تدريب الشبكة واختبارها على 300 صورة مأخوذة من قاعدة البيانات CALTECH\_101، وذلك لاكتشاف نوعين شائعين من أخطاء النسيج وهما: HOLE و LINE، وأظهرت النتائج أنه تم تصنيف العيوب بمعدل دقة (0.83%).

كلمات مفتاحية: معالجة الصور - اكتشاف عيوب القماش - الشبكات العصبونية التلافيفية.

## Fabric Fault Detection using Image Processing

**Dr. Ammar Ali Zakzouk**

Professor in Automatic Control and Computers Engineering Department  
Mechanical and Electrical Engineering Faculty  
Albaath University

### Abstract

The field of textiles is one of the major business all over the world. The price of the product and its competitiveness is directly related to the quality of the product. Only good quality products can survive the fierce competition in the market. But fabric defects are the most important weaknesses in this field, as they lead to poor product quality and also affect the economic growth of the industry. Tissue examination is very important, but the old methods used to detect errors such as human visual inspection are cumbersome and time-consuming, so to reduce time and pressure and increase productivity, it was proposed in this study to use an automatic mechanism to detect these defects. It is implemented via a user interface prepared using MATLAB software. The defect classification approach is based on the Gray Level Co-occurrence Matrix (GLCM) and the classification is done using a convolutional neural network. The network was trained and tested on 300 images taken from the database CALTECH\_101 in order to discover two common types of texture errors: HOLE and LINE. The results showed that the defects were classified with an accuracy rate of (0.83%).

**Key-words:** Images Processing – Fabric Fault Detection – Convolution Neural Networks.

## 1- مقدمة:

في صناعة النسيج، كان تحديد نمط النسيج يدوياً يتطلب جهوداً بشرية كبيرة. استغرقت هذه العملية الصعبة وقتاً طويلاً لم يكن مفيداً للصناعة. هذا هو السبب في أنه من المستحسن للغاية تطوير نظام التعرف التلقائي لأنماط النسيج. أثبتت معالجة الصور أنها طريقة فعالة لتحليل هياكل النسيج، وتمت دراسة التعرف إلى أنماط بنية القماش (النسيج) عن طريق تحليل الصور منذ منتصف الثمانينيات.

## 2- التعرف إلى الأنماط:

التعرف إلى الأنماط (Pattern Recognition: PR) يتعلق بوصف أو تصنيف (التعرف) القيم المدخلة، وهو ليس تقنية واحدة، بل هو عبارة عن مجموعة واسعة من المعارف والتقنيات. يعتمد التعرف إلى الأنماط بشكل طبيعي على الأنماط، ويمكن أن يكون النمط أساسياً كمجموعة من القياسات. المفتاح في العديد من تطبيقات التعرف إلى الأنماط هو تحديد السمات (الميزات)<sup>1</sup> المناسبة وتشكيل مقياس جيد للتشابه وعملية المطابقة المرتبطة بها، وذلك بالاعتماد على الميزات المستخرجة من النمط المدخل من الأمثلة على الميزات منخفضة المستوى شدة الإشارة، وقد تكون الميزات رمزية أو رقمية أو كليهما، ومثال على السمة الرمزية هو اللون؛ مثال على السمة العددية الوزن. من الناحية التاريخية، فإن النهجين الرئيسيين للتعرف إلى الأنماط هما الأسلوب الإحصائي (أو نظرية القرار)، والمشار إليه فيما بعد بـ StatPR، والنحوي (أو البنوي)، ويشار إليهما فيما بعد بـ SyntPR. والطريقة المستخدمة في هذه الدراسة هي الطريقة الإحصائية وهي خوارزمية (GLCM).

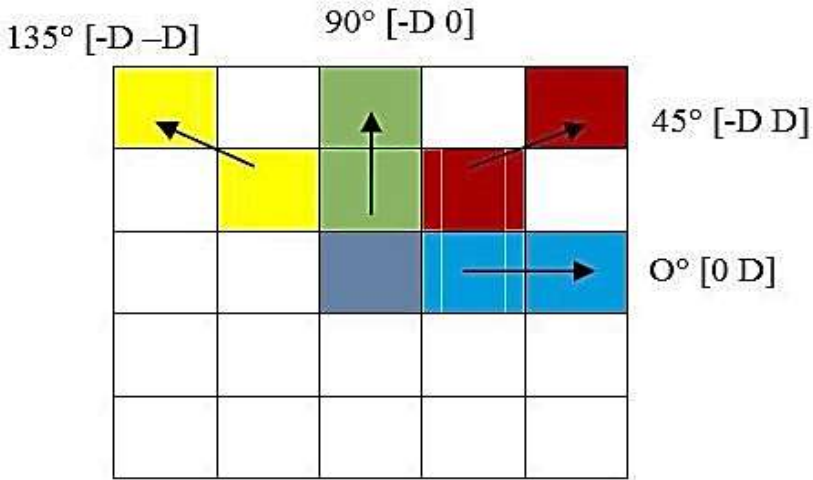
## 3- استخراج الميزات باستخدام خوارزمية GLCM:

يعتمد استخراج الميزة على الخصائص المحددة لوحدات البيكسل في الصورة. لإدارة تصنيف الأقمشة المنسوجة، اخترنا طريقة تعتمد على نهج إحصائي، وهي خوارزمية (GLCM). هي مصفوفة مربعة بحجم  $L * L$ ، حيث  $L$  هو رقم المستوى الرمادي في

<sup>1</sup> الميزات هي أي قياس مستخرج مستخدم.

الصورة الأصلية. هناك عاملان يؤثران في حساب مصفوفة التواجد (GLCM) هما  $D$  وهي المسافة بين وحدتي بكسل، و  $\theta$  زاوية الموضع بين وحدتي بكسل ( $q, p$ ) و ( $i, j$ )، تحوي هذه المصفوفة على القيمة الاحتمالية لورود وحدتي بكسل بكثافة  $i, j$  على التوالي، يفصل بينهما المسافة  $d$  والاتجاه  $\theta$ . وبالتالي، يمكن كتابة قيمة الاحتمال كـ  $P(i, j, d, \theta)$ . يمكن اختيار المسافة  $d$  من 1 إلى 8، ويمكن أن يكون الاتجاه أيّاً من 0، 45، 90، 135، 180، 225، 270، 315.

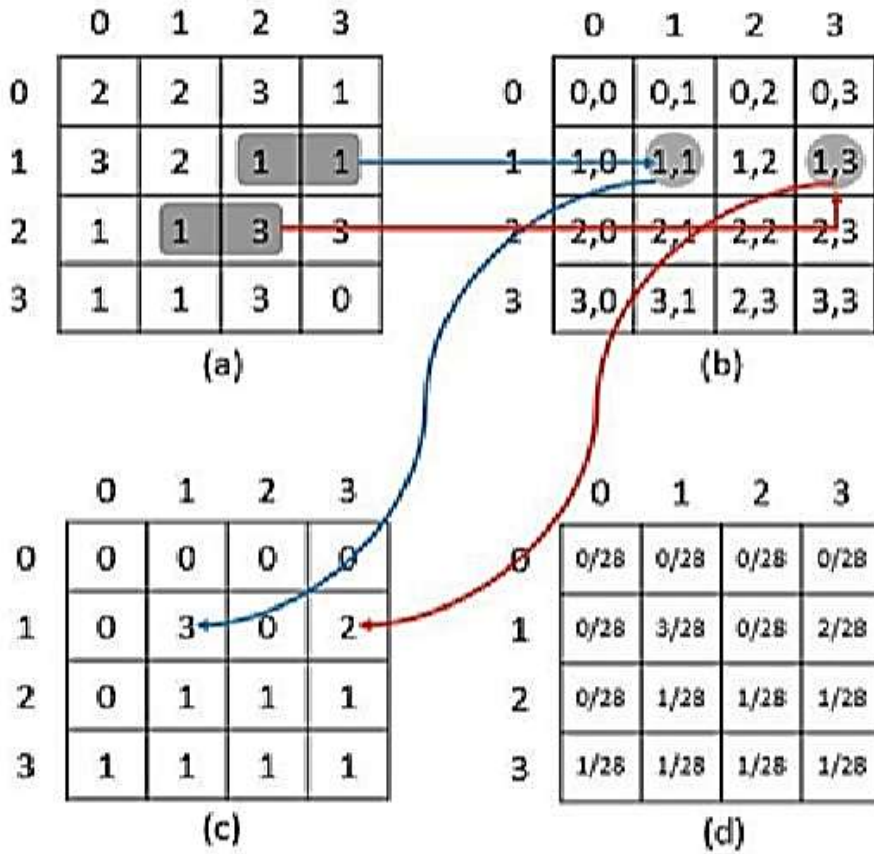
يظهر الشكل (1) مصفوفة GLCM وعلاقة البيكسل بجواره بأربعة اتجاهات.



الشكل (1): مصفوفة GLCM وعلاقة البيكسل بجواره بأربع اتجاهات.

يبين الشكل (2) مراحل حساب المصفوفة GLCM.

تعطي مصفوفة التواجد المشترك ذات المستوى الرمادي 13 سمة للصورة. في دراستنا، سنركز على السمات الأربع فقط، وهي: (التجانس، الطاقة، الارتباط، التباين). تتميز كل واحدة من هذه السمات بإشارتها الخاصة. يتعرف المصنف (Classifier) إلى كل نسيج وفقاً لطبيعة الإشارة. لقد تم في هذه الدراسة استخدام عدداً مختلفاً من الصور لكل فئة من القماش. بعد المعالجة المسبقة، نحسب مصفوفة التواجد المشترك لكل صورة، ثم نستخرج السمات الإحصائية الأربعة وهكذا. يتم تمثيل كل صورة بوساطة متجه من السمات، وبالتالي يتم التصنيف بالاعتماد على الطبيعة المختلفة للسمات المستخرجة لكل نوع من أنواع القماش.



الشكل (2): مراحل حساب المصفوفة GLCM.

يتم حساب قيم هذه السمات عن طريق العلاقات الآتية:

Homogeneity:

$$ENT = \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} \frac{C_{mn}}{1 + |m - n|}$$

Correlation:

$$COR = \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} \frac{(1 - \mu_x)(1 - \mu_y)}{\sigma_x \sigma_y} C_{mn}$$

$$Energy = \sum_i \sum_j C^2(i, j)$$

Contrast:

$$CON = \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} (m-n)^2 \cdot C_{mn}$$

حيث:

1- Contrast: يقيس الاختلافات المحلية في مصفوفة التكرار ذات المستوى الرمادي (GLCM).

2- Correlation: يقيس حدوث الاحتمال المشترك لأزواج البكسل المحددة.

3- Homogeneity: يقيس تقارب توزيع العناصر في GLCM على قطري GLCM.

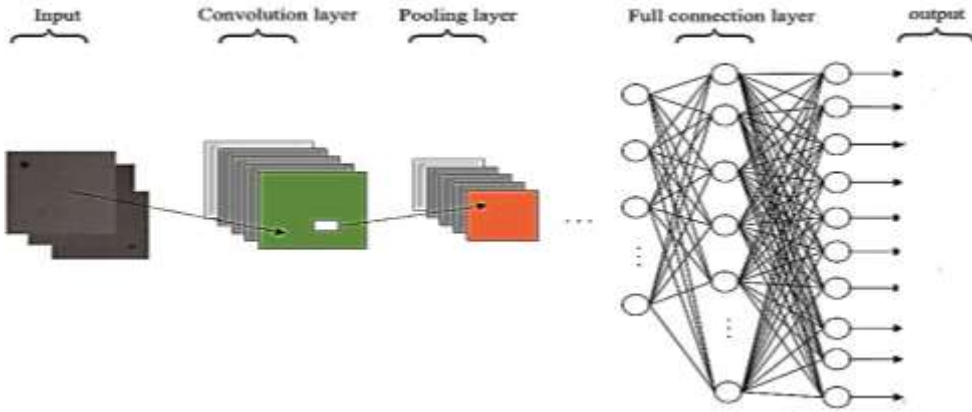
4- Energy: يقيس طاقة البكسل.

#### 4- الشبكات العصبونية الالتفافية (CNN):

شبكات CNN هي نماذج خاصة للشبكات العصبية، وهي مستوحاة من نظام الرؤية البشرية. إن طبقات الالتفاف لشبكات CNN لها أوزان مشتركة. حققت الشبكات العصبونية التلافيفية (CNNs) في التعلم العميق نجاحاً ملحوظاً في تطبيقات الرؤية الحاسوبية، والتي لها مزايا خاصة في تصنيف الصور والتعرف والاكتشاف، وتمكنت هذه الشبكات من تحسين دقة الكشف والتصنيف من خلال دراسة الارتباط المكاني للبيانات وتقليل عدد معاملات التدريب في الشبكة.

يظهر الشكل (3) طبقات شبكة CNN.


مع الأخذ بالحسبان أن CNN لا يمكنها التعامل مع مشكلة أحجام العينات الصغيرة بشكل جيد للغاية في التصنيف، فمن الضروري بناء بنية تعلم أعمق والحصول على بيانات كبيرة لتدريب النموذج من أجل الحصول على دقة كشف وتصنيف أفضل. إحدى أنواع شبكات CNN هي شبكة RESNET50، وهي شبكة تتكون من 50 طبقة مدربة بشكل مسبق على 1000000 كائناً مختلفاً تم تقسيمهم إلى 1000 صنفاً. سنقوم في هذه الدراسة بتدريب هذه الشبكة على الأصناف HOLE و LIN، والتي تستخدم SVM كمصنف.



الشكل (3): طبقات شبكة CNN.

### 5- خوارزمية SVM:

هي نماذج تعلم خاضعة للإشراف مع خوارزميات التعلم المرتبطة التي تحلل البيانات المستخدمة في التصنيف وتحليل الانحدار. فإذا كان لدينا مجموعة بيانات مقسومة لفئتين، فإن خوارزمية تدريب SVM أولاً تمثل بيانات التدريب وكأنها نقاط في الفضاء يتم تعيينها بحيث يتم تقسيم بيانات الفئات المنفصلة بوساطة فجوة واضحة واسعة قدر الإمكان، ويتم تصنيف البيانات الجديدة في المساحة نفسها والتنبؤ بأنها تنتمي إلى فئة بناءً على جانب الفجوة التي تقع عليها. تبني نموذجاً يصنف البيانات جديدة لأي فئة تنتمي ما يجعلها مصنفاً خطياً. بالإضافة إلى إجراء التصنيف الخطي، يمكن أن تقوم SVM بكفاءة بإجراء تصنيف غير خطي باستخدام ما يسمى خدعة kernel. يظهر الشكل (4) آلية مبسطة لعمل SVM الخطية.



الشكل (4): آلية مبسطة لعمل SVM الخطية.

## 6- الدراسات المرجعية:

### 1 " *Real Time Automated Fabric Defect Detection System using Microcontroller* "

تم إجراء هذه الدراسة في بنغلادش في عام 2008، قام الباحثون Tamnun E Mursalin\*1, Fajrana Zebin Eishita\*2, Ahmed Ridwanul Islam\*3, Dr. Md Jahangir Alam بإجراء هذه الدراسة لاكتشاف ثلاثة أنواع من الأخطاء الشائعة جداً في إنتاج المنسوجات، وهي الثقب والخدش والتلاشي، إذ يطبق هذا البحث كاشف عيوب النسيج الذي يستخدم منهجية الرؤية الحاسوبية مع مزيج من الشبكات العصبية متعددة الطبقات لتحديد تصنيف عيوب النسيج واكتشافها بنظام ميكانيكي تم تكوينه في الوقت الفعلي يحتوي على متحكم دقيق. وبينت النتائج أنه تم تحديد الثقب بنجاح بنسبة 86%، والتلاشي 66%، والخدش 77%. يبلغ متوسط الدقة الإجمالية لاكتشاف الأخطاء 76.3%.

الإيجابيات:

- إن الفحص البصري التلقائي يحمي كلاً من: العامل من التعب والإرهاق والجودة.
  - تم إثبات أن نظام التعرف إلى عيوب المنسوجات قادر على اكتشاف عيوب الأقمشة بمزيد من الدقة والكفاءة.
- السلبات:
- في بعض الأحيان يتم العثور على النسيج المثالي أيضاً كجزء معيب.

### 2 " *Development of a machine vision system: real-time fabric defect detection and classification with neural network* "

تم إجراء هذه الدراسة في عام 2013، وهذه الدراسة تم نشرها في مجلة The Journal of The Textile Institute في 26 December 2014, At: 15:56. قام الباحثون H.İ. Çelika\*, L.C. Dülgerb and M. Topalbekiroğlu بإجراء هذه الدراسة على خمسة أنواع من العيوب شائعة الحدوث، عدم الالتواء (warp lacking)، نقص اللحمة (weft lacking)، ثقب (hole) الخيط المتسخ (soiled yarn)، تدفق



الغزل (yarn flow) كانت أنواع الأقمشة المدرجة في قاعدة البيانات بشكل أساسي أقمشة منسوجة من نسيج قطني طويل عادي. إذ تم تطوير نظام رؤية الآلة لتحقيق عمليات فحص النسيج وتصنيف العيوب تلقائياً. يتكون النظام من أجهزة الحصول على الصور وبرنامج معالجة الصور. تم تصميم نظام بسيط ومحمول بحيث يمكن تكييفه بسهولة مع جميع أنواع آلات فحص النسيج. يتكون برنامج النظام من خوارزميات الكشف عن العيوب والتصنيف. تم تطبيقه في الزمن الحقيقي عبر واجهة مستخدم تم إعدادها باستخدام برنامج MATLAB. يعتمد نهج تصنيف الخلل على مصفوفة التواجد ذات المستوى الرمادي وتغذية الشبكة العصبونية الأمامية. وبينت النتائج أنه تم الكشف عن مناطق النسيج المعيبة والخالية من العيوب بدقة 93.4% وتم تصنيف العيوب بمعدل دقة 96.3%.

الإيجابيات:

- سيعمل نظام الكشف الآلي عن العيوب على تعزيز الإنتاجية.
- يمكن تحقيق عملية فحص النسيج في وقت أقصر.
- سيتم تخفيض تكلفة العمالة .
- سيتم خفض التكاليف المتعلقة بالجودة غير الملائمة.

### (3) " A PAPER ON AUTOMATIC FABRICS FAULT PROCESSING USING IMAGE PROCESSING TECHNIQUE IN "MATLAB

قام الباحثان R.Thilepa و M.Thanikachalam بإجراء هذه الدراسة، إذ تم تحديد الخطأ الموجود على الأقمشة باستخدام MATLAB مع تقنيات معالجة الصور. يتم التقاط صورة قماش معيبة ثم تصفية الضوضاء في المرحلة الأولية. ثم يتم تحويل الصورة المصفاة الناتجة إلى صورة ذات مقياس رمادي. الآن، تتم معالجة الصورة ذات المقياس الرمادي لعملية الرسم البياني، وأخيراً يتم تنفيذ Thresholding باستخدام برنامج MATLAB 7.3. وهكذا يطبق هذا البحث كاشف عيوب النسيج بمنهجية رؤية النظام في معالجة الصور.

تم استخدام هذه الطريقة لتحديد الأخطاء مثل الثقب والخدش والتلاشي والأخطاء الأخرى في الأقمشة.

وكانت النتائج زادت الكفاءة الإجمالية بنسبة 85% باستخدام هذه العملية مقارنة بالطرائق الأخرى لتحديد الخطأ.

الإيجابيات:

نظام التعرف على عيوب المنسوجات قادر على اكتشاف عيوب الأقمشة بمزيد من الدقة والكفاءة.

#### "4 Texture Feature Extraction Using Co-Occurrence Matrices"

##### "of Sub-Band Image For Batik Image Classification"

تم إجراء هذه الدراسة في 2014 في أندونيسيا من قبل الباحثين Agus Eko Minarno \* و Yuda Munarko \* و Arrie Kurniawardhani † و Fitri Bimantoro † Nanik Suciati، إذ أن الطريقة المقترحة في هذه الدراسة تسمى مصفوفات التواجد المشترك لصور النطاق الفرعي. تم اقتراح هذه الطريقة للتغلب على مشكلة تصنيف صور الباتيك التي يتم الحصول عليها بشكل عشوائي من الإنترنت. مشكلة تلك الصور هي أن الصور الباتيك تحتوي على أنواع مختلفة من الضوضاء، مثل السطوع غير المتوازن، وهناك طيات على صور الأقمشة، ومختلف أحجام الدوافع الأساسية، والتباين المنخفض، وهناك علامات مائية على التباين. DWT. أولاً، يتم تحليل الصورة الأصلية باستخدام DWT لتوفير صور النطاق الفرعي. ثانيًا، يتم تطبيق GLCM على صور النطاق الفرعي لاستخراج ميزات النسيج. ستصبح هذه الميزات هي المدخلات للشبكة العصبية الاحتمالية (PNN). أظهرت النتائج أن هذه الطريقة قوية بما يكفي لتصنيف صور الباتيك. الدقة القصوى التي يمكن تحقيقها هي 72%.

الإيجابيات:

- الكشف عن صور الباتيك التي تحوي أنواعاً مختلفة من الضوضاء.
- تم الاستنتاج أن الجمع بين تحليل نسيج الموجات و GLCM قادر على استخراج الخاصية المتأصلة في كل فئة من صور الباتيك بشكل فعال.

السليبيات:

- كانت دقة الكشف منخفضة.

5 " *Brain MR image classification using two-dimensional discrete wavelet transform and AdaBoost with random forests* "

قام الباحثون Deepak Ranjan Nayak/ Ratnakar Dash/ Banshidhar Majhi بإجراء هذه الدراسة في 2016، يقدم هذا البحث نظام تشخيص آلي ودقيق بمساعدة الكمبيوتر (CAD) لتصنيف صور الرنين المغناطيسي للدماغ (MR) يستخدم النظام أولاً التحويل المويجي المنفصل ثنائي الأبعاد (2D DWT) لاستخراج الميزات من الصور. بعد تسوية متجه السمات للصورة، يتم استخدام تحليل المكون الرئيس الاحتمالي (PPCA) لتقليل أبعاد متجه السمات. يتم تطبيق الميزات المصغرة على المصنف لتصنيف صور الرنين المغناطيسي إلى صور عادية وغير طبيعية. يستخدم هذا النظام خوارزمية AdaBoost مع غابات عشوائية كمصنف أساسي. تم استخدام ثلاث مجموعات بيانات معيارية لصورة MR، وهي Dataset-66 و Dataset-160 و Dataset-255، للتحقق من صحة النظام المقترح. يتم استخدام مخطط تحقق متقاطع طبقي 5×5 لتعزيز قدرة التعميم للمخطط المقترح. تتم مقارنة نتائج المحاكاة مع المخططات الحالية، ويلاحظ أن المخطط المقترح يتفوق على الآخرين في جميع مجموعات البيانات الثلاث.

6 " *Fabric Defect Detection Using Fuzzy Inductive Reasoning Based on Image Histogram Statistic Variables* "

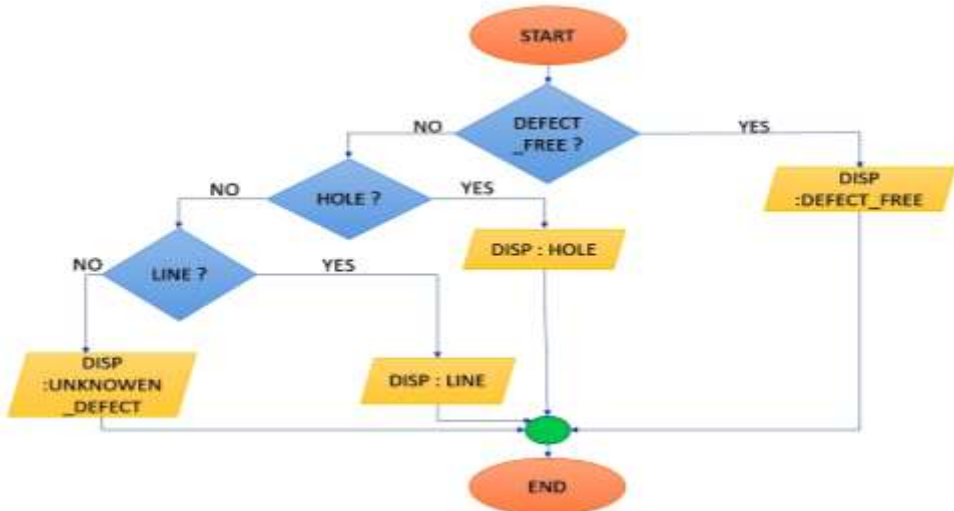
قام الباحث Yuan Ye بإجراء هذه الدراسة في الصين، وتم نشرها في 2009 في المؤتمر الدولي السادس حول الأنظمة الضبابية واكتشاف المعرفة، تتناول هذه الورقة الاستدلال الاستقرائي الضبابي (FIR) لاكتشاف عيوب النسيج. استناداً إلى الملمس الخطي والمنتظم للنسيج، نقوم أولاً باستخراج هيستوغرام المتغيرات الإحصائية كسمات مميزة بين صور النسيج الخالية من العيوب والمعيوبية من خلال تطبيق FIR على هيستوغرام المتغيرات الإحصائية وطرح قيم فئة المتغيرات الإحصائية الحقيقية وقيم الفئة المتوقعة باستخدام النموذج النوعي. يتم حساب الأخطاء التراكمية التي تُستخدم لتحديد ما

إذا تم اكتشاف عيب. تظهر تجارب المحاكاة أن الطريقة المقترحة يمكن أن تحقق كشف قوي ودقيق لعيوب النسيج.

### 7- منهجية العمل:

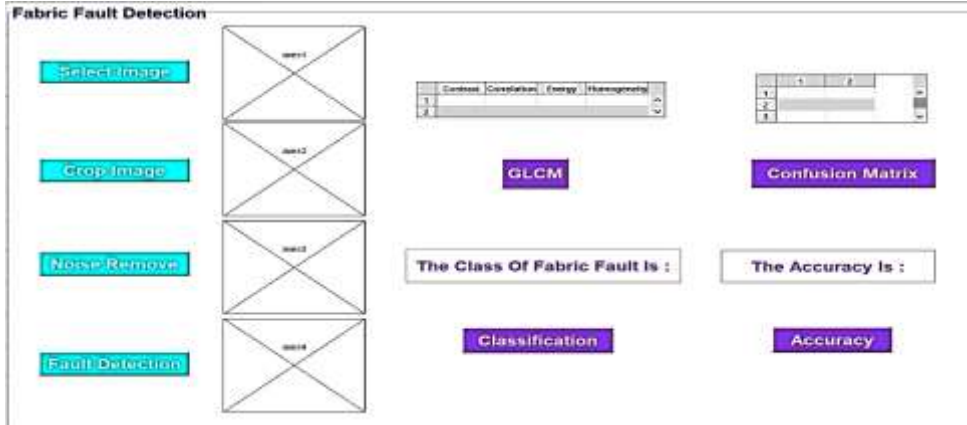
يمكننا تقسيم خوارزمية العمل إلى ثلاث خطوات رئيسية، الشكل (5).

1. مرحلة ادخال ومعالجة الصورة (Input and Pre-Processing Image):  
يتم اختيار الصورة من قاعدة البيانات الخاصة بنا، إذ من الممكن أن يتم أخذ هذه الصورة عن طريق ماسح ضوئي متصل بجهاز كمبيوتر شخصي، ولكن عادةً ما تكون الصور التي تم الحصول عليها غير مناسبة للتصنيف بسبب عوامل مختلفة، مثل الضوضاء واختلافات الإضاءة، وما إلى ذلك. لذلك، تتم معالجة هذه الصور مسبقاً باستخدام مرشحات لإزالة الميزات غير المرغوب فيها.
2. مرحلة حساب متجه سمات الصورة باستخدام خوارزمية GLCM (Features Extraction).  
مرحلة حساب متجه سمات الصورة باستخدام خوارزمية GLCM (Features Extraction).
3. تصنيف الصورة باستخدام مصنف SVM (Classification Using SVM).  
تصنيف الصورة باستخدام مصنف SVM (Classification Using SVM).  
(Classifier).



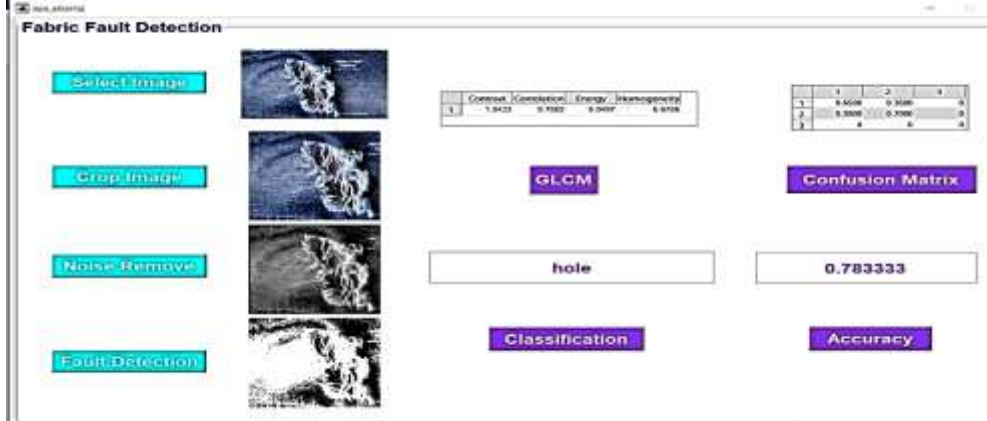
الشكل (5): خوارزمية العمل المقترحة.

ثم نقوم بتقييم أداء الشبكة، وذلك من خلال حساب مصفوفة الارتباك والدقة، وكذلك تم تصميم واجهة GUI لتسهيل تعامل المستخدم مع هذا النظام. يوضح الشكل (6) الواجهة التي تم تصميمها.



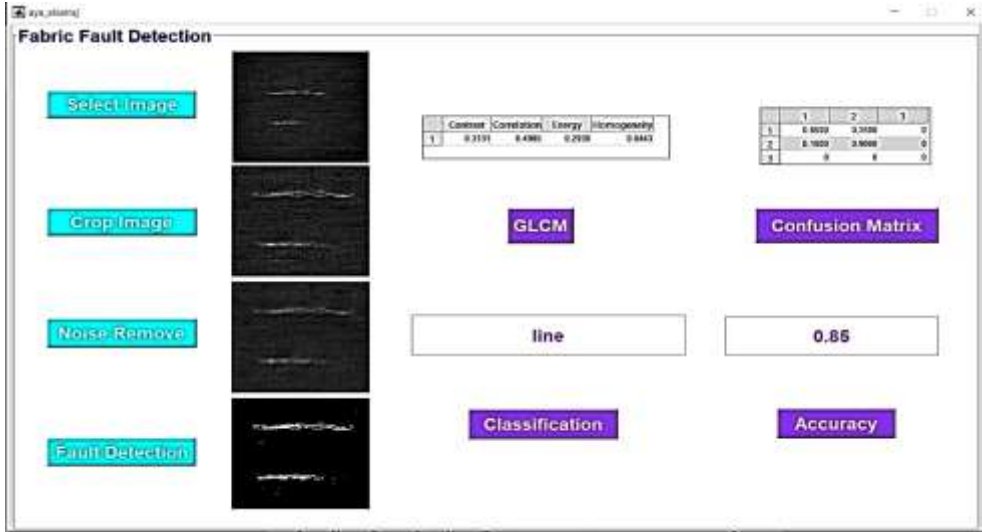
الشكل (6): الواجهة التي تم تصميمها.

اختبار الثقب:



الشكل (7): اختبار الثقب.

## اختبار الخط:



الشكل (8): اختبار الخط.

## 8- الاستنتاج:

في هذه الدراسة، تم إنشاء نظام كشف آلي عن عيوب النسيج، وذلك للتعرف على نوعين من أنواع عيوب النسيج (Hole, Line). إذ يتم إدخال هذه الصورة للنظام ومعالجتها (تنقية من الضجيج، تعتيب، ثم قمنا باستخراج ميزات هذه الصورة باستخدام خوارزمية التواجد المشترك (GLCM)، وتم التصنيف باستخدام خوارزمية SVM. وكانت النتائج أنه حصلنا على دقة كشف للقب 78.33 % ودقة كشف للخط 85,00%.

## 9- المراجع:

1- A. E. MINARNO, Y. MUNARKO, A. KURNIAWARDHANI, F. BIMANTORO AND N. SUCIATI, "TEXTURE FEATURE EXTRACTION USING CO-OCCURRENCE MATRICES OF SUB-BAND IMAGE FOR BATIK IMAGE CLASSIFICATION," 2014 2ND INTERNATIONAL CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGY (ICOICT), BANDUNG, 2014, PP. 249-254, DOI: 10.1109/ICOICT.2014.6914074.

- 2- SALEM, YASSINE BEN, AND SALEM NASRI. "TEXTURE CLASSIFICATION OF WOVEN FABRIC BASED ON A GLCM METHOD AND USING MULTICLASS SUPPORT VECTOR MACHINE." 2009 6TH INTERNATIONAL MULTI-CONFERENCE ON SYSTEMS, SIGNALS AND DEVICES. IEEE, 2009.
- 3- Minarno, Agus Eko, et al. "Texture feature extraction using co-occurrence matrices of sub-band image for batik image classification." 2014 2nd International Conference on Information and Communication Technology (IColCT). IEEE, 2014.
- 4- Wei, Bing, et al. "A new method using the convolutional neural network with compressive sensing for fabric defect classification based on small sample sizes." Textile Research Journal 89.17 (2019): 3539-3555.
- 5- Schalkoff, Robert J. "Pattern recognition." Wiley Encyclopedia of Computer Science and Engineering) 2007.

