

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR
ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITE MOHAMED SEDDIK BENYAHIA JIJEL

Faculté des sciences et de la technologie

Département d'Automatique

N° :...../2023

MEMOIRE DE MASTER

DOMAINE: Sciences et Technologies

FILIERE: Automatique

SPECIALITE : Automatique et Informatique Industrielle

Thème

Détection de défauts de textiles par vision industrielle

Présenté Par : LEBDJIRI Houssem

Encadré Par : Dr. S. BIAD

Date de soutenance : 03/07/2023

Jury de Soutenance

Président : M. HALIMI

Grade : MCB

Univ MSB jijel

Encadreur : S. BIAD

Grade : MCB

Univ MSB jijel

Examineur 1 : I. BOURAOUI

Grade : MCA

Univ MSB jijel

Promotion : 2022 /2023

Remerciement

*Avant d'aborder le vif du sujet, Je tiens à remercier
vivement :*

*Le Dieu qui m'a donné la force et le courage de
poursuivre, illuminant ainsi mon chemin pour achever
humblement ce travail.*

*Madame S. BIAD pour tout le soutien et précieux
conseils qu'elle m'a donnés.*

*À tous les membres du jury, Votre expertise et votre
dévouement sont inestimables. Merci infiniment.*

*Mes parents, mes sœurs et mes frères qui m'ont
soutenu et encouragé tout au long de ma carrière
académique.*

*Mes amis en souvenir de nos éclats de rire et des bons
moments.*

A tous, un grand merci

Dédicace

A ma très chère mère

Quoi que je fasse ou que je dise, je ne saurai point te remercier comme il se doit. Ton affection me couvre, ta bienveillance me guide et ta présence à mes côtés a toujours été ma source de force pour affronter les différents obstacles.

A mon très cher père

*Tu as toujours été à mes côtés pour me soutenir et m'encourager.
Que ce travail traduit ma gratitude et mon affection*

A mes très chers frères

*Mohamed, Abd Rahman et Islam
Et mes belles sœurs....*

A ma chère tante

Tout au long de ma vie, tu as été mon pilier, et je prie pour que Dieu te protège.

*À tous mes amis et collègues chacun
De son nom et de ses particularités.*

H. LEBDJIRI

Sommaire

Liste des figures	i
Liste des tableaux	ii
Introduction générale.....	1

Chapitre I : vision industrielle et détection de défauts de textile

I.1. Introduction.....	3
I.2. Vision industrielle	3
I.2.1. Avantages de la vision industrielle.....	3
I.2.2. Applications de la vision industrielle.....	4
I.2.3. Principe de l'inspection de défauts par Vision Industrielle.....	6
I.2.3.1. Acquisition des images	7
I.2.3.2. Unité de traitement	7
I.2.4. Automate et Prise de décision.....	8
I.3. Inspection des tissus de textile.....	8
I.3.1. Systèmes d'inspection basés sur l'homme.....	8
I.3.2. Inspection automatisée des tissus	9
I.3.2.1. Acquisition d'images	10
I.3.2.2. Prétraitement	11
I.3.2.3. Extraction de fonctionnalités	12
I.3.2.4. Détection/Classification	13
I.4. Textiles et défauts de fabrication.....	13
I.4.1. Types de défauts :	14
I.5. Conclusion.....	16

Chapitre II : Approches proposées

II.1. Introduction	17
II.2. Approches de détection des défauts de tissu	17
II.2.1. Approches structurelles.....	17
II.2.2. Approches statistiques.....	17
II.2.3. Approches spectrales	18
II.2.4. Approches basées sur des modèles	18

II.2.5. Approche d'apprentissage	18
II.2.6. Études comparatives	18
II.3. Approche proposée	19
II.3.1. Lissage par minimisation de la norme L0 gradient	19
II.3.2. Première approche : Algorithme localisation	21
II.3.2.1. Lissage préservant les contours	22
II.3.2.2. Binarisation	22
II.3.2.3. Localisation	22
II.3.3. Deuxième approche : Algorithme de classification	22
II.3.3.1. Extraction de caractéristique d'histogrammes	23
II.3.3.2. Classification défaut non-défaut	24
II.4. Classification	25
II.4.1. Classification non supervisée	25
II.4.2. Classification supervisée	25
II.4.3. Méthodes de classification	26
II.4.3.1. K-NN	26
II.4.3.2. SVM	27
II.4.4. Déroulement de la classification	28
II.4.4.1. La matrice de caractéristiques	28
II.4.4.2. La validation croisée	29
II.4.4.3. Matrice de confusion	30
II.4.4.4. Précision	31
II.4.4.5. La courbe ROC	31
II.5. Conclusion	32

Chapitre III : Résultat de simulation

III.1. Introduction	33
III.2. Environnement de travail	33
III.2.1. Base des données	33
III.3. Choix du facteur de lissage α	34
III.4. Algorithme de localisation	37
III.5. Algorithme de classification	40
III.5.1. Matrice de caractéristiques	43
III.5.2. Taux d'erreur	43

III.5.3. Matrice de confusion.....	44
III.5.4. Courbe de ROC.....	44
III.6. Conclusion	45
Conclusion générale	46
Bibliographie.....	47

Liste des figures

Chapitre I : vision industrielle et détection de défauts de textile

Figure (I.1) : Guidage robot Zeiss de haute précision.....	4
Figure (I.2) : Techniques d'identification : (a)codes-barres (b)reconnaissance optique de caractères.....	5
Figure (I.3) : Vision industrielle comme outil de mesure.....	5
Figure (I.4) : Systèmes de vision industrielle pour la détection : (a) défauts Fonctionnels (b) des anomalies.....	6
Figure (I.5) : Composants principales du système d'inspection par vision industrielle	6
Figure (I.6) : Systèmes d'inspection basés sur l'homme.....	9
Figure (I.7) : Exemple de système d'inspection automatique.....	9
Figure (I.8) : Organigramme d'un système d'inspection automatisé.....	10
Figure (I.9) : Inspection de défaut par caméra linéaire.....	11
Figure (I.10) : Grabbers ou carte d'acquisition avec différent nombre de port.....	11
Figure (I.11) : Etapes du processus de fabrication de tissus.....	13

Chapitre II : Approches proposées

Figure (II.1) : Détection et localisation de défaut.....	21
Figure (II.2) : Classification défauts non défauts.....	23
Figure (II.3) : Classification des types de classification.....	25
Figure (II.4) : La classification avec le modèle 5-NN.....	26
Figure (II.5) : Principe de base de la méthode SVM.....	28
Figure (II.6) : Un modèle de la matrice de caractéristiques.....	28
Figure (II.7) : Principe de la validation croisée K-fold pour k = 4.....	29
Figure (II.8) : Les algorithmes des trois méthodes de la validation croisée.....	30
Figure (II.9) : Modèle d'un courbe ROC.....	32

Chapitre III : Résultat de simulation

Figure (III.1) : Extrait de la base de données.....	34
Figure (III.2) : Effet de lissage (a) image originale, (b) image lissée.....	38
Figure (III.3) : Matrice de confusion (a) méthode SVM, (b) méthode KNN.....	44
Figure (III.4) : La courbe ROC pour (a) SVM, (b) KNN.....	45

Liste des tableaux

Chapitre II : Approches proposées

Tableau (II.1) : La matrice de confusion..... 31

Chapitre III : Résultat de simulation

Tableau (III.1) : Variation du facteur de lissage α selon les différentes textures..... 35

Tableau (III.2) : Applications de l'algorithme de localisation..... 38

Tableau (III.3) : Applications de l'algorithme de classification..... 41

Tableau (III.4) : Résultats de taux d'erreur par SVM et KNN..... 43

Introduction
générale

Introduction générale

La vision industrielle est un domaine essentiel dans le contexte de l'automatisation des processus de fabrication.

La détection de défauts est une application clé de la vision industrielle, offrant des avantages significatifs tels qu'une augmentation considérable de la cadence de production par rapport à une inspection manuelle, ainsi qu'une réduction des coûts de fabrication. En identifiant et en éliminant les morceaux de tissu défectueux avant la fin de la chaîne de production, cette technologie permet d'améliorer l'efficacité et d'optimiser les ressources, contribuant ainsi à des processus de fabrication plus rentables et de meilleure qualité.

Ces dernières années, l'industrie textile a connu un développement rapide, accompagné d'une demande croissante en termes de qualité des produits. Afin de répondre à ces exigences, il est primordial de contrôler rigoureusement la qualité des textiles. En effet, les défauts présents sur les tissus ont un impact significatif sur l'évaluation de leur niveau de qualité. Ainsi, la détection des défauts devient une étape essentielle dans le processus d'évaluation de la qualité des textiles.

Dans cette étude, nous pencherons sur l'analyse d'un système de détection de défauts dans les tissus, qui repose sur l'utilisation des outils algorithmiques du traitement d'image. Un tel système est constitué principalement de deux étapes principales : extraction de caractéristiques et prises de décision/ classification [1].

Le travail élaboré consiste à développer deux approches satisfaisant cet objectif. Elles sont basées principalement sur une méthode de lissage conservant les contours, noté le lissage par minimisation du gradient L0 et proposé dans la référence [2]. L'avantage de cette dernière est qu'elle permet de mettre en évidence le défaut en atténuant le reste des informations contenu dans l'image.

Ces deux approches sont : la première vise la localisation de défaut. Après avoir lissée l'image par la méthode déjà cité, on utilise la segmentation suivie des opérateurs de morphologie mathématique pour localiser le défaut.

Tandis que la deuxième s'intéresse à la classification des échantillons de la base de données en classe défaut non défaut. L'objectif d'utiliser la classification est de vérifier la performance de la méthode d'extraction de caractéristiques basée sur le lissage par L0 gradient et les descripteurs d'histogrammes. L'évaluation de la classification est réalisée en terme d'erreur global, matrice de confusion, et de courbe ROC.

L'étude présentée dans ce mémoire est organisée comme suit :

Dans le premier chapitre, nous explorons le domaine de la vision industrielle et son application spécifique à la détection des défauts dans les textiles. Nous examinons les nombreux avantages qu'offre la vision industrielle, sa précision et sa rapidité. Nous abordons ensuite le principe fondamental de l'inspection des défauts par vision industrielle. Nous examinons enfin les défauts courants dans la fabrication des textiles.

Dans le deuxième chapitre, nous abordons les approches proposées pour la détection de défauts dans les tissus. Nous mettons l'accent sur deux algorithmes spécifiques de localisation et de classification. Nous approfondissons cette dernière, en analysant deux types de classifieurs KNN (K-Nearest Neighbors) et SVM (Support Vector Machine). Nous détaillons aussi le processus de déroulement de la classification, ainsi que les critères d'évaluation d'un tel système.

Dans le troisième chapitre, nous examinons en détail les algorithmes proposés ainsi que les différents résultats obtenus.

Nous terminons notre étude par une conclusion générale et des perspectives.

Chapitre I

Vision industrielle et détection de défauts

I.1. Introduction

La détection de défauts dans les textiles est un processus important dans l'industrie pour garantir la qualité des produits finis. Deux méthodes principales existent pour accomplir cette fonctionnalité ; l'inspection manuelle par des travailleurs qualifiés, et l'utilisation de systèmes de vision industrielle à base d'analyse d'images par ordinateur.

L'inspection manuelle est souvent considérée comme la méthode la plus fiable, mais elle peut être coûteuse et sujette aux erreurs humaines. Les systèmes de vision industrielle sont de plus en plus utilisés pour automatiser la détection de défauts dans les textiles. Ces systèmes utilisent des caméras pour capturer des images des tissus et des algorithmes pour analyser les images afin de détecter les défauts.

Dans ce chapitre nous allons présenter les notions de base ainsi que les éléments technologiques de la vision industrielle liés à l'automatisation de la détection de défauts dans les tissus.

I.2. Vision industrielle

La vision industrielle englobe toutes les applications dans lesquelles une combinaison de matériel et de logiciel fournit des directives opérationnelles aux systèmes, pour exécuter leurs fonctions et objectifs, en utilisant l'acquisition et le traitement d'images.

Les systèmes de vision industrielle nécessitent une robustesse, une fiabilité et une grande stabilité. Ils utilisent des capteurs numériques qui sont intégrés dans des caméras industrielles dotées d'optiques spéciales. Ces caméras sont conçues pour capturer des images de manière à permettre au matériel et au logiciel de traiter, analyser et mesurer différentes caractéristiques afin de prendre des décisions [3].

I.2.1. Avantages de la vision industrielle

Si le contrôle humain est bien adapté pour interpréter de manière qualitative une scène complexe et non structurée, la vision industrielle excelle en matière de mesure quantitative d'une scène structurée grâce à sa vitesse, sa précision et sa capacité à répéter les opérations [3].

Les avantages de contrôle de qualité par vision par rapport à d'autres types de capteurs sont nombreux :

– Ils sont souples d'emploi et permettent une très grande variété d'utilisation. Par simple reprogrammation, un capteur de vision peut changer radicalement de type d'inspection et peut s'adapter instantanément à d'autres pièces.

- Ils permettent de réaliser simultanément plusieurs mesures, éventuellement de nature différente.
- Ils permettent des mesures sans contact et non destructives, avec une vitesse et une précision appréciable.
- Ils permettent de rendre objectives certaines mesures et de garantir ainsi la répétabilité de l'apparence des objets (constance de la couleur, de la forme, ...).
- Plus que tous dispositifs automatiques, ils permettent de remplacer des opérateurs humains dans des tâches fastidieuses qui requièrent attention et concentration

I.2.2. Applications de la vision industrielle

Les systèmes de vision industrielle sont utilisés dans le but de repérer des anomalies, des substances contaminantes, des défauts de fonctionnement et autres irrégularités dans les produits fabriqués. Leur application s'étend à divers domaines, tels que la vérification de la conformité des comprimés médicamenteux, la détection d'icônes ou de pixels défectueux sur les écrans, la mesure du niveau de contraste de l'éclairage arrière des écrans tactiles, la vérification de l'adéquation entre le produit et son emballage dans les secteurs de l'agroalimentaire et de la pharmacie, ainsi que le contrôle des bagues, bouchons et scellés d'inviolabilité sur les bouteilles...etc. D'une manière générale, ces applications sont diverses, on peut les classer comme suit [4] :

La robotique ou guidage des robots : la vision industrielle est étroitement associée à l'introduction de la robotique dans les systèmes de fabrication automatisés. Elle est employée pour aider les robots à détecter et à reconnaître les pièces, en vue de les saisir et de les transporter vers une autre ligne de production, ou de les trier en fin de chaîne de montage ou de fabrication, facilitant ainsi leur déplacement par le robot.



Figure (I.1) : Guidage robot Zeiss de haute précision

L'identification : Les systèmes de vision industrielle permettent l'identification et reconnaissance de produits grâce à la lecture de codes-barres, de codes Data Matrix, et de caractères imprimés. Ils peuvent également repérer des formes ou des éléments en fonction de la couleur, de la forme ou de la taille. Les systèmes OCR (Optical Character Recognition) permettent de lire les caractères alphanumériques, tandis que les systèmes OCV (Optical Character Vérification) vérifient la présence d'une chaîne de caractères. Ces méthodes permettent d'améliorer la traçabilité des produits et la vérification de leurs authenticités.



(a)

(b)

Figure (I.2) : Techniques d'identification : (a)codes-barres
(b) reconnaissance optique de caractères.

La mesure : un système de mesure de vision industrielle calcule la distance entre des points ou des emplacements géométriques sur un objet, et vérifie si ses mesures tout en respectant les spécifications du cahier de charge. En cas de non-conformité, le système envoie un signal d'échec au système de commande, déclenchant un mécanisme de rejet pour éjecter l'objet de la ligne de production. Les applications de mesure peuvent mesurer des pièces avec une tolérance allant jusqu'à 0,0254 mm




Figure (I.3) : Vision industrielle comme outil de mesure

Inspection : Les systèmes de vision industrielle pour l’inspection sont utilisés pour détecter les anomalies, les contaminants, les défauts fonctionnels et autres irrégularités dans les produits manufacturés. Le sujet traité dans ce travail concerne l’inspection automatique des défauts de textiles.




Figure (I.4) : Systèmes de vision industrielle pour la détection : (a) défauts fonctionnels (b) des anomalies.

I.2.3. Principe de l’inspection de défauts par Vision Industrielle

L’objectif du processus d’inspection est d’identifier les erreurs ou défauts puis modifier un paramètre ou donner l’alerte à l’inspecteur pour le contrôle du processus de fabrication. Du Point de vue industrielle, est d’identifier les erreurs ou les défauts dans le processus de fabrication [5]. Ce processus comporte plusieurs étapes figure (I.5) et exigences que nous allons les décrire brièvement par la suite.

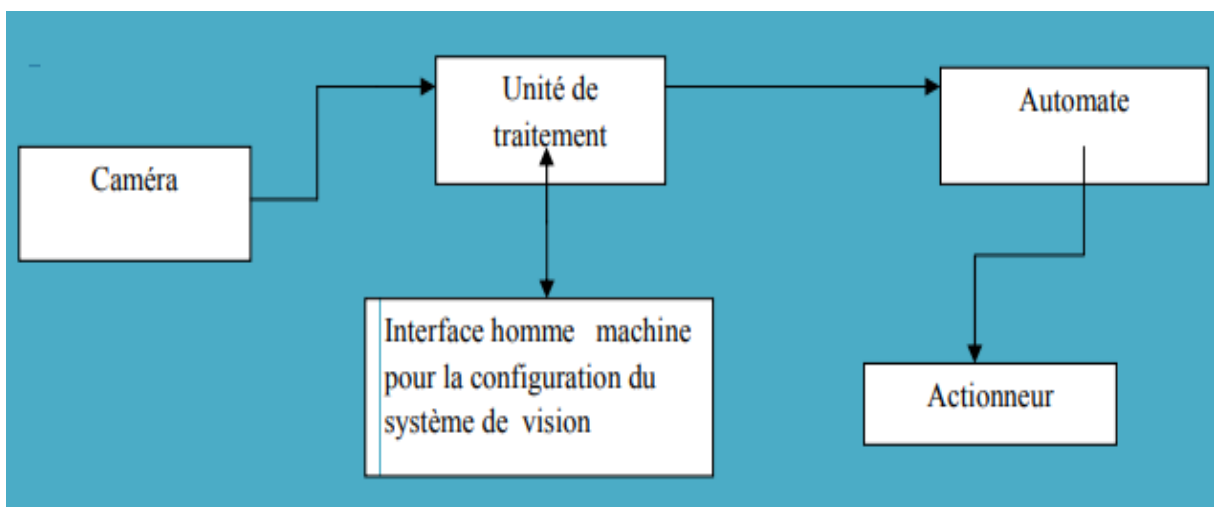


Figure (I.5) : Composants principales du système d’inspection par vision industrielle

I.2.3.1. Acquisition des images

Pour obtenir une représentation d'une scène de fabrication, des images sont acquises, mais les conditions d'acquisition peuvent altérer la représentation, ce qui est particulièrement problématique si le défaut est très petit. Il est donc essentiel de définir des paramètres et des critères appropriés. Les paramètres clés incluent l'éclairage (forme, intensité, position et type), ainsi que les caractéristiques de la caméra (objectif, position et capteur). Pour qualifier et quantifier un défaut, il doit être clairement visible avec un contraste suffisant entre le défaut et l'image, en plus sa taille doit être connue. Les acteurs clés impliqués dans ce processus sont :

- **Choix de l'éclairage** L'éclairage joue un rôle critique dans ce processus, en mettant en évidence les éléments souhaités. Un éclairage efficace permet d'éviter des traitements supplémentaires sur l'image. Il est également essentiel d'obtenir un éclairage uniforme pour tous les types de défauts, si cela est réalisable. Afin que l'éclairage soit détecté par la caméra, il doit couvrir une vaste zone autour du produit en se reflétant sur sa surface. L'intensité de l'éclairage constitue un paramètre important à prendre en considération.
- **Paramétrage de la caméra** : la position et la focale de la caméra sont des éléments cruciaux pour l'obtention d'une bonne qualité d'image. En outre, le temps d'intégration de la caméra, l'ouverture et la cadence d'acquisition sont des paramètres qui doivent être soigneusement réglés pour garantir des résultats optimaux.

I.2.3.2. Unité de traitement

L'unité de traitement dans la vision industrielle permet la numérisation, le stockage, le traitement des images, ainsi que la configuration et la programmation des outils logiciels spécifiques. Le traitement des images représente une étape cruciale dans la chaîne d'inspection, car il vise à extraire les informations pertinentes concernant les défauts à partir des images acquises (comme expliqué précédemment). Cependant, choisir la technique de traitement appropriée peut être complexe en raison de la diversité des techniques disponibles. Ce choix dépendra de plusieurs paramètres, notamment du type de défaut que l'on cherche à identifier. Les détails concernant la technique de détection utilisée dans cette étude sont exposés en détail dans le chapitre II.

I.2.4. Automate et Prise de décision

Une fois les défauts détectés et localisés lors de l'étape précédente, les résultats sont transmis à l'automate qui prend en charge l'envoi des ordres et des commandes nécessaires pour le transport et l'isolation du produit défilant.

I.3. Inspection des tissus de textile

Le processus d'inspection est très important pour l'industrie manufacturière. De nos jours l'importance du processus d'inspection est presque égale à celle du processus de fabrication dans les perspectives de l'industrialisme moderne [6]. La qualité du produit final dans l'industrie textile, à savoir le tissu lui-même, est un facteur essentiel à prendre en compte. Plus spécifiquement, la qualité d'un tissu est généralement évaluée en fonction de la présence de défauts et de leur localisation. Cela signifie qu'il est crucial de détecter et de localiser les défauts présents dans la trame de tissu lorsqu'on évalue sa qualité dans un contexte industriel. [7].

La fabrication de la trame de tissu est entièrement automatisée. Dans ce processus, le fil enroulé est déroulé par un moteur pour éviter toute coupure. Un chariot pousse une ou plusieurs aiguilles dans une direction spécifique pour former un nœud. La répétition de cette opération crée une ligne de nœuds, également appelée ligne de trame de tissu. Le nombre de fils et d'aiguilles peut varier en fonction du type de trame à produire. Pendant ce processus, différents types de défauts peuvent se produire. Par exemple, le fil utilisé peut être coupé, créant un vide dans la trame. Des taches d'huile peuvent être causées par du matériel défectueux, et des différences de couleur peuvent être constatées lors de la teinture du tissu. Une classification de ces défauts est présentée dans la section I.4.

Principalement, la détection des défauts de tissu utilise deux types de modèle d'inspection [8]. Le premier est le système d'inspection basé sur l'homme. Le deuxième est basé sur des systèmes d'inspection automatisés.

I.3.1. Systèmes d'inspection basés sur l'homme

Lorsque les machines de fabrication sont en cours de production de tissus, un inspecteur humain est chargé d'examiner les trames et de signaler la présence de défauts. Cette méthode d'inspection est considérée comme préventive, car elle vise à limiter la propagation des défauts et nécessite un contrôle total des paramètres de production. Cependant, cette approche présente des défis et limitations. Tout d'abord, interrompre et reprendre le processus de manière fluide

peut être compliqué en raison de sa complexité. De plus, la production peut être suffisamment lente pour rendre difficile la détection des défauts par l'inspecteur humain. En outre, l'environnement industriel hostile, caractérisé par la chaleur et le bruit générés par les machines de tricotage, peut être insupportable pour l'inspecteur [6].



Figure (I.6) : Systèmes d'inspection basés sur l'homme.

I.3.2. Inspection automatisée des tissus

L'utilisation de systèmes d'inspection automatique a gagné en popularité en raison des limitations de l'inspection visuelle humaine, telles que les coûts élevés, la faible précision et les performances lentes. Un exemple de ces systèmes est illustré dans la figure (I.7) Ces solutions automatisées visent à améliorer la qualité et l'efficacité du contrôle, ce qui permet d'accroître la rentabilité de la production.



Figure (I.7) : Exemple de système d'inspection automatique.

L'organigramme d'un système d'inspection automatisé est donné par la figure (I.8), il se compose généralement de quatre parties : acquisition d'image, prétraitement ou amélioration de l'image, extraction de fonctionnalités et décision confection. Toutes les parties du système doivent fonctionner de la meilleure façon possible pour avoir une efficacité et un logiciel d'inspection efficace.

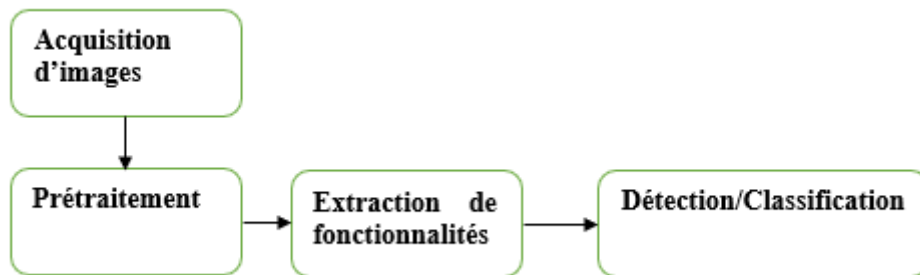


Figure (I.8) : Organigramme d'un système d'inspection automatisé

I.3.2.1.Acquisition d'images

Les systèmes d'inspection automatisés en temps réel utilisent : des caméras CCD (dispositif à couplage de charge), ou caméra CMOS (semi-conducteur complémentaire à oxyde métallique) en plus de grabbers qui sont des cartes d'acquisition sont utilisés [9,10].

Deux types de caméra sont utilisées ; Caméra à balayage par ligne et celle à balayage aléatoire. Cette dernière utilise un système de photo matricielle, qui peuvent capturer des images sans l'aide d'un codeur de transport. Par conséquent, Les résolutions d'image ne sont pas affectées par la vitesse de transport dans les deux sens. La caméra à balayage par ligne utilise des systèmes de capteurs photo linéaires, de sorte que ces derniers fournissent une résolution plus élevée et peuvent inspecter une plus grande partie d'un produit. Les inconvénients de ces systèmes sont la nécessité de présence d'un système généralement utilisé pour synchroniser la fréquence de balayage de la caméra avec la vitesse de transport du produit. Avec une caméra linéaire, une image 2D complète peut être créée à partir de balayages de plusieurs lignes. La figure (I.9) illustre le principe d'inspection par camera linéaire.

Dans les systèmes d'inspection automatique en temps réel, la résolution est un Détail significatif pour la détection des défauts. La résolution de l'image dépend du matériel utilisé et la distance entre la caméra et le produit inspecté. Une résolution faible de conduit généralement à une inspection rapide, mais fait négliger les détails et par conséquent possibilité de manquer

de petits défauts. En revanche forte résolution, permet de détecter tous les détails mais de diminuer la vitesse d'inspection.




Figure (I.9) : Inspection de défaut par caméra linéaire

Les grabbers, illustrés dans la figure (I.10), sont utilisés comme des dispositifs de transfert de données entre la caméra et l'unité de traitement de données. Ils jouent un rôle essentiel dans le stockage et la transmission rapides des données de la caméra vers l'unité de traitement. Étant donné que des caméras à grande vitesse sont nécessaires pour le processus de détection des défauts du tissu, l'utilisation de cartes d'acquisition est primordiale. Sinon, il y aurait des pertes de données provenant de la caméra, qui sont produites séquentiellement. Les cartes d'acquisition permettent le transfert simultané de plusieurs données de la caméra vers l'ordinateur.



Figure (I.10) : Grabbers ou carte d'acquisition avec différent nombre de port.

I.3.2.2. Prétraitement

Bien que les images de tissu soient capturées en haute résolution, les images incluent également des bruits et autres distorsions. Alors un prétraitement visant l'amélioration de la

qualité de l'image est nécessaire. Les techniques les plus utilisées sont le filtrage médian, l'égalisation de l'histogramme. Le filtrage médian [11] est utilisé pour de réduire le bruit tout en conservant les contours de l'image. Il permet d'éliminer les valeurs aberrantes sans se limiter à faire un calcul de moyenne qui aura tendance à contaminer les valeurs voisines avec cette valeur aberrante et flouter l'image. Il respecte aussi le contraste de l'image et la luminosité de l'image.

L'égalisation d'histogramme réduit l'effet des éclairages instables et améliore le contraste [12]. Elle consiste à appliquer une transformation sur chaque pixel de l'image, et donc d'obtenir une nouvelle image à partir d'une opération indépendante sur chacun des pixels. Cette technique permet de mieux répartir les intensités sur l'ensemble de la plage de valeurs possibles, en « étalant » l'histogramme [13].

Finalement prétraité les images revient à isoler des effets nuisibles qui rendent difficile à percevoir les défauts. Une nouvelle image modifiée est produite pour obtenir une meilleure détection. En outre, ces applications ne modifient pas les dimensions et la taille des images.

I.3.2.3.Extraction de fonctionnalités

L'extraction de caractéristiques est une étape préliminaire dans toute chaîne d'analyse d'image. Elle possède un lien étroit avec la précision de la méthode de détection utilisée. Elle permet d'obtenir des informations utiles qui seront la base de la décision sur la présence de défaut et sa localisation.

Dans le cas de détection de défauts de tissu, les textures défectueuses et non défectueuses sont caractérisées et analysées. Les relations entre les pixels ou les différenciations définissent des informations utiles et sont utilisées comme fonctionnalités.

En pratique, les caractéristiques des images texturées sont décrites comme des vecteurs d'entités. Pour discrimination dans les images de tissu, les vecteurs caractéristiques sont réalisés en mesurant ceux dont les valeurs sont très similaires dans les défauts du tissu. Les valeurs pour des tissus sans défaut sont également mesurées. Pour établir une règle de classification on se base généralement sur un ensemble de critères numériques décrivant le vecteur défaut de celui non défaut [12].

I.3.2.4. Détection/Classification

Les vecteurs de caractéristiques issues de l'étape précédente forment les informations d'entrées de cette dernière étape.

Pour la classification, on considère deux classes : le tissu sans défaut et avec défaut. Dans le cadre de notre travail, nous avons utilisé les caractéristiques des histogrammes issues des images lissées. Pour le lissage des images, nous avons utilisé la méthode basée sur la minimisation de la norme du gradient L0.

Pour la détection, l'objectif principal est de pouvoir localiser et définir le défaut avec précision. Dans le cadre de notre travail, nous avons utilisé le lissage suivi par une méthode de segmentation. Plus de détails seront exposés dans le chapitre suivant.

I.4. Textiles et défauts de fabrication

Un textile présente deux caractéristiques principales : sa composition, qui fait référence au matériau à partir duquel il est fabriqué (comme le coton, le polyester, le lin, etc.), et son tissage, également connu sous le nom d'armure, qui décrit la manière dont les fils de matériau sont entrelacés. La figure (I.11) illustre les différentes étapes du processus de fabrication industrielle des tissus.

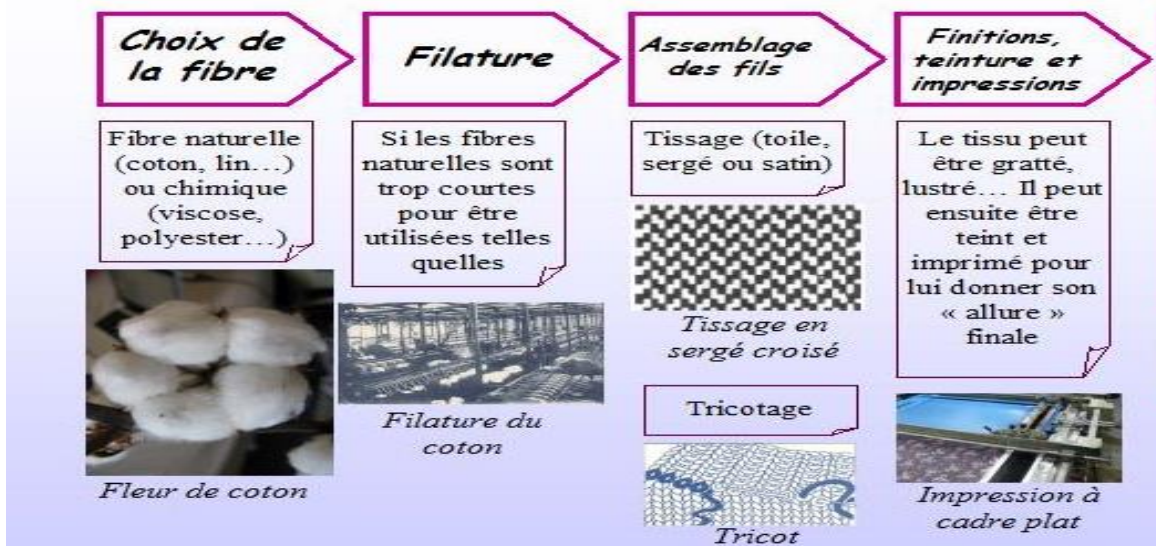


Figure (I.11) : Etapes du processus de fabrication de tissus


Les défauts dans les tissus sont des altérations qui se produisent dans le motif du tissu. Ces altérations peuvent être causées par des variations dans les fils de chaîne et de trame, la densité des fils ou les espaces entre les fils de chaîne.

Les systèmes automatisés de détection des défauts de tissu sont conçus pour repérer ces variations anormales et déterminer leur type et leur emplacement. Dans le paragraphe suivant, nous présenterons une classification des différents types de défauts de tissu.


I.4.1. Types de défauts :

Les tissus sont produits après avoir passé par de nombreux traitements, figure (I.11). Différentes machines et techniques sont utilisées pendant les étapes de traitement. Ainsi, les tissus sont exposés à des forces et des contraintes qui causent des défauts. Selon leurs formes et leurs directions, les défauts prennent différents noms. Les descriptions suivantes résument les défauts de tissu les plus courants ainsi que leurs raisons [14].


Gouttes : Un morceau de fils étranger tissé comme des fils originaux qui provoquent une apparence sur la surface du tissu. Ces défauts ont les mêmes directions avec la trame et la chaîne.




Trous : Les défauts sur les machines à tisser sont à l'origine de ces défauts. Généralement une aiguille cassée provoque ce type de défaut.




Taches d'huile : Elles sont causées par beaucoup des lubrifiants des machines ou des taches extérieures de l'huile sur les tissus.




Nœuds : Les régions de nœuds se connectent entre elles. La raison de ces défauts est que les fils cassés flottent pour maintenir la continuité du processus de tissage.




Briser : De nombreux fils de chaîne décomposent le motif, elle est causée par un mauvais moment d'excrétion, cueillette douce, contrôle insuffisant de la navette dans les boîtes, borbier sévère accessoires de prélèvement endommagés ou cassés.




Densité de pics irréguliers : Il s'agit d'un défaut mécanique décrit comme une zone coincée ou ouverte formée dans le tissu dû à une densité de pics inégale et causé par un passage à tabac irrégulier.



Larme : Les défauts de déchirure ont des structures similaires avec des défauts de trou, mais les larmes ont irrégulier formes. Les rouleaux de tissu peuvent être déchirés avec des arêtes vives ou des objets rigides qui utilisent dans procédés de fabrication ou en grenages endommagés sur les machines.



Slubs : Défauts régionaux qui entraînent une détérioration de la symétrie structurelle entre les fils, elle est causée par un morceau de fil supplémentaire qui est tissé dans le tissu. Ces défauts sont composés en raison des troubles structurels des fibres.



I.5. Conclusion

La vision industrielle est un domaine multidisciplinaire qui combine des connaissances en physique, optique, informatique, mécanique et électronique pour résoudre des problèmes d'inspection et de contrôle de qualité dans diverses industries.

L'intérêt d'un système de vision industrielle est d'améliorer la productivité et la qualité de la production. Le contrôle par vision évite le travail fastidieux d'un contrôle manuel, et permet d'être plus rapide pour des tâches répétitives.

Chapitre II

Approches proposées pour la détection de défauts

II.1. Introduction

Ce chapitre explore les approches de détection des défauts de tissu basé sur le traitement d'image, suivie par une présentation détaillée des approches proposées dans cette étude.

En effet, nous nous sommes concentrés sur deux objectifs : le premier sur la détection et la localisation du défaut sur différents types d'images. Le deuxième sur l'élaboration d'un système de classification de type défaut, non défauts. Pour ce faire, nous avons examiné deux types de classifieurs : le KNN (K-Nearest Neighbors) et les SVM (Support Vector Machine). Nous décrivons les différentes étapes du déroulement de la classification, y compris la sélection des caractéristiques, la création des ensembles d'entraînement et de test, ainsi que les critères d'évaluation de performance d'un tel système.

II.2. Approches de détection des défauts de tissu

Les méthodes de détection des défauts de tissu sont classées en différentes classes : structurelles, statistiques, spectrales, basées sur des modèles, apprentissage [1].

II.2.1. Approches structurelles

Les approches structurelles considèrent la texture comme une composition de primitives texturales et se basent sur l'analyse de texture pour détecter et modéliser les motifs globaux du tissu. Cependant, ces approches ont une fiabilité limitée car elles ne sont efficaces que lorsque la texture du tissu présente un motif très régulier. Elles peuvent avoir du mal à détecter des défauts structurels dans des textures plus complexes. Il est donc important de prendre en compte ces limitations lors de l'utilisation d'approches structurelles pour la détection des défauts de tissu.

II.2.2. Approches statistiques

Les approches statistiques utilisent des statistiques de premier ordre et des statistiques de second ordre pour extraire des caractéristiques de texture dans la classification des textures. La plupart des méthodes utilisées dans cette approche comprennent la matrice de cooccurrence, les caractéristiques d'histogramme, l'autocorrélation Approches fonctionnelles et morphologiques mathématiques. En outre, il existe d'autres approches statistiques telles que la corrélation croisée, Moments statistiques, détection des bords et méthodes de réseaux neuronaux dans les revues de littérature [1].

II.2.3. Approches spectrales

Les approches de détection de défauts de tissus requièrent à la fois des informations spatiales et fréquentielles. Les informations fréquentielles sont essentielles pour détecter la présence d'un défaut, tandis que les informations spatiales permettent d'identifier son emplacement. Les approches spectrales sont couramment utilisées dans la détection de défauts de tissus, visant à supprimer les éléments de base de la texture de l'image et à généraliser leur disposition spatiale. Cependant, ces approches sont plus adaptées aux structures périodiques et ne conviennent pas aux textures aléatoires. Parmi les approches spectrales utilisées dans ce domaine, on cite celles basées sur la transformée en ondelettes, la transformée de Fourier, et la transformée de Gabor.

II.2.4. Approches basées sur des modèles

Les approches de détection de défauts basées sur des modèles reposent sur la construction d'un modèle d'image. Avec l'aide du modèle construit, l'identification de la texture ainsi que la synthèse de texture sont effectuées. Cette technique convient aux images de tissus qui peuvent présenter des changements de surface dus à des défauts tels que la rupture de fil et la rupture d'aiguille. Les paramètres du modèle à utiliser sont importants pour capturer les détails nécessaires dans la texture. L'avantage de ce type d'approches est qu'elles peuvent produire des textures de tissus qui peuvent correspondre aux textures de tissus observées. De ce fait ces approches peuvent être combinées avec des techniques d'estimation pour la détection de défauts [1].

II.2.5. Approche d'apprentissage

D'une manière générale, l'apprentissage automatique utilise des modèles et des algorithmes pour analyser des données et réaliser des tâches spécifiques. Le système apprend à partir d'exemples plutôt que d'être programmé explicitement. Les modèles, tels que les réseaux neuronaux sont alors entraînés sur des données pour détecter des schémas et prendre des décisions sur la présence de défauts.

II.2.6. Études comparatives

Il est crucial de comparer les méthodes de détection des défauts de tissu, mais il faut considérer les différences dans les bases de données, les systèmes d'imagerie et les paramètres. Des études ont comparé des méthodes telles que les champs aléatoires de Markov, les filtres

bidimensionnels, la transformée de Fourier, la transformée de Karhunen-Loève, les filtres de Laws et la matrice de cooccurrence. [1]. Les champs aléatoires de Markov se sont avérés les plus performants lors des comparaisons. Les filtres de Sobel, les méthodes de seuillage et l'analyse de la dimension fractale ont également été évalués, la dimension fractale étant considérée comme la méthode la plus fiable. Une étude récente a montré que l'approche des bandes régulières était la plus efficace dans l'ensemble, mais les filtres de Gabor étaient particulièrement précis pour détecter les défauts dans les images de tissu présentant de multiples anomalies. [1].

II.3. Approche proposée

Le schéma général de la détection de défaut est présenté dans le chapitre I sur la figure I.8. Les deux étapes clés dans ce schéma sont : la phase extraction de caractéristiques et celle de décision. L'étude menée dans ce travail repose sur deux objectifs principaux : le premier vise la localisation du défaut, tandis que le deuxième correspond à la classification défauts, non défauts des images de la base de données. Pour accomplir ces objectifs, deux approches ont été proposées. Notons que ces deux dernières sont basées sur la même méthode pour l'étape d'extraction de caractéristiques ; la méthode de lissage par minimisation de la norme L_0 du gradient

D'après l'état de l'art présenté dans le paragraphe précédent, cette méthode fait partir des approches statistiques. Cette classification est justifiée par le fait que la méthode est basée sur la réduction des changements abruptes des intensités de l'image. Ces derniers sont mesurés par les valeurs non nulles de la norme L_0 du gradient. Ce calcul peut être interprété comme mesure statistique de l'image. Cette méthode est présentée en détail dans la section suivante.

II.3.1. Lissage par minimisation de la norme L_0 gradient

Le lissage d'images en général, est une opération importante en traitement d'images, utilisée pour atténuer un bruit qui corrompt l'information avant d'autres traitements. Par contre le lissage déployé dans cette étude est un cas particulier, il préserve les contours en les accentuant, tout en éliminant à un degré gérable les structures de faible amplitude contenues dans l'image. L'utilisation d'une telle technique dans ce travail est alors justifiée et va permettre de mettre en évidence le défaut.

L'algorithme se base sur une approche d'optimisation spécifique pour obtenir ce type de lissage préservant les contours, comme proposé par les auteurs de la référence [2].

Une minimisation d'une fonction objectif dérivée de la distribution des valeurs des gradients des pixels de l'image est alors utilisée.

Pour cela, chaque pixel de l'image est associé à un poids basé sur la similarité de ses pixels voisins. Cette fonction de pondération est ensuite utilisée pour lisser l'image en attribuant des niveaux de gris moyens aux pixels voisins ayant des poids similaires. En conséquence, les pixels présentant une similarité élevée subiront un lissage important, créant ainsi des zones homogènes, tandis que les pixels présentant des différences importantes seront moins lissés. Cette approche permet d'obtenir une image lissée qui préserve les contours tout en réduisant les variations indésirables. Plus de détails sur cette approche est donnée dans la référence [2].

Son formalisme mathématique peut être résumé comme suit :

Soit :

g : image d'entrée

f : image lissée

On considère la relation suivante pour compter discrètement les changements d'amplitude :

- $c(f) = \#\left\{\frac{p}{|f_p - f_{p+1}|} \neq 0\right\}$ avec p et p+1 : pixels voisins,

$|f_p - f_{p+1}|$: gradient

$\#\{\}$ operateur de comptage donnant le nombre de p qui satisfait $|f_p - f_{p+1}| = 0$

Cet opérateur est noté : **la norme L0 gradient**.

- Cette mesure ($\#\{\}$) n'est pas fonctionnelle seule, elle est combinée avec une contrainte générale, c.-à-d., f doit être similaire au signal d'entrer g.

- La fonction objective à minimiser est alors donnée par :

$$\min_f \sum (f_p - g_p)^2 \quad \text{Sous contrainte } c(f)=k$$

Avec k : le nombre des non zéro gradient

Pour pouvoir contrôler le nombre k, qui peut aller de dizaines à des milliers, les auteurs de la référence [2] propose de prendre une fonction générale pour la recherche de l'équilibre entre l'aplatissement de la structure et la similitude des résultats.

Cette forme sera donner comme suit :

$$\min_f \sum (f_p - g_p)^2 + \alpha c(f)$$

Avec α : paramètre de pondération contrôlant directement la significativité de $c(f)$.

Le paramètre α est dit paramètre ou **facteur de lissage**. Les valeurs que peut prendre ce facteur influe directement sur la qualité du lissage. Elles seront discutées en détail dans le chapitre III.

II.3.2. Première approche : Algorithme localisation

La localisation précise des défauts dans le textile est cruciale pour garantir la qualité des produits. L'approche proposée se déroule comme suit : premièrement le lissage de l'image originale pour réduire les régions homogènes et ne garder que le défaut, ensuite la binarisation pour séparer les défauts du reste de l'image, et enfin l'application de techniques de morphologie mathématique pour localiser les défauts.

Ces différentes étapes ainsi que les résultats d'application de chacune d'elles sont présentées sur la figure (II.1).

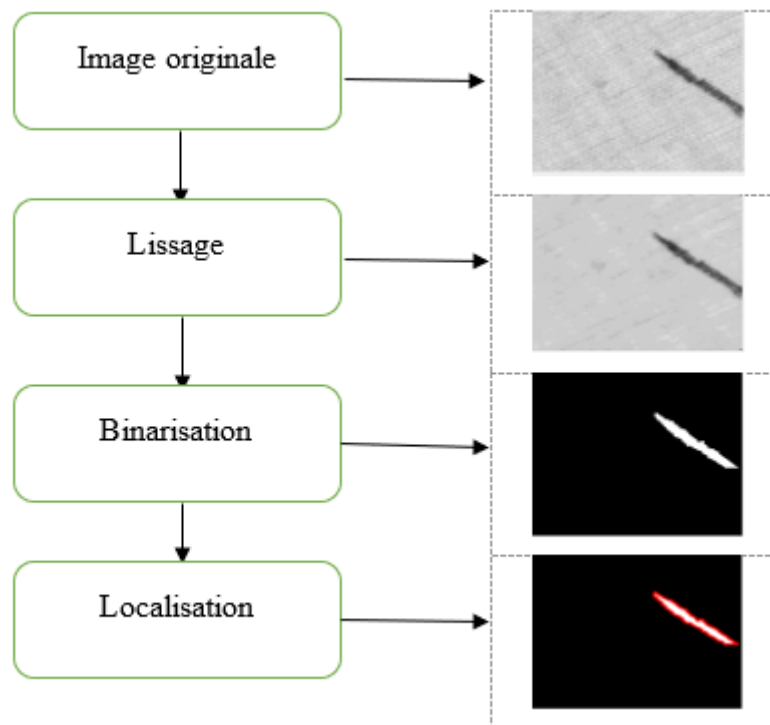


Figure (II.1) : Détection et localisation de défaut

II.3.2.1. Lissage préservant les contours

L'objectif visé par la méthode de lissage utilisée, est de trouver une version lissée de l'image d'origine tout en préservant les contours et les structures importantes de l'image. Cette technique a été utilisée comme première étape dans la phase d'extraction de caractéristiques.

II.3.2.2. Binarisation

En traitement d'image, la binarisation est une opération de seuillage qui produit une image ayant deux classes de pixels, on parle alors d'une image binaire. En général, les pixels sont représentés par des pixels noirs et des pixels blancs dans une image binaire. Le seuil de binarisation est choisi d'une manière automatique par l'algorithme d'Otsu développé sous Matlab. Pour cette étape l'image d'entrée est celle résultante du lissage par minimisation de la norme L0 du gradient.

II.3.2.3. Localisation

Dans cette étape, on utilise l'image binarisée issue de l'étape précédente pour entourer et localiser le défaut avec précision. Pour ce faire, les outils utilisés dans le cadre de ce travail sont les algorithmes de morphologie mathématique connus pour l'analyse et le traitement des formes géométriques dans les images.

La morphologie mathématique est basée sur des opérations morphologiques, telles que la dilatation, l'érosion, l'ouverture et la fermeture. Ces opérations permettent de modifier la forme et la structure des objets présents dans une image. Pour localiser des défauts, une combinaison de ces opérations est utilisée pour mettre en évidence les caractéristiques spécifiques des défauts.

II.3.3. Deuxième approche : Algorithme de classification

La classification défauts et non-défauts dans le textile est cruciale pour la qualité des produits. L'approche utilisée est de type supervisé ; chaque image de la base possède un label défaut ou non-défaut. Ces notions sont bien définies dans la section suivante.

L'algorithme se déroule à travers une série d'opération de traitement en commençant par la technique de lissage déjà présenté dans la section (II.3.1). Cette dernière permet de réduire les variations et mettre en évidence le défaut.

Dans ce travail, on a proposé d'utiliser les caractéristiques d'histogramme des images lissées comme vecteur de caractéristiques. Il existe 7 caractéristiques calculées à partir de la

fonction de probabilité d’histogramme de premier ordre : la moyenne, l’écart-type, asymétrie et kurtose, énergie, entropie et douceur.

L’ensemble des vecteurs issus des différentes images de la base de données vont former le modèle du classifieur, et la décision sur la présence de défauts sera faite grâce à ce modèle. Cette approche automatique nous a permis d’identifier efficacement les images avec défauts de celles non-défauts comme nous allons le voir dans le chapitre III. La figure (II.2) illustre les étapes de la classification proposée.

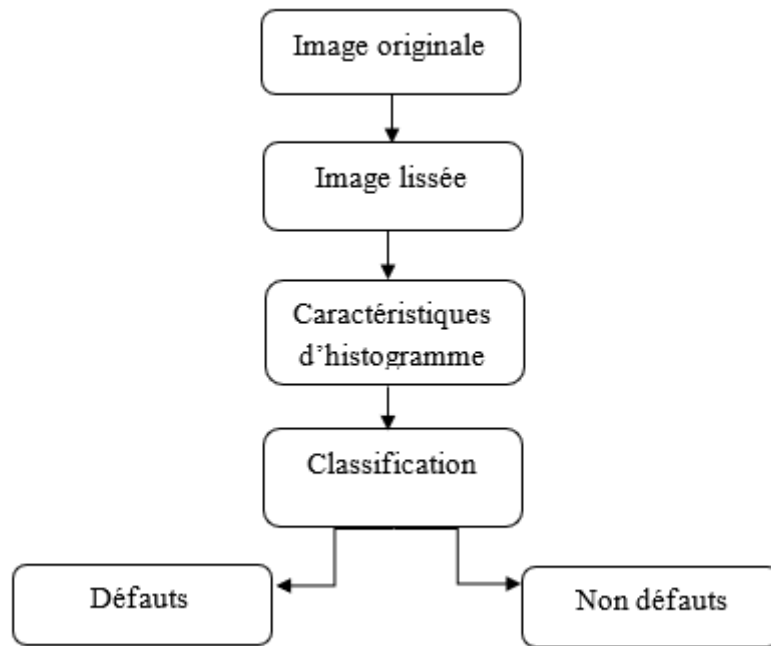


Figure (II.2) : Classification défauts non défauts

II.3.3.1. Extraction de caractéristique d’histogrammes

Étant donné une image en Niveaux de Gris I, avec « L » représente la valeur d’intensité maximale, la probabilité d’histogramme p(g) est défini comme suit :

$$P(g) = \frac{N(g)}{M} \tag{II. 1}$$

Avec : M est le nombre total de pixels dans l’image I et N(g) est le nombre de pixels au niveau de gris g.

Les caractéristiques basées sur la probabilité d’histogramme sont données comme suit [15]:

- **Moyenne** : représente la valeur moyenne de gris qui décrit la luminosité de l’image

$$\mu = \sum_{g=0}^{L-1} gp(g) \quad (\text{II. 2})$$

-**Ecart-type** : mesure la distribution de la valeur de gris et nous indique le contraste de l'image,

$$\delta = \sqrt{\sum_{g=0}^{L-1} (g - \mu)^2 p(g)} \quad (\text{II. 3})$$

- **Asymétrie** : elle mesure la distribution inégale des valeurs de gris de l'histogramme sur la valeur moyenne

$$S = \frac{1}{\delta^3} \sum_{g=0}^{L-1} (g - \mu)^3 p(g) \quad (\text{II. 4})$$

- **Kurtose** : mesure le pic ou la non-gaussianité des distributions des valeurs de gris autour de la valeur moyenne

$$K = \frac{1}{\delta^4} \sum_{g=0}^{L-1} (g - \mu)^4 p(g) \quad (\text{II. 5})$$

- **Energie** : montre l'uniformité de la distribution des niveaux de gris NG

$$G = \sum_{g=0}^{L-1} p(g)^2 \quad (\text{II. 6})$$

- **Entropie** : nous indique le caractère aléatoire de la distribution des niveaux de gris

$$E = \sum_{g=0}^{L-1} p(g) \log[p(g)] \quad (\text{II. 7})$$

-**Douceur** : utiliser pour mesurer la surface de l'image :

$$R = \frac{1}{1+\delta^2} \quad (\text{II. 8})$$

II.3.3.2. Classification défaut non-défaut

La classification des défauts et des non-défauts permet de distinguer clairement les caractéristiques indésirables des caractéristiques normales et acceptables des produits textiles. Des critères et des normes peuvent être établis pour définir les défauts tels que les fils cassés, les taches, les irrégularités de couleur et les trous. Pour ce travail on s'est limité juste pour la question défaut, non-défaut.

Les classifieurs testés au sein de cette étude sont les KNN et les SVM qui sont présentés dans le paragraphe suivant.

II.4. Classification

Il est possible de regrouper les algorithmes de classification de différentes manières. Un premier critère concerne le niveau de supervision, c'est-à-dire la mesure dans laquelle l'intervention de l'utilisateur est nécessaire dans les processus de classification. En outre, il est également possible de distinguer les algorithmes paramétriques, qui sont associés à un modèle probabiliste, des algorithmes non paramétriques [16].

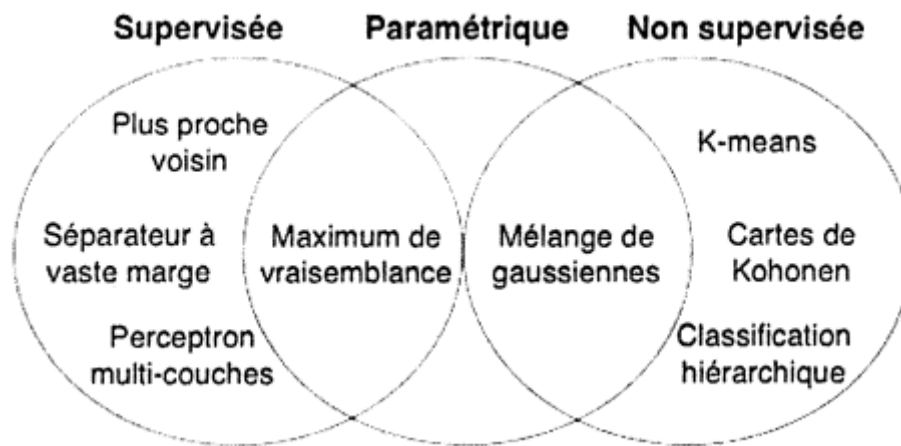


Figure (II.3) : Classification des types de classification

II.4.1. Classification non supervisée

La classification non supervisée est une technique d'apprentissage automatique qui vise à organiser des données en groupes ou en clusters, sans avoir de classes prédéfinies. Contrairement à la classification supervisée, elle ne nécessite pas d'exemples d'apprentissage étiquetés. Au lieu de cela, l'algorithme de classification non supervisée analyse les caractéristiques des données et cherche des similarités ou des structures intrinsèques pour les regrouper. Cela permet d'identifier des relations et des patterns cachés dans les données, et de découvrir de nouvelles perspectives ou catégories. La classification non supervisée est utilisée dans divers domaines tels que l'exploration de données, la segmentation d'image, l'analyse de texte et la recommandation de contenu.

II.4.2. Classification supervisée

La classification supervisée est une méthode d'apprentissage automatique qui permet de catégoriser des données en fonction de classes prédéfinies. Elle repose sur l'utilisation d'un ensemble d'exemples d'apprentissage étiquetés pour entraîner un modèle prédictif. Ce modèle

est ensuite utilisé pour attribuer des classes prédites à de nouveaux échantillons. La classification supervisée trouve de nombreuses applications dans des domaines tels que la reconnaissance d'images, la détection de spam, l'analyse de sentiment et bien d'autres. Cependant, pour obtenir des résultats précis, il est essentiel de choisir judicieusement les caractéristiques pertinentes et l'algorithme de classification adapté, tout en s'assurant d'avoir un ensemble d'apprentissage représentatif et étiqueté avec soin.

II.4.3. Méthodes de classification

Il, existe plusieurs méthodes de classification, le plus simple est le procédé des k plus proches voisins ou KNN [17]. Ce dernier consiste à attribuer au pixel étudié la classe majoritaire parmi les k échantillons les plus proches de lui dans le nuage de points considéré. Un algorithme plus récent, appelé les Séparateurs à Vastes Marges (SVM) [18], utilise des hyperplans pour séparer les différentes classes dans l'espace de représentation des données. Sa complexité est également influencée par la taille de la base d'apprentissage.

II.4.3.1. K-NN

L'algorithme des k plus proches voisins (k-NN) est une méthode utilisée à la fois pour la classification. Il est appelé « plus proches voisins » car il se base sur le principe de sélection des k échantillons des plus proches du point étudié afin de prédire sa valeur. Le k-NN permet ainsi de déterminer la classe ou la valeur d'un échantillon en se basant sur les caractéristiques des échantillons similaires dans son voisinage. Cet algorithme est souvent utilisé dans des domaines tels que la reconnaissance de formes, l'analyse de données et la recommandation personnalisée [19].

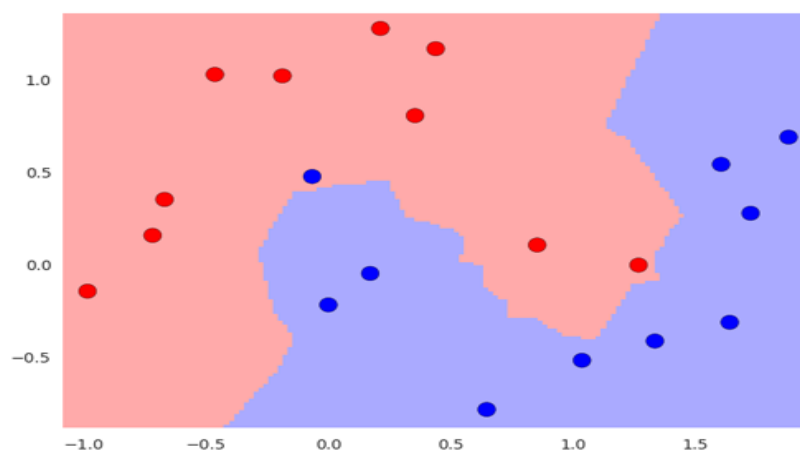


Figure (II.4) : Classification avec le modèle 5-NN

II.4.3.2. SVM

Les SVM Support Vector Machine (SVM) est un algorithme d'apprentissage supervisé largement utilisé pour la classification dans divers domaines tels que le traitement du signal médical, le traitement du langage naturel, la reconnaissance vocale et la reconnaissance d'images.

➤ L'objectif principal de l'algorithme SVM

L'objectif principal de l'algorithme SVM est de trouver un hyperplan qui sépare de manière optimale les points de données appartenant à différentes classes. Idéalement, cet hyperplan doit avoir la plus grande marge possible entre les classes, comme illustré par les exemples positifs et négatifs dans la figure (II.3). La marge est définie comme la plus grande distance entre l'hyperplan et les points de données les plus proches. Cependant, dans la pratique, les problèmes de classification ne sont pas toujours linéairement séparables. Dans de tels cas, l'algorithme SVM utilise une approche de marge souple qui permet une certaine flexibilité en autorisant un petit nombre d'erreurs de classification [20].

➤ Approche mathématique pour les Support Vector Machines (SVM)

Les Support Vector Machines (SVM) sont des algorithmes de Machine Learning qui font partie des méthodes à noyau. Ces méthodes permettent de transformer les caractéristiques des données à l'aide de fonctions noyau. Les fonctions noyau permettent de projeter les données dans un espace dimensionnel différent, souvent de dimension supérieure, dans l'espoir que les classes deviennent plus facilement séparables. Cette transformation offre la possibilité de simplifier les frontières de décision complexes non linéaires en des frontières linéaires dans cet espace de dimension supérieure. L'avantage de cette approche est qu'il n'est pas nécessaire de transformer explicitement les données, ce qui évite un coût de calcul élevé. C'est ce qu'on appelle couramment l'astuce des noyaux. [20].




Figure (II.5) : Principe de base de la méthode SVM

II.4.4. Déroulement de la classification

Un algorithme de classification repose sur la constitution d’un modèle à partir des caractéristiques issues de la phase d’extraction. Pour évaluer ce modèle, plusieurs critères existent et vont permettre d’avoir une vue bien précise sur ces performances. Pour notre travail, nous avons utilisé la matrice de confusion, taux de classification (accuracy) et la courbe ROC.

Avant de décrire ces critères, nous allons donner certaines définitions nécessaires pour le fonctionnement de la classification.

II.4.4.1. La matrice de caractéristiques

La matrice utilisée pour effectuer la classification est généralement appelée matrice de données d’entraînement ou matrice de design. Elle est représentée par une matrice rectangulaire où chaque ligne correspond à un échantillon d’apprentissage et chaque colonne représente une caractéristique de cet échantillon. La taille de la matrice est donc déterminée par le nombre d’échantillons d’apprentissage et le nombre de caractéristiques.

Attributs									classe
X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	Y
21	14	14	25	39	18	28	16	21	C1
33	13	16	17	45	20	13	15	24	c2
25	13	15	16	49	20	21	20	17	C2
33	13	17	16	44	17	23	15	18	C1
.
.
33	21	10	7	71	9	11	11	23	C2

Figure (II.6) : Un modèle de la matrice de caractéristiques

II.4.4.2. La validation croisée

La validation croisée est une technique d'évaluation des performances d'un modèle de classification en divisant les données en ensembles d'entraînement et de test, et en effectuant plusieurs itérations pour évaluer le modèle sur différents sous-ensembles.

Il existe trois méthodes principales de la validation croisée :

➤ Méthode Holdout

La méthode Holdout est le type de méthode le plus simple pour évaluer un classificateur. Dans cette méthode, l'ensemble de données (une collection d'éléments de données ou d'exemples) est séparé en deux ensembles, appelés ensemble d'apprentissage et jeu de tests.

➤ Méthode K-Fold Cross-Validation

La validation croisée k-Fold Cross-Validation est une procédure de rééchantillonnage utilisée pour évaluer les modèles d'apprentissage automatique sur un échantillon de données limité. La procédure a un paramètre unique appelé k qui fait référence au nombre de groupes dans lesquels un échantillon de données donné doit être divisé. La figure (II.7) explique le fonctionnement de la méthode pour k=4.

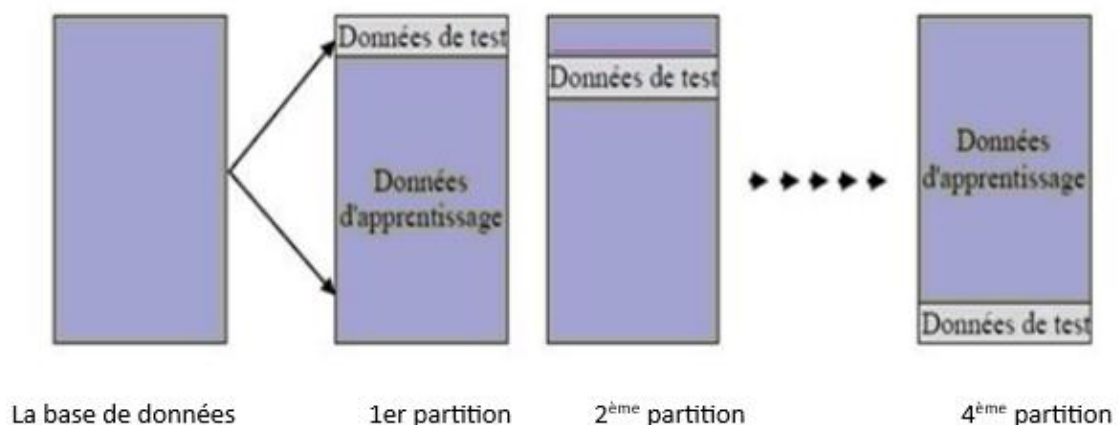


Figure (II.7) : Principe de la validation croisée K-fold pour k = 4

➤ **Méthode Leave-one-out cross-validation (sans issue)**

Leave-one-out cross-validation, ou LOOCV, est une configuration de validation croisée k-fold où k est défini sur le nombre d'exemples dans le jeu de données. LOOCV est une version extrême de la validation croisée k-fold qui a un coût de calcul maximal. Il nécessite la création et l'évaluation d'un modèle pour chaque exemple de l'ensemble de données d'apprentissage.

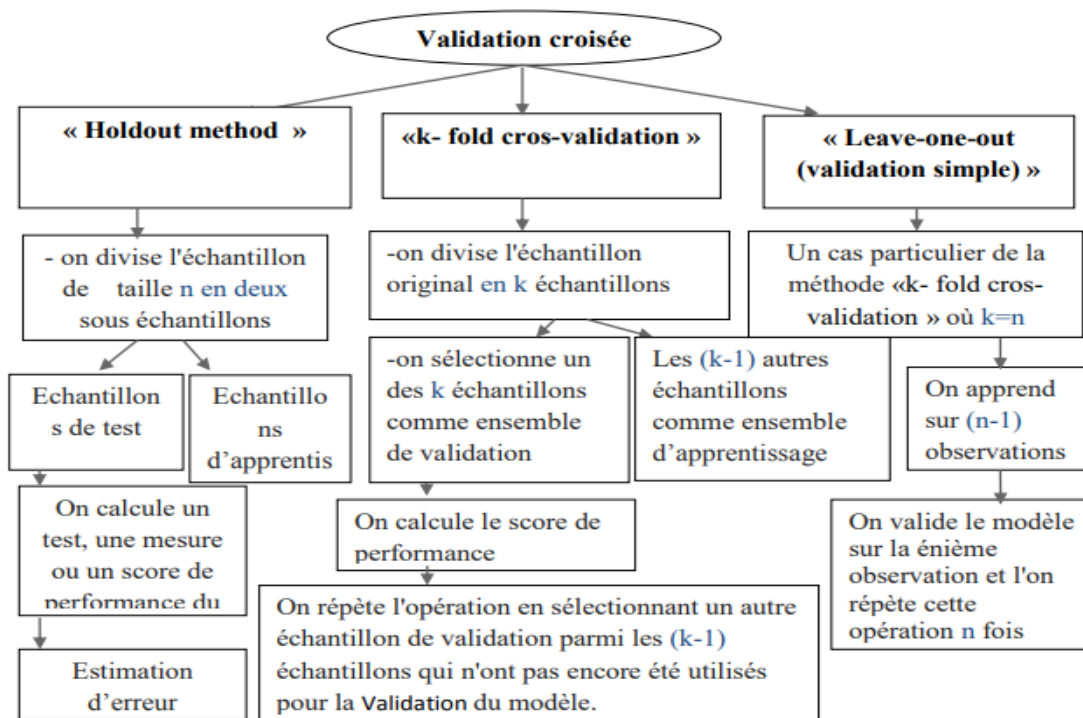


Figure (II.8) : Algorithmes des trois méthodes de la validation croisée.

II.4.4.3. Matrice de confusion

La matrice de confusion est un tableau utilisé pour évaluer la performance des modèles de classification en comparant les valeurs réelles et prédites d'une variable cible. Elle permet de visualiser les prédictions correctes et incorrectes par classe, et de détecter les erreurs d'un algorithme. La matrice de confusion peut être binaire, lorsqu'il y a deux classes, ou multi classe, lorsqu'il y a plus de deux classes. Elle fournit une vue détaillée de la qualité des prédictions d'un modèle de classification.

Elle permet de calculer le taux d'erreur de la classification de deux classes, notées P et N. La matrice de confusion données sur le tableau suivant :

Tableau (II.1) : Matrice de confusion

Décision ↓ Vérité →	Décision Positifs, P	Décision Négatifs, N	Total
Étiquette Positifs, P	TP	FP	TP+FP
Étiquette Négatifs, N	FN	TN	FN+TP

Avec :

- **TP** (true positives) : les prédicts positifs qui le sont vraiment.
- **FP** (false positives) : les prédicts positifs qui sont en fait négatifs.
- **TN** (true négatives) : les prédicts négatifs qui le sont vraiment
- **FN** (false négatives) : les prédicts négatifs qui sont en fait positifs.
- **P** (positives) : tous les positifs quel que soit l'état de leur prédiction. **P=TP+FN.**
- **N** (négatives) : tous les négatifs quel que soit l'état de leur prédiction. **N=TN+FP.**
- La spécificité et la sensibilité défini par : -La sensibilité : $TP / (TP+FN) = TP/P$
 - La spécificité : $TN / (TN+FP) = TN/N$

II.4.4.4.Précision

La relation suivante permet d'utiliser cette matrice pour calculer le taux d'erreur.

$$E = \frac{TN + FP}{P + N} \times 100 \tag{II.9}$$

II.4.4.5.La courbe ROC

La courbe ROC (Receiver Operating Characteristic) est un outil graphique couramment utilisé dans l'évaluation des performances des modèles de classification. Elle représente la relation entre le taux de vrais positifs (sensibilité) et le taux de faux positifs (1 - spécificité) pour différents seuils de classification.

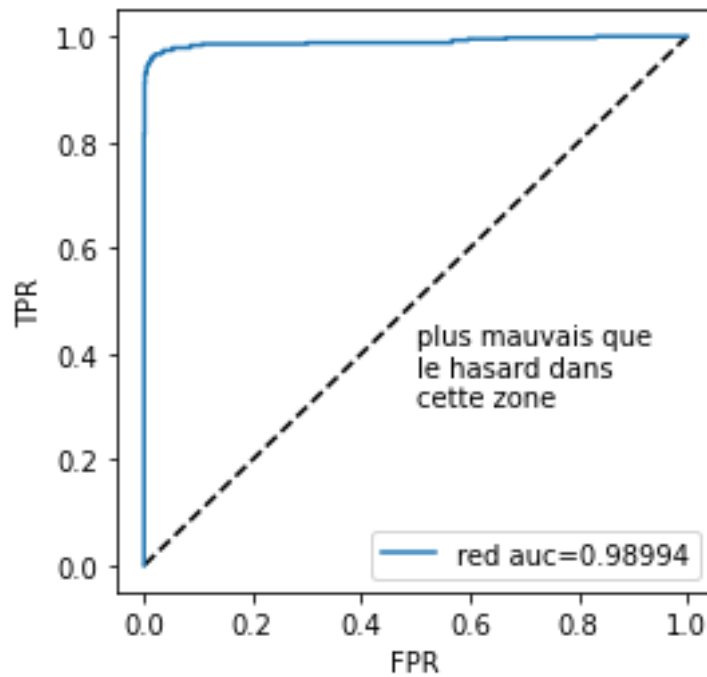


Figure (II.9) : Modèle d'un courbe ROC

Une courbe ROC idéale est celle qui se rapproche le plus possible du coin supérieur gauche du graphique, ce qui indiquerait une sensibilité maximale (100%) et une spécificité maximale (0% de faux positifs). Une courbe ROC aléatoire, en revanche, correspondrait à une ligne diagonale reliant le coin inférieur gauche au coin supérieur droit, indiquant une performance de classification aléatoire sans aucune discrimination entre les classes.

C'est un outil essentiel pour évaluer les performances des modèles de classification en fournissant une visualisation claire de la sensibilité et de la spécificité à différents seuils de classification. Elle permet de comparer les performances des modèles et d'identifier celui qui offre la meilleure discrimination entre les classes.

II.5. Conclusion

Dans ce chapitre on a présenté les approches proposées dans le contexte de la détection de défauts ainsi que les différentes notions liées. Les approches se basent sur une combinaison de techniques d'extraction de caractéristiques, de classification. Les résultats expérimentaux d'application de ces algorithmes seront détaillés dans le chapitre suivant.

Chapitre III

Résultats de simulation

III.1. Introduction

Dans ce chapitre, nous présentons les résultats de simulation -des algorithmes décrits au chapitre précédent- que nous avons menées sur les différents échantillons de la base de données choisie. Les simulations ont été faites pour tester d'une part les performances de l'approche de localisation de défaut, ainsi que celle de la classification.

L'objectif d'utiliser la classification est de vérifier les performances du descripteur de choisis, la technique de lissage préservant les contours (L0 gradient) combiné avec les caractéristiques d'histogramme.

III.2. Environnement de travail

Pour réaliser notre travail, nous avons utilisé un ordinateur portable Dell avec les caractéristiques suivantes :

Processeur : Intel(R) Core (TM) i56440HQ CPU 2.60GHz

Mémoire RAM : 8.00 GB

Disque dur : SSD 256

Carte graphique : Intel HD 530

Système d'exploitation : Windows 10 professionnel 64-bit

Pour la réalisation de notre système nous avons choisi le langage de programmation MATLAB version 9.8 (R2020a).

III.2.1. Base des données

La base de données utilisée dans ce travail a été collectée à partir des images contenues dans la base « TILDA » ainsi que de certains sites Internet. TILDA est une base de données de textile qui a été développée en 1996 dans le cadre du groupe de travail analyse de texture du programme de recherche majeur de la DFG (Deutsche Forschungs Gemeins chaft) "Automatic Visual Inspection of Technical Objects".

Notre propre base de données contient 85 images de taille 256x256 réparties sur 8 types de textures différentes. La base utilisée est divisée en deux groupes comme suit :

1^{er} groupe : 52 images avec défauts.

2^{ème} groupe : 33 images sans défauts.

Sur la figure (III.1), un extrait de la base de données contenant différents types de textures.




Figure (III.1) : Extrait de la base de données

III.3. Choix du facteur de lissage α

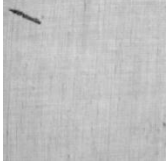

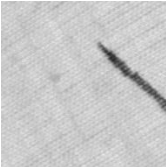
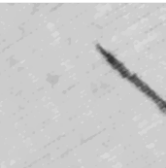
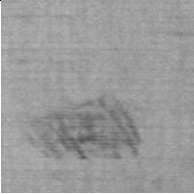

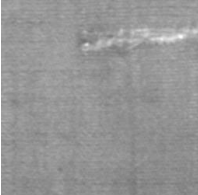

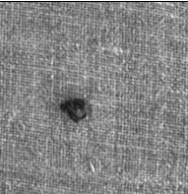



Le choix de la valeur α – paramètre de lissage défini dans le chapitre II- est crucial pour notre travail. La valeur de α dépend étroitement de la nature de la texture du tissu.

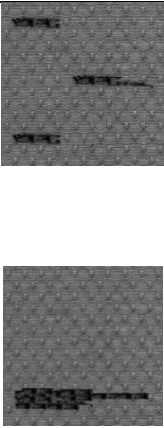

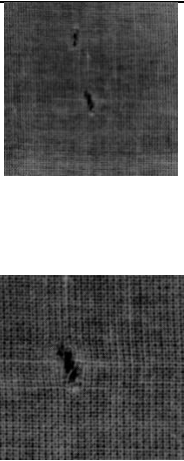

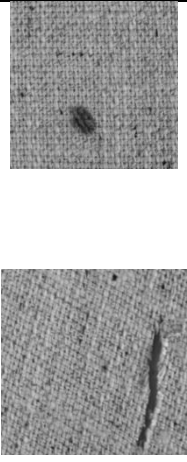

Par définition, la texture est une répétition spatiale d'un même motif dans plusieurs directions. D'une manière générale, une texture peut être qualifiée par la perception visuelle de fine ou grossière, homogène, régulière, dense, linéaire, tacheté, ...etc.


Pour un échantillon de texture fine, le α possède une faible valeur. Cette valeur augmente d'une manière croissante avec régularité de la texture. Les images de même texture sont lissées avec le même facteur de lissage α

Voici un exemple de différents type de textile lorsque on applique le lissage présenter dans le tableau (III.1)

Tableau (III.1) : Variation du facteur de lissage α selon les différentes textures

Facteur de lissage α	Les images	Image lissé
$\alpha = 0.0008$		
		
$\alpha = 0.0025$		
		
$\alpha = 0.004$		
		

$\alpha = 0.008$		
$\alpha = 0.01$		
$\alpha = 0.025$		



III.4. Algorithme de localisation

L'algorithme de localisation de défauts dans le textile, en intégrant les techniques de lissage, de binarisation et de détection, permet d'analyser les images de textile afin d'identifier les défauts présents. Grâce à la méthode de lissage préservant les contours, à la segmentation de l'image en une représentation binaire et à l'application de techniques avancées de détection, cet algorithme contribue à améliorer la précision et l'efficacité du processus de détection des défauts dans l'industrie textile. Ces techniques sont bien détaillées dans la section (II.3.1), chapitre II.

Le lissage par minimisation de la norme L0 gradient d'une image de textile avec une valeur bien appropriée du facteur de lissage α , nous a permis de laisser les contours et éliminer la zone homogène de la texture du tissu. Un exemple sur l'effet du lissage sur l'image on 3D est présenté dans la figure (III.2)

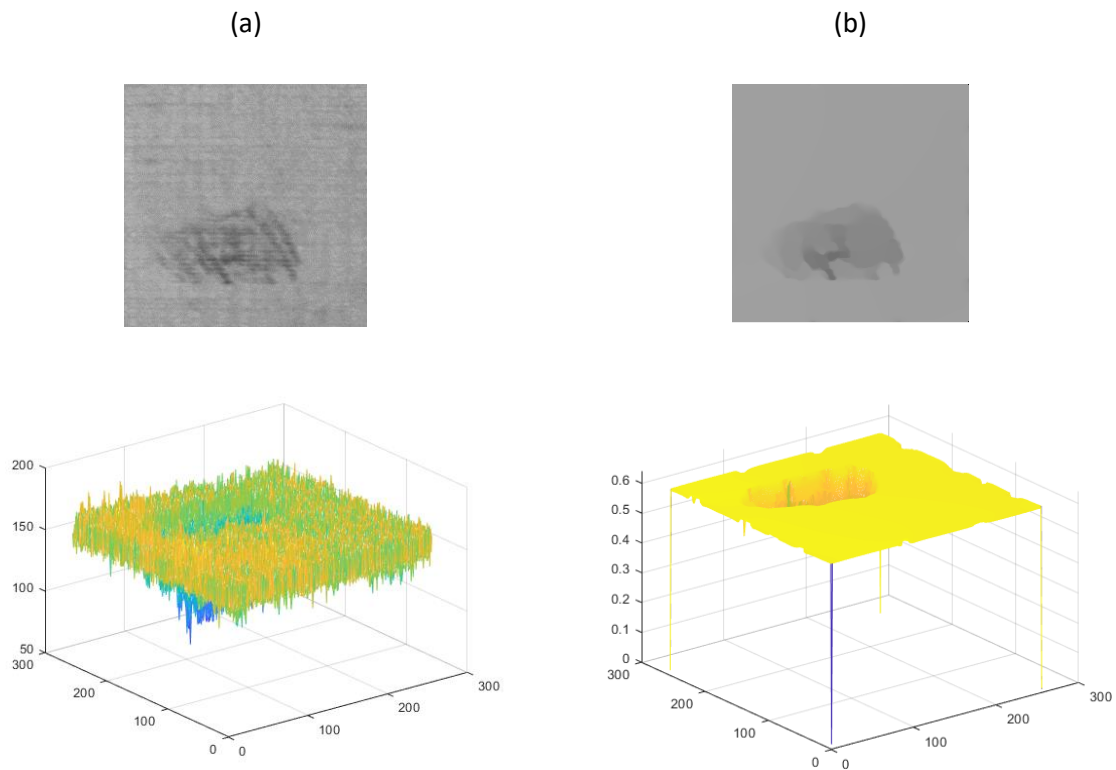



Figure (III.2) : Effet de lissage (a) image originale, (b) image lissée


Les résultats d’application de l’algorithme proposé de localisation est présenté sur le tableau (III.2).

Par perception visuelle, on peut remarquer une localisation précise des défauts présents sur les différentes images de la base.

Tableau (III.2) : Applications de l’algorithme de localisation

Image originale	Image lissée	Image binarisée	Localisation de défaut



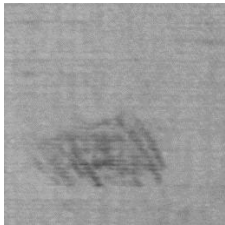
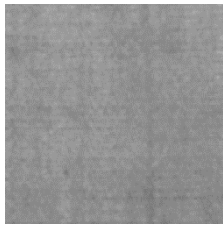
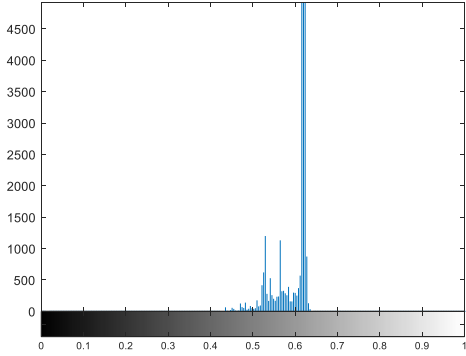
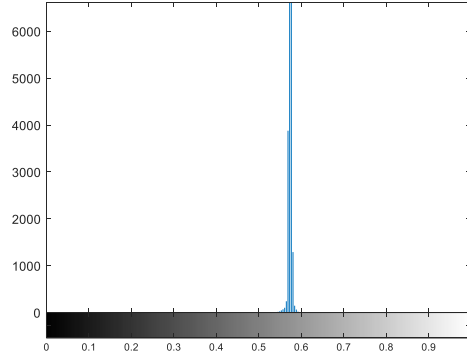
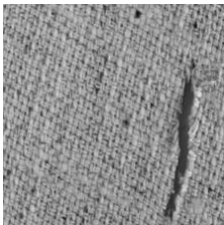
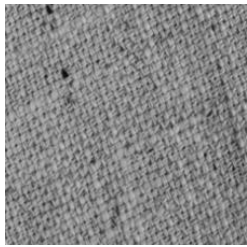
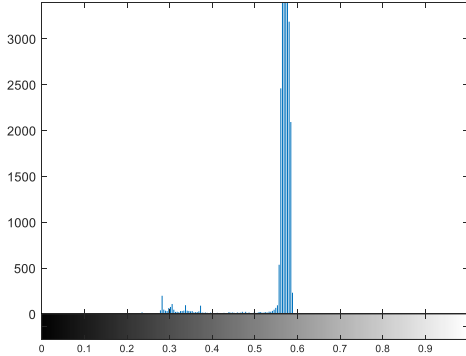
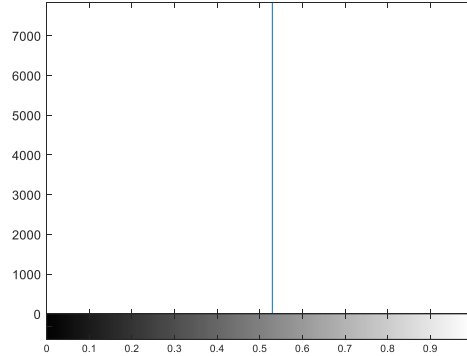



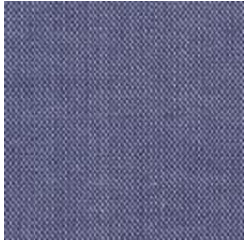
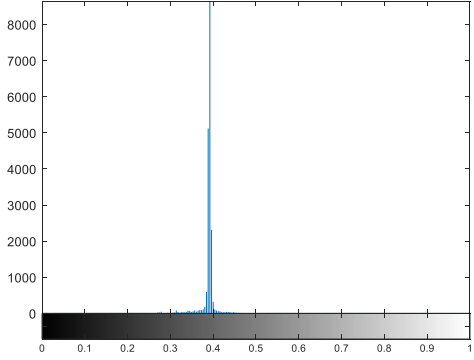
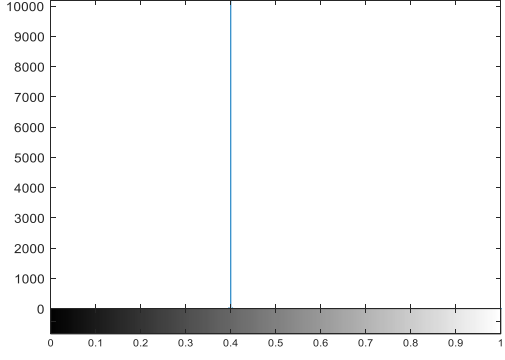
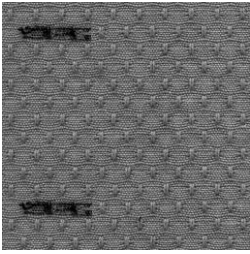
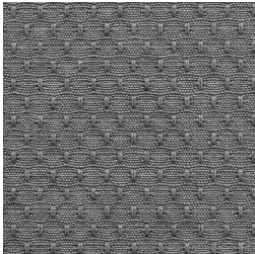
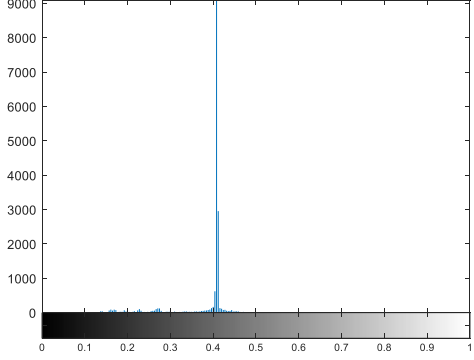
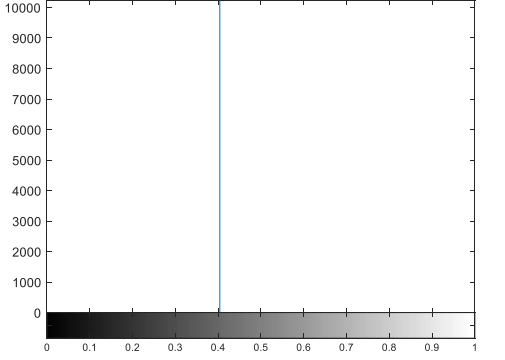
III.5. Algorithme de classification

L'algorithme de classification des défauts et non-défauts dans le textile, en intégrant les étapes de lissage, de calcul des caractéristiques d'histogramme et de classification par SVM, permet d'analyser les images de textile pour effectuer une classification précise. Le lissage améliore la visibilité du défaut, le calcul des caractéristiques d'histogramme fournit des informations significatives sur la distribution des valeurs de pixels, et la classification par SVM ou KNN permet de prendre une décision basée sur les caractéristiques extraites.

L'apparence des histogrammes de certaines images de la base utilisée est présentée sur le tableau (III. 3). Les histogrammes après le lissage des images avec et sans défauts sont différents, d'où l'efficacité de l'utilisation de ses caractéristiques pour la classification.

Tableau (III.3) : Applications de l'algorithme de classification

Image avec défauts	Image sans défauts
	
	
Image avec défauts	Image sans défauts
	
Histogramme	Histogramme
	
Image avec défauts	Image sans défauts

	
Histogramme	Histogramme
	
Image avec défauts	Image sans défauts
	
Histogramme	Histogramme
	

III.5.1. Matrice de caractéristiques

La matrice de caractéristiques d'histogramme est une structure de données qui représente les informations extraites des histogrammes des images. Elle facilite l'analyse et la classification des images en fournissant des valeurs numériques pour chaque caractéristique d'histogramme. Un échantillon de cette matrice est donné par la suite. La dernière colonne correspond aux labels ou étiquettes associés à chaque image. Le label « 0 » pour l'image avec défaut, « 1 » pour celle sans défaut.

Notons que nous avons utilisé seulement les 5 premiers caractéristiques d'histogramme.

6.84412	0.33099	-4.79957	28.82399	0.81993	0
5.15378	0.21571	0.46885	4.16837	0.62026	0
6.00425	0.00698	-9.28277	1128.06450	0.98989	0
4.96166	0.03947	-5.53999	40.35985	0.92814	0
4.00714	0.15497	0.06455	6.85694	0.72851	0
4.99845	0.00463	-20.10500	1110.53078	0.99317	0
4.99976	0.00098	-127.98829	16382.00006	0.99988	1
5.99944	0.00179	-104.56867	12048.83492	0.99936	1
6.99949	0.00235	-117.06467	14351.20172	0.99958	1
3.99955	0.00083	-81.26994	7685.04565	0.99933	1
6.00057	0.00321	-37.21863	3880.99967	0.99653	1
3.99931	0.00106	-62.95632	4913.23892	0.99887	1

III.5.2. Taux d'erreur

Le taux d'erreur d'un modèle de classification dépend de plusieurs facteurs, tels que la qualité des données, la sélection des caractéristiques, et la taille de l'ensemble de données d'entraînement.

Les résultats obtenus dans le tableau (III.4) résument le taux d'erreur pour les deux classifieurs SVM et KNN. On remarque que le classifieur SVM nous donne le résultat plus précis que KNN.


Tableau (III.4) : Les résultats de taux d'erreur par SVM et KNN

Classifieur	Taux d'erreur
SVM	97.6%
KNN	95.3%

III.5.3. Matrice de confusion

Dans le modèle 1, utilisant SVM, la matrice de confusion a été obtenue en évaluant 52 images contenant des défauts. Parmi ces images, 50 ont été correctement classées comme présentant des défauts, tandis que 2 ont été incorrectement classées comme étant sans défauts. De plus, dans le même modèle 1, en évaluant 33 images sans défauts, toutes ces images ont été bien classées comme étant sans défauts.

Dans le modèle 2 basé sur l'algorithme KNN, une matrice de confusion a été générée à partir de l'évaluation de 52 images contenant des défauts. Parmi ces images, 50 ont été correctement classées comme ayant des défauts, tandis que 2 ont été incorrectement classées comme n'ayant pas de défauts. De plus, lors de l'évaluation de 33 images sans défauts dans le même modèle 1, 31 de ces images ont été correctement classées comme étant sans défauts, tandis que 2 ont été incorrectement classées comme ayant des défauts.



(a)

(b)

Figure (III.3) : Matrice de confusion (a) méthode SVM, (b) méthode KNN

III.5.4. Courbe de ROC

Un résultat de 0.98 pour l'aire sous la courbe ROC est encourageant et indique que le modèle a de bonnes capacités de classification, avec une précision élevée et une capacité à distinguer efficacement les classes positives et négatives pour le classifieur SVM.




Figure (III.4) : Courbe ROC pour (a) SVM, (b) KNN

III.6. Conclusion

Les résultats obtenus avec l'algorithme de localisation ont démontré une capacité réussie à localiser précisément les défauts de textile dans les images. Pour l'algorithme de classification par SVM a été plus efficace que par KNN. Ces résultats très satisfaisants témoignent de l'efficacité des algorithmes utilisés dans la détection et la classification des défauts de textile, ce qui ouvre des perspectives prometteuses pour l'automatisation du contrôle qualité dans l'industrie textile.

*Conclusion
générale*

Conclusion générale

En conclusion, la détection de défauts dans les textiles est un domaine crucial de la vision industrielle, offrant des avantages majeurs en termes d'efficacité de production et de qualité des produits.

L'objectif principal de notre étude était d'explorer les principes fondamentaux et les avancées pratiques de la vision industrielle, en mettant l'accent sur son application dans l'inspection et le contrôle de la qualité du textile. On a examiné les différentes techniques d'acquisition d'images, de traitement d'images et d'analyse des données visuelles utilisées dans les systèmes de vision industrielle. On a également étudié les algorithmes avancés de détection de défauts, et de classification.

Dans cette étude a examiné deux approches basées sur la méthode de lissage d'image préservant les contours, connue sous lissage par minimisation du gradient L0. La première approche se concentre sur l'algorithme de localisation, tandis que la deuxième approche intègre l'extraction de caractéristiques d'histogrammes et la classification à l'aide de SVM et KNN.

Les résultats obtenus grâce à ces approches ont été évalués à l'aide de la matrice caractéristique, de la validation croisée, de la matrice de confusion et de la courbe ROC. Ils étaient très satisfaisants avec un taux de classification dépassant 97%.

Le choix du facteur de lissage dans les approches proposées est réalisé manuellement, alors et en perspective, on propose de penser à une approche automatique pour le faire.

L'étude a montré que la détection de défauts dans les textiles à l'aide de la vision industrielle est un domaine prometteur offrant de nombreux avantages. Les principes fondamentaux et les avancées pratiques de la vision industrielle ont été explorés, en mettant l'accent sur leur application spécifique à l'inspection et au contrôle de la qualité du textile.

Bibliographie

- [1] Hanbaya K, Talub MF, Ozgvenc OF. Systèmes et méthodes de détection des défauts de tissu — Une revue systématique de la littérature. *Optik*. 2016 ; **127** : 11960- 11973.
- [2] Li, Xu, Cewu, Lu, Jiaya, Jia et AI <<Image Smoothing via L0 Gradient Minimization>>. *ACM Transactions on Graphics*. 2011, Vol. 30, No. 6, 1-12
- [3] <https://www.cognex.com/fr-fr/what-is/machine-vision/what-is-machine-vision>
- [4] <https://www.cognex.com/fr-fr/what-is/machine-vision/applications>
- [5] Smith, J. (2020). Inspection and Control in Industrial Manufacturing : A Comprehensive Review. *International Journal of Advanced Manufacturing Technology*, 45(3), 321-345
- [6] Newman T. S., & Jain A.K. (1995). A Survey of Automated Visual Inspection. *Computer Vision and Image Understanding*, 61, 2, 231-262.
- [7] Marouene, Mejri. Modélisation Statistique de Transformées Multi résolutions et Application à la Détection de Défauts de Textures. Mémoire de master 2. Gatineau, Québec, Canada, université du Québec en outaouais. 2013
- [8] Kumar A. (2008). Computer vision-based fabric defect detection : a survey, *IEEE, Transactions on Industrial Electronics*, 55, 1, 348-363.
- [9] Mufti M. (1995). Fault Detection and Identification Using Fuzzy Wavelets, Ph. D. Thesis. School of Electrical and Computer Engineering, Georgia Institute of Technology.
- [10] Bodnarova A., Bennamoun M., & Latham S. J. (2000). A constrained minimisation approach to optimise Gabor filters for detecting flaws in woventextiles, *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing*, 6, 3606-3609.

[11] JeongS. H., ChoiH.T., KimS. R., JaungJ. Y., & KimS. H. (2001) Detecting Fabric Defects with Computer Vision and Fuzzy Rule Generation, Part I : Defect Classification by Image Processing. Textile Research Journal, 71, 518 – 526.

[12] ZhangY. F., &BreseeR. R. (1995). Fabric Defect Detection and Classification Using Image Analysis, Textile Research Journal, 65, 1, 1 – 9

[13] GonzalezR. C., &WoodsR. E. (2002). Digital Image Processing, 2nd Ed. Upper Saddle River, N.J.

[14] Aasim A. (2004). A Catalogue of Visual Textile Defects, Ministry of Textiles.

[15] <https://doi.org/10.1111/coin.12206>

[16] Guillaume ROUSSEL. "Développement et évaluation de nouvelles méthodes de classification spatiale-spectrale d'images hyper spectral :", doctorat de I 'université de Toulouse,2012.

[17] T. M. Cover and P. E. Hart. "Nearest neighbor pattern classification". IEEE Transactions on Infomation Theory, pages 21-27,1967

[18] C. J. C. Burges. "A tutorial on support vector machines for pattern recognition". Data Min. Knowl. Discov., 2 :121-167,1989

[19]<https://openclassrooms.com/fr/courses/4011851-initiez-vous-au-machine-learning/4022441-entraenez-votre-premier-k-nn>

[20] <https://fr.mathworks.com/discovery/support-vector-machine.html#:~:text=L%27objectif%20de%20l%27algorithme%20SVM%20est%20de%20trouver%20un>,

Résumé

La détection de défauts dans les textiles est un domaine crucial de la vision industrielle, offrant des avantages majeurs en termes d'efficacité de production et de qualité des produits. Cette étude a examiné deux approches basées sur la méthode de lissage d'image par minimisation du gradient L0, visant à améliorer la détection des défauts. La première approche se concentre sur l'algorithme de localisation, tandis que la deuxième approche intègre l'extraction de caractéristiques d'histogrammes et la classification à l'aide de SVM et KNN. On a obtenu des résultats très satisfaisants pour les deux approches. Le taux de classification dépasse 97%.

Abstract

Detecting defects in textiles is a crucial field in industrial vision, offering significant advantages in terms of production efficiency and product quality. This study examined two approaches based on the image smoothing method through L0 gradient minimization, aiming to enhance defect detection. The first approach focuses on the localization algorithm, while the second approach integrates histogram feature extraction and classification using Support Vector Machines (SVM) and K-Nearest Neighbors (KNN). Both approaches yielded highly satisfactory results. The classification rate surpasses 97%.

ملخص

الكشف عن العيوب في المنسوجات هو مجال حاسم في رؤية الصناعة، حيث يوفر مزايا كبيرة من حيث كفاءة الإنتاج وجودة المنتجات. قامت هذه الدراسة بفحص نهجين يستندان إلى طريقة تمهيد الصورة بتقليل الانحدار L0، بهدف تحسين كشف العيوب. يركز النهج الأول على خوارزمية التحديد المكاني، بينما يدمج النهج الثاني استخراج الميزات من الهيبستوغرامات والتصنيف باستخدام طرق SVM و KNN. تم الحصول على نتائج مرضية جداً للنهجين. نسبة التصنيف تتجاوز 97%.

