

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique




UNIVERSITÉ DE JIJEL

Faculté des Sciences et de la Technologie

Département d'Automatique

Mémoire



Reconnaissance de forme pour la vision industrielle: Détection de défauts dans les tissus

Présenté Par :

DEMIA Noura
CHETTIBI Louiza

Membres de Jury:

Président : Pr BOUDEN Toufik
Examineur : M^{me} KMIHA Mina
Encadreur : Dr.S. Biad

Année Universitaire 2016-2017

Remerciement

Nous tenons tout d'abord à remercier Dieu le tout puissant, qui nous a donné la force et la patience d'accomplir ce modeste travail.

En second lieu, nous tenons à remercier notre encadreur Dr.S. Biad son précieux conseil et son aide durant toute la période du travail.

Nos vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner notre travail et de l'enrichir par leurs propositions.

Merci à mes amis et à ma famille pour leur soutien et leurs encouragements ainsi que d'être toujours là pour moi.

Merci à tous et à toutes.



DEDICACES

Je dédie ce modeste travail à :

A ma Mère et Mon père

Aucune dédicace ne serait exprimée à leurs justes valeurs, mon profond respect, et ma gratitude pour tous les efforts que vous avez fournis pour moi.

À mes chères sœurs, À mes chers frères.

À mes deux grandes familles, maternelle et paternelle.

À tous mes proches, mes amis, mes collègues de classes.

DEMIA Noura

DEDICACES

Je dédie ce modeste travail à :

A ma Mère et Mon père

Aucune dédicace ne serait exprimée à leurs justes valeurs, mon profond respect, et ma gratitude pour tous les efforts que vous avez fournis pour moi.

À mes chères sœurs, À mes chers frères.

À mes deux grandes familles, maternelle et paternelle.

À tous mes proches, mes amis, mes collègues de classes.



CHETTEBI Louiza

Table des matières

Remerciements	i
Dédicace	ii
Dédicace	iii
Table des matières	iv
Liste des tableaux	vi
Table des figures	vii
Introduction Générale	1
1 Vision Industrielle	3
1.1 Introduction	4
1.2 Vision industrielle.....	4
1.3 Applications de la vision industrielle.....	5
1.3.1 La vision pour la robotique ou guidage de robot.....	5
1.3.2 La vision pour la détection de défaut.....	6
1.3.3 La vision pour le guidage d'automobile ou la sécurité des piétons.....	6
1.3.4 La vision pour la surveillance et sécurité.....	7
1.4 La détection de défauts dans l'industrie du textile.....	8
1.5 Système de vision industrielle.....	9
1.5.1 Description.....	10
1.5.2 Eléments constituants	10
1.6 Application proposé.....	12
1.7 Conclusion.....	14
2 Reconnaissances De Forme	15
2.1 Introduction.....	16
2.2 Reconnaissance de formes.....	16
2.2.1 Domaine d'utilisation.....	17
2.3 Reconnaissance de formes pour la détection de défauts.....	18

2.3.1	Approches statistiques	18
2.3.2	Approches spectrales	18
2.3.3	Approches basées sur la modélisation	19
2.4	Méthodes d'extraction de caractéristiques.....	19
2.5	Méthode LBP.....	20
2.5.1	Motif binaire locaux (LBP)	20
2.5.2	Motif binaire locaux (LBP) invariant par rotation uniformes.....	22
2.5.3	Motif binaire locaux (LBP) Complete Magnitude	25
2.6	Classification	25
2.6.1	Classification par apprentissage supervisé.....	26
2.6.2	Validation croisée.....	27
2.6.3	Matrice de confusion	29
2.6.4	Courbe ROC.....	29
2.7	Conclusion.....	31
3	Résultat	32
3.1	Introduction	33
3.2	Base de données utilisés.....	33
3.3	Algorithme proposé pour la détection de défauts	34
3.3.1	Apprentissage	34
3.3.2	Détection	35
3.4	Résultat expérimentaux.....	36
3.4.1	Résultats de détection de défauts.....	36
3.4.2	Résultats de classification.....	39
3.4.2.1	La méthode LBP^{riu2}	39
3.4.2.2	La méthode $LBPM^{riu2}$	43
3.4.2.3	Classification de la base de données.....	46
3.4.3	Discussion	47
3.5	Conclusion	48
	Conclusion générale.....	49
	Bibliographie.....	50

Liste des tableaux

Tableau 2.1	Avantages et inconvénients entre les méthodes de validation croisées....	28
Tableau 2.2	La forme de la matrice de confusion.....	29
Tableau 3.1	Taux d'erreur, la sensibilité et la spécificité par les deux méthodes de classification par LBP^{riu2}	40
Tableau 3.2	Taux d'erreur, la sensibilité et la spécificité par les deux méthodes de classification par $LBPM^{riu2}$	43
Tableau 3.3	Taux d'erreur, la sensibilité et la spécificité de la base de données pour les différentes méthodes validation.	46

Table des figures

Figure 1.1	Le principe de la vision humaine.....	4
Figure 1.2	Le principe de la vision industrielle.....	5
Figure 1.3	Déplacement de pièces à l'aide du robot.....	5
Figure 1.4	Détection de défaut.....	6
Figure 1.5	Vérification d'orientation.....	6
Figure 1.6	Image de caméra infrarouge identifiant un piéton dans la route.....	7
Figure 1.7	Caméra de surveillance sur réseau internet sans PC.....	8
Figure 1.8	Système de tricotage industriel.....	8
Figure 1.9	Schéma descriptive du système de vision industrielle.....	10
Figure 1.10	Caméra linéaire.....	11
Figure 1.11	Caméra intelligente.....	11
Figure 1.12	Caméra matricielle.....	11
Figure 1.13	Unité centrale d'un ordinateur.....	12
Figure 1.14	Architecture d'un système typique d'inspection automatique de tissu.....	13
Figure 2.1	Principe des K-plus proches voisins.....	17
Figure 2.2	La procédure de calcul de LBP.....	21
Figure 2.3	Quelques exemples de différents points de voisinage avec le rayon.....	22
Figure 2.4	Exemple de calcul de l'opérateur LBP : (a) image originale, (b) image LBP, (c) histogramme de LBP.....	22
Figure 2.5	Construction et uniformité d'un motif LBP.....	23
Figure 2.6	36 schémas binaires invariables de rotation unique qui peuvent se produire dans l'ensemble voisin symétrique circulaire de $LPB_{P,R}^{riu2}$	23
Figure 2.7	Exemples de motifs uniformes et non-uniformes.....	24
Figure 2.8	Exemple de calcul de l'opérateur $LPB_{8,1}^{riu2}$: (a) image originale, (b) image $LPB_{8,1}^{riu2}$, (c) histogramme $LPB_{8,1}^{riu2}$	24

Figure 2.9	exemple de calcul de l'opérateur $LBPM_{8,1}^{riu2}$: (a) image originale, (b) image $LBPM_{8,1}^{riu2}$, (c) histogramme $LBPM_{8,1}^{riu2}$	25
Figure 2.11	Problème de classification par apprentissage supervisé à 2 classes	27
Figure 2.12	Principe de la validation croisée pour $m=4$	28
Figure 2.13	Décision d'un classifieur binaire en fonction du seuil de discrimination s...	30
Figure 3.1	Courbe ROC	31
Figure 3.2	Base de données utilisée	33
Figure 3.4	Exemple de traitement d'image par chevauchement de blocs	34
Figure 3.5	Schéma général de l'algorithme étudié	35
Figure 3.6	Résultats des tests de certains échantillons pour $LBPM^{riu2}$	37
Figure 3.7	Résultats des tests de certains échantillons pour $LBPM^{riu2}$	38
Figure 3.8	Les différentes courbes ROC des images défectueuses de validation croisée par $LBPM^{riu2}$	41
Figure 3.9	Les différentes courbes ROC des images défectueuses de validation simple par $LBPM^{riu2}$	42
Figure 3.10	Les différentes courbes ROC des images défectueuses de validation croisée par $LBPM^{riu2}$	44
Figure 3.11	Les différentes courbes ROC des images défectueuses de validation simple par $LBPM^{riu2}$	45
Figure 3.12	Les différentes courbes ROC de base de données par les deux méthodes de validation	47

Introduction générale

La vision par ordinateur est un domaine de recherche qui n'a cessé de se développer depuis le début des années 40, et qui trouve aujourd'hui des applications dans de nombreux secteurs d'activité. Les systèmes d'imagerie, caméras et systèmes de vision, sont de plus en plus accessibles et performants, et induisent des progrès considérables dans les domaines de la santé (scanners, endoscopes, échographes, etc.), de l'industrie (réalisation de tâches dans des environnements à risque), de la production (systèmes de production automatisés) ou de la communication (réalité virtuelle, télévision numérique, 3D TV, etc.). D'une manière générale, la vision par ordinateur peut être considérée comme un processus de traitement de l'information, information issue d'images numérisées. Ce traitement est basé potentiellement sur les techniques de reconnaissance de forme. Cette discipline possède plusieurs applications, dans ce travail on s'est intéressé à la détection de défaut de tissus dans une chaîne industrielle.

La détection de défaut est une tâche propre à la vision industrielle qui permet, dans certains cas, d'augmenter la cadence de production (centaines de fois plus rapide qu'un homme) et surtout de diminuer les coûts de fabrication, ceci en éliminant les morceaux de tissu défectueux avant la fin de la chaîne de production.

Le développement de l'industrie du textile est très rapide ces dernières années. Simultanément les exigences de qualité pour les gens augmentent. Par conséquent, la qualité des textiles doit être strictement contrôlée. Les défauts ont un impact sérieux sur l'identification de niveaux de qualité pour les tissus. Par conséquent, la détection des défauts devient une étape essentielle lors de l'évaluation de la qualité des tissus.

Dans le cadre de cette étude, nous allons étudier un système de détection de défauts de tissus, à base d'un outil algorithmique utilisé au niveau de l'unité de traitement pour l'extraction des défauts. Il est basé essentiellement sur la méthode LBP (Local Binary Pattern).

Les LBP ou motifs binaires locaux ont initialement été proposés par Ojala, Pietikäinen et Harwood en 1996. Son principe est basé sur l'assignation d'un code binaire à chaque pixel de l'image en fonction de son voisinage. Cette méthode a l'avantage d'être simple et efficace dans le cadre de la reconnaissance de forme. Nous avons utilisé deux types de méthodes LBP.

Notre travail est réparti comme suit :

- Le premier chapitre présente le système de la vision industrielle en général ainsi que ces différents domaines d'applications.
- Le deuxième chapitre sera consacré à la description des techniques de reconnaissance de forme utilisées en vision industrielle en se basant sur la description de la méthode utilisée dans cette étude qui consiste en la méthode LBP ainsi que ses différentes variantes.
- Le troisième chapitre présente l'algorithme utilisé pour la détection de défauts de texture dans les tissus ainsi que les résultats obtenus pour les différentes images utilisées. Nous finissons ce mémoire par une conclusion générale et des perspectives.



CHAPITRE 1

VISION

INDUSTRIELLE

1.1 Introduction

La vision industrielle peut être définie comme l'application de la vision par ordinateur à des problématiques de production. Son principe est de pouvoir automatiser les tâches de contrôle de qualité ou de contrôle de processus. Ce processus d'automatisation permet d'augmenter les performances et les cadences de production, de rendre la production plus fiable, d'améliorer la qualité des produits, d'assurer leur traçabilité, et de garantir la sécurité.

Dans ce chapitre, nous allons introduire les notions de bases de ce procédé industriel et qui est devenu indispensable dans les chaînes de productions actuelles. Ensuite nous allons décrire l'application proposée dans cette étude qui consiste à l'élaboration d'un algorithme pour la détection de défauts de texture de tissus.

1.2 Vision industrielle

La vision Industrielle est un ensemble de techniques qui simule la vision humaine par un système automatique de prise d'image et de calcul pour interpréter cette image. En effet, la vision humaine est constituée de l'œil qui est l'organe de la vision, qui nous permet de capter la lumière de notre environnement et de la convertir en message nerveux, lequel est transmis au cerveau pour l'analyser [1] (Figure 1.1).

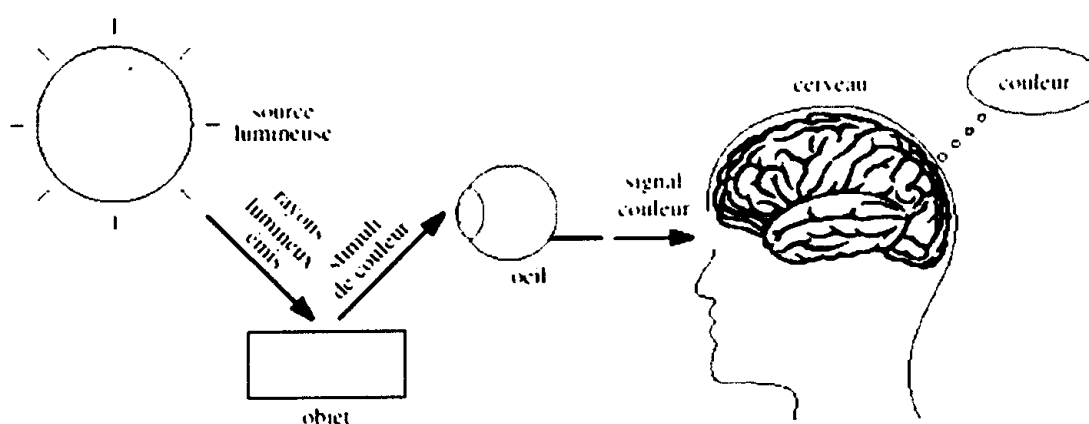


Figure 1.1 : Le principe de la vision humaine (inspiré de [1]).

L'œil humain est remplacé par des caméras. Ces dernières ont l'avantage d'être infatigables et quasi inusables. Elles sont plus rapides, mais ont une plage de luminosité plus faible que celle de l'œil. La vision industrielle ne se contente pas de capter une image et de la

reproduire sur un écran déporté. Elle a pour but d'interpréter l'image pour en retirer des informations. La vision industrielle doit simplifier le contexte de vision pour que l'interprétation soit possible et résolue grâce à des moyens mathématiques relativement simples contenus dans l'unité de calcul et visant à remplacer le cerveau humain (Figure 1.2).




Figure 1.2 : Le principe de la vision industrielle (inspiré de [1]).

1.3 Applications de la vision industrielle

Les applications de la vision industrielle sont aujourd'hui nombreuses et se sont ouvertes à tous les secteurs de l'industrie :

1.3.1 La vision pour la robotique ou guidage de robot

L'usage de la vision industrielle est fortement lié à l'avènement de la robotique dans les systèmes de fabrication automatisés. Elle est utilisée pour aider le robot à localiser et identifier des pièces dans le but de les récupérer puis de les transférer à une autre chaîne de fabrication, ou pour le tri en fin de chaîne de montage ou de fabrication. La Figure 1.3 illustre un déplacement de pièce à l'aide du robot.




Figure 1.3 : Déplacement de pièces à l'aide du robot

1.3.2 La vision pour la détection de défaut

La détection des défauts est une tâche propre à la vision industrielle. Elle permet d'augmenter la cadence de production, et diminuer les coûts de fabrication en éliminant les pièces en rebut. Par la suite elle élimine la perte de temps sur le complément d'usinage d'une pièce défectueuse. La figure 1.4 représente une détection de défaut.




Figure1.4 : Détection de défaut

Un autre exemple sur la détection de défaut est donné par la (Figure1.5). Un joint a correctement été placé sur un composant d'assemblage. Une machine d'assemblage place le joint sur la pièce. Le joint peut se trouver dans deux positions distinctes mais une seule est correcte.



Figure 1.5: Vérification d'orientation

1.3.3 La vision pour le guidage d'automobile ou la sécurité des piétons

Des caméras industrielles sont utilisées dans le guidage des automobiles. Les applications commencent à devenir nombreuses, par exemple rendre le système de conduite

de voiture autonome, éliminer l'effet de l'éblouissement des conducteurs en proposant une image filtrée de la route. La vision est utilisée aussi pour arrêter la voiture en cas de présence d'un piéton dans la route, pour la surveillance de la trajectoire qui doit être signalée au conducteur en cas d'écart significatif de la route, elle est aussi utilisée dans des applications nocturnes pour détecter les sources de chaleur avec un système de vision infrarouge permettant d'augmenter la visibilité des voitures ou des piétons. Également, elle permet d'assurer une autonomie de conduite complète, et pour ce faire, il suffit de définir l'adresse de destination et à l'aide du guidage satellite, la voiture pourra emmener les passagers en toute sécurité [2, 3,4]. La Figure 1.6 illustre une image d'infrarouge identifiant un piéton dans la route.



Figure 1.6: Image de caméra infrarouge identifiant un piéton dans la route

1.3.4 La vision pour la surveillance et sécurité

Les caméras industrielles sont très utilisées dans la surveillance et la sécurité. Elles remplacent la présence humaine dans un milieu nocif ou dangereux. Elles sont aussi utilisées pour la surveillance des chaînes de fabrication et pour la surveillance des locaux. Les algorithmes sont basés généralement sur la détection de mouvement. D'autres applications concernent la surveillance des personnes âgées dans leurs domiciles. Il s'agit là de signaler un accident (Chutes, immobilisation, ...) ou encore pour la détection de fumée et l'enclenchement des alarmes. Les caméras Ethernet sont les plus prisées pour ce type d'application parce qu'elles permettent une installation rapide, à une grande distance et une vitesse d'acquisition très importante. Les caméras surveillance représente sur la Figure 1.7.




Figure 1.7 : Caméra de surveillance sur réseau internet sans PC

1.4 La détection de défauts dans l'industrie du textile:

L'objectif du travail effectué au cours de ce mémoire est l'élaboration d'un algorithme de détection automatique de défauts dans les tissus. Nous allons expliquer le processus de fabrication de tissus ensuite nous intéressants à la définition des différents défauts de tissus.

Dans un système industriel, le tricotage de trame de tissu est totalement automatisé. Le fil est enroulé par un moteur pour éviter sa coupure. Le chariot est responsable de pousser une ou plusieurs aiguilles dans un sens déterminé pour former un nœud. La succession de cette opération produit une ligne de nœud dite aussi une ligne de trame de tissu [5]. La figure 1.8 présente un schéma simplifié d'un système de tricotage industriel.




Figure 1.8 : système de tricotage industriel.

Durant le processus de tricotage d'une trame de tissu, plusieurs types de défauts peuvent se produire ; le fil utilisée peut être coupé résultant alors en un vide dans la trame, une tache d'huile peut être causée par le matériel de tricotage ou une différence de couleur peut être marqué durant la teinture du tissu. En général les défauts peuvent être nombreux,

mais sont soit au niveau du tissage ou du tricotage, soit des matières, soit de métrologie (taille, ...). Les caractéristiques peuvent elles aussi être nombreuses (motifs : cercle, triangle, rectangle, formes diverses, couleurs, ..., matériaux : laine, coton, cachemire, fibres synthétiques, ...) .Les techniques d'inspection dans ce domaine sont nombreuses. En effet, pour détecter les erreurs ou les caractéristiques; l'inspection humaine n'est pas suffisante dans une démarche qualité. C'est pour cela il y a eu le recourt aux systèmes de Vision artificielle ou industrielle.

Ci-après, nous présentons les défauts les plus fréquents dans la fabrication de tissu [6].

- **Extrémités cassées** : Si un fil de chaîne est absent dans le tissu pour une distance courte ou longue.
- **Médiateur brisé** : Si un fil de trame est absent dans le tissu pour une largeur courte ou longue.
- **Trame frisée** : Si les fils de chaînes ou de trames sont très torsadés ou détendus.
- **Limaces** : lorsque le fil de trame est impur et contient des irrégularités de diamètre.
- **Couture** : les extrémistes et les pics ne sont pas entrelacés selon l'ordre correct de la structure.
- **Densité irrégulière** : Si la densité de sélection qui est prise par pouce varie en raison de panne mécanique.
- **Tissu poilu** : Les fibres dans le fil ont été rendus rugueuses avant, pendant ou après le tissage.
- **Trous** : Présence des petits trous dans le tissu.
- **Taches d'huile** : Taches causées par la lubrification des pièces mécaniques de la machine de tricotage.
- **Défaut de point de départ** : Causé par l'arrêt et le départ d'un métier à tisser.
- **Défaut de teinture** : durant le processus de teinture, des bandes de couleur plus dense que la couleur supposée, peuvent apparaître.

1.5 Système de vision industrielle

La vision industrielle, est une discipline appliquée de la vision artificielle qui emploie le traitement numérique d'images pour automatiser des tâches. Elle utilise des moyens électroniques et informatiques pour doter des machines et robots de capacités sensorielles analogues à la vision humaine. Autrement dit, elle utilise des caméras comme capteurs pour

détecter des défauts sur des objets manufacturés, inspecter les tissus en cours de fabrication, les compter, les trier, les classer, les mesures à partir de leur apparence visuelle.

1.5.1 Description

Un système de vision industrielle est principalement constituée : d'une caméra avec objectif pour la prise d'images, de produits sur les lignes de production, d'un dispositif d'éclairage spécifique pour mettre en évidence les tissus à contrôler, d'un ordinateur de visualisation et de traitement des images lié à un automatisme d'éjection, d'un automate pour exécuter les commandes délivrées par l'unité de traitement et par la suite activer les actionneurs, et d'une interface homme machine pour la configuration du système de vision la Figure.1.9 représenté un Schéma descriptive du système de vision industrielle .

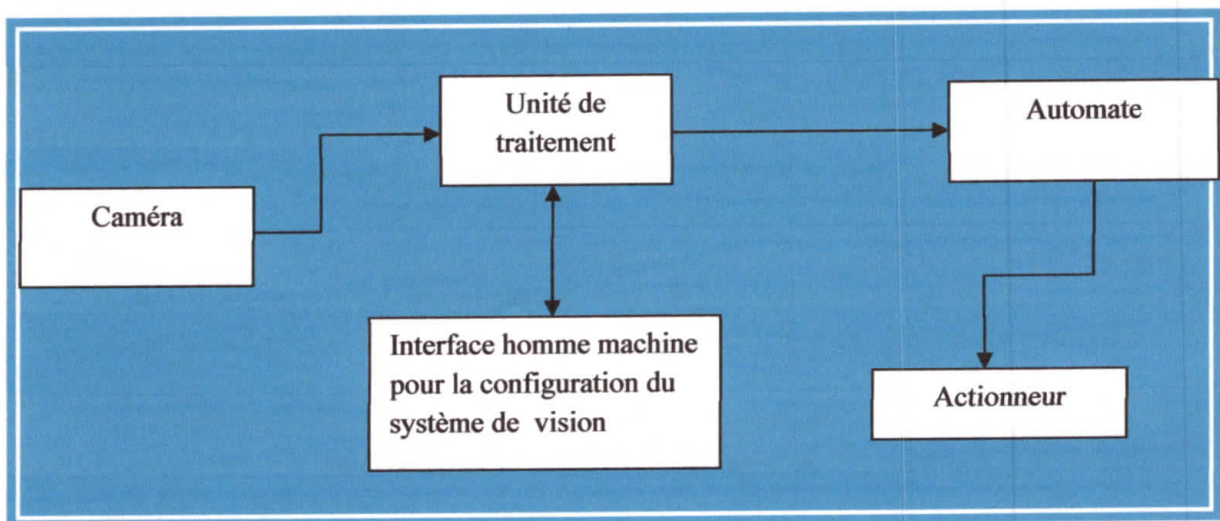


Figure 1.9 : Schéma descriptive du système de vision industrielle

1.5.2 Eléments constitutants

Les différents éléments constitutants un système de vision industrielle sont :

a. Les Caméra : c'est l'appareil de prise de vue destiné à enregistrer des images successives. On distingue trois types de caméras utilisés dans un tel système :

- **caméra linéaire :** Les caméras industrielles de type linéaire réalisent des prises de vue en une dimension (1D), elles peuvent être synchronisées sur la vitesse de défilement du produit par le biais d'un signal encodeur. Les caméras linéaires sont principalement utilisées pour le contrôle et l'inspection de produits de longueur infinie fabriqués en continu (ex: verre, papier, non-tissé, plastique...).




Figure 1.10 : Caméra linéaire

- **caméra intelligente**: est un système de vision industrielle qui capture des images et les interprète.




Figure 1.11 : Caméra intelligente

- **caméras matricielles** : Les caméras industrielles de type matriciel réalisent des prises de vue en deux dimensions (2D), elles peuvent être synchronisées sur le processus externe par le biais d'un signal de trigger externe ou fonctionner en mode continu. Les caméras matricielles sont principalement utilisées pour le contrôle et l'inspection de produits aux dimensions finies. la figure 1.12 illustre une caméra matricielles.




Figure 1.12: Caméra matricielles

b. Dispositif d'éclairage

L'éclairage est un élément déterminant dans un système de contrôle par vision industrielle. En fonction de la technique d'éclairage employée, on pourra faire ressortir certains défauts. Il définit les caractéristiques de la lumière qui éclaire l'objet à contrôler et doit être parfaitement maîtrisé [7].

Il existe plusieurs types d'appareils pour l'éclairage :

- Le tube fluorescent.
- Le tube fluo-compact.
- La LED.



c. Unité de traitement

Elle permet de numériser, stocker et traiter les images ainsi que de configurer ou programmer les outils logiciels de vision industrielle (Figure1.13).




Figure1.13 : Unité centrale d'un ordinateur

1.6 Application proposé

Dans le cadre de cette étude, nous allons étudier un système basé sur détection de défauts, Le processus étudié concerne un système d'inspection automatique de tissu. En effet un système d'inspection automatique de tissu prend des images de la trame en cours de production et effectue le traitement sur ces images afin de détecter les anomalies. Figure 1.14 montre l'architecture typique d'un système d'inspection automatique de tissu [8]. Les caméras installées en parallèle permettent d'acquérir des images de la trame en cours de production. Une seule caméra permet alors d'obtenir une image à une échelle réduite et certains petits défauts peuvent échapper à la détection. Le système d'illumination situé au-dessous de l'enrouleur de tissu permet une meilleure condition d'acquisition d'image. Il est manipulé par

un contrôleur spécifique afin de paramétrer l'illumination du système selon la nature du tissu ou l'illumination globale de l'usine.

Une fois les images sont acquises, elles sont transférées à un dispositif d'acquisition d'images qui permet de rassembler les données sous le format pixel pour obtenir la totalité de l'image dans une bonne résolution et avec la richesse souhaitée.

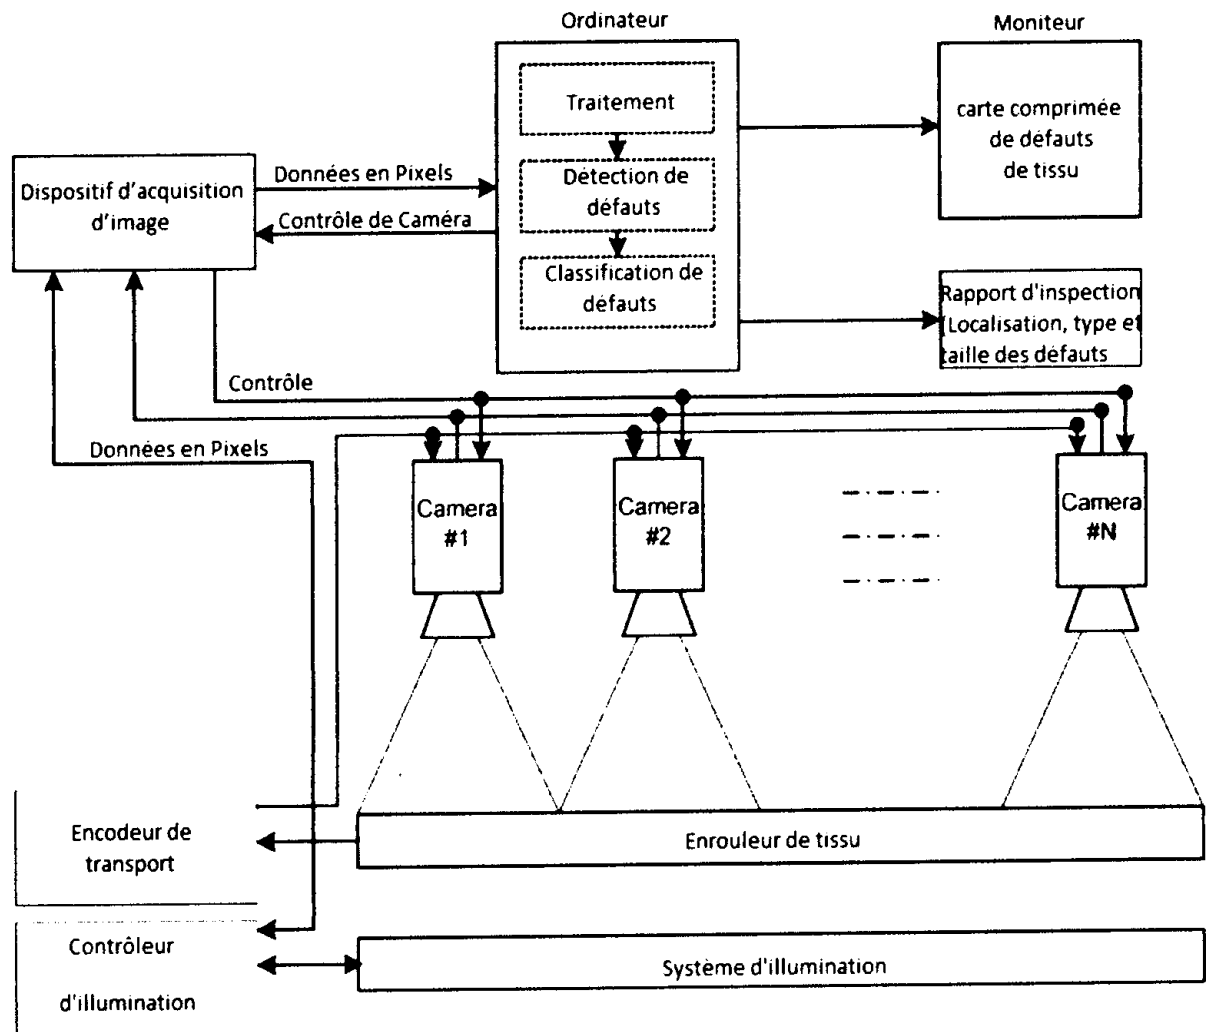


Figure 1.14 : l'architecture d'un système typique d'inspection automatique de tissu [8].

L'ordinateur effectue le traitement nécessaire sur ces images afin de détecter les défauts, les produits de cette tâche sont la carte de défauts qui indique les coordonnées géométriques des défauts présents dans le tissu et le rapport de statistiques des défauts qui sera analysé par la direction pour prendre les décisions nécessaires. L'outil algorithmique utilisé au niveau de l'unité de traitement pour l'extraction des défauts est la méthode LBP qui sera détaillée dans le chapitre suivant.

1.7 Conclusion

La vision industrielle fait intervenir plusieurs disciplines telles que la physique, l'optique, l'informatique, la mécanique ou l'électronique et demande des connaissances aussi bien pratiques que théoriques. Elle procède plusieurs applications telles que l'inspection de défaut de tissu. Dans le chapitre suivant nous allons présenter l'algorithme de reconnaissance de forme utilisé pour l'application visée à savoir la détection de défauts de texture de tissus.





CHAPITRE 2

RECONNAISSANCE

DE FORME

2.1 Introduction

La reconnaissance des formes a pour objet de simuler les activités de perception sensorielle du cerveau. La reconnaissance a besoin d'un modèle de l'objet. Pour l'être humain, ce modèle correspond à une représentation mentale de l'objet qui peut être apprise en retenant les caractéristiques les plus discriminantes de l'objet. Les caractéristiques peuvent être toutes sortes d'attributs de l'objet : forme, couleur, texture, taille, volume, etc.

Dans ce chapitre nous allons faire un tour d'horizon sur les méthodes de reconnaissances de formes en général ainsi que ses applications dans le domaine de la vision industrielle et plus précisément pour la détection de défauts. Ensuite nous présentons en détail la méthode LBP utilisé dans ce travail pour l'extraction de caractéristiques pertinentes.

2.2 Reconnaissance de formes

La reconnaissance de formes est un processus de traitement automatique de donnée qui consiste à chercher une forme requête (modèle) extraite d'une image dans une base de données composée de formes issues d'une ou plusieurs images. Elle peut alors être définie comme un problème d'apprentissage du modèle dans le but d'affecter des données à des classes représentatives du problème. Ce processus consiste généralement en étapes fondamentales suivantes :

1. prétraitement.
2. extraction et codage invariant des formes ou extraction de caractéristiques.
3. comparaison ou classification.
4. Décision.

Chacune de ces étapes est cruciale, et un mauvais choix pour l'une d'elles peut affecter la chaîne entière. C'est pourquoi la plupart des algorithmes de reconnaissance de formes sont en fait dédiés à une application ou à un type d'images ou de formes particulier.

Dans cette étude, l'application visée est la détection de défauts de texture de tissus. Par la suite, l'extraction de formes précises contenues dans l'image ne constitue pas l'objectif de l'application. C'est plutôt une description robuste et invariante de l'image toute entière (la texture de tissu) qui nous intéresse. Chose qui va permettre de faire une classification des textures étudiées avec défauts et sans défauts. De ce faite, l'approche étudiée nécessite les étapes suivantes :

- **étape de prétraitement** : elle permet de "nettoyer" les images ; d'atténuer toute information susceptible de nuire à la description du contenu pertinent lors de la phase

d'extraction de caractéristiques [9]. On retrouve les techniques d'accentuation de contraste pour faire apparaître les détails, les techniques de filtrage pour l'extraction de contour

- **étape d'extraction de caractéristiques** : c'est l'étape fondamentale qui détermine la qualité des résultats du processus de détection. En fait, elle permet de d'écrire l'information pertinente contenue dans l'image à l'aide d'opérateurs ou de descripteurs discriminants. Plus de détail seront donnés par la suite;

- **étape de classification** : permettant de construire une frontière de décision pour identifier la classe d'une image présentée à l'entrée du système. Les méthodes utilisées pour la classification sont d'une grande variété mais pour notre contexte nous utilisons le K Plus Proche voisin (KNN). La méthode KNN est une méthode basée sur le calcul de distance entre le descripteur de l'échantillon de test et celui de ces voisins de la base de données pour pouvoir le classer à la classe appropriée. La figure illustre son principe général.




Figure 2.1 : Principe des K-plus proches voisins (KNN)

2.2.1 Domaine d'utilisation

La reconnaissance de formes est utilisée dans plusieurs domaines, on peut citer :

- L'analyse automatique des images médicales obtenues de microscopes, digitaliseurs, d'appareils à résonance, d'appareils à rayons X, d'appareils de médecine nucléaire.
- Reconnaissance de l'écriture manuscrite : cette technologie fait appel à la reconnaissance de forme, mais également au traitement automatique du langage naturel. Cela veut dire que le système ; tout comme le cerveau humain, reconnaît des mots et des phrases existant dans un langage connu plutôt qu'une succession de caractères. ceci améliore grandement la robustesse.
- Classification de documents : son activité est essentielle dans de nombreux domaines économiques : elle permet d'organiser des corpus documentaires, de les trier, et d'aider à

les exploiter dans des secteurs tels que l'administration, l'aéronautique, la recherche sur internet, les sciences.

- Le domaine urbain comme la reconnaissance de panneaux de signalisation et de la reconnaissance de piéton et la détection des véhicules.
- Reconnaissance du type de sol et des grains et l'agriculture et la classification de pollen.
- Classification des électrocardiogrammes selon les catégories de maladie cardiaques.
- La reconnaissance de bâtiment.
- Identification des personnes à partir des empreintes digitales, de la forme des mains, d'empreintes rétiniennes, de la voix.
- Assemblage automatique de pièces.
- Détection automatique de pièces.
- Géophysique : analyse d'images de satellites pour prévisions météorologiques.

2.3 Reconnaissance de formes pour la détection de défauts

Dans cette étude, l'application visée comme déjà citée-est la détection de défauts de texture de tissus. En effet le tissu est considéré comme un matériau texturé. Alors s'il s'agit d'un défaut dans un tissu, il devrait absolument être un défaut de texture. Selon l'état de l'art de détection de défauts de texture, pour traiter le problème de détection automatisée de défauts dans les tissus uniformément texturés, il existe trois types d'approches utilisées dans la phase d'extraction de caractéristiques:

2.3.1 Approches statistiques : Les approches statistiques sont basées sur une hypothèse commune ; les régions sans défauts admettent des statistiques stationnaires et s'étalent sur une grande région de l'image. Par la suite toute région qui admet des statistiques différentes de celles des régions sans défauts est une région porteuse de défauts. Dans ce cadre on peut citer les approches basées sur l'histogramme de l'image, la dimension fractale, les statistiques du premier ordre [10].

2.3.2 Approches spectrales : Les chercheurs ont remarqué une haute périodicité de primitives de texture de base, causée par les fils dans le tissu textile. L'utilisation de cette périodicité permet alors la détection de défauts de texture. Pour ce faire, les chercheurs ont eu recours aux transformées fréquentielles telles que la transformée de Fourier et la transformée en cosinus discrète, et spatio-fréquentielles telles que la transformée en ondelettes discrète [10].

2.3.3 Approches basées sur la modélisation : L'hypothèse générale de ces approches est la possibilité de résumer la texture dans un modèle statistique. Ce modèle constitue une signature compacte d'une texture donnée. Les zones texturées qui ont la même apparence ont deux modèles similaires. Ainsi, le problème de détection de défauts devient un problème de comparaison de modèles qui est un problème considérablement plus facile à résoudre. En effet, pour comparer deux modèles, plusieurs méthodes ont été utilisées et efficacement implémentées. Les méthodes LBP qui seront employé en phase d'extraction de caractéristique dans cette étude font parties de ce type d'approches.

2.4 Méthodes d'extraction de caractéristiques

La phase d'extraction des caractéristiques constitue généralement l'une des phases les plus importants dans l'élaboration d'un système de vision [9]. Il s'agit en effet de déterminer un espace numérique de description dans lequel les données de l'image seront projetées et permettant une séparation optimale des classes en présence. On distingue plusieurs classifications pour les méthodes d'extraction de caractéristiques, dont on peut les résumer comme suit :

Les descripteurs de bas niveau s'intéressant à l'information contenue dans l'image au niveau du pixel et des descripteurs de plus haut niveau nécessitant une représentation intermédiaire de l'image plus adaptée [11]. Cette description peut être locale (description de motifs de textures) ou globale (histogramme des orientations de la distribution gradients de toute l'image) selon la nature de l'information à prélever et se fait à l'aide d'opérateurs ou de descripteurs [12,13].

a-extracteurs de bas niveau : Les extracteurs bas niveau permettent de traduire l'information présente au niveau du pixel, sans tenir compte des formes ou des patterns présents dans l'image. Parmi les caractéristiques extraites, nous retrouvons l'intensité du pixel brut, l'histogramme des intensités de pixel, les statistiques sur cet histogramme (moyenne, entropie, variance, coefficient d'aplatissement, asymétrie), la densité de pixel.

b-extracteurs de plus haut-niveau : La méthode d'extracteurs de plus haut-niveau tiennent compte des forme et des structures dans l'image, des relations spatiales entre les pixels ou ces structures. Les propriétés les plus recherchées dans ces extracteurs sont, outre leur pouvoir descriptif, l'invariance et la robustesse à différentes transformations pouvant affecter l'image [12,14 ,15]. La méthode LBP fait partie de ce type d'approches [16,17].

c- caractérisation local et globale : les caractéristiques globales qui sont calculées sur toute l'image et la caractéristiques locales qui sont calculées autour de point d'intérêt , il peut aussi s'agir de points pris aléatoirement ou règlement dans l'image, le vecteur caractéristique contient parfois des ordonnées provenant de la détection, telle que l'orientation de l'arête ou la magnitude du gradient dans la zone d'intérêt.

Généralement le vecteur caractéristique en un pixel est calculé sur un voisinage de ce pixel, Il peut être calculé à différentes échelles de manière à s'affranchir du facteur de zoom. Parmi les caractéristiques locales, on retrouve les motifs binaires locaux sont un calcul de concurrence des niveaux de gris locaux d'une image.

2.5 Méthode LBP

Les Motifs Binaires Locaux (LBP) sont des caractéristiques utilisées en vision par ordinateur pour la classification des textures, la détection des défauts et la reconnaissance de forme dans une séquence d'image. L'approche (LBP) se base sur la comparaison de niveaux de luminance d'un pixel à analyser avec celles de ces proches voisins et la valeur qui le caractérise est calculé par leur somme pondérée par un certains poids (code binaire). Selon l'échelle du voisinage utilisé, certaines zones d'intérêts tels des coins ou des bords peuvent être détectées par ce descripteur [18]. L'histogramme des codes LBP constitue le descripteur caractérisant l'image étudiée.

2.5.1 Motif binaire Locaux(LBP)

L'opérateur LBP a été proposé à la fin des années 90 par [16,17]. L'idée de cet opérateur de texture est de donner à chaque pixel un code dépendant des niveaux de gris de son voisinage. Une fois le code LBP calculé pour chaque pixel de l'image, l'histogramme de cette image LBP est calculé pour former un vecteur de caractéristiques représentant l'image codée par l'opérateur LBP. Ce vecteur représente le descripteur LBP qui sera utilisé en phase de classification pour prendre la décision sur la classe de l'image concernée. L'utilisation des descripteurs LBP basiques ont eu un grand succès dans divers applications, tels que : la reconnaissance de forme, La segmentation,...

Le concept du LBP basique [16] consiste à générer un motif binaire pour chaque pixel P de l'image à analyser. En effet, tous les voisins dans une région de taille R prendront alors une valeur "1" si leur valeur est supérieure ou égale au niveau de gris de pixel à analyser

(Central) et "0" sinon. Les pixels de ce motif binaire sont alors multipliés par des poids (code binaire) et sommés afin d'obtenir un code LBP du pixel courant.

La propriété importante du code LBP est que ce code est invariant aux changements uniformes d'illumination parce que le LBP d'un pixel ne dépend que des différences entre son niveau de gris et celui de ses voisins.

Pour calculer un code LBP dans un voisinage de P pixels, dans un rayon R, on compte simplement les occurrences de niveaux de gris g_k plus grands ou égaux la valeur centrale.

$$LBP_{P,R} = \sum_{k=0}^{P-1} S(g_k - g_c) 2^k \tag{2.1}$$

Ou $s(x)$ est la fonction donnée par l'équation (2.2) :

$$S(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases} \tag{2.2}$$

Avec : g_k et g_c sont respectivement les niveaux de gris d'un pixel voisin et du pixel central.

La figure 2.2 illustre la procédure de calcul de LBP sur une fenêtre de taille 3x3.

Exemple de calcul du LBP d'un pixel donné : $1 + 16 + 32 + 64 + 128 = 241$




Image brute

Image seuillée

poids

LBP

Figure 2.2 : la procédure de calcul de code LBP

L'opérateur LBP a été étendu ensuite par l'utilisation des différentes tailles du cercle de voisinage. Il est noté par $LBP_{(P,R)}$.

Avec : P : le nombre de pixel voisin.

R : le rayon du cercle.

La figure 2.3 montre quelques exemples de différents points de voisinage avec le rayon :





Figure 2.3 : Quelques exemples de différents points de voisinage avec le rayon.

La méthode LBP est très utilisée pour les images de tissu texturées. Ces dernières sont caractérisées en utilisant directement l’histogramme des codes binaires. La figure 2.4 présente un exemple de calcul de l’opérateur LBP sur une image au niveau de gris.



(a) (b) (c)

Figure 2.4 : (a) image originale, (b) image LBP, (c) histogramme de LBP.

2.5.2 Motif binaire Locaux (LBP) invariant par rotation uniforme

Dans l’objectif d’améliorer la méthode LBP classique, Ojala et al. [17,19] relèvent qu’il est possible d’utiliser uniquement un sous ensemble de 2^P LBP pour décrire les images texturées. Ce sous ensemble est appelé motif uniforme ou motif fondamental. Un LBP est appelé uniforme de la configuration binaire circulaire s’il contient au maximum deux transition de 0 à 1, par exemple : 00000000 et 11111111 contiennent 0 transition tandis que 00000110 et 01111000 contiennent deux transition mais 00101000 contiennent 4 transitions ce n’ai pas un motif uniforme et ainsi de suite, ce type de LBP est noté $LBP_{(R,P)}^{U2}$, contient moins de 2^P bits.

Les raisons de l'omission des motifs non uniformes sont de deux ordres. Premièrement, la plupart des motifs binaires locaux dans les images naturelles sont uniformes. La deuxième raison pour considérer les modèles uniformes est la robustesse statique. L'utilisation de modèles uniformes au lieu de tous les motifs possibles a produit un meilleur résultat de reconnaissance dans de nombreuses applications. Un exemple est donné par la figure 2.5.




Figure 2.5 : Construction et uniformité d'un motif LBP (ici non uniforme)

Pour tout pixel (x y), le calcul du motif uniforme est donné par Ojala [17] :

$$LBP_{P,R}^i(x y) = \min \{ROR (LPB_{P,R}(x y), i/i \in [0, p-1])\} \tag{2.3}$$

Où ROR (a, i) correspond au résultat de i décalages circulaires successifs vers la droite des bits du nombre a (codé sur P bits). $LBP_{P,R}^i$ Quantifie ainsi les statistiques d'occurrence de modèles individuels invariants en rotation correspondant à certaines micros caractéristiques de l'image. Avec cette méthode, 36 motifs différents (figure 2.6) sont considérés au lieu de 2^P .




Figure 2.6 : Les 36 schémas binaires invariables de rotation unique qui peuvent se produire dans l'ensemble voisin symétrique circulaire de $LBP_{P,R}^i$

Pour une valeur $R=1$, $LBP_{P,R}^{riu2}$ est l'équivalent de LBP_{ROT} proposé par Pietikainen et al [20] qui est moins performant. Pour remédier ce problème, une mesure est effectuée sur les motifs pour déterminer leur uniformité. L'opérateur est appelé $LBP_{P,R}^{riu2}$ et défini de la manière suivante :

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_p^{p-1} \mu(g_0 - g_c) & \text{si } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{autrement} \end{cases} \quad (2.4)$$

Où U est une fonction qui retourne le nombre de transitions spatiales.

Avec :

$$U(LBP_{P,R}) = U|\mu(g_{p-1} - g_c) - \mu(g_0 - g_c)| + \sum_p^{p-1} |\mu(g_p - g_c) - \mu(g_{p-1} - g_c)| \quad (2.5)$$

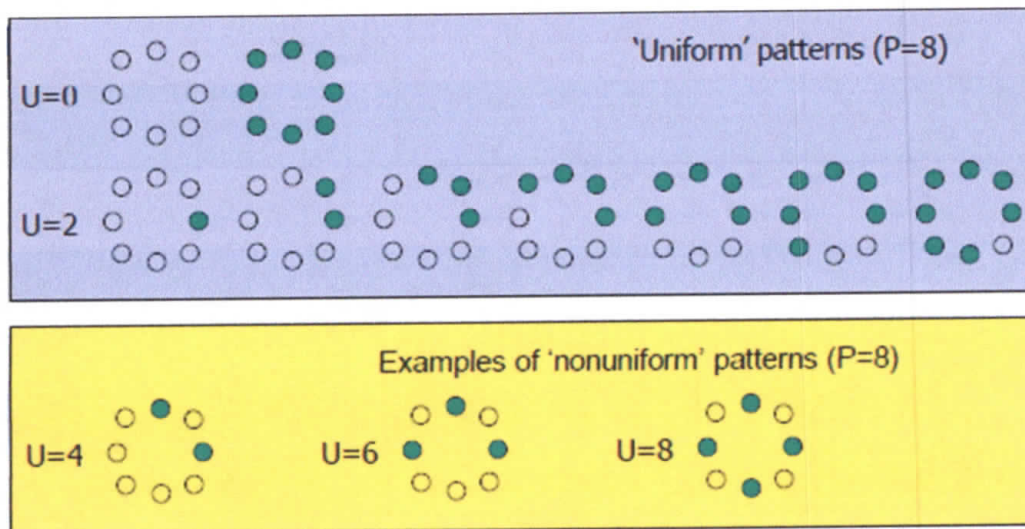


Figure 2.7: exemples de motifs uniformes et non-uniformes.

La figure 2.8 présente un exemple de calcul de l'opérateur $LBP_{8,1}^{riu2}$ sur une image au niveau de gris.




Figure 2.8 (a) image originale, (b) image $LBP_{8,1}^{riu2}$, (c) histogramme $LBP_{8,1}^{riu2}$

2.5.3 LBP Complete Magnitude

Une autre variante de LBP a été proposée dans la référence [17] pour compléter la description des images texturées. Elle s'appelle patron binaire local complet. Le principe consiste à ajouter la composante de magnitude du LBP au signe afin de généraliser le concept de LBP. Celle-ci se calcule de la manière suivante :

$$LBPM_{P,R} = \sum_{p=0}^{P-1} t(m_p, c) 2^p \quad (2.6)$$

$$\text{Avec } t(x, c) = \begin{cases} 1, & x \geq c \\ 0, & \text{sinon} \end{cases} \quad (2.7)$$

Le paramètre C est un seuil déterminé selon l'application, mais souvent mis à la valeur moyenne d'intensité de l'image. Similairement au $LBPM_{P,R}^{riu2}$, on peut construire un opérateur invariant en rotation $LBPM_{P,R}^{riu2}$ pour la magnitude. La combinaison des histogrammes de signe du LBP et de la magnitude du LBP donne ainsi des meilleures classifications de texture, par rapport à l'information de signe seule. La figure 2.9 présente un exemple de calcul de l'opérateur $LBPM_{8,1}^{riu2}$ sur une image au niveau de gris.

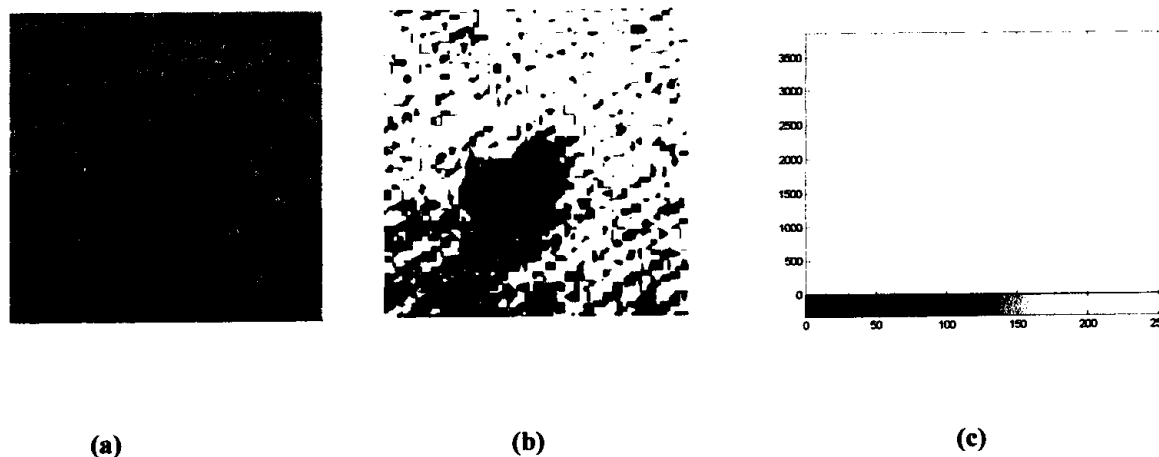


Figure 2.9: (a) image originale, (b) image $LBPM_{8,1}^{riu2}$, (c) histogramme $LBPM_{8,1}^{riu2}$.

2.6 Classification

Après avoir extrait les caractéristiques pertinentes par les méthodes LBP des différentes images de la base de données, la dernière phase de l'algorithme de reconnaissance de forme est la prise de décision ou la classification. En fait cette dernière est une procédure

permettant d'affecter un échantillon à la famille à laquelle il appartient ou autrement dit définir sa classe (dans notre cas dire, es que cet échantillon est avec ou sans défaut). L'évaluation des classifieurs est une question récurrente en apprentissage supervisé. Parmi les différents indicateurs existants, la performance en prédiction calculée à l'aide du taux d'erreur (ou son complémentaire à 1, le taux de bon classement) est un critère privilégié. Le taux d'erreur théorique est défini comme la probabilité de mal classer un échantillon dans un ensemble de données. Pour calculer ce taux d'erreur, nous allons utiliser la méthode de la validation croisée. Avant de détailler cette dernière, nous allons expliquer la manière de disposition des données issues de la phase d'extraction de caractéristiques.

2.6.1 La classification par apprentissage supervisé

En apprentissage automatique, le problème de classification se présente sous la forme d'un ensemble de données, contenant des exemples issus de l'observation d'un phénomène, cet ensemble est appelé ensemble d'apprentissage. Chaque exemple de cet ensemble est constitué d'une description (attributs ou caractéristiques) et d'une étiquette (classe). Un algorithme d'apprentissage analyse ces données afin de construire un modèle (classifieur). C'est à ce modèle que revient ensuite la tâche d'étiqueter de nouveaux exemples à partir de leur description [21].

Soit un problème de classification avec un ensemble d'apprentissage de N exemples, et un ensemble de M classes: si X_i ($i = 1, \dots, N$) est un vecteur d'attributs d'entrée décrivant l'exemple i , et $Y_i \in \{0, 1\}$ sa classe, on dénote l'ensemble d'apprentissage par:

$$LS = (X^i, Y^i), i = 1, \dots, N \quad (2.8)$$

Dans notre cas, les éléments X_k^i ($k=1, \dots, m$) de X^i sont des valeurs numériques du vecteur de caractéristique issu de la méthode LBP avec $m=9$.

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 2.10 : problème de classification par apprentissage supervisé à 2 classes : les exemples de l'ensemble d'apprentissage sont décrits par 9 attributs et une classe de sortie.

Après la construction du modèle, une méthode pour vérifier la généralisation du modèle au-delà de LS est l'utilisation d'un échantillon de test contenant des exemples distincts de ceux de LS. La précision du modèle est ainsi exprimée par son taux d'erreur sur cet échantillon.

2. 6. 2. Validation croisée : C'est une méthode qui permet de prédire la performance de la classification. Il existe trois méthodes principales de la validation croisée appelées: « *holdout method* », « *k-fold cross-validation* » et « *leave-one-out cross-validation* ».

- **Validation croisée par la méthode « *holdout method* »** : il suffit de diviser l'échantillon de taille n en deux sous échantillons, le premier d'apprentissage et le second de test. Le modèle est bâti sur l'échantillon d'apprentissage et validé sur l'échantillon de test. L'erreur est estimée en calculant un test, une mesure ou un score de performance du modèle sur l'échantillon de test.
- **Validation croisée par la méthode « *k-fold cross-validation* »** : on divise l'échantillon original en k échantillons, puis on sélectionne un des k échantillons comme ensemble de validation et les $(k-1)$ autres échantillons constitueront l'ensemble d'apprentissage. On calcule comme dans la première méthode le score de performance. Puis on répète l'opération en sélectionnant un autre échantillon de validation parmi les $(k-1)$ échantillons qui n'ont pas encore été utilisés pour la validation du modèle.

- **Validation croisée par la méthode « leave-one-out (validation simple) »** : un cas particulier de la deuxième méthode où $k=n$, c'est-à-dire que l'on apprend sur $(n-1)$ observations puis on valide le modèle sur la n ème observation et l'on répète cette opération n fois.

Le tableau suivant présente les différentes Avantages et inconvénients entre les méthodes de validation croisée.

La méthode	Avantage	Inconvénient
<i>holdout</i>	la méthode plus simple permet alors de faire une sélection sur le modèle plus facilement	Perte de donnée on a 30% moins d'information pour établir le modèle si on n'a pas suffisamment de données on peut avoir de faux résultat on aura une variance élevée
<i>leave-one-out</i>	Pas de perte de données	La plus lente et donc moins utilité
<i>k-fold</i>	Consiste à trouver le juste milieu des avantages et inconvénients des 2 méthodes précédentes	

Tableau 2.1 Avantages et inconvénients entre les méthodes de validation croisée

La Figure 2.11 présente le principe de la validation croisée sur 4 partitions.

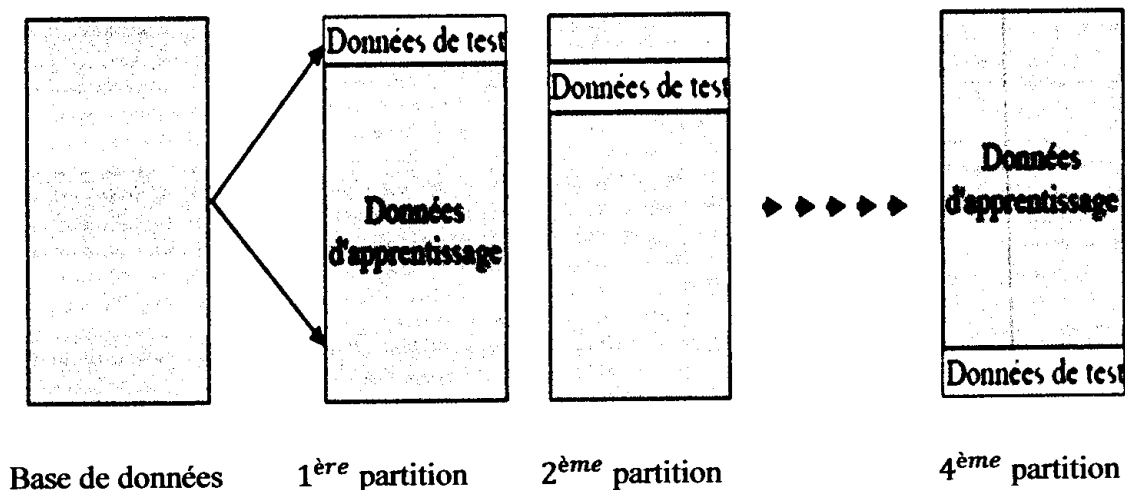


Figure 2.11: Principe de la validation croisée pour $m = 4$

2.6.3 Matrice de confusion

La matrice de confusion est un outil servant à mesurer la qualité d'un système de classification. Elle permet de calculer le taux d'erreur de la classification de deux classes, notées P et N.

La matrice de confusion donnée sur le tableau suivant :

Décision ↓ Vérité →	P	N	Total
P	TP	FP	TP+FP
N	FN	TN	FN+TP

Tableau 2.2 la forme de la matrice de confusion

Avec :

- **TP** (true positives) : les prédits positifs qui le sont vraiment.
- **FP** (false positives) : les prédits positifs qui sont en fait négatifs.
- **TN** (true négatives) : les prédits négatifs qui le sont vraiment.
- **FN** (false négatives) : les prédits 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. $N=TN+FP$.

On définit alors la spécificité et la sensibilité :

- La **sensibilité** est : $TP / (TP+FN) = TP/P$.
- La **spécificité** est : $TN / (TN+FP) = TN/N$.

Cette matrice permet de calculer le taux d'erreur à l'aide de la relation suivante :

$$E = \frac{FN + FP}{P + N} * 100 \quad (2.9)$$

2.6.4 La courbe ROC :

La courbe ROC représente l'évolution de la sensibilité (taux de vrais positifs) en fonction de 1 spécificité (taux de faux positifs) quand on fait varier le seuil s [22].

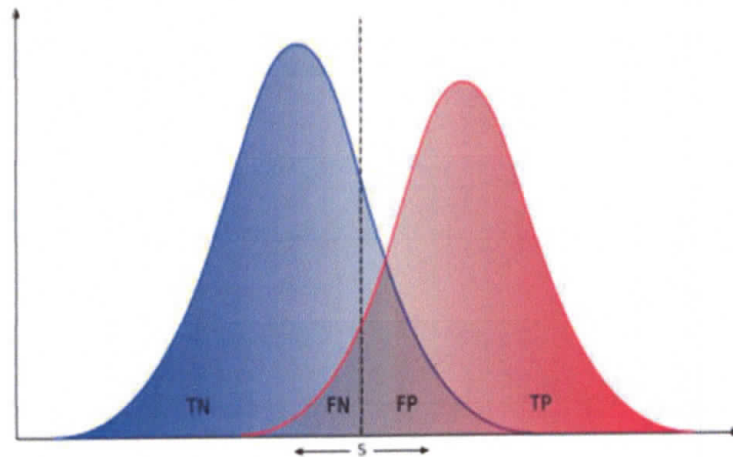


Figure 2.12 : Décision d'un classifieur binaire en fonction du seuil de discrimination s : la courbe bleue représente la probabilité a posteriori de la classe « négative » et la courbe rouge représente la probabilité a posteriori de la classe « positive ».

- C'est une courbe croissante entre le point $(0,0)$ et le point $(1,1)$ et en principe au-dessus de première bissectrice.
- Une prédiction random donnerait la première bissectrice.
- Meilleure est la prédiction, plus la courbe est au-dessus de la première bissectrice.
- Une prédiction idéale est l'horizontale $y=1$ sur $]0,1]$ et le point $(0,0)$.
- L'aire sous la courbe ROC (AUC, Area Under the Curve) donne un indicateur de la qualité de la prédiction (1 pour une prédiction idéale, 0.5 pour une prédiction random).

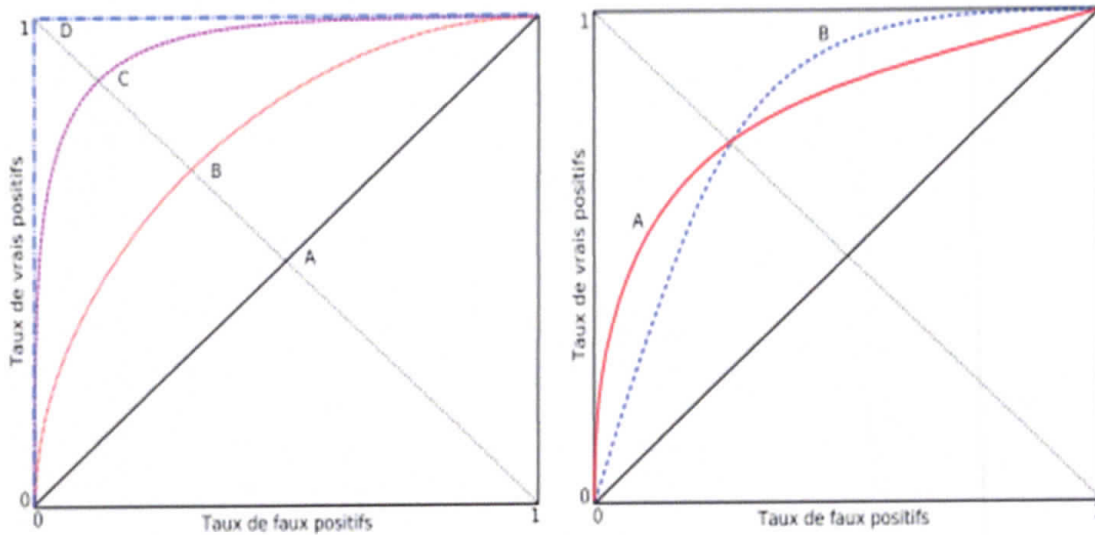


Figure 2.13 : Courbes ROC : à gauche, les courbes A, B, C et D sont respectivement associées à des classifieurs de performances croissantes. A droite, les courbes A et B ont la même aire (AUC) et la même valeur EER et sont pourtant associées à des classifieurs qui n'ont pas les mêmes qualités.

2.7 Conclusion

La classification automatique d'image en image défectueuse et image idéale est une application de reconnaissance de forme que nous avons présentée au cours de ce chapitre. L'approche utilisée est basée sur la méthode LBP qui représente une méthode récente d'extraction de caractéristiques. Dans le troisième chapitre, nous allons présenter les différents résultats de simulation obtenus.



CHAPITRE 3

RESULTATS

3.1 Introduction

Dans ce chapitre, nous allons exposer les tests effectués et les résultats obtenus pour la détection de défauts dans les tissus. Nous commençons tous d'abord par la présentation de l'algorithme général utilisé au cours de cette étude, suivi par les résultats de détection de défauts, et enfin nous exposerons les résultats de la classification. Nous avons utilisé la classification par la méthode de validation croisée et la méthode de validation simple.

3.2 Base de données

Nous avons appliqué l'algorithme de détection de défauts sur des images de tissu. Pour ce faire, nous avons collecté un ensemble d'images issues de l'internet pour former la base de données. La figure 3.1 montre l'ensemble d'image utilisé.




Figure 3. 1 : base de données utilisée

Notons ici que nous avons filmé quelques morceaux de tissu en essayant de leurs créer un défaut, mais nous n'avons pas pu les utiliser. Les images obtenues sont de très mauvaises qualités à cause de l'éclairage excessif du flash.

3.3 Algorithme proposé pour la détection de défauts

Le processus utilisé dans ce travail pour la détection de défauts est proposé par les auteurs de la référence [23]. Il est composé de deux phases : phase d'apprentissage et phase de détection.

- a. **Apprentissage** : on prend une image d'un tissu sans défaut. Au début, l'image entière sans défaut est disposé à l'opérateur *LBP* et un vecteur de caractéristique est obtenu et noté *M*.

D'un autre coté et pour augmenter l'efficacité de la méthode en termes de taux de détection de défaut, nous procédons à la division de l'image en blocs chevauchés. L'image sans défaut est alors décomposée en fenêtres de taille $w_d \times w_d$ pixels chevauchées par 2 pixels. La figure 3.2 illustre le concept de traitement par chevauchement de bloc.




Figure 3. 2 : exemple de traitement d'image par chevauchement de blocs

Le vecteur de caractéristique de chaque fenêtre est calculé par l'opérateur LBP^{riu2} , on le note S_k . Pour la prochain étape, on va calculée la similitude de S_k et M par la formule suivante :

$$L_k(S_k, M_k) = \sum_{i=0}^{P+1} \frac{(S_{ki} - M_{ki})^2}{S_{ki} + M_{ki}}, k = 1, 2, \dots, N \quad (3.1)$$

Puis on prend le maximum de L_k comme un seuil utilisé pour déterminer les fenêtres défectueuses :

$$T = \max(L_k), k=1, 2, \dots \quad (3.2)$$

b. Détection : on prend une image d'un tissu avec défaut puis divisée l'image en fenêtres non chevauchées de taille $w_d \times w_d$. Le vecteur de caractéristique de chaque fenêtre est calculé par l'opérateur *LBP* noté S_k . On calcule la similitude entre S_k et M (le vecteur de caractéristique de l'image entier sans défaut) on le note L_k . En fin, nous comparerons L_k avec le seuil T .

Si $L_k > T$, la fenêtre détectée est considérée comme la fenêtre de défauts. Sinon, la fenêtre détectée est considérée comme la fenêtre sans défaut. Le processus de détection des défauts est exprimé par le schéma général illustré par la figure 3.3 [24].

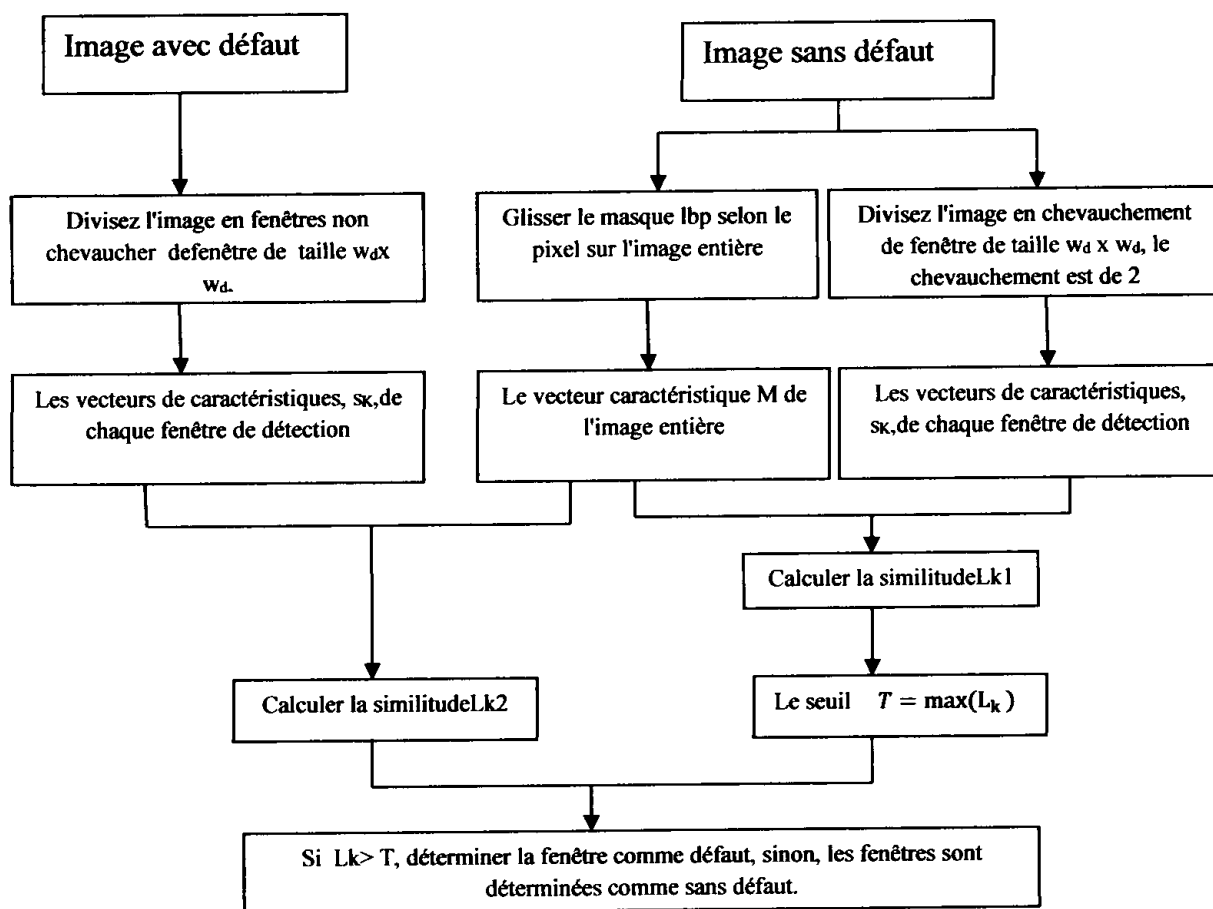


Figure 3.3 : schéma général de l'algorithme étudié

3.4 Résultats expérimentaux

Les expériences effectuées au cours de cette étude se déroulent avec MATLAB 7.9.0 (R2009b). Le processus de détection de défauts (apprentissage, détection) est appliqué sur les images de la base de données. On obtient ainsi les blocs avec défauts et ceux sans défauts, alors on leur affecte les étiquettes ou les labels correspondants (0 pour les blocs sans défauts et 1 pour les blocs avec défauts). Ces labels représentent en fait les classes des différents blocs. Les méthodes utilisées pour la détection de défauts sont LBP uniforme et invariante par rotation LPB Magnitude uniforme et invariante par rotation citées au chapitre 2 et notées respectivement par LBP^{riu2} et $LBPM^{riu2}$. Les vecteurs de caractéristiques obtenus par ces deux méthodes sont utilisés par la suite pour former la matrice d'apprentissage citée au paragraphe (2. 6. 2). Cette matrice est utilisée en phase de classification. La méthode utilisée pour tester la performance de la classification est celle de la validation croisée définie au chapitre 2. Cette dernière utilise la méthode du k plus proche voisin (KNN) pour classer les différents échantillons (vecteurs de caractéristiques des différents blocs).

3.4.1 Résultats de détection de défauts

Les différents résultats de la détection sont représentés par les figure 3.4 et 3.5 respectivement la première c'est la méthode LBP^{riu2} et la deuxième c'est la méthode $LBPM^{riu2}$:




Figure 3.4 : Les résultats des tests de certains échantillons LBP_{riu2}

- Les résultats de la détection par la méthode $LBPM^{riu2}$




Figure 3.5 : Les résultats des tests de certains échantillons $LBPM^{riu2}$

D'après les images obtenues, nous pouvons constater que l'algorithme proposé a réussi à détecter et localiser les blocs contenant les défauts avec des précisions qui varient d'une méthode à l'autre et d'une image à l'autre.

Les résultats obtenus par la méthode LBP^{riu2} sont mieux que ceux LBP^{riu2} obtenus par. Ceci est attendu du fait que LBP^{riu2} permet une meilleure description de l'image par rapport à celle de LBP^{riu2} . En fait elle utilise en plus de l'information signe de la différence entre le pixel central et ses voisins, l'information sur l'amplitude des voisins (voir chapitre 2) pour décrire les images.

3.4.2 Résultats de classification

On a appliquée deux fois la procédure de classification, la première pour chaque image et la deuxième pour la base entière. Les deux variantes de LBP ont été utilisées ; LBP^{riu2} et LBP^{riu2} . En plus, on a utilisé deux variantes de la classification croisée (K-fold et validation simple). Les différents résultats de classification obtenus sont présentés par les tableaux (3.1 jusqu'à 3.3) ainsi que les courbes ROC (les figures 3.6 jusqu'à 3.10).

3.4.2.1 La méthode LBP^{riu2}

D'après les résultats du tableau 3. 1 ainsi que les courbes ROC de la figure 3. 6, nous pouvons constater les remarques suivantes :

- la sensibilité de la méthode avec la valeur de $R=1$ et $P=8$ est maximale. Chose qui peut être expliquée par l'apparence de bloc sans défaut en phase de détection de défauts. On peut dire qu'on a une sur-détection.
- généralement, on a obtenu un faible taux d'erreur pour les trois variantes de LBP utilisés. Chose qui montre la qualité de l'algorithme utilisé. Le taux d'erreur vari d'une image à l'autre. On peut dire que pour $R=2$ et $P=16$, on obtenu les meilleurs scores.
- la validation K-fold donne de meilleurs résultats par rapport à celle de la validation simple.

Tableau 3.1 : Taux d'erreur, la sensibilité et spécificité par les deux méthodes de classification de LBP^{riu2} .

Images avec défauts	La méthode	<i>K_fold</i>			<i>Validation simple</i>		
		Taux d'erreur%	Sensibilité	Spécificité	Taux d'erreur%	Sensibilité	Spécificité
A	$LBP_{8,1}^{riu2}$	2.47	73.55	99.37	1.98	94.12	98.30
	$LBP_{16,2}^{riu2}$	2.28	58.45	99.76	1.21	100	98.77
	$LBP_{24,3}^{riu2}$	1.57	78.27	99.16	5.24	100	94.65
B	$LBP_{8,1}^{riu2}$	4.21	73.43	98.60	12.90	73.08	88.74
	$LBP_{16,2}^{riu2}$	0.23	95.30	100	0.81	88.89	99.58
	$LBP_{24,3}^{riu2}$	2.28	51.39	100	1.61	100	98.33
C	$LBP_{8,1}^{riu2}$	4.59	73.30	97.88	10.08	54.17	93.75
	$LBP_{16,2}^{riu2}$	1.24	81.85	100	4.03	92.86	96.15
	$LBP_{24,3}^{riu2}$	3.58	56.25	99.10	3.23	83.33	97.46
D	$LBP_{8,1}^{riu2}$	2.15	14.58	99.17	1.61	100	98.39
	$LBP_{16,2}^{riu2}$	0	NaN	NaN	1.25	0	100
	$LBP_{24,3}^{riu2}$	0.90	62.92	100	3.55	0	100
E	$LBP_{8,1}^{riu2}$	3.17	74.37	99.74	4.84	53.85	100
	$LBP_{16,2}^{riu2}$	1.24	100	98.7	5.24	87.50	95.00
	$LBP_{24,3}^{riu2}$	2.86	64.53	99.10	0.81	90.00	99.58
F	$LBP_{8,1}^{riu2}$	1.18	95.59	99.06	1.92	81.32	99.30
	$LBP_{16,2}^{riu2}$	1.08	50.83	99.77	1.56	22.50	99.77
	$LBP_{24,3}^{riu2}$	0.65	NaN	NaN	5.68	0	100
G	$LBP_{8,1}^{riu2}$	1.37	86.54	100	0.81	100	99.12
	$LBP_{16,2}^{riu2}$	2.55	78.33	98.69	4.03	100	95.78
	$LBP_{24,3}^{riu2}$	0.23	83.33	100	8.3	0	100

La figure 3.6 représenté les différentes courbe ROC des images défectueuses de la validation croisée par LBP^{riu2} :



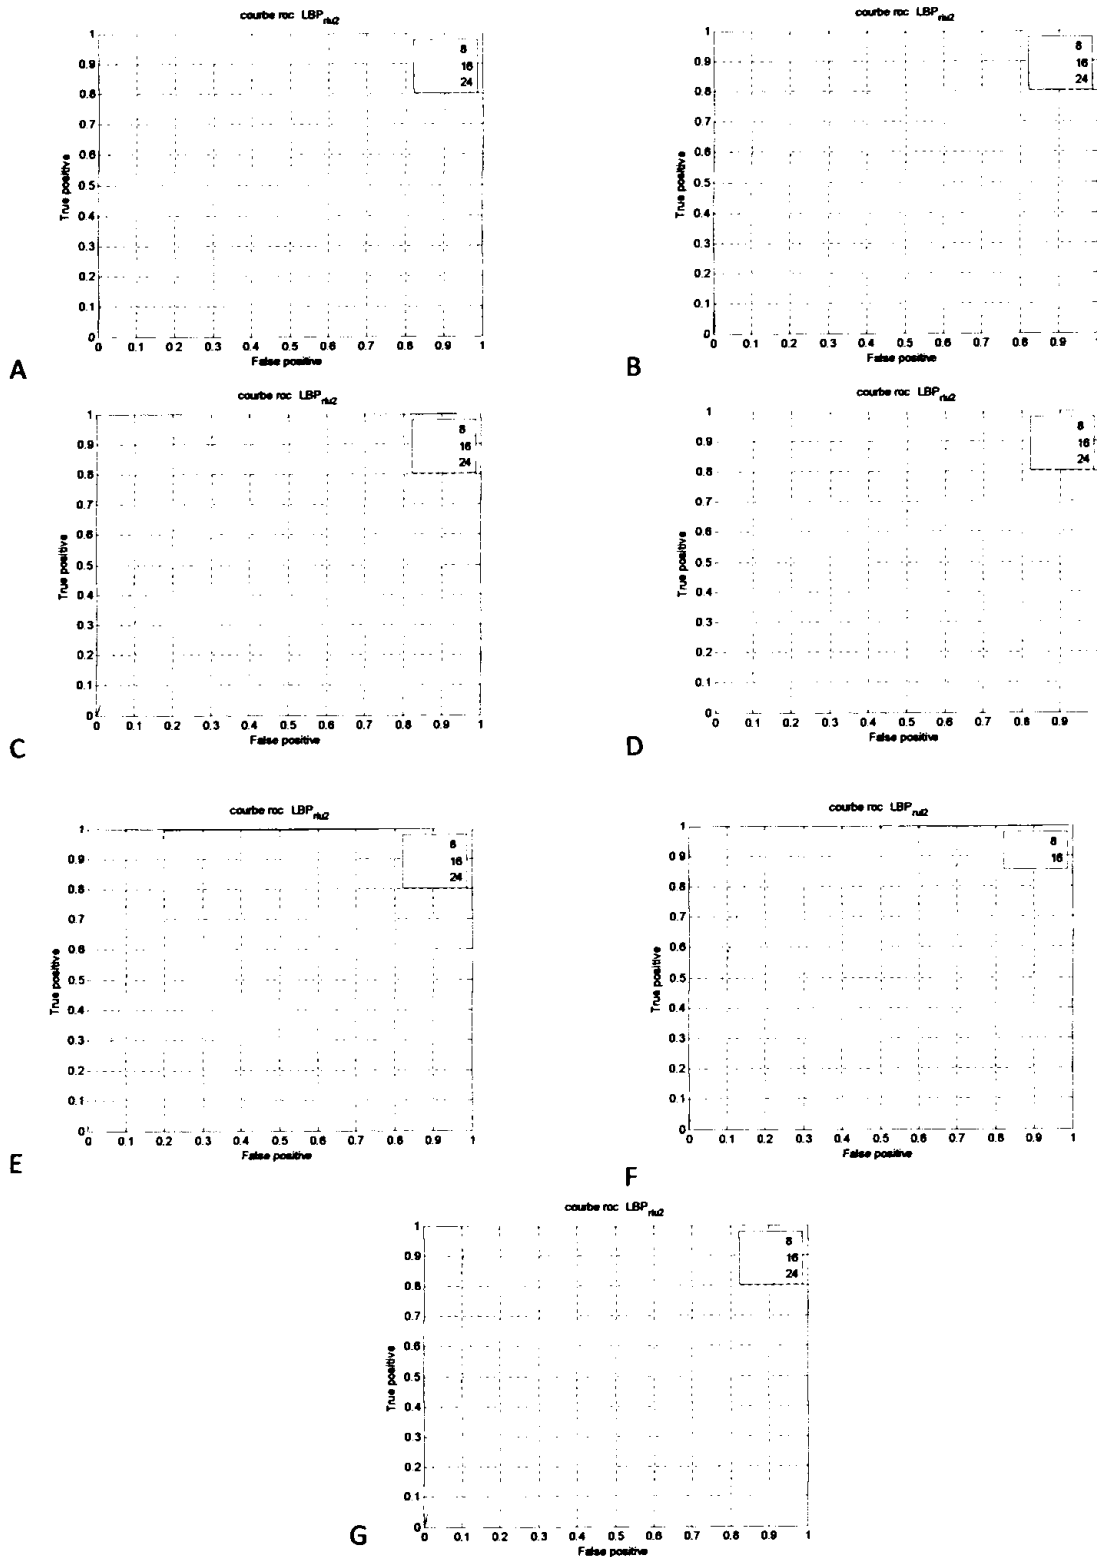


Figure 3.6 : Les différentes courbe ROC des images défectueuses de la validation croisée par LBP^{riu2}

La figure 3.7 représenté les différentes courbe ROC des images défectueuses de la validation simple par LBP^{riu2} :

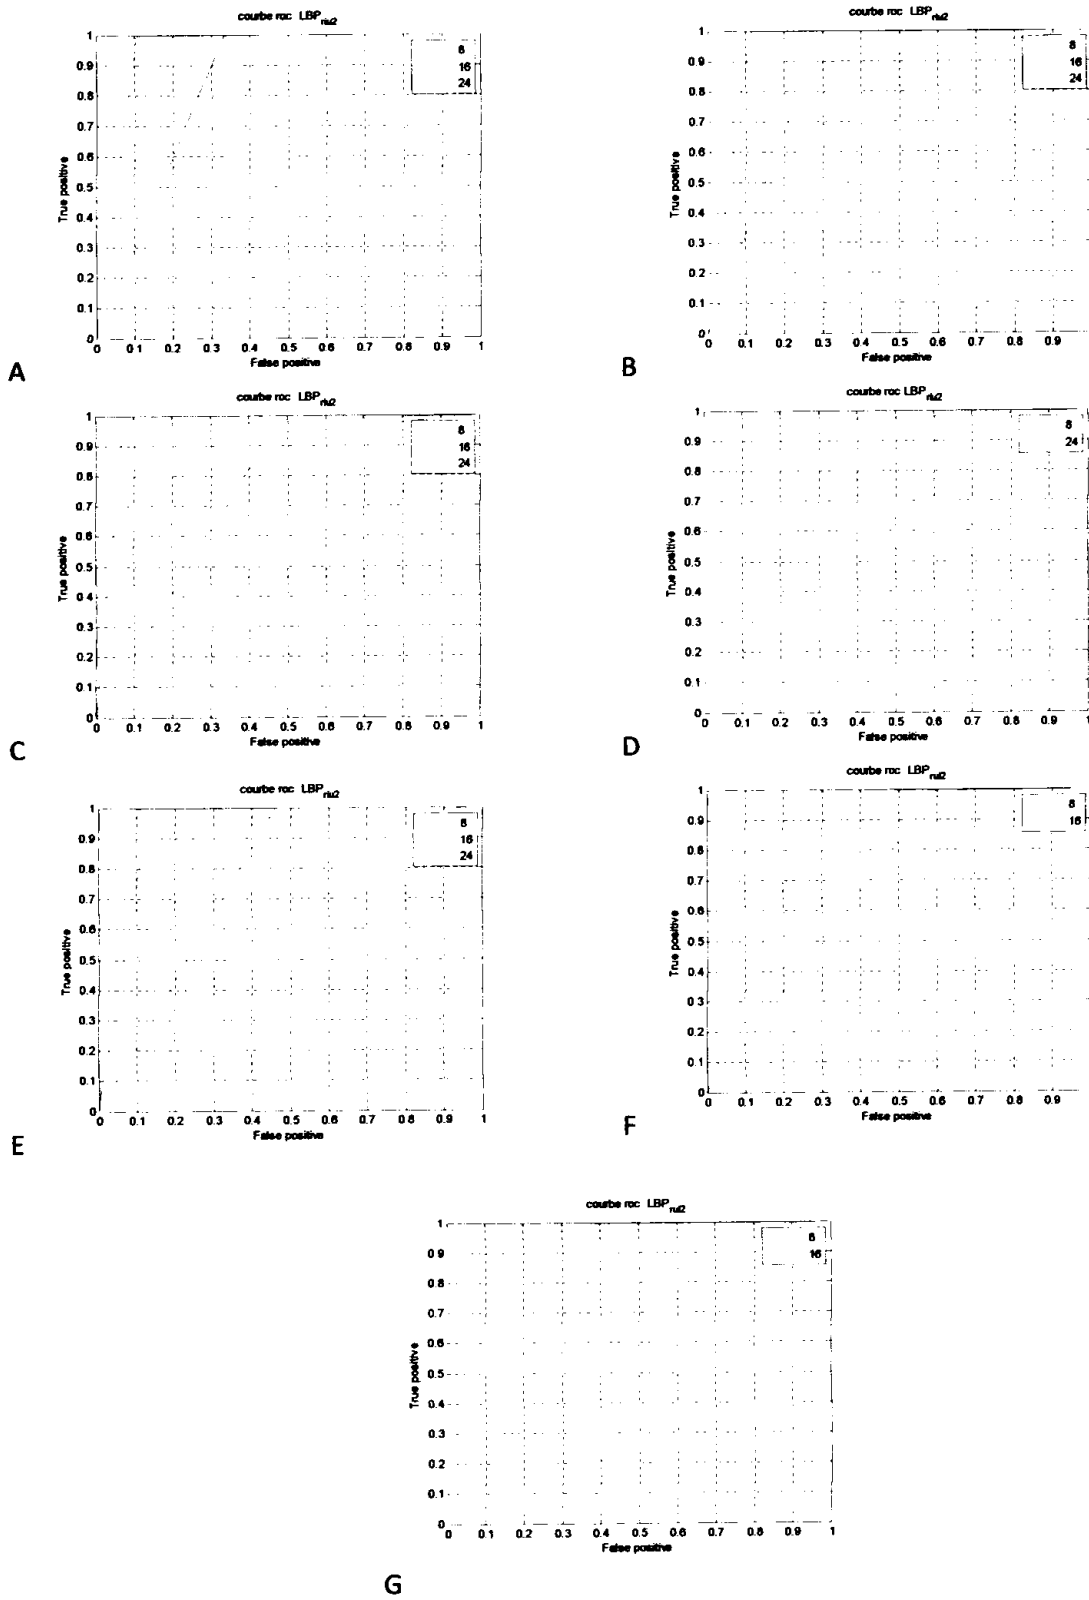


Figure 3.7 : les différentes courbe ROC des images défectueuses de la validation simple par *LBP_{riu2}*

3.4.2.2 La méthode $LBPM^{riu2}$

Les résultats du tableau 3. 2 ainsi que les courbes ROC, on peut tirer les conclusions suivantes :

- Les résultats de la validation simple sont meilleures que ceux de la validation K-fold.

Images défectueuses	La méthode	<i>K_fold</i>			<i>Validation simple</i>		
		Taux d'erreur%	Sensibilité	Spécificité	Taux d'erreur%	Sensibilité	Spécificité
A	$LBPM_{8,1}^{riu2}$	1.04	96.9	99.12	4.44	93.33	95.71
	$LBPM_{16,2}^{riu2}$	41.11	80.09	36.10	1.21	100	98.77
	$LBPM_{24,3}^{riu2}$	1.17	79.25	99.56	2.02	100	97.94
B	$LBPM_{8,1}^{riu2}$	5.47	68.33	98.01	6.75	39.29	100
	$LBPM_{16,2}^{riu2}$	0.42	91.13	100	7.66	100	92.05
	$LBPM_{24,3}^{riu2}$	2.90	38.19	100	3.63	100	96.25
C	$LBPM_{8,1}^{riu2}$	5.47	60.71	98.68	5.95	61.54	97.79
	$LBPM_{16,2}^{riu2}$	0.52	92.52	100	5.24	85.71	95.3
	$LBPM_{24,3}^{riu2}$	2.70	60.42	99.76	4.44	100	95.34
D	$LBPM_{8,1}^{riu2}$	1.47	87.07	100	1.98	100	98.0
	$LBPM_{16,2}^{riu2}$	1.56	73.61	99.66	2.25	0	100
	$LBPM_{24,3}^{riu2}$	3.02	51.19	99.45	0	100	100
E	$LBPM_{8,1}^{riu2}$	2.34	80.00	100	7.14	35.71	100
	$LBPM_{16,2}^{riu2}$	1.46	90.97	98.91	4.03	75.00	96.67
	$LBPM_{24,3}^{riu2}$	2.38	70.60	99.11	2.02	100	97.9
F	$LBPM_{8,1}^{riu2}$	2.73	63.07	99.79	20.24	100	78.48
	$LBPM_{16,2}^{riu2}$	0.85	64.1	99.90	6.45	100	93.52
	$LBPM_{24,3}^{riu2}$	1.23	0	100	3.25	0	100
G	$LBPM_{8,1}^{riu2}$	0.78	92.31	100	3.78	83.33	98.68
	$LBPM_{16,2}^{riu2}$	2.79	72.56	98.79	2.36	100	96.20
	$LBPM_{24,3}^{riu2}$	0.81	41.67	100	2.25	0	100

Tableau 3.2 : Taux d'erreur, la sensibilité et spécificité par les deux méthodes de classification par $LBPM^{riu2}$

La figure 3.8 illustre les différentes courbe ROC des images défectueuses de la validation croisée par $LBPM^{riu2}$:

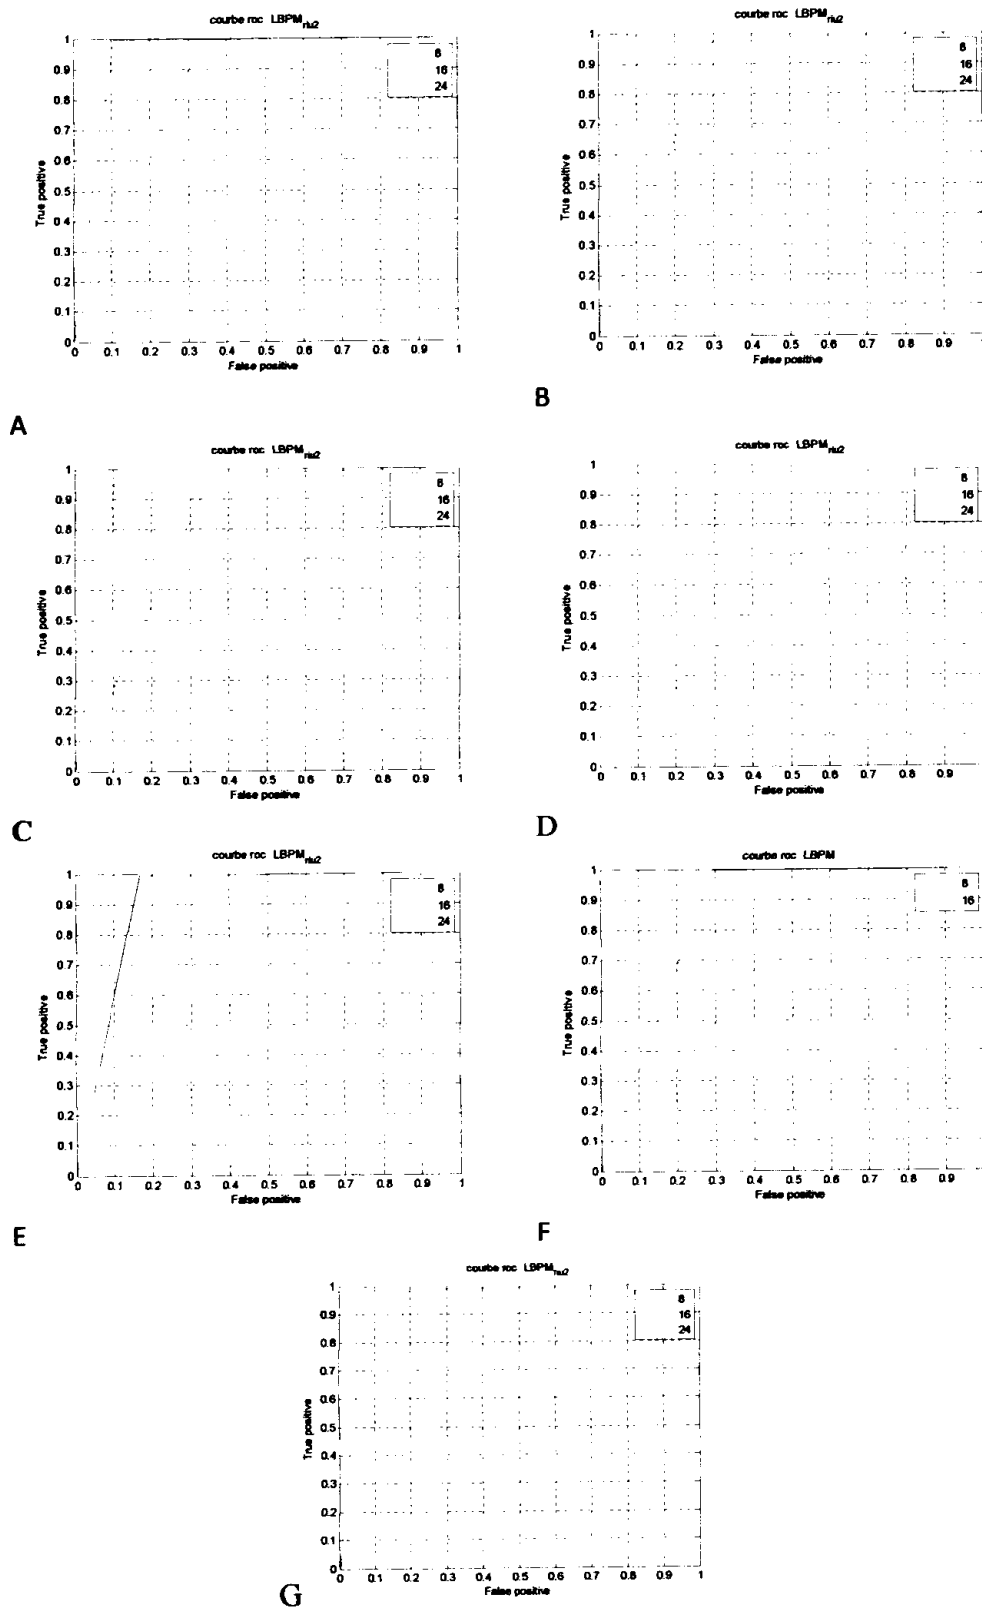


Figure 3.8 :courbe ROC des images défectueuses de la validation croisée par $LBPM^{riu2}$

La figure 3.9 illustre les différentes courbe ROC des images défectueuses de la validation simple par $LBPM^{riu2}$.

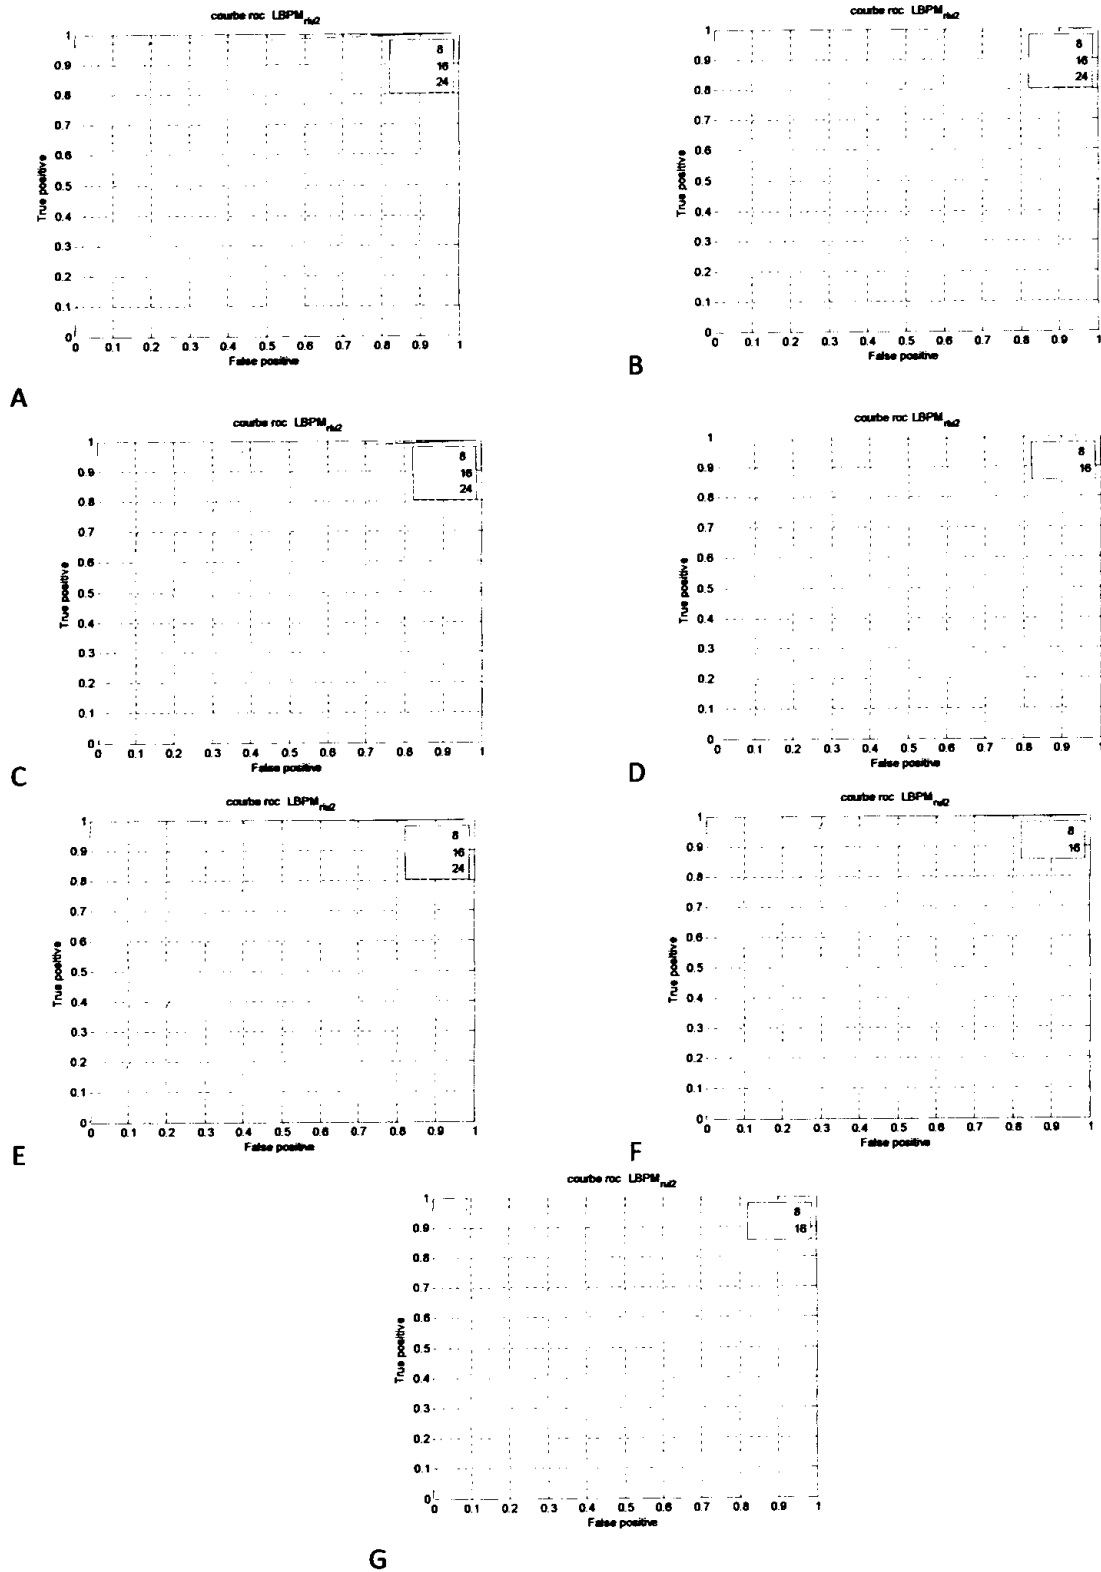


Figure 3.9 : les courbes ROC des images défectueuses de la validation simple par $LBPM^{riu2}$

3.4.2.3 Classification de la base de données

Dans le tableau, on présente les résultats pour toutes les images de la base de données. On a utilisé la validation croisée (k-fold) et la validation simple pour les différentes méthodes de LBP.

		<i>K_fold</i>			<i>Validation simple</i>		
La méthode		Taux d'erreur%	Sensibilité	Spécificité	Taux d'erreur%	Sensibilité	Spécificité
base de données	$LBP_{8,1}^{riu2}$	2.89	78.27	98.88	10.71	63.16	90.16
	$LBP_{16,2}^{riu2}$	0.85	84.62	99.97	6.89	97.18	92.94
	$LBP_{24,3}^{riu2}$	3.05	58.67	98.28	12.95	74.00	88.25
	$LBPM_{8,1}^{riu2}$	2.36	78.36	99.45	2.37	80.35	99.27
	$LBPM_{16,2}^{riu2}$	1.44	82.27	99.26	1.42	74.28	99.65
	$LBPM_{24,3}^{riu2}$	2.91	48.27	98.79	31.05	78.95	68.62

Tableau 3.3 : taux d'erreur, Sensibilité et Spécificité de la base de données pour les différentes méthodes classification

La figure 3.10 représente les différentes courbes ROC de la base de données par les deux méthodes de la validation.

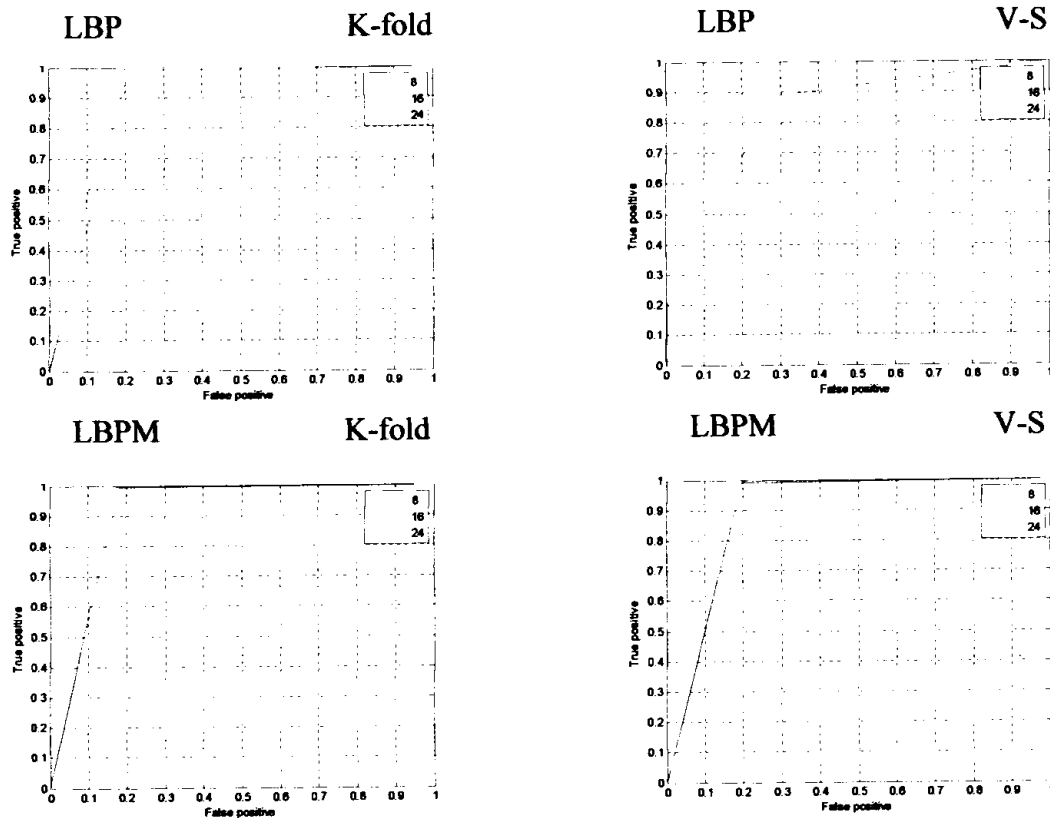


Figure 3.10 les différentes courbes ROC de la base de données par les deux méthodes de la validation

3.4.3 Discussion

D'après les résultats expérimentaux obtenus, nous pouvons conclure les points suivants :

- Le meilleur taux de classification est obtenu par la méthode $LBPM^{riu2}$ en utilisant la base de données globale avec un taux moyen d'erreur de 2.23%, et des valeurs de sensibilité et de spécificité élevées.
- Les résultats obtenus sont très proches de ceux présentés dans l'article [24].
- Le taux d'erreur est très sensible à la nature de la texture présente dans le tissu. Pour les tissus en laine, on a obtenu les mauvais résultats de classification.
- L'utilisation des caractéristiques LBP pour les deux paramètres P et R a permis de voir les variations des taux de classification par rapport aux performances individuelles de chacune des deux méthodes LBP. Les expériences ont mis l'accent sur l'importance de l'information du voisinage des pixels pour modéliser des images texturées réelles.

- les variantes de LBP (uniforme et invariante par rotation) ont permis la réduction des nombres de caractéristiques (les formes uniformes) utilisées pour modéliser le voisinage des pixels. Cette réduction en même temps peut être considérée comme un avantage du point de vue temps d'exécution et présente un inconvénient du fait qu'elle peut influencer sur les performances de l'algorithme étudié. Cette réduction va rendre la description insuffisante dans les cas des changements de rotation, d'échelle et d'orientation.

3.5 Conclusion

Dans ce chapitre nous avons présenté les résultats de la classification des images texturées en utilisant les caractéristiques obtenues par les méthodes LBP. L'objectif d'utiliser la classification est de vérifier la performance des descripteurs de texture choisis et de trouver les classes appropriées aux images fournies au système. Afin de pouvoir évaluer notre méthode, nous avons utilisé une base de données constituée des images de différentes textures pour extraire les descripteurs LBP et nous avons effectué la classification par validation simple et validation croisée.

Conclusion générale

Le sujet de la reconnaissance de forme et la vision industrielle est très motivant, en raison de son importance pratique et théorique, il reste toujours un centre important de recherche. L'élaboration d'un outil automatisé de détection de défauts est devenue une nécessité pour l'industrie de textile dans la reconnaissance de forme et l'industrie. Cette détection est déterminée par des méthodes efficaces comme les méthodes LBP qui sont utilisés dans ce mémoire. Tout d'abord, nous avons commencé par le premier chapitre qui expose les différentes notions liées à la vision industrielle, les différentes applications, ainsi que les composants de base d'un tel système. Dans le deuxième chapitre nous avons présenté un état de l'art sur les techniques de reconnaissance de forme. L'application de reconnaissance de forme visée dans cette étude est la détection de défaut de texture de tissu. Nous avons utilisé un algorithme proposé dans la littérature pour la détection de défauts. L'application de cet algorithme a fait l'objet du dernier chapitre. On a pu montrer l'efficacité de ce système pour l'inspection automatique en détection de défauts. La Classification par apprentissage supervisé a permis d'obtenir des taux très élevés d'erreur. Les résultats obtenus sont très motivants et ouvre de larges perspectives dans le domaine de la détection de défauts dans les tissus.

Bibliographie

- [1] N. VANDENBROUCKE. Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'images de football". Thèse de doctorat, Université des Sciences et Technologies de Lille, décembre 2000.
- [2] Chich-chih Wong, Charles Thorp, Sebastien Thrun, Online simultaneous localisation and mapping with detection and tracking of moving objects: theory and results from a ground vehicle in crowded urban areas.
- [3] Howard Andrew, Maja J. Matoric, Gawave S. Sukhatme, Putting the 'I' in 'TEAM': Aego-Centric approach to cooperative localization.
- [4] Masahiro Tomon, Shin'chi Yuta, Object-based localization and mapping using loop constraints and geometric prior knowledge.
- [5] S. Piotin. Vers un Outil C.A.O. Pour la Maille. THESE de Doctorat de l'Université de Reims Champagne-Ardenne (URCA), Ecole Doctorale Sciences, Technologies et Santé, France 2009.
- [6] R. Jadav, K. Thakkar et V. Patel. Fabric Defects and Point Grading System.
<http://www.scribd.com/doc/52291149/FABRIC-DEFECTS-AND-POINTGRADING-SYSTEM>. Dernière consultation : Février 2012.
- [7] <http://www.bienacheterbienrenover.fr/les-fiches-qualite/amenagement-interieur/eclairage/les-appareils-declairage.html>.
- [8] A. Kumar. Computer-Vision-Based Fabric Defect Detection: A Survey. IEEE Trans. on Industrial Electronics, Vol. 55, No. 1, pp. 348-363, 2008.



- [9] Due Trier et al, 1991, Due Trier, O., Jain, A., and Taxt, T. (1996). Feature Extraction methods for character recognition-a survey. *Pattern recognition*, 29(4):641–662. (cf. 16, 17, and 18).
- [10] Cocquerez, J.-P. and Philipp, S. (1995). *Analyse d'images : filtrage et segmentation*. Masson : enseignement de la physique.
- [11] Srinivasan, G. and Shobha, G. (2008). Statistical texture analysis. In *Proceedings of World academy of science, engineering and technology*, volume 36, pages 1264–1269. (cf. 18).
- [12] Mikolajczyk, K. and Schmid, C. (2005), A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 27(10) :1615–1630. (cf. 16, 18, 21, and 22).
- [13] Zhang, J., Marszalek, M., Lazebnik, S., and Schmid, C. (2007). Local features and kernels for classification of texture and object categories: A comprehensive study. *International Journal of Computer Vision*, 73(2): 213–238. (cf. 18).
- [14] Mikolajczyk, K. and Schmid, C. (2004). Scale and affine invariant interest point detectors. *Int. J. Comput. Vision*, 60(1): 63–86. (cf. 21).
- [15] Bay, H., Tuytelaars, T., and Van Gool, L. (2006). Surf: Speeded up robust Features. *Computer Vision–ECCV 2006*, pages 404–417. (cf. 18, 21, 22, and 24).
- [16] OJALA T, Pietikainen M and Harwood D (1996) A comparative study of texture measures with classification based on featured distribution. *Pattern Recognition*, 29(1):55–59. (cf. 21 and 24).
- [17] Ojala et al (2000). Gray scale and rotation invariant texture classification with local binary patterns. *Computer Vision-ECCV 2000*. pages 404–420. (cf. 21 and 24.)
- [18] Hanane Rami. *Contribution au développement de descripteurs LBP pour le suivi d'objet en mouvement*. 30 Avril 2016 .pages :6. 68-72.
- [19] OJALA and al, 2002. Multi resolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 24(7) :971–987. (cf. 48).



- [20] Pietikainen M., Hadid, A., Zhao, G., Ahonen, T. (2011). Description of Interest Regions. In *Computer Vision Using Local Binary Patterns* (pp. 81-88).Springer London.
- [21] M.W.Ashour,M.F.Hussin,and K.M.Maher,"Supervised texture classification us Using serval features extraction techniques based on ANN", in *computer Systems and Applications,AICCSA 2008*.
- [22] T. Fawcett. ROC graphs: notes and practical considerations for researchers. Technical Report HPL-2003-4, HP Laboratories, Palo Alto, USA, 2004.
- [23] Marouene Mejri *Modélisation Statistique de Transformées Multi résolutions et Application à la Détection de Défauts de Textures*. Gatineau, Québec, Canada mai 2013.
- [24] Pengfei Li, Xuan Lin, Junfeng Jing, and Lei Zhang, *Defect Detection in Fabrics Using Local Binary Patterns*.