



**HAL**  
open science

# Contribution au Système d'Information d'un Produit “ Bois ” : appariement automatique de pièces de bois selon des critères de couleur et de texture

Emmanuel Schmitt

## ► To cite this version:

Emmanuel Schmitt. Contribution au Système d'Information d'un Produit “ Bois ” : appariement automatique de pièces de bois selon des critères de couleur et de texture. Sciences de l'ingénieur [physics]. Université Henri Poincaré - Nancy 1, 2007. Français. NNT : 2007NAN10079 . tel-00170106v1

**HAL Id: tel-00170106**

**<https://hal.univ-lorraine.fr/tel-00170106v1>**

Submitted on 21 May 2021 (v1), last revised 6 Sep 2007 (v2)

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



## AVERTISSEMENT

Ce document est le fruit d'un long travail approuvé par le jury de soutenance et mis à disposition de l'ensemble de la communauté universitaire élargie.

Il est soumis à la propriété intellectuelle de l'auteur. Ceci implique une obligation de citation et de référencement lors de l'utilisation de ce document.

D'autre part, toute contrefaçon, plagiat, reproduction illicite encourt une poursuite pénale.

Contact : [ddoc-theses-contact@univ-lorraine.fr](mailto:ddoc-theses-contact@univ-lorraine.fr)

## LIENS

Code de la Propriété Intellectuelle. articles L 122. 4

Code de la Propriété Intellectuelle. articles L 335.2- L 335.10

[http://www.cfcopies.com/V2/leg/leg\\_droi.php](http://www.cfcopies.com/V2/leg/leg_droi.php)

<http://www.culture.gouv.fr/culture/infos-pratiques/droits/protection.htm>

**U.F.R. Sciences et Techniques en Mathématiques, Informatique et Automatique**  
**Ecole Doctorale IAEM Lorraine**  
**Département de Formation Doctorale « Automatique et Production automatisée »**

## Thèse

Présentée pour l'obtention du titre de

**Docteur de l'Université Henri Poincaré, Nancy - I**

en Automatique, Traitement du Signal et Génie Informatique

Par **Emmanuel SCHMITT**

### **Contribution au Système d'Information d'un Produit « Bois ». Appariement automatique de pièces de bois selon des critères de couleur et de texture.**

Soutenue publiquement le 28 septembre 2007

Membres du jury :

Président :	Mme. Sylvie PHILIPP-FOLIGUET (Prof.)	ENSEA, ETIS
Rapporteurs :	Melle. Sylvie GALICHET (Prof.)	Université de Savoie, LISTIC
	M. Carl FRELICOT (Prof.)	Université de La Rochelle, L3I
Encadrants :	M. Patrick CHARPENTIER (Prof.)	Université Henri Poincaré, CRAN/SYMPA
	M. Vincent BOMBARDIER (MdC)	Université Henri Poincaré, CRAN/SYMPA
Examineurs :	Hugues GARNIER (Prof.)	Université Henri Poincaré, CRAN/IRIS
	M. Raphaël VOGRIG (Dr.)	Société LuxScan Technologies



A mes parents, mon frère, ma famille et tous mes proches...

## Remerciements

Les travaux développés dans ce mémoire ont été effectués au Centre de Recherche en Automatique de Nancy (CRAN) de l'Université Henri Poincaré de Nancy en partenariat avec la société luxembourgeoise LuxScan Technologies.

J'adresse mes sincères remerciements à Madame Sylvie Philipp-Foliguet, Professeur à l'Ecole Nationale Supérieure de l'Electronique et de ses Applications (ENSEA), qui m'a fait l'honneur de présider le jury de thèse.

J'exprime ma profonde reconnaissance à Mademoiselle Sylvie Galichet, Professeur à l'Université de Savoie, et à Monsieur Carl Frélicot, Professeur à l'Université de La Rochelle, pour l'intérêt qu'ils ont bien voulu porter à ce travail en acceptant la lourde tâche de rapporteurs. Je remercie également Monsieur Hugues Garnier, Professeur à l'Université Henri Poincaré de Nancy, pour l'intérêt qu'il a porté à mes travaux en tant qu'examineur.

Je tiens aussi à remercier de la plus sincère des manières Monsieur Patrick Charpentier, Professeur à l'Ecole Nationale Supérieure des Technologies de Industries du Bois (ENSTIB) de l'Université Henri Poincaré de Nancy, et Monsieur Vincent Bombardier, Maître de Conférences à l'Ecole Supérieure d'Informatique et Applications de Lorraine (ESIAL) de l'Université Henri Poincaré de Nancy, pour m'avoir encadré et pour toute la confiance qu'ils ont su me donner. Leurs expériences, leurs conseils et leurs encouragements m'ont permis de mener à bien mes recherches.

Mes remerciements sont également adressés à Monsieur Raphaël Vogrig, gérant de la société LuxScan Technologies et Docteur de l'Université Henri Poincaré de Nancy, qui a cofinancé ces travaux. Par la même occasion, je remercie tous les employés de cette société qui ont rendu plus facile mon intégration au sein de l'équipe de travail.

Je remercie également l'Etat luxembourgeois, et plus particulièrement le Ministère de la Culture, de l'Enseignement Supérieur et de la Recherche pour m'avoir attribué une Bourse-Formation-Recherche (BFR) pour mener à bien ces travaux.

Je tiens aussi à remercier l'ensemble du personnel du CRAN et plus particulièrement les gens du groupe thématique SYMPA (Systèmes de Production Ambiants) et de l'Equipe de Recherche Technologique Tracilog (ERT Tracilog). Une pensée spéciale est dédiée à Monsieur Cyril Mazaud, également doctorant au CRAN en partenariat avec la société LuxScan Technologies avec qui nous avons toujours eu des discussions très enrichissantes. De la même manière, je remercie l'équipe du département Génie Electrique et Informatique Industrielle (GEII) de l'Institut Universitaire Technologique (IUT) de Saint-Dié des Vosges qui a su m'accueillir pour faciliter mes interventions en tant qu'Attaché Temporaire d'Enseignement et de Recherche (ATER).

Pour finir, cette thèse n'aurait jamais abouti sans le soutien de ma famille et de mes proches qui m'ont toujours encouragé à faire du mieux possible. Je remercie particulièrement Sandrine pour ces longues soirées passées à discuter sur Internet, ainsi que Dalila et Stéphanie mes secrétaires préférées. Une pensée toute particulière va à mon amie Blandine qui nous a quittés beaucoup trop tôt, et pour qui j'avais le plus grand respect. Et pour finir, je remercie également mes amis Rémi, Guillaume, Stéphane, Soulivanh, et tous ceux que j'oublie de citer, pour les bons moments partagés durant ces années de thèse.

## Tables des matières

<b>REMERCIEMENTS .....</b>	<b>- 3 -</b>
<b>TABLES DES MATIERES.....</b>	<b>- 4 -</b>
<b>LISTE DES FIGURES .....</b>	<b>- 7 -</b>
<b>LISTE DES TABLEAUX.....</b>	<b>- 11 -</b>
<b>1. INTRODUCTION.....</b>	<b>- 14 -</b>
<b>2. CONTROLE QUALITE PAR SYSTEME DE VISION ET RECONNAISSANCE DE FORMES DANS LES INDUSTRIES DU BOIS.....</b>	<b>- 26 -</b>
<b>2.1. CONTROLE QUALITE .....</b>	<b>- 26 -</b>
<b>2.1.1. <i>La reconnaissance des singularités</i> .....</b>	<b>- 28 -</b>
<b>2.1.2. <i>La reconnaissance des couleurs et du grain</i>.....</b>	<b>- 34 -</b>
<b>2.1.3. <i>Le besoin de systèmes industriels de vision</i> .....</b>	<b>- 36 -</b>
<b>2.2. INSPECTION PAR RECONNAISSANCE DE FORMES.....</b>	<b>- 38 -</b>
<b>2.2.1. <i>L'inspection visuelle automatisée</i> .....</b>	<b>- 38 -</b>
<b>2.2.2. <i>Les algorithmes de classification</i> .....</b>	<b>- 44 -</b>
<b>2.2.3. <i>La couleur dans un processus industriel « bois »</i> .....</b>	<b>- 47 -</b>
<b>2.3. ARCHITECTURES DES CAPTEURS DE VISION.....</b>	<b>- 53 -</b>
<b>2.3.1. <i>Capteurs intelligents</i>.....</b>	<b>- 53 -</b>

---

2.3.2.	<i>Capteurs symboliques</i> .....	- 55 -
2.3.3.	<i>Capteurs flous</i> .....	- 58 -
2.4.	CONCLUSION .....	- 60 -
<b>3.</b>	<b>DU CAPTEUR AUX MESURES FONCTIONNELLES .....</b>	<b>- 64 -</b>
3.1.	LA MESURE .....	- 65 -
3.1.1.	<i>Présentation du système d'acquisition</i> .....	- 66 -
3.1.2.	<i>Correction des perturbations lumineuses</i> .....	- 71 -
3.1.3.	<i>Correction des données fournies par le capteur</i> .....	- 79 -
3.2.	MODELISATION DE LA MESURE – DEFINITION DU VECTEUR CARACTERISTIQUE .....	- 85 -
3.2.1.	<i>Configuration fonctionnelle : choix du repère colorimétrique</i> .....	- 85 -
3.2.2.	<i>Spécification des zones d'intérêts (ROI)</i> .....	- 91 -
3.2.3.	<i>Aspect statistique de la couleur</i> .....	- 92 -
3.2.4.	<i>Répartition spatiale de la couleur</i> .....	- 99 -
3.3.	CONCLUSION .....	- 105 -
<b>4.</b>	<b>DES MESURES FONCTIONNELLES A LA DECISION : VERS UN CAPTEUR FLOU .....</b>	<b>- 110 -</b>
4.1.	SYSTEMES A BASE DE REGLES LINGUISTIQUES FLOUES .....	- 112 -
4.1.1.	<i>Imprécisions et incertitudes des données</i> .....	- 112 -
4.1.2.	<i>Variables linguistiques – propositions floues – règles floues</i> .....	- 117 -
4.2.	CLASSIFICATEUR A RAISONNEMENT FLOU .....	- 121 -
4.2.1.	<i>Principe de la méthode</i> .....	- 122 -
4.2.2.	<i>Fuzzification des attributs du vecteur caractéristique</i> .....	- 124 -
4.2.3.	<i>Génération des règles linguistiques</i> .....	- 137 -
4.2.4.	<i>Résultats comparatifs de classification</i> .....	- 141 -
4.3.	UTILISATION CONJOINTE DE DEUX CAPTEURS FLOUS.....	- 147 -
4.3.1.	<i>Choix de l'opérateur de fusion</i> .....	- 149 -
4.3.2.	<i>Résultats comparatifs de classification rive/rive</i> .....	- 152 -
4.4.	CONCLUSION .....	- 155 -
<b>5.</b>	<b>CONCLUSION ET PERSPECTIVES.....</b>	<b>- 158 -</b>
5.1.	CONCLUSION .....	- 158 -
5.2.	PERSPECTIVES.....	- 163 -
<b>ANNEXES A.....</b>		<b>- 166 -</b>
ANNEXE A.1 :	L'ŒIL HUMAIN ET LA PERCEPTION DES COULEURS .....	- 166 -
ANNEXE A.2 :	RECOMPOSITION DES IMAGES COULEURS.....	- 170 -

---

<b>ANNEXES B.....</b>	<b>- 173 -</b>
<b>ANNEXE B.1 : ALGORITHME D'ISHIBUCHI ET AL. ....</b>	<b>- 173 -</b>
<b>ANNEXE B.2 : VALIDATION DES CHOIX DE PARAMETRES PERTINENTS A PARTIR D'UN CLASSIFICATEUR     KPPV .....</b>	<b>- 177 -</b>
<b>ANNEXE B.3 : VALIDATION DE LA METHODE DE FUZZIFICATION AUTOMATIQUE POUR UN AUTRE DOMAINE     D'APPLICATIONS .....</b>	<b>- 178 -</b>
<b>ANNEXE B.4 : ETUDES DES CONSTANTES D'APPRENTISSAGE DE L'ALGORITHME D'ISHIBUCHI ET AL. ..</b>	<b>- 179 -</b>
<b>REFERENCES BIBLIOGRAPHIQUES.....</b>	<b>- 186 -</b>

## Liste des figures

FIGURE 1.1 : REPRESENTATION SCHEMATIQUE DES PRODUITS FINAUX DU CAS APPLICATIF 1 .....	- 16 -
FIGURE 1.2 : PHOTOGRAPHIE DE PRODUITS FINAUX DU CAS APPLICATIF 1 .....	- 16 -
FIGURE 1.3 : REPRESENTATION SCHEMATIQUE DES PRODUITS FINAUX DU CAS APPLICATIF 2 .....	- 17 -
FIGURE 1.4 : PHOTOGRAPHIE DE PANNEAUX DU CAS APPLICATIF 2 .....	- 17 -
FIGURE 1.5 : PHOTOGRAPHIES DE PLACAGES DE BOIS PROVENANT DU CAS APPLICATIF 3 .....	- 18 -
FIGURE 1.6 : POSITIONNEMENT DE LA FONCTION D'OBSERVATION DANS LA BOUCLE DE CAUSALITE CIRCULAIRE EN PRODUCTIQUE [PERE-00] .....	- 19 -
FIGURE 1.7 : DECOMPOSITION DU SYSTEME D'OBSERVATION .....	- 20 -
FIGURE 1.8 : SCHEMA DE VALIDATION PAR LA FINALITE.....	- 20 -
FIGURE 2.1 : ILLUSTRATIONS DE QUELQUES DEFORMATIONS DU BOIS .....	- 27 -
FIGURE 2.2 : TAXINOMIE DES CONTROLES APPLIQUES AU BOIS ET POSITIONNEMENT DE L'ETUDE .....	- 28 -
FIGURE 2.3 : SINGULARITES DU BOIS .....	- 30 -
FIGURE 2.4 : ARCHITECTURE ENVISAGE DE TRI D'UN PRODUIT BOIS SELON UN MECANISME AUTOMATISE .....	- 31 -
FIGURE 2.5 : EFFET SCATTER – DIFFUSION DE LA SOURCE LASER DANS LE BOIS EN FONCTION DE SA DENSITE OU DU SENS DU FIL .....	- 33 -
FIGURE 2.6 : ORIGINE DES TEXTURES DU BOIS .....	- 36 -
FIGURE 2.7 : INFLUENCE DE L'ENVIRONNEMENT D'UNE COULEUR SUR SA PERCEPTION PAR L'ŒIL HUMAIN .....	- 37 -
FIGURE 2.8 : POSITIONNEMENT DES INSPECTIONS INTERVENANT SUR UNE CHAINE DE PRODUCTION .....	- 39 -
FIGURE 2.9 : CHAINE DE TRAITEMENT DE L'IMAGE CONTENUE DANS UN SYSTEME DE VISION ARTIFICIELLE .....	- 40 -
FIGURE 2.10 : PRINCIPE DE RECONNAISSANCE DE FORMES .....	- 42 -
FIGURE 2.11 : LES APPROCHES DE TRAITEMENTS HAUT-NIVEAU.....	- 45 -
FIGURE 2.12 : FONCTIONNALITES D'UN CAPTEUR INTELLIGENT DECRIVANT LES BESOINS UTILISATEURS.....	- 54 -
FIGURE 2.13 : REPRESENTATION D'UN CAPTEUR SYMBOLIQUE.....	- 56 -
FIGURE 2.14 : IDENTIFICATION DE LA BASE DE CONNAISSANCE D'UN CAPTEUR SYMBOLIQUE PAR RAPPORT A SON CONTEXTE D'UTILISATION .....	- 56 -
FIGURE 2.15 : UNIVERS DE DISCOURS ASSOCIES AUX COMPOSANTES COLORIMETRIQUES ROUGE (R), VERTE (V) ET BLEUE (B).....	- 57 -

## LISTE DES FIGURES

---

FIGURE 2.16 : STRUCTURE D'UN CAPTEUR FLOU.....	- 59 -
FIGURE 2.17 : TRADUCTION FLOUE ET INTERPRETATION FLOUE DE LA TEMPERATURE.....	- 60 -
FIGURE 2.18 : REPRESENTATION DU LIEN ENTRE L'UNIVERS DE DISCOURS ET L'UNIVERS LEXICAL.....	- 61 -
FIGURE 3.1 : RAPPROCHEMENT DE LA CHAINE DE TRAITEMENT D'IMAGES AU FONCTIONNEMENT D'UN CAPTEUR INTELLIGENT.....	- 65 -
FIGURE 3.2 : LIGNES DE PRODUCTION INTEGRANT LES SYSTEMES DE VISION (A- LIGNE DE TRONÇONNAGE / B- LIGNE DE TRI).....	- 66 -
FIGURE 3.3 : PHOTOGRAPHIE DU SYSTEME D'ACQUISITION UTILISE POUR LE CAS APPLICATIF 2.....	- 67 -
FIGURE 3.4 : REPARTITION DES PHOTOSITES SUR LA CAMERA COULEUR UTILISEE.....	- 68 -
FIGURE 3.5 : IMAGES COULEURS OBTENUES A PARTIR DU SYSTEME D'ACQUISITION (A- CERISIER / B- CHENE / C- ERABLE).....	- 69 -
FIGURE 3.6 : PROFILS MOYENS DES COMPOSANTES R, V ET B AVANT (A) ET APRES (B) LA REALISATION D'UNE BALANCE DE BLANC.....	- 70 -
FIGURE 3.7 : SPECTRES D'EMISSION DES ECLAIRAGES NEONS (A) ET DIODES (B).....	- 71 -
FIGURE 3.8 : SCHEMA (VUE DE DESSUS) ET PHOTOGRAPHIES DU SYSTEME DE CONVOYAGE UTILISE DANS LE CAS APPLICATIF 1.....	- 72 -
FIGURE 3.9 : INTENSITE LUMINEUSE SUR UNE PIECE DE BOIS EN FONCTION DE LA POSITION DE LA LIGNE D'ACQUISITION.....	- 73 -
FIGURE 3.10 : VARIATION DE LA MOYENNE DES COMPOSANTES R, V ET B EN FONCTION D'UN ECART DE POSITION AUTOUR DU POINT DE REFERENCE.....	- 74 -
FIGURE 3.11 : RECONSTRUCTION DES NIVEAUX COLORIMETRIQUES A PARTIR DES MODELES LINEAIRES.....	- 74 -
FIGURE 3.12 : EVOLUTION DE L'INTENSITE LUMINEUSE AU COURS DU TEMPS POUR UN ECLAIRAGE FLUORESCENT.....	- 76 -
FIGURE 3.13 : EVOLUTION DE L'INTENSITE LUMINEUSE AU COURS DU TEMPS POUR UN ECLAIRAGE COMPOSE DE DIODES BLANCHES.....	- 76 -
FIGURE 3.14 : PHOTOGRAPHIE DES HUIT PIECES DE BOIS DE REFERENCE.....	- 77 -
FIGURE 3.15 : EVOLUTION DE LA METRIQUE $\Delta E_{RVB}$ EN FONCTION DE LA TEMPERATURE - ECLAIRAGE FLUORESCENT.....	- 78 -
FIGURE 3.16 : EVOLUTION DE LA METRIQUE $\Delta E_{RVB}$ EN FONCTION DE LA TEMPERATURE - ECLAIRAGE A DIODES.....	- 78 -
FIGURE 3.17 : METHODOLOGIE DE CORRECTION CHROMATIQUE.....	- 81 -
FIGURE 3.18 : IMAGES DES REFERENCES COULEUR AUX DIFFERENTS INSTANTS $T_0$ , $T_1$ ET $T_2$ AVANT ET APRES CORRECTION.....	- 84 -
FIGURE 3.19 : REPERE COLORIMETRIQUE TLS.....	- 87 -
FIGURE 3.20 : REPERE COLORIMETRIQUE CIE LAB.....	- 89 -

---

FIGURE 3.21 : VARIATION DES COEFFICIENTS D'INERTIES INTRA ET INTERCLASSE POUR 5 REPERES COLORIMETRIQUES .....	- 90 -
FIGURE 3.22 : REPRESENTATION DES 7 ROI SUR UNE IMAGE TIREE DU CAS APPLICATIF 1 .....	- 91 -
FIGURE 3.23 : AVIVES DE 6 DIFFERENTES COULEURS POUR PLUSIEURS ESSENCES (LISTE NON EXHAUSTIVE) – CAS APPLICATIF 2 .....	- 93 -
FIGURE 3.24 : HISTOGRAMMES NORMALISES DES COMPOSANTES L (A), A (B), B (C), H (D) ET C (E) D'UN AVIVE DE CHENE ROUGE DE COULEUR ROUGE CLAIR (F) – CAS APPLICATIF 1 .....	- 94 -
FIGURE 3.25 : INERTIE MOYENNE DE CHAQUE PARAMETRE POUR LA DISCRIMINATION DES CLASSES .....	- 98 -
FIGURE 3.26 : PHOTOGRAPHIES D'UN AVIVE AVANT (A) ET APRES (B) UNE DECOUPE LONGITUDINALE.....	- 100 -
FIGURE 3.27 : INERTIE MOYENNE DE CHAQUE PARAMETRE POUR LA DISCRIMINATION DES CLASSES (A : 65 CARACTERISTIQUES, B : 90 CARACTERISTIQUES).....	- 104 -
FIGURE 3.28 : REPRESENTATION DU LIEN ENTRE L'UNIVERS DE DISCOURS ET L'UNIVERS LEXICAL – CARACTERISATION DE LA COULEUR .....	- 107 -
FIGURE 4.1 : PARALLELE ENTRE LA CHAINE DE TRAITEMENT D'IMAGES ET LA STRUCTURE D'UN CAPTEUR INTELLIGENT .....	- 111 -
FIGURE 4.2 : REPRESENTATIONS GRAPHIQUES DE LA DISTRIBUTION DES POINTS DE LA BASE DE DONNEES BASE_COULEUR_1 DANS LES DIFFERENTS PLANS DU REPERE COLORIMETRIQUE CIE LAB.....	- 114 -
FIGURE 4.3 : IMAGE D'UNE PIECE DE BOIS PRESENTANT UN CHANGEMENT DE COULEUR PROGRESSIF.....	- 115 -
FIGURE 4.4 : IMPRECISIONS ET INCERTITUDES A PRENDRE EN COMPTE DANS LA METHODE DE CLASSIFICATION COLORIMETRIQUES DES AVIVES.....	- 117 -
FIGURE 4.5 : FONCTIONNEMENT DE L'ALGORITHME DURANT LES ETAPES D'APPRENTISSAGE ET DE GENERALISATION .....	- 123 -
FIGURE 4.6 : EXEMPLE DE PARTITIONNEMENT EN CINQ TERMES SUIVANT DES COURBES TRAPEZOÏDALES.....	- 124 -
FIGURE 4.7 : EXEMPLE DE PARTITIONNEMENT EN SEPT TERMES SUIVANT DES COURBES TRIANGULAIRES/TRAPEZOÏDALES .....	- 126 -
FIGURE 4.8 : MODELE DE L'EXPERT BOIS ASSOCIE A LA BASE DE DONNEES BASE_COULEUR_1 .....	- 127 -
FIGURE 4.9 : MODELE GENERAL DES DEUX DOMAINES D'EXPERTISE ASSOCIE A LA BASE DE DONNEES BASE_COULEUR_1 .....	- 128 -
FIGURE 4.10 : SCORES DE TYPICALITE POUR LES ECHANTILLONS DE LA BASE DE DONNEES BASE_COULEUR_1 POUR LES DIFFERENTS PARAMETRES CONSTITUANT LE VECTEUR CARACTERISTIQUE.....	- 131 -
FIGURE 4.11 : REPRESENTATION SCHEMATIQUE DE L'ALGORITHME DE PARTITIONNEMENT AUTOMATIQUE....	- 134 -
FIGURE 4.12 : PARTITIONNEMENT DE LA COMPOSANTE L DE LA BASE DE DONNEES BASE_COULEUR_1 .....	- 135 -
FIGURE 4.13 : PROCESSUS D'AJUSTEMENT DES REGLES .....	- 140 -
FIGURE 4.14 : TAUX DE RECONNAISSANCE EN GENERALISATION SUR LA BASE DE DONNEES IRIS .....	- 142 -

---

## LISTE DES FIGURES

---

FIGURE 4.15 : TAUX DE RECONNAISSANCE EN GENERALISATION SUR LA BASE DE DONNEES BASE_COULEUR_ETENDUE.....	- 144 -
FIGURE 4.16 : TAUX DE RECONNAISSANCE EN GENERALISATION SUR LES TROIS BASES DE DONNEES INDUSTRIELLES .....	- 146 -
FIGURE 4.17 : APPLICATION DE LA FUSION D'INFORMATIONS AU CAS APPLICATIF 1 .....	- 148 -
FIGURE 4.18 : COMPORTEMENT DE L'OPERATEUR F .....	- 151 -
FIGURE 4.19 : TAUX DE RECONNAISSANCE APRES FUSION DES INFORMATIONS MONO CAPTEUR – CAS APPLICATIF 1 .....	- 154 -
FIGURE 4.20 : REPRESENTATION DU LIEN ENTRE L'UNIVERS DE DISCOURS ET L'UNIVERS LEXICAL – CLASSIFICATION/DECISION .....	- 155 -
FIGURE 5.1 : EVOLUTION DU PROJET DE DEVELOPPEMENT DU CAPTEUR FLOU COULEUR .....	- 161 -
FIGURE 5.2 : EVOLUTION DU TAUX DE RECONNAISSANCE POUR LE CAS APPLICATIF 1 DURANT LES TRAVAUX DE THESE .....	- 162 -
FIGURE 5.3 : PRINCIPE D'INTEGRATION DES CONNAISSANCES EXPERTES PERMETTANT LA SPECIALISATION DES TRAITEMENTS D'IMAGES – APPLICATION BOIS.....	- 164 -
FIGURE A.1 : COUPE D'UN ŒIL HUMAIN [KOLB-00] .....	- 167 -
FIGURE A.2 : COURBES D'ABSORPTION DES DIFFERENTS PHOTORECEPTEURS DE L'ŒIL HUMAIN EN FONCTION DE LA LONGUEUR D'ONDE .....	- 168 -
FIGURE A.3 : DIAGRAMMES DES SYNTHESSES ADDITIVE (A) ET SOUSTRACTIVE (B).....	- 168 -
FIGURE A.4 : DIAGRAMME DE SENSIBILITE DES PRIMAIRES NECESSAIRE A LA COMPOSITION DES COULEURS ..	- 169 -
FIGURE A.5 : DIAGRAMMES DE CHROMATICITE DE L'ŒIL HUMAIN ET ELLIPSES DE MACADAM.....	- 170 -
FIGURE A.6 : REPARTITION DES PHOTOSITES SUR LA CAMERA COULEUR UTILISEE .....	- 170 -
FIGURE B.1 : EXEMPLE DE PROBLEME DE CLASSIFICATION A DEUX CLASSES.....	- 173 -
FIGURE B.2 : EXEMPLE DE CONSTRUCTION DE SOUS-ESPACES FLOUS .....	- 174 -
FIGURE B.3 : EVOLUTION DES TAUX DE RECONNAISSANCE EN GENERALISATION EN FONCTION DES VALEURS DES CONSTANTES D'APPRENTISSAGE $\eta_1$ ET $\eta_2$ - BASE_COULEUR_1 .....	- 180 -
FIGURE B.4 : EVOLUTION DES TAUX DE RECONNAISSANCE EN GENERALISATION EN FONCTION DES VALEURS DES CONSTANTES D'APPRENTISSAGE $\eta_1$ ET $\eta_2$ - BASE_COULEUR_2 .....	- 181 -
FIGURE B.5 : EVOLUTION DU TAUX DE RECONNAISSANCE EN GENERALISATION EN FONCTION DU SEUIL DE CLASSIFICATION - BASE_COULEUR_1 .....	- 182 -
FIGURE B.6 : EVOLUTION DU TAUX DE RECONNAISSANCE EN GENERALISATION EN FONCTION DU SEUIL DE CLASSIFICATION - BASE_COULEUR_2 .....	- 183 -

## Liste des tableaux

TABLEAU 2.1 : SINGULARITES DU BOIS ET CARACTERISTIQUES ASSOCIEES (X : NOTION FREQUEMMENT UTILISEE, - : NOTION PEU UTILISEE).....	- 29 -
TABLEAU 2.2 : CONTROLE SURFACIQUE DU PRODUIT BOIS – TECHNOLOGIES EMPLOYEES ET APPLICATIONS.....	- 32 -
TABLEAU 2.3 : CLASSIFICATION DE COULEURS ET DE GRAINS SUR UN PRODUIT BOIS .....	- 35 -
TABLEAU 2.4 : METHODES DE RECONNAISSANCE DES SINGULARITES DU BOIS .....	- 49 -
TABLEAU 2.5 : METHODES DE RECONNAISSANCE DES COULEURS ET DES TEXTURES SUR UN PRODUIT BOIS .....	- 51 -
TABLEAU 3.1 : ERREUR QUADRATIQUE MOYENNE NORMALISEE AVANT ET APRES CORRECTION SUR LES REFERENCES COULEUR .....	- 83 -
TABLEAU 3.2 : TAUX DE RECONNAISSANCE EN FONCTION DE LA TAILLE DES ROI – CAS APPLICATIF 1.....	- 91 -
TABLEAU 3.3 : VECTEUR CARACTERISTIQUE DE SIX AVIVES DE <i>CHENE ROUGE</i> DE COULEUR DIFFERENTE .....	- 96 -
TABLEAU 3.4 : TAUX DE RECONNAISSANCE POUR DIFFERENTS VECTEURS CARACTERISTIQUES.....	- 99 -
TABLEAU 3.5 : CARACTERISTIQUES EXTRAITES DES MATRICES DE CO-OCCURRENCES POUR 2 IMAGES DE COMPOSANTE COLORIMETRIQUE L .....	- 103 -
TABLEAU 3.6 : TAUX DE RECONNAISSANCE POUR DIFFERENTS VECTEURS CARACTERISTIQUES.....	- 105 -
TABLEAU 4.1 : PROPORTION DE CHAQUE COULEUR SUR UNE POPULATION DE 943 ECHANTILLONS DE BOIS ....	- 116 -
TABLEAU 4.2 : TAUX DE RECONNAISSANCE OBTENUS POUR DIFFERENTES FORMES DE FONCTIONS D’APPARTENANCE DANS LE CAS D’UN PARTITIONNEMENT EQUIREPARTI.....	- 125 -
TABLEAU 4.3 : NOMBRE DE SOUS-ESPACES OBTENUS POUR CHAQUE PARAMETRE A PARTIR DE LA CONNAISSANCE DES EXPERTS DANS LE CAS DE LA BASE DE DONNEES BASE_COULEUR_1 .....	- 128 -
TABLEAU 4.4 : TAUX DE RECONNAISSANCES EN GENERALISATION POUR UN PARTITIONNEMENT ADAPTE .....	- 129 -
TABLEAU 4.5 : EVALUATION DU COEFFICIENT $\rho_{corr/xcorr}$ POUR LA COMPOSANTE L ET LES DIFFERENTES CLASSES PRESENTES DANS LA BASE DE DONNEES BASE_COULEUR_1 .....	- 133 -
TABLEAU 4.6 : NOMBRE DE SOUS-ESPACES OBTENUS POUR CHAQUE PARAMETRE A PARTIR DU PARTITIONNEMENT AUTOMATIQUE DANS LE CAS DE LA BASE DE DONNEES BASE_COULEUR_1 .....	- 135 -
TABLEAU 4.7 : COMPARAISON DES TAUX DE RECONNAISSANCE OBTENUS A PARTIR DE DIFFERENTES METHODES DE PARTITIONNEMENT .....	- 136 -

## LISTE DES TABLEAUX

---

TABLEAU 4.8 : COMPARAISON DES TAUX DE RECONNAISSANCE OBTENUS A PARTIR DES MODELES DE LARSEN ET DE MAMDANI .....	- 138 -
TABLEAU 4.9 : COMPARAISON DES TAUX DE RECONNAISSANCE OBTENUS A PARTIR DE DIFFERENTES METHODES AUTOMATIQUES DE GENERATIONS DE REGLES LINGUISTIQUES .....	- 141 -
TABLEAU 4.10 : TABLE DE FUSION DE DONNEES SYMBOLIQUES ASSOCIEE AU CAS APPLICATIF 1.....	- 150 -
TABLEAU 4.11 : DECISIONS PRISES PAR CHAQUE CAPTEUR ET FUSION DE DONNEES .....	- 153 -
TABLEAU 4.12 : DEFINITION MATHEMATIQUE DES T-NORMES DUALES ETUDIEES .....	- 154 -
TABLEAU B.1 : TAUX DE RECONNAISSANCE POUR DIFFERENTS VECTEURS CARACTERISTIQUES – ALGORITHME DES K PLUS PROCHES VOISINS.....	- 178 -
TABLEAU B.2 : TAUX DE RECONNAISSANCE POUR DIFFERENTS TYPES DE FUZZIFICATION – LOT TEXTILE .....	- 179 -

# **CHAPITRE 1 : INTRODUCTION**

---

## 1. Introduction

Notre étude se place dans le cadre de la reconnaissance de formes pour l'inspection qualitative de produits manufacturés. La finalité de nos travaux réside dans le développement d'un système automatisé d'appariement colorimétrique d'avivés apte à remplacer un opérateur humain. Un individu est doté de plusieurs capacités définissant son intelligence : l'acquisition d'information, le raisonnement dédié aux données acquises, la communication avec d'autres individus et la décision relative aux traitements raisonnés [MARR-76] [LEVI-85]. Les scientifiques cherchent à intégrer ces aptitudes dans des systèmes artificiels. Il s'agit en fait de spécialiser les traitements offerts aux industriels afin de faciliter l'intégration de leur Savoir-Faire dans leur processus industriel de fabrication. L'idée d' « intelligence artificielle » prend alors tout son sens. Cette notion va à l'encontre de la standardisation souhaitée par de nombreux théoriciens durant les années 80 [CLAR-04]. Cette divergence entre standardisation et spécialisation semble être encore plus importante dans le domaine du traitement d'images appliqué aux tâches d'inspection automatique qualitative au sein de chaînes de production industrielles. Ainsi, dans ce domaine de l'inspection, une définition d'un système de vision peut être proposée :

*« Un système de vision est un système automatique qui interagit avec son environnement afin d'acquérir des images de la scène et d'analyser les faits qui s'y trouvent. »*

Classiquement les systèmes de vision sont constitués d'un ou plusieurs capteurs fournissant des informations complémentaires d'une même scène, ou des informations de plusieurs vues de la scène considérée. Le développement des systèmes de vision repose sur plusieurs avantages très nets [NEWM-95] dont la répétabilité et la rapidité.

En effet, un opérateur ne fournit pas des décisions identiques à propos de la qualification d'un produit à deux instants différents alors que le système automatique de vision assigne toujours le même résultat à ce même produit, inspecté plusieurs fois sur une courte période. De plus, un système automatique n'est pas soumis aux contraintes que peut ressentir un être humain : fatigue, monotonie, danger, ... Il peut donc fiabiliser les inspections qualitatives des produits de part la répétabilité de ses traitements. Le deuxième avantage d'un tel système consiste en sa rapidité d'analyse. En effet, une inspection artificielle peut regrouper simultanément un grand nombre de traitements, alors qu'un individu se concentrera sur une

tâche bien précise. Ces traitements réalisés sont souvent assimilés au vaste domaine de la reconnaissance de formes.

Ainsi, au vu des avantages cités, l'utilisation d'un système automatique d'inspection peut permettre une valorisation économique des produits d'une entreprise manufacturière (amélioration de la qualité des produits impliquant une éventuelle hausse de la valeur ajoutée) dans la mesure où l'inspection est réalisée de manière fiable sur des volumes importants de matière (accroissement de la productivité, amortissement rapide de l'investissement).

Depuis le milieu du siècle dernier, les industries manufacturières sont placées sur un marché concurrentiel dans lequel il est difficile de s'imposer. Afin de se démarquer des entreprises fabriquant des produits d'« entrée de gamme », ou d'asseoir leur position de leader, certaines sociétés se sont fixées des objectifs conséquents. Ces objectifs peuvent concerner directement la chaîne de contrôle qualité des produits au niveau des flux entrants (matière première) et des flux sortants (produits manufacturés) de matière. Ils peuvent également concerner l'optimisation de la gestion de la production (coût, flux de matières, ...), tant au niveau du rendement matière qu'au niveau de la gestion de l'information au sein du système de production.

Les industries du bois ne dérogent pas à cette évolution. Ainsi, plusieurs solutions sont proposées par des fabricants de scanners afin de contrôler et améliorer les performances de production. C'est le cas de la société LuxScan Technologies qui est à l'origine des travaux de thèse présentés dans ce mémoire. Cette entreprise, implantée au Luxembourg, conçoit et développe des systèmes de vision adaptés au contrôle qualitatif dans les industries du bois (fabricants de meubles, de parquets, de lambris, ...). Initialement, la gamme de scanners de cette entreprise permettait un contrôle qualitatif et une optimisation de la production à partir de la détection des singularités du bois (nœuds, fentes, trous, ...). Suite à une demande spécifique concernant le tri colorimétrique d'avivés, la société a décidé d'élargir ses activités au développement d'un nouveau scanner adapté à l'appariement des planches selon un critère couleur. Cet objectif a servi de cadre applicatif à notre étude aux travers de trois cas. Ainsi, deux projets industriels avec des clients nord-américains et un cas d'étude de faisabilité ont été utilisés pour valider les choix et les propositions émises :

- une application de tronçonnage de pièces homogènes en couleur pour la réalisation de lisses qui sera nommé **cas applicatif 1** ;
- une application de tri pour la confection de panneaux homogènes en couleur qui sera nommé **cas applicatif 2** ;
- une application de tri sur des feuilles de placage qui sera nommé **cas applicatif 3**.

Ce mémoire fait régulièrement référence à ces trois cas concrets. Ainsi, des détails sur les procédés industriels mis en œuvre sont nécessaires pour comprendre les besoins et attentes liés à ces projets. Dans les trois cas applicatifs cités, la notion d'appariement de couleur intervient dans la phase d'uniformisation des produits finaux.

- **Cas applicatif 1**

La première application concerne le tronçonnage de planches de bois de longueur variable uniformes en couleur. Le système de vision doit permettre l'optimisation de la production en purgeant les planches rabotées de leurs singularités et en les triant suivant leur couleur. L'originalité de ce système réside dans l'application du tri colorimétrique en scrutant uniquement les rives des planches (figure 1.1) en vue de la confection des produits finaux du client : des mains courantes (ou lisses) (figure 1.2).

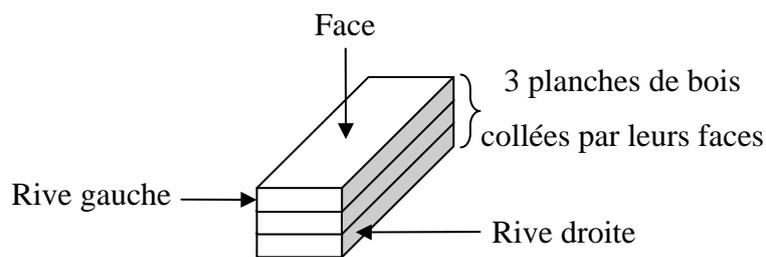


Figure 1.1 : Représentation schématique des produits finaux du cas applicatif 1



Figure 1.2 : Photographie de produits finaux du cas applicatif 1

La réalisation de tels produits se fait par collage de trois planches par leurs faces. L'intérêt d'avoir des rives de même couleur est donc important afin de donner l'illusion d'un produit final taillé dans un unique produit brut. Les essences de bois communément utilisées par ce client et nécessitant un tri colorimétrique sont : le chêne rouge, l'érable, le peuplier, le cerisier, le hêtre et le sycomore. Le *chêne rouge* sera l'essence privilégiée de cette application pour valider les développements réalisés. Il représente le cas le plus défavorable car, pour une teinte particulière, il est très difficile de définir avec précision les classes de couleur « client ». Les variations présentes sont très graduelles (rouge clair, rouge moyen et rouge foncé).

- **Cas applicatif 2**

La deuxième application concerne le tri de planches de bois uniformes en couleur, de longueur fixe et de largeur variable. Le système de vision doit permettre un pré tri

colorimétrique de planches parfaitement propres et purgées de leurs singularités. Ce tri est appliqué sur les faces des planches (figure 1.3) en vue d'un panneautage uniforme (figure 1.4).

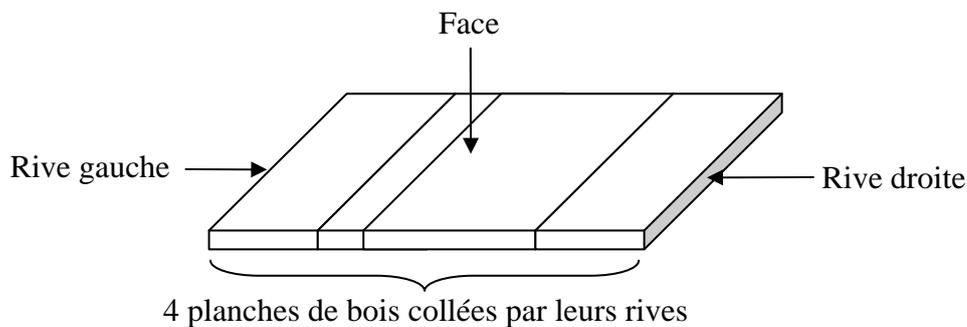


Figure 1.3 : Représentation schématique des produits finaux du cas applicatif 2



Figure 1.4 : Photographie de panneaux du cas applicatif 2

La réalisation de tels produits se fait par collage de plusieurs planches par leurs rives pour obtenir des panneaux de largeur fixe. Le chêne rouge, l'érable et le cerisier sont les essences de bois communément utilisées par ce client et nécessitant un tri colorimétrique. Ces panneaux sont ensuite utilisés pour confectionner essentiellement des éléments de meubles de cuisine qui doivent être parfaitement homogènes en couleur sur les faces.

- **Cas applicatif 3**

La troisième application concerne une étude de faisabilité d'un tri colorimétrique sur du placage de bois massif (figure 1.5). Ces feuilles de bois d'une faible épaisseur (entre 0,3 mm et 0,9 mm) sont utilisées pour recouvrir des panneaux de particules afin de donner un aspect massif à des meubles de moindre coût. Il faut donc effectuer un tri colorimétrique assez précis car les acheteurs de placages doivent toujours pouvoir obtenir la même couleur de placage lorsqu'ils définissent une gamme de meuble bien précise. Le tri des feuilles de bois est effectué uniquement sur la meilleure des faces, cette sélection étant réalisée préalablement par des opérateurs humains. Le hêtre et le chêne sont les essences de bois communément utilisées par ce client et nécessitant un tri colorimétrique.



Figure 1.5 : Photographies de placages de bois provenant du cas applicatif 3

- **Protocole de tests**

Notre étude portant sur le développement d'un système de vision adapté au contrôle qualité dans les industries du bois, il est nécessaire d'approfondir certains points qui sont à la base de nos développements : le contrôle qualité dans les industries du bois, les systèmes de vision, le traitement d'images associé à la reconnaissance de formes, et les capteurs mis en œuvre pour reproduire les qualités perceptuelles d'un individu. Ces concepts peuvent être regroupés sous l'expression « inspection visuelle automatisée ». Sous-jacente à cette expression, la notion d'observation tient une place importante au sein des systèmes de production nécessitant ce type de contrôle. La figure 1.6 illustre le positionnement de cette fonction d'observation au sein d'un système de production telle que nous pouvons la rencontrer dans les industries du bois. Au sens de la systémique, il s'agit d'un opérateur de nature qui permet de transformer un flux produit en un flux d'informations [LEMO-90].

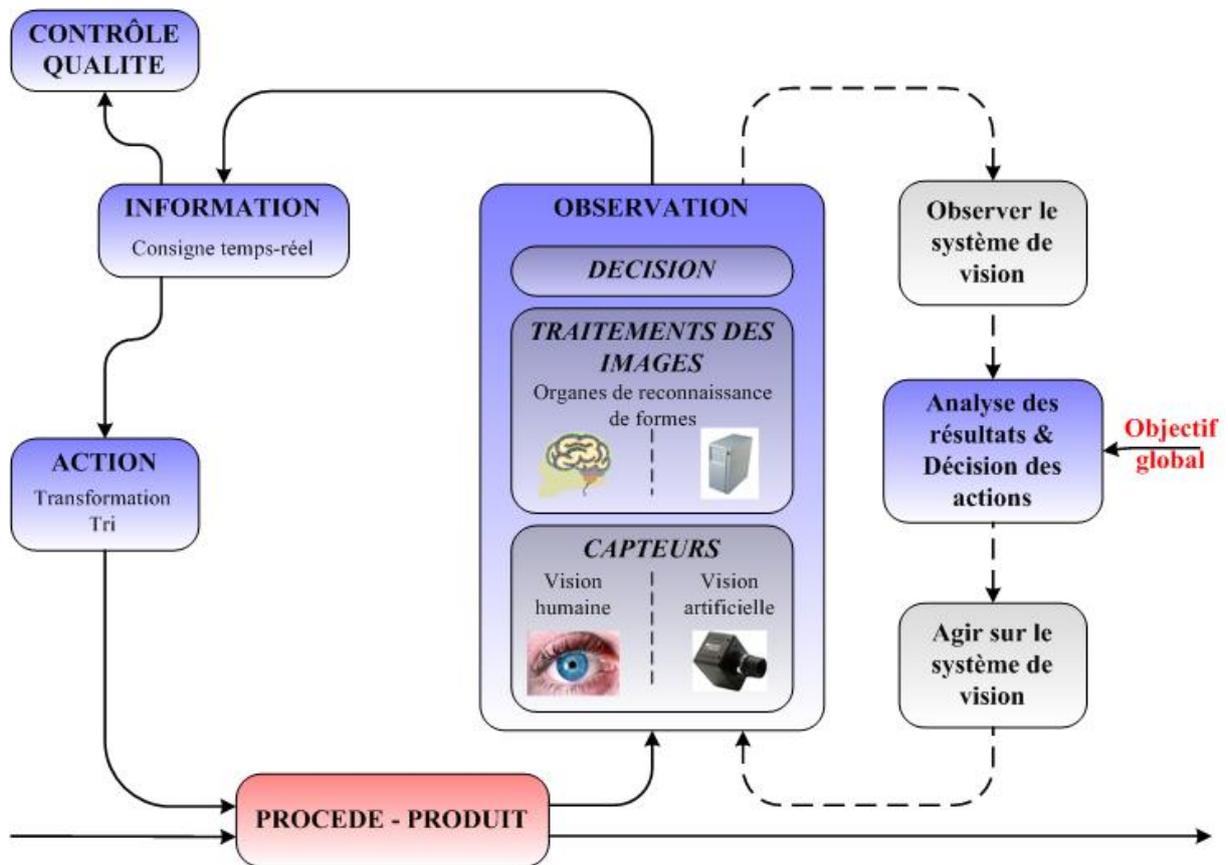


Figure 1.6 : Positionnement de la fonction d'observation dans la boucle de causalité circulaire en productique [PERE-00]

Le système d'Observation a donc pour objectif de fournir une information à partir d'une mesure prise sur le système physique. La qualité de cette information est évaluée par rapport à la consigne globale. Dans notre cas, le client veut obtenir le taux de reconnaissance maximum.

Le système d'observation peut lui-même être décomposé de façon systémique [BOMB-07b]. Nous nous apercevons alors, que pour pouvoir assurer la qualité globale du système, nous pouvons essayer « d'optimiser » chacun des sous-systèmes (figure 1.7). Cependant, deux problèmes se posent. Premièrement, rien ne certifie que l'optimisation locale des sous-systèmes mène à un optimum global. Deuxièmement, pour optimiser les sous-systèmes, il faudrait pouvoir évaluer un critère local par rapport à une consigne locale, déduite de la consigne globale. Or, le problème d'évaluation de la performance d'un traitement d'image reste un problème ouvert [GDR-01]. C'est pourquoi, même si pour certains modules comme l'acquisition, il est possible d'agir au plus tôt à partir d'une évaluation de certains paramètres externes (section 3.1.2.), nous avons choisi de valider chaque étape de la chaîne de traitements

d'images par rapport à la finalité industrielle (figure 1.8). Ainsi, l'efficacité de chaque outil ou méthode sera évalué par rapport au taux de reconnaissance global.

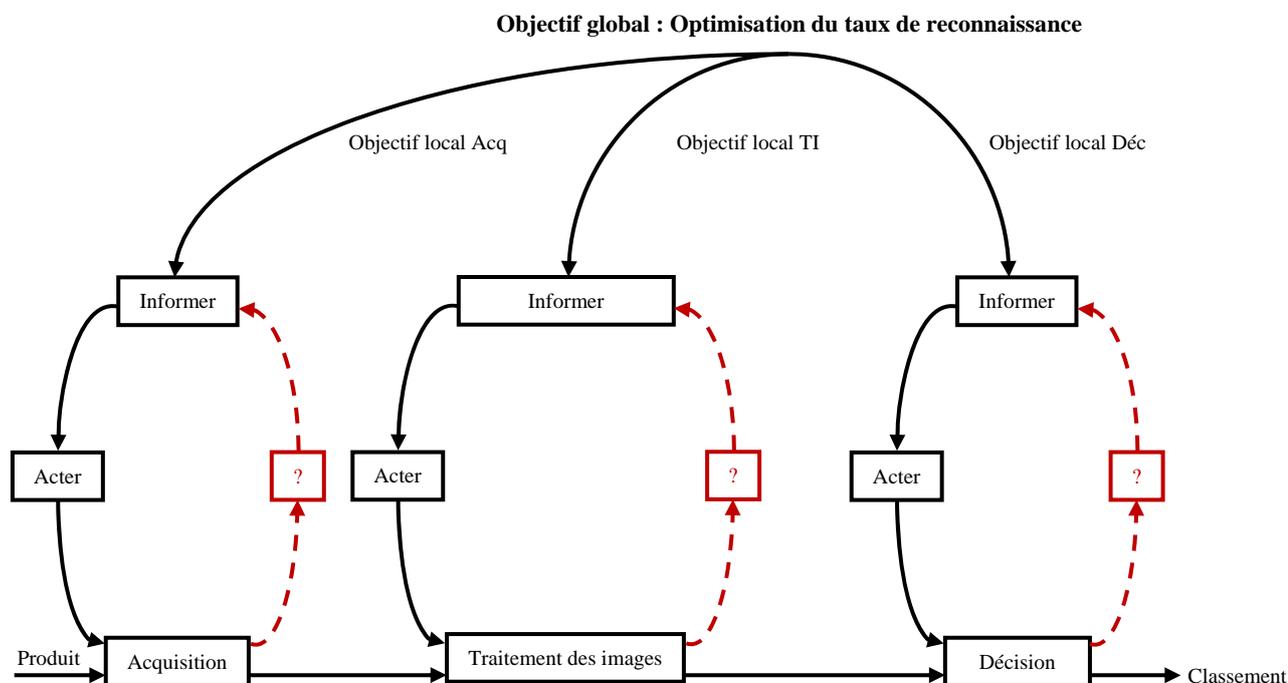


Figure 1.7 : Décomposition du système d'observation

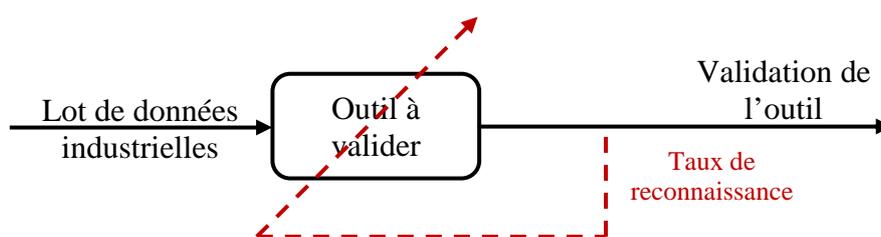


Figure 1.8 : Schéma de validation par la finalité

Ce choix s'explique aussi par le caractère applicatif de ce travail de thèse et par les objectifs « clients ». En effet, un gain de 5% sur le taux de reconnaissance correspond à un gain de 1000 mètres de bois linéaire pour une production journalière de 20 000 m d'avivés.

- **Présentation des bases de données liées aux cas applicatifs**

L'ensemble des tests présentés dans la suite de ce mémoire fait référence à 5 bases de données différentes. Leur composition, qui diffère suivant le cas applicatif, est décrite ci-dessous.

La base de données **Base\_Couleur\_1** est issue du cas applicatif 1. Les 943 échantillons utilisés sont des avivés de *chêne rouge*. Les classes de sortie sont au nombre de 6 : Brun Foncé, Brun, Brun Clair, Rouge Foncé, Rouge, Rouge Clair. La répartition des échantillons dans les différentes classes de sortie se fait de la manière suivante : 84 échantillons « Brun Foncé », 176 échantillons « Brun », 259 échantillons « Brun Clair », 54 échantillons « Rouge Foncé », 197 échantillons « Rouge » et 173 échantillons « Rouge Clair ».

La base de données **Base\_Couleur\_2** est issue du cas applicatif 2. Les 627 échantillons utilisés sont des avivés d'*érable*. Les classes de sortie sont au nombre de 9 (du blanc jaunâtre au blanc rosé suivant trois intensités lumineuses) que nous notons Grade 1, ..., Grade 9. La répartition des échantillons dans les différentes classes de sortie se fait de la manière suivante : 78 échantillons « Grade 1 », 49 échantillons « Grade 2 », 68 échantillons « Grade 3 », 87 échantillons « Grade 4 », 109 échantillons « Grade 5 », 79 échantillons « Grade 6 », 91 échantillons « Grade 7 », 49 échantillons « Grade 8 » et 17 échantillons « Grade 9 ».

La base de données **Base\_Couleur\_3** est issue du cas applicatif 3. Les 1834 échantillons utilisés sont des placages de *hêtre*. Les classes de sortie sont au nombre de 4 : Brun, Rosé, Rouge, Blanc. La répartition des échantillons dans les différentes classes de sortie se fait de la manière suivante : 522 échantillons « Brun », 514 échantillons « Rosé », 475 échantillons « Rouge » et 323 échantillons « Blanc ».

La base de données **Base\_Couleur\_Gauche** est issue du cas applicatif 1. Il s'agit des mêmes échantillons que ceux de la base **Base\_Couleur\_1**. Ils correspondent à l'étiquetage des 943 rives gauches. Elle servira à valider les travaux réalisés sur la fusion de capteur.

La base de données **Base\_Couleur\_Droite** est issue du cas applicatif 1. Les 943 échantillons utilisés correspondent à l'étiquetage des 943 rives droites des avivés de la base **Base\_Couleur\_1**. Les classes de sortie sont donc également au nombre de 6 : Brun Foncé, Brun, Brun Clair, Rouge Foncé, Rouge, Rouge Clair. La répartition des échantillons dans les différentes classes de sortie se fait de la manière suivante : 93 échantillons « Brun Foncé », 188 échantillons « Brun », 243 échantillons « Brun Clair », 42 échantillons « Rouge Foncé », 212 échantillons « Rouge » et 165 échantillons « Rouge Clair ».

Il est à noter qu'aucune de ces bases n'a été épurée de ses « points » aberrants. En phase d'exploitation, l'étiquetage sera fait par un opérateur « novice » en vision, n'ayant pas les compétences pour effectuer ce filtrage de points. Pour l'ensemble des tests, la même décomposition est faite sur toutes les bases de données : un tiers des échantillons servant à la phase d'apprentissage, et les deux tiers restants servant à la phase de généralisation.

Pour reproduire la vision humaine dans les cas applicatifs présentés, la notion de couleur doit être abordée de manière précise. En effet, l'utilisation de la couleur implique un accroissement de la quantité d'informations pour la qualification des scènes étudiées. La compréhension des mécanismes d'interprétation de la couleur peut alors permettre une meilleure approche dans l'implémentation des traitements sur des systèmes de vision. Le contexte industriel implique également un certain nombre d'obstacle à l'application de techniques déjà existantes.

Tout d'abord, le matériau bois est un produit très variable au sens où les couleurs ne sont pas homogènes d'une production à l'autre. Il en résulte alors un premier problème quant à la définition incomplète des classes « clients ». Ainsi, ces classes peuvent être représentées par un faible nombre d'échantillons, ce qui rend difficile la phase d'apprentissage.

En outre, les définitions des classes en fonction des desiderata du client peuvent être vagues et/ou imprécises. En effet, la couleur telle que la voient les industriels du domaine du bois est une notion particulièrement difficile à quantifier et qualifier. Derrière le mot couleur se cache en réalité plusieurs notions comme la texture, qui représente plus l'orientation des fibres et la présence de singularités au sein du bois, et la couleur à proprement parler. C'est pourquoi il est préférable d'employer le terme d'*aspect* du bois pour qualifier l'esthétisme de sa surface. Un fossé sémantique apparaît donc entre les définitions de la couleur par un client et celles données par un expert en vision.

Ainsi, au sein d'un système automatisé, il est nécessaire de définir une base de représentation compréhensible par l'être humain afin que le système soit totalement interprétable par l'utilisateur. Il s'agit en fait de définir des techniques de représentation, manipulation et reproduction des couleurs. Pour ce faire, le principe d'équivalence des couleurs a été établi et a fait l'objet de nombreuses normalisations depuis 1924, date de création de la Commission Internationale de l'Eclairage (CIE). En considérant les systèmes de vision, les équivalences de couleurs permettent de réaliser principalement deux types de traitement :

- l'identification ou la localisation d'objets ou de formes dans les scènes capturées par le système (connaissance *a priori* des couleurs des objets);
- l'appariement couleur de mêmes objets traités par le système (connaissance *a priori* des objets à classer suivant leur couleur).

La vision utilisée dans les systèmes automatisés, nommée communément vision « artificielle », ne peut se concevoir sans une connaissance *a priori* de la vision humaine. Cela s'explique assez facilement en raison des comparaisons qui sont effectuées pour valider les performances des systèmes développés en référence à la vision humaine. Il faut donc pouvoir établir un vocabulaire commun pour la définition des couleurs afin de permettre le dialogue et la comparaison entre la machine (système de vision) et l'opérateur qui l'utilise.

Le contrôle qualitatif, né dans les années 60 [MOSL-67], représente aujourd'hui un enjeu majeur pour offrir des produits de qualité. Il n'existe cependant pas encore de systèmes « clé

en main » pour prétendre réaliser ce type de contrôle colorimétrique. Plusieurs études ont été réalisées dans ce sens [LU-97b] [HANB-02], mais les difficultés rencontrées avec le matériau bois n'ont pas permis la définition d'un système répondant aux attentes des industriels en termes de simplicité d'utilisation, de fiabilité et de robustesse. En effet, il est difficile d'intégrer, dans le système automatisé, la subjectivité et les connaissances des opérateurs humains effectuant le tri des couleurs. Un deuxième aspect important concerne l'évolution des capteurs utilisés pour effectuer ces contrôles qualitatifs. Dans un milieu industriel où la productivité est synonyme d'utilisation d'outils et de traitements rapides, il est important de concevoir un système intégrant le module de décision dans le capteur lui-même. Cette idée s'approche au mieux des mécanismes du raisonnement humain qui sont eux aussi centralisés dans le même être. En fait, l'opérateur peut réaliser en même temps les mesures, les traitements et la décision. Ainsi, les travaux exposés dans ce mémoire ont pour but d'apporter une solution à une telle intégration des traitements sous un capteur développé suivant la notion de capteur flou [SCHM-05b] [SCHM-06b].

Cette thèse présente l'étude et le développement d'un système d'inspection colorimétrique temps-réel dans le but d'uniformiser le tri des avivés de bois selon leur couleur. Cependant, les techniques de vision couleur peuvent être applicables à d'autres domaines que l'appariement couleur de planches de bois. Trois thèmes doivent être abordés pour répondre au problème proposé par cette étude : la définition du système de vision et plus particulièrement du système d'acquisition, le traitement d'images, et la reconnaissance de formes si la couleur est considérée comme telle. La méthode proposée pour effectuer la classification des couleurs repose sur l'utilisation de la logique floue car elle permet de s'approcher des raisonnements humains qui sont à la base de l'étude présentée [ZADE-73]. Elle permet également de prendre en compte les incertitudes et les imprécisions pouvant être liées aux capteurs de vision eux-mêmes [AQUI-02].

Ce mémoire est organisé en trois parties. La première partie positionne les recherches menées par rapport aux travaux existants dans le domaine du contrôle qualité par système de vision. Dans ce contexte, il est impératif de rappeler les bases de la vision humaine afin de la comparer à la vision artificielle qui est mise en œuvre. Des rappels, concernant les chaînes de traitement d'images, sont proposés dans le but de faciliter la compréhension des systèmes de reconnaissance de formes. De plus, pour valider le choix concernant le développement d'un capteur flou, un état de l'art de l'évolution des capteurs est proposé depuis l'intégration de l'intelligence à la définition d'un capteur flou.

La deuxième partie vise à dimensionner le système d'acquisition mis en œuvre pour réaliser la classification des planches de bois selon leur couleur. Une étude sur la fiabilisation du capteur est présentée pour marquer les difficultés rencontrées par l'utilisation d'un système de vision automatisé dans un environnement industriel. Une fois la partie « matériel » explicitée, les mesures des capteurs sont détaillées. En effet, la base de tout traitement d'images appelle la connaissance des mesures ou la caractérisation des scènes visualisées par le système. Il s'agit en réalité de définir tout un ensemble de paramètres permettant la modélisation des concepts abordés lors de cette étude (couleur, texture).

La dernière partie du mémoire est consacrée à la présentation de la méthode proposée pour l'appariement des couleurs proposées. La logique floue et ses apports dans l'étude sont ainsi exposés. Tout d'abord, le traitement des informations fournies par un unique capteur est abordé. Dans ce cadre, une proposition de méthode de classification par règles linguistiques est faite. Afin de simplifier son utilisation par des non spécialistes, il est alors nécessaire de se focaliser sur son paramétrage. Ensuite, pour positionner nos travaux, une comparaison avec des méthodes de références (SVM, Réseaux de neurones, ...) est proposée. Enfin, cette étude est étendue à la réalisation d'un système de vision multi-capteur permettant une amélioration des performances de tri dans le cas applicatif 1.

**CHAPITRE 2 : CONTROLE QUALITE PAR  
SYSTEME DE VISION ET RECONNAISSANCE DE  
FORMES DANS LES INDUSTRIES DU BOIS**

---

## **2. Contrôle qualité par système de vision et reconnaissance de formes dans les industries du bois**

Les systèmes de vision, et plus particulièrement les techniques de reconnaissance de formes utilisées par ces systèmes sont très largement employés pour le contrôle qualité de produit.

En s'appuyant sur la problématique de cette étude et un état de l'art associé, il est possible de spécifier les différentes parties qui constituent un système d'inspection visuelle automatisé. Dans une première partie, nous présentons les différents types de contrôle qualité appliqués au matériau bois en citant les technologies mises en œuvre et les besoins en termes d'automatisation des contrôles. En effet, le processus d'inspection visuelle étant réalisé par un être humain, il est important d'avoir une certaine connaissance des mécanismes intervenant dans la perception visuelle humaine. A partir de cet état de l'art, notre réflexion s'étend aux systèmes de vision plus généraux utilisant des techniques de reconnaissances de formes que nous précisons. Pour cela, une présentation des différents processus composant la chaîne de traitement d'images est faite. Cherchant à développer un capteur adapté au contrôle qualité, il est utile de positionner et structurer notre réflexion à partir des catégories de capteurs existants.

### **2.1. Contrôle qualité**

Le contrôle qualité dans les industries du bois se divise en trois grandes catégories applicatives : le contrôle géométrique, le contrôle structurel et le contrôle surfacique. Le choix de la catégorie de contrôle se fait généralement par la finalité d'utilisation des produits : ameublement, revêtement de surfaces (lambris, parquet), construction.

Tout d'abord, le contrôle géométrique d'une pièce de bois permet d'analyser sa géométrie : déformations longitudinales (arc et courbure, ou « bow » et « bend » en anglais, figure 2.1), déformations axiales (hélice ou « twist » en anglais, figure 2.1), variations d'épaisseur ou de largeur. Dans des processus de fabrication à grandes échelles (par exemple pour la confection d'un grand nombre d'exemplaires d'un même meuble), il est important de contrôler la géométrie des différentes pièces composant les produits, afin de répondre aux

spécifications des cahiers des charges associés aux produits, et ainsi limiter la dévalorisation de ces produits.

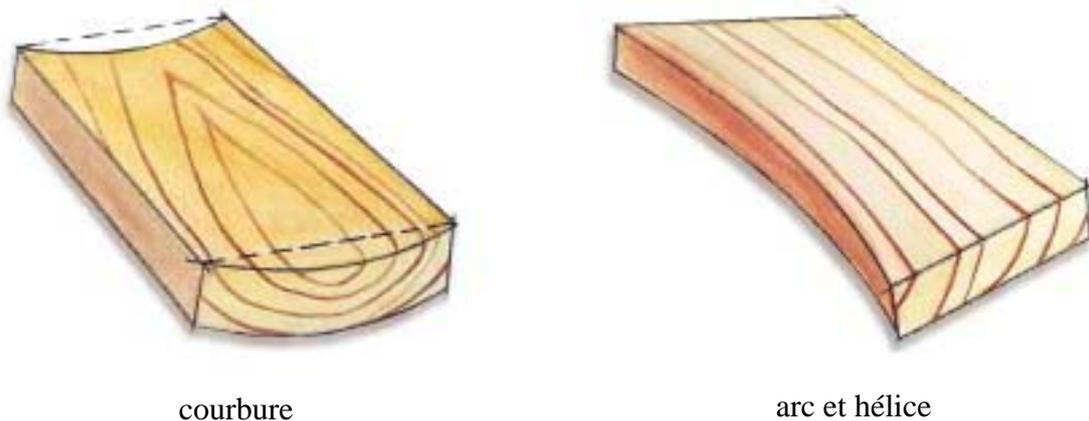


Figure 2.1 : Illustrations de quelques déformations du bois

Le contrôle structurel, quant à lui, permet de caractériser les propriétés mécaniques d'une pièce de bois de part sa structure interne (présence de nœuds et de trous, différence de densité, ...). Par exemple, lors de la mise en place de charpente, il est important d'assurer la résistance mécanique de chaque pièce de bois. Dans ce cas, le contrôle structurel permet alors de limiter le risque de rupture de ces pièces.

Enfin, le contrôle surfacique regroupe à la fois les notions d'aspect esthétique et de qualité mécanique des surfaces du bois. Les travaux exposés dans ce mémoire se rapportent exclusivement au contrôle de l'aspect esthétique. Il est donc intéressant de réaliser un état de l'art des systèmes existants. Lorsque le terme « qualité » est employé, les êtres humains font très souvent le parallèle avec la détection et la qualification des défauts (singularités du bois). D'ailleurs, de nombreuses recherches s'attardent à répondre à ces problématiques. Ainsi, la première partie de ce chapitre présente les systèmes mis en œuvre pour faciliter l'inspection automatisée des planches de bois et son application à la détection de singularités. Dans un deuxième temps, des notions plus en rapport avec l'esthétisme viennent compléter cet état de l'art. La couleur et le grain du bois (ou fil du bois) sont les principaux concepts abordés ici. Enfin, nous montrons le besoin d'utiliser des systèmes de vision pour ce type de contrôle qualité.

La figure 2.2 reprend de manière schématique les différents types de contrôles pouvant intervenir sur le produit « Bois ».

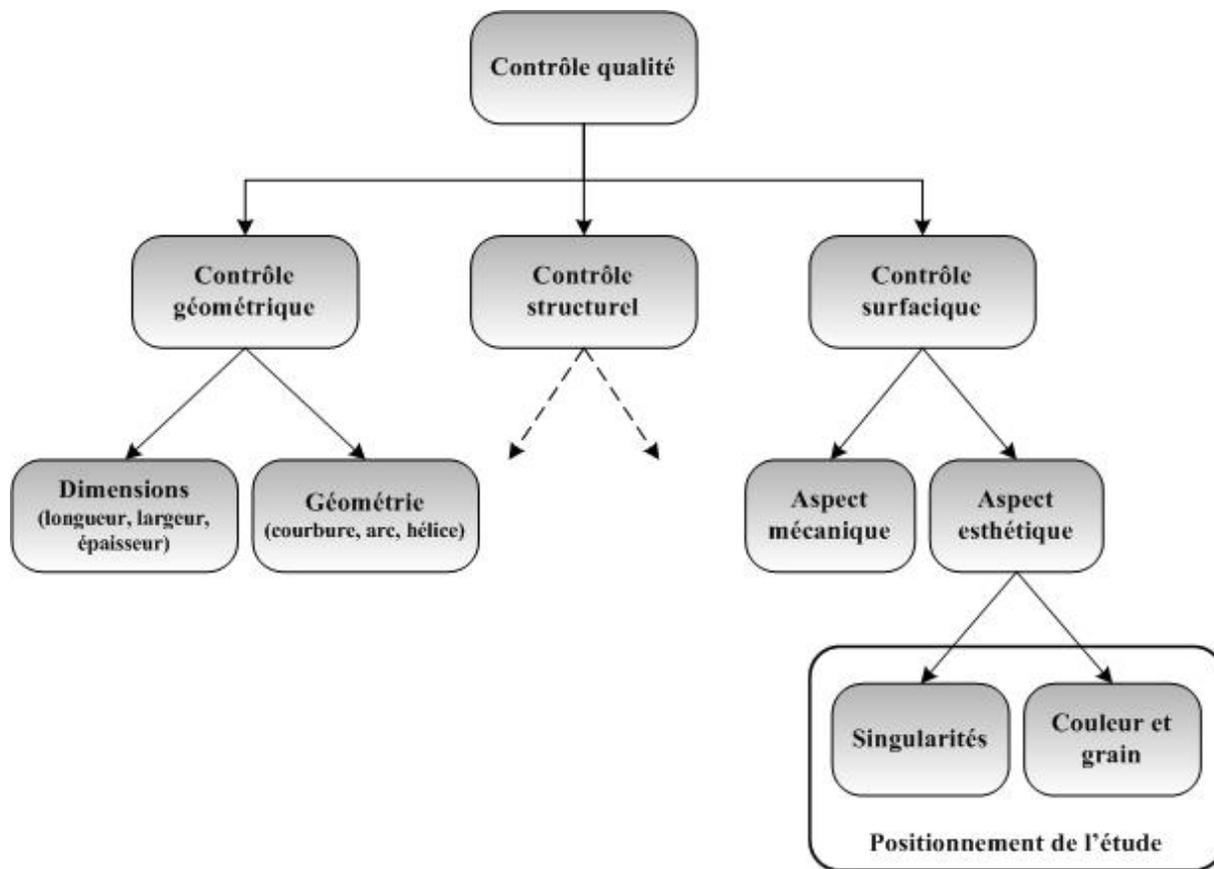


Figure 2.2 : Taxinomie des contrôles appliqués au bois et positionnement de l'étude

### 2.1.1. La reconnaissance des singularités

Les techniques de reconnaissance de singularités sont apparues durant les années 70 et s'appliquaient essentiellement aux bois résineux (pins, pins maritimes, ...), les bois de type feuillus (chêne, érable, hêtre, peuplier, ...) possédant trop de variations colorimétriques. Les systèmes développés pour répondre aux besoins de ce domaine industriel ont été appliqués à plusieurs types de production : parquets, panneaux, lambris, ... Dans tous ces cas, le processus de fabrication peut suivre deux voies. Certains industriels préfèrent effectuer un simple tri qualitatif des produits, alors que d'autres préfèrent purger les produits de toutes les singularités présentes. Le terme « singularité » englobe, dans ce contexte, un certain nombre de défauts qui peuvent être retrouvés sur un avivé : les nœuds (sains, cernés, noirs), les fentes, les flaches (ou manques de matière), les trous, les poches de résine, les colorations, ...

Les industriels emploient aujourd'hui des opérateurs humains afin d'effectuer ces détections. Pour répondre aux différents critères qualité imposés, ces individus doivent à eux seuls quantifier et qualifier l'ensemble de ces singularités. De plus, les règles de décisions, qui

dépendent du contexte d'utilisation des produits, ne sont pas toujours évidentes et sont le reflet d'un compromis entre le nombre de défauts, le type de défauts et l'aspect global du produit. Ces règles font intervenir plusieurs caractéristiques issues de chaque singularité. Ainsi, en fixant des critères sur ces caractéristiques, il est plus aisé de prendre une décision quant à la qualification des singularités. Le tableau 2.1 présente l'importance de différentes notions qui peuvent être associées à une singularité. La figure 2.3 illustre, en partie, par des exemples la liste des singularités énoncées dans le tableau 2.1.

En prenant l'exemple d'un petit nœud noir, quatre notions sont employées pour le qualifier. En effet, un nœud noir est identifié grâce à :

- sa forme circulaire ou elliptique (suivant le mode de sciage d'un avivé) ;
- sa taille qui est petite si son diamètre est inférieur à 5 millimètres par exemple ;
- son contraste par rapport à la couleur du bois sain généralement plus claire (propriété non vérifiée sur des bois plus sombre comme le noyer par exemple) ;
- sa couleur qui s'approche du noir ou d'un brun très foncé.

Tableau 2.1 : Singularités du bois et caractéristiques associées (X : notion fréquemment utilisée, - : notion peu utilisée)

Nom des singularités	Notion de forme	Notion de taille	Notion de position	Notion de contraste	Notion de couleur	Notion de texture
Nœud sain	X	X	-	X	-	-
Nœud cerné	X	X	-	X	X	-
Nœud noir	X	X	-	X	X	-
Fente	X	X	-	X	-	-
Flache	X	X	X	X	X	X
Entre écorce Ecorce	X	-	-	X	X	X
Trou	X	X	-	X	-	-
Bois de compression	-	-	-	X	X	X
Aubier	-	-	X	X	X	-
Moelle Bois de coeur	X	X	X	X	X	-
Poche de résine	X	X	-	X	X	-
Bleuissement	-	X	-	X	X	-
Coloration	-	-	-	X	X	X



Figure 2.3 : Singularités du bois

La définition des singularités et leurs règles de qualification par un expert (qualification associée aux notions du tableau 2.1) permet de schématiser le fonctionnement souhaité des systèmes automatisés de tri surfacique d'avivés (figure 2.4). Un nouvel opérateur humain travaillant sur l'évaluation qualitative des avivés apprend ces mécanismes d'identification des singularités. Il doit tout d'abord être capable de reconnaître les zones de bois sain (zones ne présentant aucune singularité) pour ensuite identifier les singularités afin d'attribuer une qualité au produit. Implicitement, il suit le schéma de la figure 2.4.

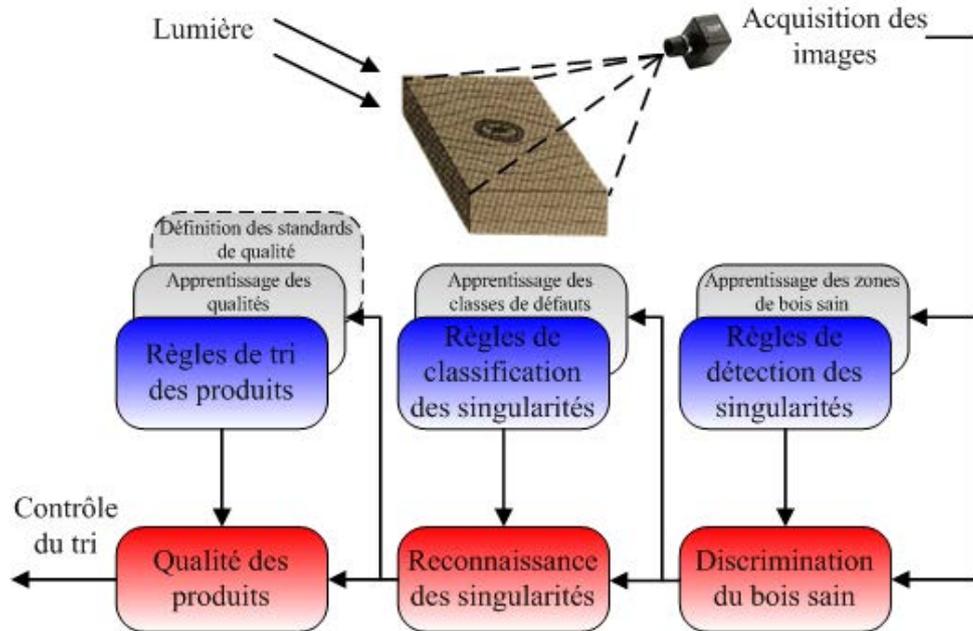


Figure 2.4 : Architecture envisagée de tri d'un produit bois selon un mécanisme automatisé

La détection automatisée de singularités peut s'effectuer de plusieurs manières. Le tableau 2.2 résume plusieurs technologies utilisées pour le contrôle surfacique du bois.

Tableau 2.2 : Contrôle surfacique du produit bois – Technologies employées et applications

<b>Références</b>	<b>Technologies (Systèmes d'acquisition)</b>	<b>Applications</b>
[CHO-91]	Caméras couleurs Caméras monochromes	Identification et localisation de quatre singularités (nœuds, trous, flaches et fentes). Différenciation des zones de bois sain et des zones défectueuses.
[CONN-92]	Caméras couleurs Caméras monochromes	Identification et localisation de singularités sur du feuillus.
[KIM-94]	Caméras monochromes	Identification de huit singularités. Classification d'avivés de chêne rouge en neuf classes.
[SCHM-95]	Caméras couleurs Caméras monochromes	Classification de produits à partir de l'identification de singularités. Analyse spatiale de la répartition des singularités.
[KAUP-99]	Caméras couleurs	Identification et localisation de singularités sans précision sur leur nombre.
[KABI-00]	Capteurs ultrasons	Détection de singularités sur du chêne rouge.
[PHAM-01]	Caméras couleurs Caméras monochromes	Caractérisation de douze singularités.
[ESTE-03]	Caméras couleurs	Caractérisation de dix singularités.
[FUNC-03]	Caméras couleurs	Détection de singularités.
[KLIN-03]	Caméras couleurs Caméras monochromes Sources lasers Rayons X	Système de classification automatique d'avivés (chêne rouge) à partir de l'identification et la localisation des singularités (le nombre de singularités à identifier n'est pas spécifié).
[FUEN-05]	Capteurs micro-ondes	Identification de nœuds à partir de signatures micro-ondes.
[RUZ-05]	Caméras couleurs	Identification de zones défectueuses possédant des propriétés différentes de celles du bois sain.
[BOMB-07a]	Caméras monochromes Sources lasers	Identification de plusieurs singularités (le nombre de singularités à différencier n'est pas précisé).

Dans ce tableau, plusieurs catégories d'applications se distinguent :

- les applications liées à l'identification et la localisation de singularités [CHO-91] [CONN-92] [KAUP-99] [KABI-00] [ESTE-03] [FUNC-03] [FUEN-05] [RUZ-05] ;
- les applications liées aux classifications d'avivés suivant des classes définies par la présence ou non de singularités [KIM-94] [SCHM-95] [KLIN-03] ;

- les applications liées à l'étiquetage de singularités [PHAM-01] [BOMB-07a].

De la même manière que pour les applications, les technologies employées permettent également de classer ces références bibliographiques. Il faut noter que l'ensemble des solutions techniques citées permet des contrôles non destructifs au sens où elles n'entraînent pas de modification physique du produit bois. Six catégories sont recensées : les caméras monochromes et couleurs, les sources lasers, les capteurs ultrasons, les capteurs micro-ondes et les rayons X. Chacun d'entre eux possède ses propres avantages.

Les rayons X fournissent des radiographies des produits bois scannés. Ces images caractérisent les zones de fortes et faibles densités [KLIN-03]. Les capteurs micro-ondes délivrent des signatures internes des pièces de bois [FUEN-05] et représentent une alternative aux rayons X parfois plus coûteux. Leur fonctionnement est basé sur l'analyse de la propagation des ondes électromagnétiques dans le produit. Sur le même principe d'analyse, les capteurs ultrasons sont utilisés pour évaluer la propagation des ondes dans le bois [KABI-00]. En fonction des temps de propagation, il est alors possible de définir la présence de zones de densité plus ou moins forte. Les caméras, quant à elles, fournissent des images telles des photographies. Deux grandes catégories se distinguent : les caméras couleurs [KAUP-99] [ESTE-03] [FUNC-03] [RUZ-05] et les caméras monochromes [KIM-94] [BOMB-07a]. Le choix de la caméra se fera alors suivant les propriétés des singularités à identifier. Enfin, des sources lasers couplées à des caméras monochromes sont utilisées pour caractériser les propriétés physiques du bois par l'effet de propagation de la lumière laser dans les fibres [KLIN-03] [BOMB-07a]. Cette propagation se nomme plus communément « effet scatter » (figure 2.5).

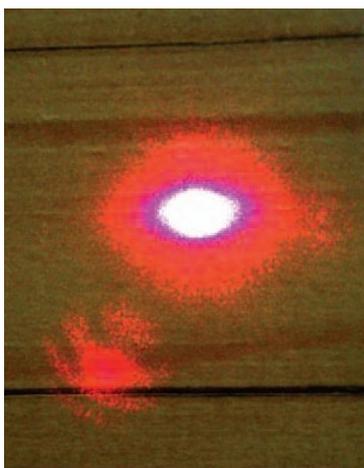


Figure 2.5 : Effet scatter – Diffusion de la source laser dans le bois en fonction de sa densité ou du sens du fil

Afin d'obtenir une représentation la plus fiable et la plus complète d'un produit, Kline *et al.* ont développé un système regroupant plusieurs de ces capteurs (caméra couleurs, caméra monochromes, sources lasers, rayons X) [KLIN-03] afin d'améliorer la détection des zones défectueuses par rapport à des systèmes plus simples utilisant uniquement des caméras couleurs.

### **2.1.2. La reconnaissance des couleurs et du grain**

La reconnaissance des couleurs et du grain dans l'industrie du bois est très souvent assimilée à la notion d'appariement. Cela signifie que le procédé mis en œuvre cherche à rapprocher les différents produits d'une ou plusieurs classes prédéfinies. Le but est d'uniformiser des lots de pièces suivant ces notions d'un point de vue esthétique. La difficulté majeure de ce traitement concerne l'aspect de surface du bois. En effet, le matériau bois présente un grand nombre de variabilités esthétiques, qu'elles soient dues au grain ou à la présence de différentes couleurs. Plusieurs études ont été réalisées pour répondre au problème d'appariement ou de classification colorimétrique d'avivés. Trois grandes catégories se distinguent :

- les articles qui abordent uniquement le tri colorimétrique d'avivés [LU-97a] [SRIK-97] [DAUL-00] [SATH-01] [LIU-02] ;
- les articles qui abordent uniquement le tri des grains du bois présents sur des avivés [HANB-01] ;
- les articles regroupant les deux notions au sein d'une même [KLIN-99] [HANB-02] [MAEN-03].

Le tableau 2.3 illustre les différentes applications en rapport avec l'aspect esthétique des produits bois. En comparaison avec la classification de singularités, très peu d'études ont été menées sur la reconnaissance des couleurs et du grain sur le matériau bois.

Concernant le tri colorimétrique des avivés, le chêne rouge, le merisier et le cerisier sont les trois types d'essence classiquement étudiées. De plus, les gammes de couleur restent assez proches les unes des autres (du clair au foncé suivant les teintes rouge et brune). La perception humaine de ces couleurs peut être influencée par le grain du bois. En effet, en fonction du mode de débit d'une grume, plusieurs dessins peuvent apparaître sur les avivés. Cela correspond à la disposition spatiale du veinage du bois. La figure 2.6 illustre les différents modes de débit qui sont les trois classes de grain les plus étudiées (dosse, quartier et faux-quartier) [KLIN-99] [HANB-01] [HANB-02] [MAEN-03].

Tableau 2.3 : Classification de couleurs et de grains sur un produit bois

Types de classification	Références bibliographiques	But de l'étude
Couleur	[LU-97a] [SRIK-97]	Tri de planches de bois pour la confection de panneaux homogènes en couleur.
	[DAUL-00]	Classification colorimétriques de planches de bois.
	[SATH-01]	Classification colorimétriques de panneaux homogènes constituant des meubles de cuisine.
	[LIU-02]	Caractérisation quantitative des variations de couleur sur une surface.
Grain	[HANB-01]	Description quantitative du grain du bois.
Couleur et Grain	[KLIN-99]	Tri de planches de bois pour la confection de panneaux homogènes en couleur et en grain.
	[HANB-02]	Tri de planches de bois pour la confection de panneaux homogènes en couleur et en grain.
	[MAEN-03]	Optimisation des caractéristiques de couleur et de grain pour l'inspection visuelle du bois.

Toutes les études présentées sur la classification des couleurs et des textures dans le domaine du bois souffrent cependant d'un manque de pertinence par rapport aux traitements réalisés à la main. Cela se traduit généralement par la divergence entre les interprétations pouvant être faite par les experts « bois » et les experts des systèmes de vision. En effet, aucune des techniques de vision ne reprend les connaissances des experts « bois » concernant les modes de tri des avivés. La qualification des classes de sortie étant soumise à la subjectivité des opérateurs humains, il est très difficile d'exprimer les connaissances bois en termes de vision. Ainsi, une certaine quantité d'imprécisions et d'incertitudes liées au vocabulaire employé pour exprimer les différentes classes à identifier apparaît.

En approchant les deux domaines, que sont l'expertise bois et l'expertise vision, nous nous rendons compte qu'il existe un fossé sémantique entre les définitions des classes de sortie par les deux domaines. En effet, une teinte de bois peut être définie par un expert bois à partir de symbole linguistique (« Rouge », « Brun », ...), alors qu'un expert vision préfère par exemple lui associer un angle en coordonnées polaires ou encore un triplet de valeur numérique dans le repère colorimétrique RVB par exemple (« rouge » = {R : 255, V : 0, B : 0}) (valeur numérique). Ce fossé sémantique est constaté dans beaucoup d'autres applications de vision où l'être humain est acteur et notamment dans le domaine médical [HUDE-06].

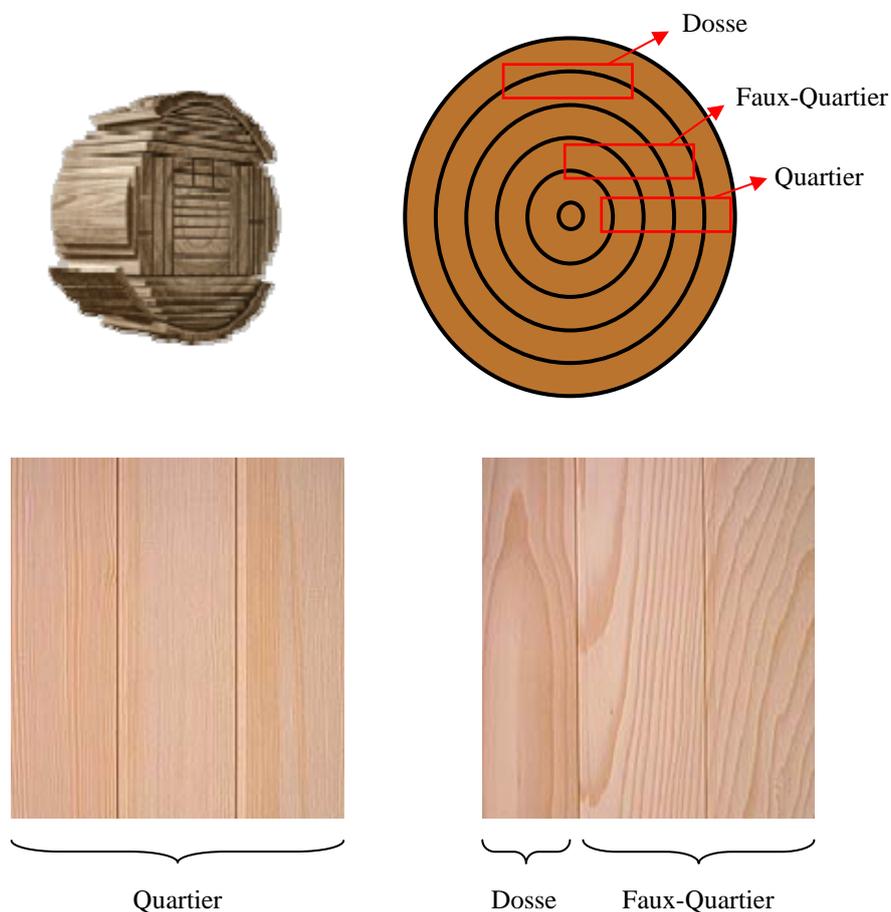


Figure 2.6 : Origine des textures du bois

### 2.1.3. Le besoin de systèmes industriels de vision

En se plaçant dans un contexte purement industriel, l'utilisation de systèmes automatisés possède un avantage majeur en termes de rendement matière. En effet, en considérant le domaine du bois, les opérateurs doivent, en un seul coup d'œil, examiner les différentes faces d'un avivé pour en déterminer la qualité. Les cadences de qualification sont généralement de l'ordre de 10 planches par minute et ceci plusieurs heures par jour. En considérant des avivés de longueur fixe d'environ 1 mètre et en considérant une journée de travail de 8 heures, un opérateur qualifiera 4800 mètres de bois linéaire. Il est donc évident qu'une certaine lassitude et/ou une certaine fatigue interviennent dans les tris effectués par l'homme. La qualité de la production peut alors décroître durant les dernières heures de la journée. Le premier intérêt d'utiliser un système artificiel de vision consiste donc à réduire les erreurs de qualification et

à accroître les cadences de traitements tout en gardant une forte qualité dans la production. Pour avoir une idée des performances envisageables, il faut savoir que les systèmes industriels actuellement sur le marché permettent de traiter environ 35000 mètres de bois linéaire pour 8 heures de travail. Cela représente un net accroissement de la production (un système automatisé équivaut à environ 7 opérateurs) tout en gardant une qualité constante des produits.

Il ne s'agit cependant pas là du seul avantage à développer des systèmes automatisés. Dans le cas de la qualification des couleurs sur des avivés, nous avons vu que la décision prise par l'opérateur humain est fortement liée à la perception qu'il peut avoir. Le cerveau humain, qui réalise l'interprétation des couleurs visualisées, peut donc induire des imprécisions dues à la perception. Cette interprétation peut être ambiguë. Des illusions interviennent dans les mécanismes visuels, pouvant être causées par une fatigue de la vue. Ainsi, un être humain ne caractérise pas la couleur d'un objet en faisant abstraction de la scène qui l'entoure (figure 2.7).

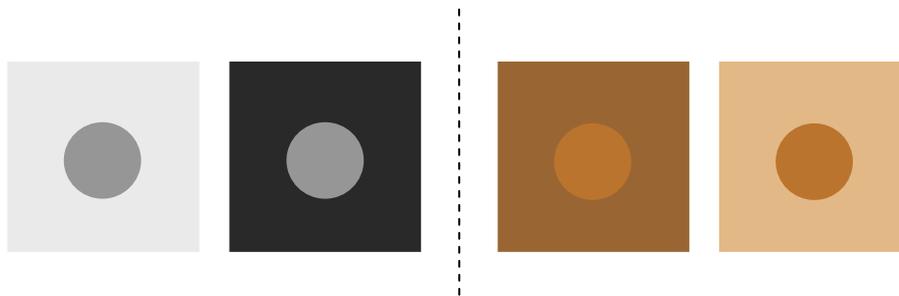


Figure 2.7 : Influence de l'environnement d'une couleur sur sa perception par l'œil humain

En reprenant les exemples de la figure 2.7, le même cercle gris paraît plus clair dans un environnement sombre et plus foncé dans un environnement clair. Il en est de même pour un même cercle de couleur brune. Il est donc aisé de comprendre l'avantage des systèmes de vision artificielle. En effet, ils sont dépourvus de subjectivité lors de l'acquisition des images et sont en partie épargnés par la fatigue que peut ressentir un opérateur. Ces systèmes sont alors considérés comme visuellement passifs dans le sens où ils n'agissent pas directement sur la scène observée.

La perception visuelle est caractérisée plus précisément par l'acquisition de connaissances concernant l'objet considéré. Elle est donc très différente des traitements optiques comme la photographie qui permet uniquement de reproduire et figer une scène. Une activité cognitive intervient dans le sens où l'être humain opère un raisonnement sur les images acquises. L'interprétation d'une scène et l'extraction de connaissances associées sont sujettes à la subjectivité des individus. L'inspection du bois est un domaine dans lequel se retrouvent ces mécanismes subjectifs. En effet, Grönlung observe une différence dans la classification réalisée par plusieurs opérateurs [GRÖL-95]. Seules 60% des décisions sont similaires entre deux individus. Ce point illustre la grande différence qui peut exister entre un œil et une caméra. Cette divergence de décisions prouve l'importance du développement de

systèmes automatisés permettant d'accroître la reproductibilité des qualifications visuelles. L'enjeu est donc d'intégrer la notion d'extraction de connaissance aux systèmes de vision artificielle sans pour autant injecter la subjectivité des raisonnements humains liés aux décisions. La définition de Zeller concernant la vision artificielle peut alors être reprise [ZELL-96] :

*« L'objet de la vision par ordinateur est l'étude de l'art et de la manière d'obtenir des informations sur notre environnement à partir de capteurs passifs visuels ou caméras. »*

La décision finale étant prise par le client (homme en fin de chaîne de production), il est nécessaire de prendre en compte son « avis ». Le classement automatique obtenu doit donc être compatible avec les désirs du client. Ne pouvant pas prétendre imiter totalement un être humain dans un système de vision, il est intéressant de chercher à tenir compte du point de vue des deux domaines d'expertise afin de réduire le fossé sémantique existant. Pour ce faire, il est possible de spécialiser les traitements des systèmes de vision artificielle pour l'appariement de pièces de bois selon des critères esthétiques, tout en tenant compte des critères d'inspection manuelle. Afin de positionner cette proposition, nous allons rappeler les fondements du traitement d'images et de la reconnaissance de formes adaptés aux systèmes de vision.

## **2.2. Inspection par reconnaissance de formes**

L'inspection visuelle automatisée fait appel à de nombreuses connaissances en traitement d'images et en reconnaissance de formes. Cette partie présente les structures et les techniques employées pour développer un tel système. Les apports de l'utilisation de la couleur dans un milieu industriel sont précisés et étayés par une illustration des traitements possibles à travers quelques exemples tirés de la littérature.

### **2.2.1. L'inspection visuelle automatisée**

L'inspection dans un contexte industriel correspond à un processus de validation des produits par rapport à leurs spécifications [NEWM-95]. En parlant d'inspection visuelle automatisée, il s'agit d'analyser les informations perçues par le système de vision. Les analyses effectuées concernent essentiellement le contrôle qualité des produits. Cependant, il existe quatre types de contrôle qui nécessitent souvent une connaissance *a priori* sur le produit (il s'agit généralement des spécifications du produit), les trois premiers étant largement utilisés dans le domaine du bois (voir section 2.1) :

- un contrôle structurel qui permet d'informer sur les caractéristiques intrinsèques d'un produit ;
- un contrôle surfacique ou superficiel qui permet d'assigner et/ou de vérifier la qualité externe d'un produit ;
- un contrôle géométrique qui permet d'évaluer les caractéristiques géométriques (taille, forme, poids, ...) d'un produit ;

- un contrôle opérationnel qui permet de valider le produit face à ces spécifications.

Classiquement, ces contrôles se réalisent à différents niveaux du processus industriel : en entrée de chaîne sur les produits bruts, au milieu d'un processus afin de valider des produits intermédiaires, et en fin de chaîne sur le produit final (figure 2.8). Dans le cadre des trois cas applicatifs introduits, le contrôle intervient soit sur des produits intermédiaires (cas applicatifs 1 et 2), soit sur des produits finis (cas applicatif 3).

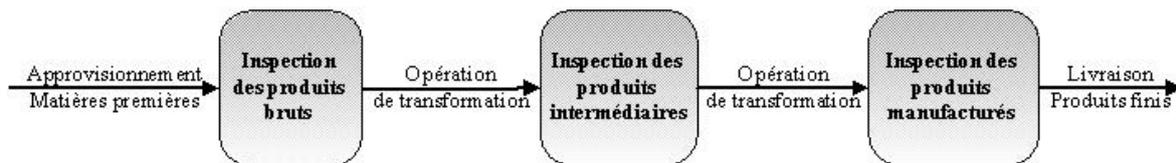


Figure 2.8 : Positionnement des inspections intervenant sur une chaîne de production

L'inspection visuelle automatisée est basée sur l'utilisation d'un système de vision artificielle. Deux catégories de système se distinguent : les systèmes intelligents (qui fournissent une décision) et les systèmes uniquement perceptifs (qui fournissent uniquement des données brutes). Cette dichotomie est principalement faite à partir des traitements qui sont réalisés sur les informations acquises. Dans un cadre industriel, un système de vision fait intervenir des parties matérielles et logicielles [MALA-03]. La figure 2.10 illustre la structure du fonctionnement d'un capteur de vision artificielle.

Le traitement d'images se décompose en trois niveaux principaux : les traitements de bas niveau, de niveau intermédiaire et de haut niveau (figure 2.9). Le but, en associant ces trois parties, est de réduire l'information acquise à la seule information qualitative utile au système. Le bas niveau regroupe les parties *acquisition de données* et *pré-traitements* de la chaîne de traitement d'images ; le niveau intermédiaire reprend les parties *segmentation*, *représentation* et *description*, alors que le haut niveau concerne plus l'*interprétation* et la *décision* à partir d'un ensemble de connaissances énoncées par les experts [DERU-97]. Ce dernier niveau doit servir à réduire l'erreur d'interprétation des données quantitatives afin de fournir une décision qualitative.

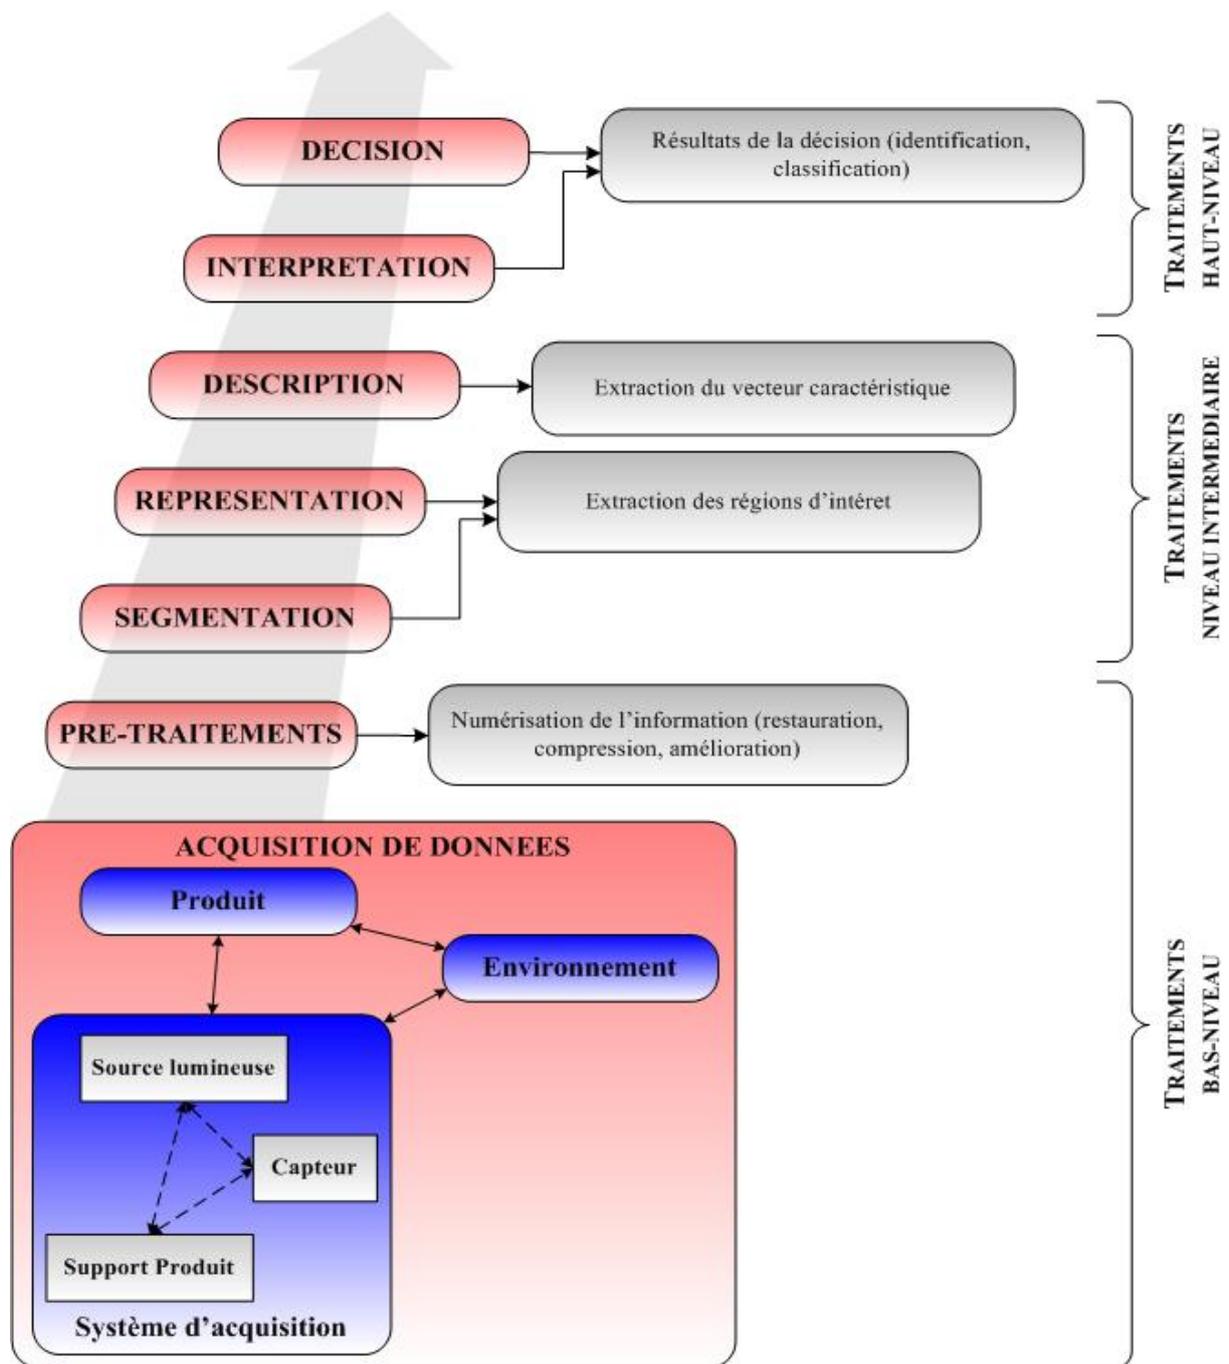


Figure 2.9 : Chaîne de traitement de l'image contenue dans un système de vision artificielle

- **Les traitements de bas niveau**

L'*acquisition de données* ou acquisition d'images est une composante essentielle d'un système de vision artificielle. En effet, elle fournit une représentation de la scène observée. Si des informations ne sont pas acquises au moment de la prise de vue, elles ne pourront être générées en vue des traitements. Il s'agit cependant d'une partie très spécifique, dépendante du produit observé, du contexte d'observation et de la finalité. Comme nous le montrons dans la suite de ce mémoire (chapitre 3), les conditions d'illumination sont importantes et doivent être maîtrisées durant cette phase d'acquisition de données [HEAL-92]. Une fois les images transmises à l'unité de traitements, une chaîne classique de traitement d'images est employée [ROSE-01].

Les *pré-traitements* des images acquises permettent d'isoler les informations utiles et pertinentes. Il s'agit, la plupart du temps, d'opération de restauration (filtrage du bruit), d'amélioration (renforcement des contrastes), ou de compression (réduction de la taille des images en vue d'un stockage ou d'un transfert). Ces actions effectuées directement sur les informations brutes (matrice de pixels, représentation fréquentielle des données par transformée de Fourier) sont déterminées en fonction du contexte d'utilisation des images. Pour compléter cette présentation succincte, l'ensemble de ces techniques peut être consulté dans l'ouvrage de référence de Gonzalez et Woods [GONZ-02].

- **Les traitements de niveau intermédiaire**

La *segmentation* se réalise de différentes manières suivant la définition qui en est prise. Généralement, cette étape sert à distinguer les différentes entités qui constituent une image. Ces objets possèdent des caractéristiques intrinsèques similaires mais sont tous différents les uns des autres. Le résultat de cette analyse est souvent appelé description structurelle de l'image. Deux grandes catégories de traitements sont utilisées à ce stade :

- les techniques basées sur la recherche de transition : les approches « contours » ;
- les techniques basées sur la recherche d'homogénéité : les approches « régions ».

Dans le premier cas, il s'agit de localiser les discontinuités présentes dans une image à partir de l'étude de la connexité de chaque pixel. Cela définit des frontières entre des zones supposées différentes. Les principaux algorithmes utilisés à ce niveau sont ceux qui implémentent des calculs de gradients. Parmi eux, les algorithmes de Sobel, Canny-Dérivée, Prewitt peuvent être cités [COCQ-95]. Dans le cas de la segmentation par identification de régions, il faut localiser les zones d'intérêt (ROI : Regions Of Interest en anglais) qui correspondent aux différents objets qui composent la scène. Les techniques employées reposent plus sur la recherche de continuité des caractéristiques entre des pixels connexes. Plusieurs méthodes de détection de régions peuvent être recensées : la classification par seuillage d'histogramme appliquée sur une ou plusieurs propriétés de chaque pixel [DAI-96],

l'algorithme « *split and merge* » reposant classiquement sur des divisions géométriques de l'image [SALA-99], les pyramides irrégulières adaptatives et stochastiques qui réalise une agglomération de pixels suivant des règles de fusion préalablement définies [JOLI-92]. Les résultats obtenus par une segmentation correspondent donc à une **représentation** fiable des éléments qui composent une scène. La **description** correspond, quant à elle, à l'extraction de données numériques quantitatives à partir des régions préalablement distinguées.

- **Les traitements haut-niveau**

Les traitements de haut niveau (**interprétation** et **décision**) font souvent référence au vaste domaine de la reconnaissance de formes (RdF). Dans ce cadre, une forme correspond à toutes sources pouvant être identifiées par une technique de classification à partir d'une ou plusieurs variables (ou paramètres) de nature homogène ou non [NEWM-95]. La RdF répond toujours au même schéma (figure 2.10). Elle fait intervenir généralement six concepts distincts :

- le vecteur caractéristique constitué de paramètres numériques (attributs ou primitives) qui décrivent une forme ;
- les méthodes de classifications qui regroupent les différentes formes suivant leurs propriétés communes ;
- les méthodes de discrimination qui permettent de prendre une décision sur une forme ;
- les symboles qui correspondent à l'étiquetage d'une forme ;
- les classes qui représentent les choix possibles de l'étiquetage ;
- les prototypes ou représentants qui constituent les éléments d'une classe.

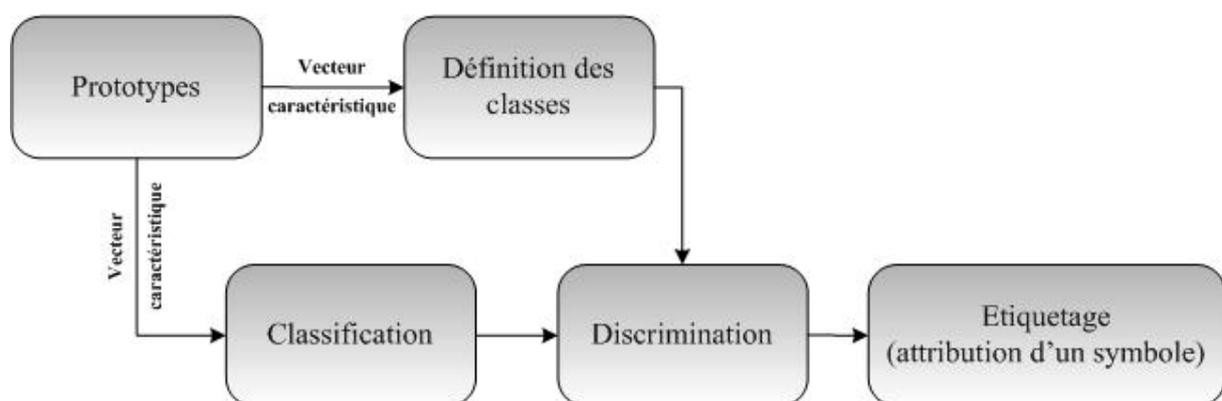


Figure 2.10 : Principe de reconnaissance de formes

Deux grandes étapes peuvent être distinguées dans la reconnaissance de formes : l'extraction de paramètres pertinents qui définissent le vecteur caractéristique et la classification/discrimination des formes (identification des classes) [DUBU-90].

Pour qu'un système reconnaisse des objets, il faut disposer d'exemples de formes triées en fonction de leurs propriétés. Il s'agit là de la définition des classes qui induit la notion d'apprentissage. Au niveau de l'apprentissage, deux catégories de représentation d'une classe se distinguent :

- en intension : la représentation des classes se fait par une composition de plusieurs propriétés des formes, par un langage défini dans le cadre de l'étude, par un graphe ou par l'utilisation d'un sous-espace de l'ensemble des propriétés de la forme. Dans ce cas, les classes sont définies par leurs frontières ;
- en extension : la représentation des classes se fait par l'utilisation d'un ou plusieurs prototypes de chaque classe. Dans ce cas, les classes sont définies à partir de leur centre.

Ces classes ainsi constituées sont différenciables par des attributs calculés sur ou à partir des formes (descripteurs ou primitives). L'extraction de caractéristiques permet alors de réduire la complexité des données issues de la segmentation. Elles décrivent de manière plus ou moins discriminante des formes n'appartenant pas à une même classe.

Une fois le vecteur caractéristique généré, deux solutions sont envisageables pour effectuer la classification.

D'une part, la classification supervisée repose sur l'utilisation d'un ensemble de prototypes étiquetés par un expert du domaine. Un apprentissage des différentes classes est alors effectué afin de travailler avec des références de comparaison pour identifier les formes dites « inconnues ». En fait, cette étape doit permettre la généralisation de l'information contenue dans les données caractéristiques afin d'obtenir une représentation fiable et robuste des différentes classes (minimisation du taux d'erreur d'étiquetage).

D'autre part, la classification non supervisée repose sur l'utilisation d'un lot d'échantillons non étiquetés. L'apprentissage, dans ce cas, nécessite la définition d'un critère d'évaluation de la variabilité intraclasse afin de construire des partitions de l'espace des réalisations possibles. Ce type d'apprentissage est utilisé notamment dans le cas où nous manquons de connaissance exprimée par des experts.

Dans notre cas d'étude, le système doit répondre aux desiderata des utilisateurs. Le système automatisé doit donc effectuer une reconnaissance de formes à partir d'échantillons préalablement étiquetés par un individu (apprentissage supervisé). Cet étiquetage est réalisé pour répondre aux besoins d'apprentissage et de validation de la reconnaissance.

L'ensemble des mécanismes de décision découle des raisonnements de l'expert qui spécifie les modes de représentation des formes considérées. Il faut donc prendre en compte

les raisonnements d'un individu, en le traduisant sous la forme de base de connaissances. Ainsi, les procédés d'identification sont fondés sur un traitement collaboratif entre les données perçues et les connaissances recensées [CLAR-04].

### 2.2.2. Les algorithmes de classification

Il existe de nombreuses techniques de classification/discrimination. Néanmoins, elles possèdent toutes un point commun : le système doit évaluer un critère et déterminer un coefficient de confiance caractérisant la décision prise. Suivant les applications, il faut donc trouver un compromis entre le risque d'erreur et le coût de ces erreurs. En recoupant les études de Milgram [MILG-93] et, Newman et Jain [NEWM-95], ces algorithmes de classification peuvent être groupées suivant trois catégories :

- les méthodes, dites d'appariement, qui permettent d'identifier des objets inconnus en les comparant à des exemples ;
- les méthodes syntaxiques et structurelles qui permettent de classer les objets suivant un ensemble de descriptions sur la structure des objets appris ;
- les méthodes globales qui utilisent les caractéristiques numériques extraites d'un objet.

La figure 2.11 illustre la taxinomie qui peut être faite sur les différentes méthodes citées.

Les *méthodes par comparaison directe* sont basées sur l'utilisation de formes de référence. Ces dernières servent alors de point de comparaison par rapport aux objets à classer. Les appariements sont effectués par ressemblance ou dissemblance par rapport aux modèles. Deux sous-catégories sont présentées : le « template matching » et l'« elastic matching ». Dans le premier cas, les formes à reconnaître ne subissent pas de déformation. Les modèles permettent alors d'évaluer directement les critères de correspondance : les mesures de dissemblance tels que les distances (Euclidienne, Hamming, Mahalanobis, ...) ou les critères de similarité (Jaccard, Yule, ...), les mesures de ressemblance telle que l'inter-corrélation. Dans le deuxième cas, les formes à identifier peuvent subir des déformations pour qu'elles s'apparentent au mieux aux modèles. La ressemblance est alors évaluée par rapport au taux de déformation qu'a subi la forme « inconnue ».

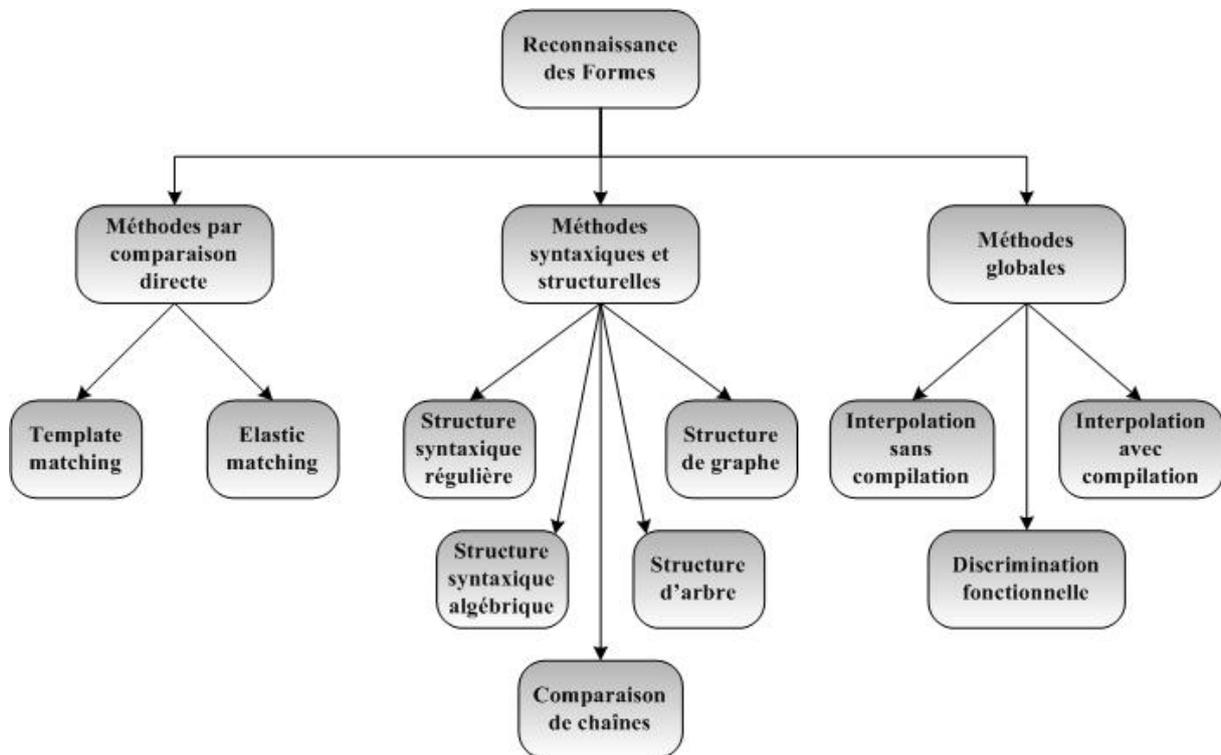


Figure 2.11 : Les approches de traitements haut-niveau

Les *méthodes syntaxiques et structurelles* reposent sur la structure même des objets à identifier. En effet, la reconnaissance se fait à partir de l'analyse d'une suite de primitives pouvant être représentée par des graphes, des arbres, des chaînes ou même l'utilisation d'une syntaxe (définition d'un vocabulaire et d'une grammaire associée). Dans les trois premiers cas, il s'agit de définir des relations entre les différentes primitives afin de minimiser l'écart avec les formes de référence. Dans le cas de l'utilisation d'une syntaxe, les formes qui constituent le modèle ou qui doivent être identifiées sont décomposées en éléments simples (primitives). Ces éléments définissent alors le vocabulaire qui est ensuite utilisé pour composer des phrases représentatives des formes. Ce processus définit ensuite une grammaire type des objets appris. La reconnaissance d'une forme s'effectue enfin par une comparaison de la définition syntaxique de la forme par rapport à la grammaire type.

Les *méthodes globales* exploitent une réduction de l'espace de représentation des objets utilisé par les méthodes d'appariement. En effet, les propriétés des objets sont décrites sous une forme vectorielle. Il s'agit de la définition du **vecteur caractéristique** qui constitue l'ensemble des paramètres caractérisant les objets à reconnaître. Cela permet alors d'établir des groupements de formes similaires afin de définir les classes de sortie. Ces classes peuvent être discriminées de trois manières.

- Par discrimination fonctionnelle (apprentissage en intension) : il s'agit de représenter les limites qui existent entre les classes, et de les caractériser sous la forme d'hyperplans dans  $\mathcal{R}^n$  ( $n$  étant le nombre de paramètres du vecteur caractéristique).
- Par interpolation sans compilation (apprentissage en extension) : il s'agit d'utiliser les représentants ou prototypes de chaque classe comme un unique point de l'espace de représentation.
- Par interpolation avec compilation (apprentissage en extension) : il s'agit de réduire la définition des classes à une seule information caractérisant l'ensemble des prototypes constituant ces classes (généralement le centre d'une classe).

L'ensemble de ces techniques se dérivent de différentes manières suivant la conception des modèles de reconnaissance, qu'elle soit floue, probabiliste ou connexionniste.

Les méthodes probabilistes sont basées sur le théorème de Bayes qui minimise la probabilité d'erreur globale [DUDA-73]. Les décisions sont prises à partir de l'estimation des densités de probabilités de chaque classe définie (méthode par interpolation avec compilation). Cependant, les données utilisées doivent répondre à certains critères pour que la méthode soit robuste : même vecteur caractéristique constitué des mêmes paramètres, des classes de sortie bien distinctes, des lois de probabilités connues. Si ces conditions ne sont pas remplies, nous utilisons des méthodes non-paramétriques, bayésiennes ou non, telles que les fenêtres de Parzen ou les  $k$  plus proches voisins (méthodes par interpolation sans compilation). Ces techniques ont l'avantage d'être moins sensibles à la forme des représentations des classes de sortie.

Les réseaux de neurones (ou approches connexionnistes), quant à eux, sont basés sur le principe de fonctionnement du cerveau. Ils sont constitués d'éléments unitaires appelés neurones qui sont interconnectés entre eux sous la forme d'un réseau. Ces éléments sont structurés suivant des couches. Il existe trois types de couches : la couche d'entrée associée aux paramètres du vecteur caractéristique, la couche de sortie représentant les classes à reconnaître, et les couches cachées qui définissent le cœur du réseau. Chaque neurone se trouve associé à un poids d'activation qui est préalablement déterminé à partir d'un lot d'apprentissage en minimisant l'erreur de classification. Ils sont largement utilisés dans le domaine de la vision industrielle [MALA-03]. Ils possèdent néanmoins un inconvénient quant à leurs mécanismes de fonctionnement. En effet, il n'est pas possible d'interpréter exactement le fonctionnement dans les couches cachées des réseaux. Ils agissent comme une « boîte noire ». De plus, ces algorithmes nécessitent un très grand nombre de données pour l'apprentissage (chapitre 4). Enfin, il est très difficile de choisir les paramètres de réglages des réseaux de neurones (nombre de couches cachées et nombre de neurones par couche).

Avec l'introduction de la logique floue par Zadeh en 1965 [ZADE-65], de nouveaux mécanismes de classification sont apparus. Toutes les techniques évoquées ont été étendues à la théorie des ensembles flous :  $k$  plus proches voisins flous,  $k$ -moyennes floues, réseaux de neurones flous, ..., afin de mieux prendre en compte les raisonnements humains.

Cependant, Mingoti et Lima notent le peu de différence existant au niveau des taux de reconnaissance entre un mécanisme de classification implémentant un réseau de neurones et un classificateur k-moyennes floues [MING-06]. Cordon *et al.*, quant à eux, marquent les faiblesses de la phase d'apprentissage des techniques de classification à base de logique floue [CORD-04]. Ils établissent un état de l'art des techniques génétiques permettant d'améliorer cette étape.

Pourtant, en utilisant des classificateurs à bases de règles floues reprenant les connaissances expertes de l'environnement industriel, l'ensemble des mécanismes internes au système peut être interprété, chose n'étant pas le cas pour les réseaux de neurones.

Les ensembles flous, dans le cadre de la classification, peuvent être considérés comme une extension des ensembles classiques, au sens où il est possible de prendre en compte des recouvrements d'espaces de représentation. Ces mécanismes permettent de travailler à partir de données imprécises, et/ou incertaines, reflète des connaissances exprimées par les experts « bois » (connaissances liées au produit bois) et « vision » (connaissances liées au système de vision), et/ou provenant directement des mesures.

### **2.2.3. La couleur dans un processus industriel « bois »**

L'utilisation de la couleur dans un milieu industriel est de plus en plus fréquente. Les industries du bois n'échappent pas à cette tendance. Ce passage de la vision monochrome à la vision couleur s'explique par les niveaux de détails recherchés lors des contrôles visuels des produits manufacturés. La prise en compte de la couleur accroît les possibilités des systèmes visuels en terme de précision et de discrimination. Cependant, l'extraction des formes couleurs doit être compatible avec les contraintes de l'environnement industriel. Les techniques mises en œuvre ne doivent pas être trop coûteuses en temps de calcul et en mémoire.

Classiquement, plusieurs points sont alors à expliciter lors de la conception d'un système de vision : les techniques de caractérisation regroupant le matériel utilisé et l'espace de représentation, les méthodes de classification.

- **Les capteurs et les modes de représentation des couleurs**

Deux capteurs sont couramment employés pour numériser et quantifier un objet coloré : les caméras multispectrales (ou multibandes), et les caméras couleurs. Dans le premier cas, la couleur est caractérisée par l'intensité de plusieurs bandes spectrales ayant des longueurs d'onde comprises entre 300nm et 700nm. Dans le deuxième cas, les composantes colorimétriques RVB (Rouge, Verte et Bleue) fournies par la caméra représentent une composition de toutes les bandes spectrales. Dans ce cas, les informations couleur extraites sont fortement corrélées.

Le choix de la caractérisation de la couleur se fait souvent suivant les niveaux de détails et de précision recherchés dans une image. Le plus simple consiste à utiliser les composantes

colorimétriques de manière séparée, composantes pouvant être différentes suivant le repère colorimétrique choisi. Le repère RVB est classiquement utilisé mais ne fournit pas toujours la meilleure information (chapitre 3).

Même si les ordinateurs actuels permettent de gérer de grande quantité de données, le volume d'informations à traiter est important pour des images de grandes tailles. Il existe alors la possibilité de travailler sur des données statistiques liées à la couleur : la moyenne, l'écart type, le degré d'asymétrie (skewness), le degré d'écrasement (kurtosis), les maxima et minima locaux ou globaux, ... Ces données sont évaluées à partir de l'histogramme de chaque composante. Un deuxième aspect peut avoir son importance dans la caractérisation de la couleur : sa répartition spatiale. Le terme souvent employé pour désigner cette distribution spatiale est le mot « texture ». Plusieurs exemples de reconnaissance de couleur sont présentés dans la suite de ce paragraphe.

Les travaux de Swain et Ballard ont été repris de nombreuses fois pour réaliser la reconnaissance d'objet suivant leur couleur [SWAI-91] [GEVE-99]. Dans ces articles, la caractérisation de la couleur se fait par l'intermédiaire d'un histogramme à trois dimensions (trois composantes colorimétriques). Cette représentation paraît complexe de part la quantité d'informations qu'elle contient. C'est pourquoi, en fonction du degré de complexité des traitements envisagés, il est possible de n'utiliser que des représentations monodimensionnelles [PIET-96]. L'utilisation de tels descripteurs pour définir une couleur pose cependant un problème de taille et de temps dans un système de vision industrielle. Les traitements doivent être suffisamment rapide pour répondre aux contraintes de temps industrielles.

Dans ce type d'environnement, les perturbations pouvant nuire à la précision des données sont très présentes. La plus évidente concerne l'illuminant de la scène observée. En effet, une variation de ce dernier peut modifier considérablement l'allure des histogrammes. Ainsi, pour éviter ces désagréments, Tan et Kittler ont préféré calculer des descripteurs de répartition spatiale de la couleur qui sont indépendants d'une variation de l'illuminant [TAN-93]. Les valeurs obtenues correspondent en fait à l'énergie et à l'entropie des histogrammes sur chaque composante. D'autres représentations spatiales peuvent être utilisées pour caractériser une couleur, l'utilisation des champs de Markov en est un exemple. Leur principal intérêt concerne leur aptitude à prendre en compte les dépendances spatiales de chaque pixel ou objet d'une image [BENB-05].

- **Les méthodes de classification des singularités à partir des systèmes d'acquisition couleur**

Le contrôle qualité dans les industries du bois étant plus développé dans le cadre de la détection de singularité (section 2.1.1), nous proposons un classement des systèmes implémentant un capteur couleur suivant les grandes catégories de techniques de reconnaissance de formes (tableau 2.4).

Tableau 2.4 : Méthodes de reconnaissance des singularités du bois

Nature du classificateur	Type de classificateur	Références
Méthodes globales avec compilation et sans compilation	Réseaux de neurones k plus proches voisins	[CHO-91]
Méthodes globales avec compilation	Réseaux de neurones	[SCHM-95]
Méthodes globales avec compilation	Réseaux de neurones	[KAUP-99]
Méthodes globales avec compilation	Réseaux de neurones	[PHAM-01]
Méthodes globales avec compilation	Réseaux de neurones Algorithmes génétiques	[ESTE-03]
Méthodes globales avec compilation	Base de règles floues	[KLIN-03]
Méthodes globales avec compilation	Réseaux de neurones flous	[RUZ-05]

Parmi les systèmes de vision intégrant un capteur couleur adapté à la classification des singularités du bois, beaucoup d'études utilisent des réseaux de neurones. Le côté « boîte noire » ainsi que la facilité de mise en œuvre dans la plupart des cas justifient ce choix.

En s'attardant sur ces études, nous constatons que les résultats obtenus sont encourageants (taux de reconnaissance supérieur à 80% pour chaque étude). Cependant, il subsiste quelques zones d'ombre quant à ces performances. Tout d'abord, il est très difficile de juger de ces résultats du fait du manque d'informations sur les lots d'apprentissage et les singularités à reconnaître. Seuls Pham et Sagiroglu explicitent le nombre d'échantillons d'apprentissage (186 échantillons répartis suivant treize classes) et obtiennent 87% de bonnes reconnaissances [PHAM-01]. En revanche, Cho *et al.* exposent une méthode validée par un taux de reconnaissance en généralisation de 80.9% sur cinq classes de singularités, sans donner d'explications sur la constitution des lots d'apprentissage [CHO-91]. Enfin, Estevez *et al.* proposent de très bons résultats (80% de bonne reconnaissance) à partir d'un lot de données conséquent (12000 échantillons d'apprentissage répartis en onze classes) [ESTE-03]. Dans ce cas, il est très difficile de conclure sur les résultats énoncés, sachant que les méthodes neuronales sont connues pour être très performantes si elles disposent de beaucoup de points en apprentissage pour chacune des classes, avec une distribution homogène entre les classes. Ces résultats semblent être intéressants mais souffrent d'un manque de validation dans un environnement industriel, pour lequel il est très difficile d'obtenir 12000 échantillons correctement étiquetés de la part des clients. Cette phase d'étiquetage est en effet longue et fastidieuse, et coûteuse en heures/homme. De plus, malgré les performances atteintes, l'interprétabilité des mécanismes de décision de ces méthodes est totalement omise. Il est très difficile de comprendre comment le résultat est obtenu, les réseaux de neurones fonctionnant comme une boîte noire (Estevez *et al.* implémente un réseau composé d'une couche cachée, elle-même composée de 60 neurones [ESTE-03]).

- **Les méthodes de classification des couleurs dans les industries du bois**

En reprenant les références bibliographiques traitant du sujet de la classification des couleurs et des textures sur le bois, il est également possible de présenter les techniques de reconnaissance employées. Le tableau 2.5 illustre les différentes méthodes rencontrées dans ce type de contrôle.

La caractérisation des couleurs est classiquement faite à partir d'une évaluation de paramètres sur les histogrammes monodimensionnels [DAUL-00] [SATH-01] [HANB-02] ou tridimensionnels des composantes colorimétriques [LU-97a] [SRIK-97] [KLIN-99]. Certaines études montrent même que les paramètres les plus simples (moyennes, écart-types) sont souvent les meilleurs et les plus discriminants pour différencier des couleurs [DAUL-00] [SATH-01]. Concernant la texture, deux caractérisations se distinguent classiquement dans ces articles : l'extraction des matrices de co-occurrences [HANB-01] [HANB-02] [MAEN-03] et le calcul de gradients directionnels [KLIN-99]. Cependant, les deux notions que sont la couleur et la texture sont difficilement dissociables [MAEN-03]. L'évaluation de la couleur nécessite souvent l'utilisation de primitives de texture car la décision humaine est très influencée par cette notion [DAUL-00]. Par exemple, le fil du bois peut assombrir une couleur en fonction de son épaisseur et/ou sa couleur.

Outre la caractérisation de ces deux notions, les techniques de reconnaissance utilisées présentent une certaine similarité. Dans le cas de la couleur, les calculs de distance (euclidienne, de Mahalanobis, de Hamming) entre des lots d'apprentissage et les couleurs à identifier sont très fréquents [LU-97a] [SRIK-97] [DAUL-00] [HANB-02]. Il s'agit essentiellement de classificateurs non paramétriques comme la méthode des k plus proches voisins [KLIN-99] [MAEN-03]. Il faut noter que, dans les articles référencés, les résultats n'offrent aucune comparaison entre différentes méthodes. Seule la validation par rapport à un tri manuel est donnée. Les taux de reconnaissance classiquement obtenus sont compris entre 80% et 90%, et répondent souvent à des études concernant l'appariement de six couleurs de chêne rouge. Le cerisier et le merisier sont deux autres essences fréquemment utilisées. Dans le cas de la texture du bois, nous retrouvons l'utilisation de la méthode des k plus proches voisins [KLIN-99] [MAEN-03] et la maximisation de fonctions d'auto-corrélation [HANB-01]. Les résultats présentés dans ces articles montrent des taux de reconnaissance de l'ordre de 80% sur des planches de chêne rouge et de cerisier selon trois classes : la dosse, le quartier et le faux quartier (figure 2.6).

Tableau 2.5 : Méthodes de reconnaissance des couleurs et des textures sur un produit bois

Références bibliographiques	Vecteur caractéristique	Méthodes de classification
[LU-97a] [SRIK-97]	Histogramme 3D des composantes colorimétriques (rouge, verte et bleue) pour chaque échantillon	Minimisation d'une distance de Hamming par rapport à des références apprises
[KLIN-99]	Histogramme 3D des composantes colorimétriques (rouge, verte et bleue) pour chaque échantillon  Evaluation de gradients directionnels à partir d'images binarisées	Classification par la méthode des k plus proches voisins
[DAUL-00]	Moyennes et écart-types des composantes colorimétriques (teinte, saturation et luminance)  Primitives de texture à partir d'une pyramide Laplacienne de la composante luminance	Appariement relatif par minimisation d'une distance
[SATH-01]	Moyennes des composantes colorimétriques (rouge, verte et bleue)	Classification par algorithme génétique
[HANB-02]	Moyennes et écart-types des composantes colorimétriques (teinte, chroma et luminance)  Détermination de l'orientation du veinage par l'algorithme de Rao [HANB-01]  Calculs des matrices de co-occurrences et sommation des lignes de ces matrices [HANB-01]	Minimisation de la distance de Mahalanobis par rapport à des références apprises  Maximisation de la fonction d'auto-corrélation sur le profil obtenu à partir des matrices de co-occurrences
[LIU-02]	Extraction des dimensions fractales des composantes colorimétriques à partir de la méthode de l'aire de la surface triangulaire du prisme	Classification par seuillage
[MAEN-03]	Détermination des percentiles des composantes colorimétriques  Calcul d'une transformée de Hough et des matrices de co-occurrences	Classification par la méthode des k plus proches voisins

Le nombre d'applications en reconnaissance couleur dans le domaine du bois étant relativement faible, nous proposons d'étendre l'étude bibliographique à d'autres domaines d'applications.

- **Autres domaines d'application de la classification des couleurs**

Dans le domaine de la classification des couleurs, il existe cependant des études montrant l'utilisation de techniques différentes de celles employées dans le domaine du bois.

L'industrie alimentaire est soumise à de nombreux contrôles d'hygiène draconiens. Les produits doivent répondre à des normes de qualité précises. De nombreux aliments présentent des variations de couleur en présence de défauts (moisissures par exemple) [ZHAN-98]. Ainsi, l'agriculture s'est vue doter d'un grand nombre de systèmes d'inspection visuelle pour différentes applications. Par exemple, le contrôle de la qualité des pommes représente un enjeu majeur dans le tri des fruits suivant leur aspect surfacique [MEHL-04]. Les techniques d'appariement s'y retrouvent largement utilisées. Elles permettent d'évaluer l'appartenance des pixels à des classes préalablement définies suivant des classificateurs bayésien [KLEY-05]. Lorsque la texture de la couleur est prise en compte, le traitement par transformée en ondelettes est souvent employé. Les travaux d'Antonelli *et al.* montrent l'intérêt des ondelettes dans la qualification de la couleur des aliments [ANTO-04]. Les résultats proposés confirment la validité de la méthode comparée à une inspection humaine.

Dans un contexte médical, l'appariement de couleur est très souvent étudié. Par exemple, Wang *et al.* travaillent sur la caractérisation de la couleur d'une langue [WANG-07]. Ils définissent la couleur des régions par des histogrammes sous-échantillonnés afin d'obtenir des signatures composées des couples {couleur, fréquence d'apparition}. Après un apprentissage de six classes de prototypes, ils implémentent un classificateur k plus proches voisins basé sur le calcul d'une distance de dissimilarité. Les résultats obtenus montrent une amélioration de classification des pixels des images par rapport à une segmentation plus classique à partir d'un réseau de neurones. Plusieurs études concernant l'appariement couleur en odontologie ont également été menées [SPRO-01a] [SPRO-01b] [ISHI-05]. Ishikawa-Nagai *et al.* rapportent les bons résultats de l'appariement de prothèses dentaires en céramique par l'analyse d'images suivant les composantes colorimétriques du repère CIE Lab (chapitre 3). De plus, la classification par un simple calcul de distance euclidienne proposée dans cet article est reproductible.

Des techniques plus élaborées sont aussi utilisées directement au niveau des pixels lors des étapes de segmentation. Il s'agit souvent de méthodes non paramétriques telles que les k-moyennes, ou encore des méthodes connexionnistes. La logique floue a également été utilisée dans la caractérisation de la couleur [BENO-01]. Elle a pour avantage de tenir compte de définitions linguistiques des couleurs telles qu'elles peuvent être énoncées par des opérateurs.

Aucune des techniques de classification n'obtient l'unanimité des chercheurs dans la reconnaissance de couleur. Tout d'abord, les différentes études sont basées sur des lots de données bien définis (nombre d'échantillons conséquents, homogénéité des classes de sortie, ...). Travaillant dans un contexte industriel très subjectif (définition des classes de sortie par un Homme, incomplétude des lots de données), les Réseaux de neurones, les algorithmes génétiques, les Supports Vecteurs Machines, méthodes nécessitant de grands lots de données d'apprentissage, sont souvent mal adaptées. Ensuite, il n'existe pas de lien explicite entre le

vocabulaire utilisé pour définir les classes de sortie et les caractéristiques de vision. Il est donc très difficile d'interpréter les décisions prises par les méthodes de classification. Le but de cette étude est d'obtenir un capteur qui délivre une réponse dans le vocabulaire du métier (couleur du bois « Rouge Clair »), et dont les paramètres de réglage sont également exprimés de façon compréhensible pour un non spécialiste. Ainsi, nous proposons de structurer le système de vision suivant les mécanismes visuels d'un individu avec toute la connaissance *a priori*. Pour cela, il est nécessaire d'analyser la structure mêmes des capteurs.

## 2.3. Architectures des capteurs de vision

La complexité des environnements industriels nécessite l'utilisation de capteurs de plus en plus perfectionnés en terme d'intelligence déportée, de systèmes distribués, autonomes où l'information doit être conditionnée au plus tôt pour faciliter son exploitation. Cela doit permettre de répondre aux performances, essentiellement en terme de qualité, puisqu'il s'agit en priorité de satisfaire les attentes exprimées par les clients. Ainsi, de nombreuses améliorations concernant le développement des capteurs ont vu le jour depuis environ trente ans, dans le but d'approcher au mieux les mécanismes employés par l'Homme. Ces évolutions ont été envisageables grâce à l'essor de plusieurs domaines dont l'électronique et l'informatique. Les performances ainsi atteintes ont permis d'intégrer et d'adapter les capteurs à des environnements très sélectifs. De plus, l'intégration de l'intelligence artificielle au niveau de ces capteurs facilite leur utilisation par l'Homme en transmettant les résultats sous forme linguistique directement compréhensible. Historiquement, trois évolutions jalonnent le développement des capteurs : les capteurs intelligents, les capteurs symboliques et les capteurs flous.

### 2.3.1. Capteurs intelligents

Concept apparu au début des années 80 [BURD-84], le capteur intelligent est la première évolution du capteur traditionnel, qui fournit uniquement les mesures à un environnement de travail. Ces capteurs classiques sont des outils perceptifs qui peuvent ne pas assurer une répétabilité quant aux mesures qu'ils peuvent fournir au système décisionnel. Ainsi, les améliorations doivent permettre aux capteurs de prendre des décisions plus ou moins complexes à partir des données numériques acquises (les mesures). La première « intelligence » donnée aux capteurs concerne essentiellement le pré-traitement basique effectué sur les mesures. Ces traitements peuvent être des filtres, des linéarisations, ... Ces étapes permettent alors de fournir au système de décision des données plus pertinentes (réduction du bruit, réduction des redondances, ...) et représentatives des volontés du client. Afin de réduire les erreurs liées aux mesures et de réduire les informations inutiles, le capteur intelligent doit posséder et manipuler une connaissance *a priori* sur les phénomènes qu'il perçoit [KUC-86]. En se basant sur les études menées par le Comité Interprofessionnel pour l'Automatisation et la Mesure (CIAME) regroupant de nombreux laboratoires et industriels, quatre parties peuvent être distinguées dans l'étude d'un capteur intelligent : la mesure, la configuration, la validation et la communication. Ces parties résument l'ensemble des besoins des utilisateurs en matière de capteurs et actionneurs intelligents [CIAM-87] [BENO-91]. La figure 2.12 illustre ces différentes parties.

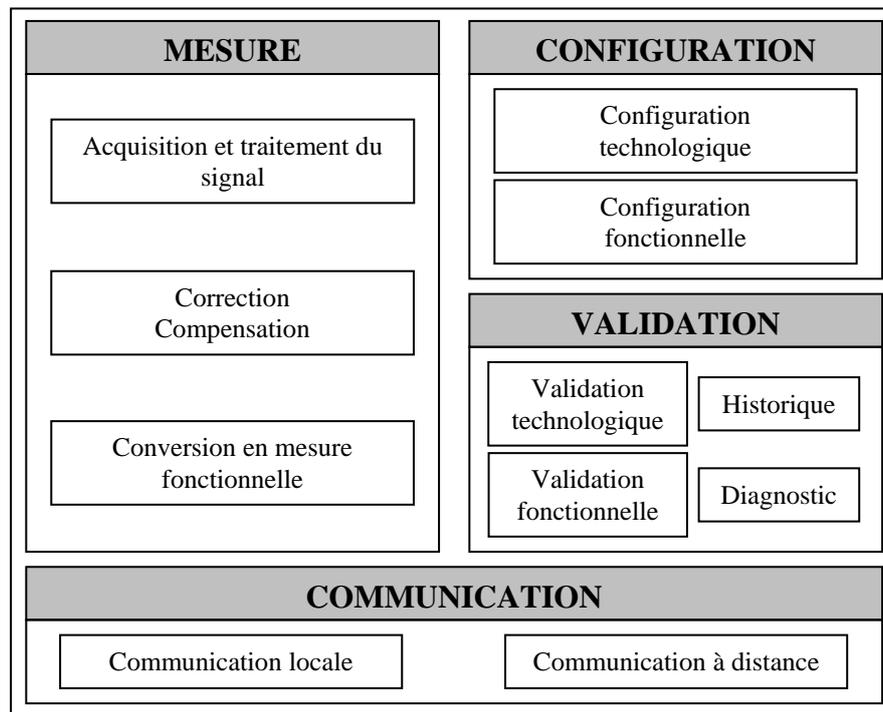


Figure 2.12 : Fonctionnalités d'un capteur intelligent décrivant les besoins utilisateurs

La **mesure** correspond à l'acquisition et aux pré-traitements des signaux afin de fournir les informations fonctionnelles aux autres entités du système. Elle remplit les fonctions de la perception visuelle. La notion de *traitement du signal* se retrouve alors au niveau de l'*acquisition* afin de minimiser l'influence du bruit sur les données utiles. La correction et la compensation permettent, quant à elles, de linéariser les mesurandes en tenant compte des informations externes au système. Pour finir, la *conversion en mesure fonctionnelle* intervient dans le but de fournir aux autres organes du système des données réutilisables.

La **configuration** du capteur correspond à l'adaptation du capteur aux besoins des utilisateurs et à son intégration dans le système global. Deux parties sont distinguées. D'une part, la *configuration technologique* permet d'adapter le capteur lui-même à sa future utilisation. Cette étape est réalisée la plupart du temps lors de sa fabrication, mais elle peut intervenir lors de son intégration dans le système global. D'autre part, la *configuration fonctionnelle* permet de spécifier précisément le contexte dans lequel sera effectuée la mesure.

La **validation** correspond à la vérification des fonctionnalités du capteur en termes de maintenance et de *diagnostic*. Il s'agit de valider le bon fonctionnement du capteur lui-même. Nous y distinguons également deux parties. Premièrement, la *validation technologique* vise à surveiller le capteur et à prévenir la moindre défaillance du matériel. Deuxièmement, la *validation fonctionnelle* informe l'utilisateur de la précision des mesures et des éventuelles erreurs commises lors de l'acquisition. Certains capteurs possèdent également une mémoire permettant de gérer l'*historique* de son fonctionnement (mesures, journal d'erreurs, ...).

La **communication** correspond à l'interfaçage du capteur avec les différents organes du système au sens large (système d'informations, centre des traitements de chaque capteur, ...) et du capteur lui-même. La *communication locale* dédiée à la configuration et à la maintenance du capteur, et la *communication à distance* dédiée au dialogue (envois et réceptions d'informations) avec les autres composantes du système de production constituent ce module.

De nombreuses études ont été menées sur les différentes parties qui composent le capteur idéal traduit par les besoins des utilisateurs. Pour exemple, les travaux de Chamberod sur l'intégration d'un DSP (Digital Signal Processor) permettent d'accélérer les pré-traitements effectués au niveau de la mesure [CHAM-92]. Mauris, quant à lui, a su intégrer la notion de validation au sein d'un télémètre ultrasonore à modulation [MAUR-92]. Cependant, toute la communauté s'accorde à dire qu'un capteur intelligent ne se définit pas par sa structure mais par les services qu'il propose et les capacités qui le caractérisent. Ainsi, l'intelligence artificielle qui permet d'intégrer trois types de connaissance [ALBU-91] dans le système est introduite :

- les Données à proprement parler ;
- le Savoir-Faire permettant d'utiliser les données ;
- la « Métaconnaissance », qui représente la connaissance sur tout le Savoir-Faire.

Pour s'orienter vers l'intégration de l'intelligence artificielle, la notion de capteur intelligent peut être améliorée par l'utilisation de capteurs symboliques.

### **2.3.2. Capteurs symboliques**

Ce type de capteur dispose de fonctionnalités avancées, comme un module d'apprentissage et un module de décision [TAKA-94]. Un capteur peut être considéré comme symbolique, s'il fournit et manipule des données sous une forme numérique ou symbolique. La figure 2.13 illustre la forme d'un capteur symbolique d'après la définition de Benoît [BENO-91].

La base de connaissance est créée à partir de plusieurs points de vue : la connaissance contenue dans le capteur, la connaissance fournie par l'environnement externe au capteur (figure 2.14). Les informations brutes ou données utiles caractérisent l'ensemble des connaissances fournies par le capteur lui-même (état de fonctionnement, configuration, ...) et le contexte d'utilisation de ce dernier (objectif lié à l'utilisation du capteur). Le Savoir-Faire, quant à lui, peut prendre différentes formes. Pour exemple, il est caractérisé par un ensemble de règles symboliques dans un système expert.

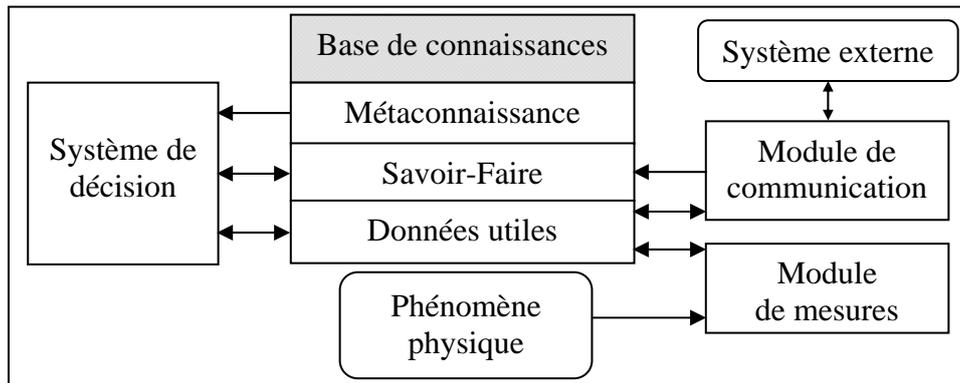


Figure 2.13 : Représentation d'un capteur symbolique

Enfin, la métaconnaissance est constituée d'un ensemble de règles permettant de valider et/ou modifier le cœur du Savoir-Faire. Par exemple, elle intervient dans la mise à jour de la base de règles symboliques pour le cas d'un système expert [NAKO-96].

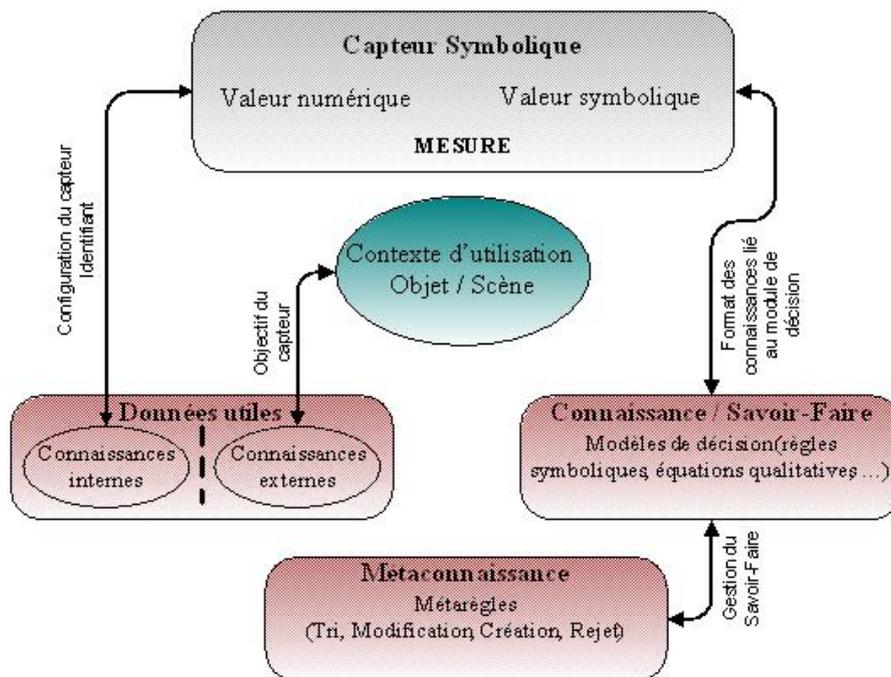


Figure 2.14 : Identification de la base de connaissance d'un capteur symbolique par rapport à son contexte d'utilisation

Les composants du capteur intelligent idéal se retrouvent également dans un capteur symbolique. Cependant, un convertisseur numérique-symbolique est ajouté au système pour

permettre l'utilisation de symboles au sein du module de décision. Il s'agit en fait du cœur du capteur symbolique. Ce convertisseur dispose en entrée des données numériques fournies par le capteur, et fournit en sortie les symboles associés à ces valeurs.

Pour ce faire, deux univers de représentation des données sont définis :

- l'univers de discours attaché aux mesures numériques ;
- l'univers lexical regroupant les symboles utilisés.

L'univers de discours fournit une information concernant l'étendue des valeurs pouvant être prises par les données numériques associées aux mesures du capteur. En prenant pour exemple un capteur colorimétrique basé sur une caméra couleur, trois univers de discours peuvent être caractérisés. Il peut s'agir de l'espace de variations des composantes colorimétriques rouge, verte et bleue. Classiquement ces espaces sont finis et les valeurs sont comprises entre 0 et 255 (figure 2.15).

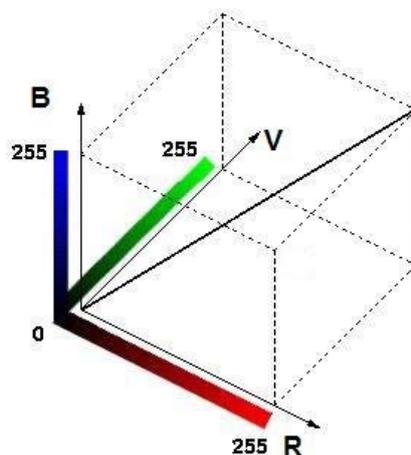


Figure 2.15 : Univers de discours associés aux composantes colorimétriques rouge (R), verte (V) et bleue (B)

L'univers lexical fournit au capteur des symboles que ce dernier associe aux valeurs mesurées. Il faut noter que l'univers de représentation doit être déterminé pour chaque application utilisant un capteur symbolique. Dans le cas de la couleur, cet univers peut être l'ensemble {rouge, vert, bleu, orange, jaune, noir, blanc}. D'autres exemples peuvent être pris. En considérant une évaluation de l'intensité lumineuse dans une pièce, cet univers peut être l'ensemble {sombre, clair} alors que si la couleur traduit la température d'un métal par exemple, cet univers serait l'ensemble {chaud, tiède, froid}.

Dans un capteur symbolique, il y a toujours des variables numériques associées à des relations symboliques, qui peuvent être combinées dans la base de connaissance. Le lien mis en place entre les deux univers de représentation est caractérisé par l'utilisation de trois relations [FINK-75] [LUZE-91] [ZING-91] :

- la première, appelée symbolisation, permet le passage d'une valeur numérique à un symbole ;
- la deuxième, appelée traduction ou signification, permet le passage d'un symbole à la partie correspondante de l'univers de discours ;
- la troisième appelée interprétation permet de rapprocher une mesure à tous les symboles qui la caractérisent.

Pour résumer, le convertisseur numérique-symbolique permet de définir différents symboles pour chaque espace de données généré dans l'univers de discours par un seuillage fixe. Les symboles sont émis sous la forme de mots qui représentent la mesure symbolique du capteur. Cette mesure est alors plus significative que les valeurs numériques malgré son imprécision et sa subjectivité. Ainsi, l'utilisation d'un tel concept facilite nettement la compréhension du fonctionnement des systèmes par un opérateur [BENO-01]. Cependant, il existe un inconvénient à utiliser ce type de capteur. Lorsqu'une mesure numérique est très loin des seuils fixés pour définir les symboles, le système n'est pas très sensible, alors qu'il l'est beaucoup plus si les mesures sont proches des seuils. En effet, en fixant des seuils sur les valeurs numériques, les transitions entre les symboles sont trop brutales et ne permettent pas de prendre la gradualité éventuelle des symboles eux-mêmes. C'est pour cette raison entre autres, que la notion de capteur flou a été introduite afin de prendre en compte cette nature graduelle des symboles utilisés, dans le sens où les mots du langage naturel sont quelquefois imprécisément définis.

### **2.3.3. Capteurs flous**

Les capteurs flous (figure 2.16) sont une amélioration directe des capteurs symboliques. La grande différence se situe au niveau du convertisseur numérique-symbolique qui utilise la théorie des sous-ensembles flous. Cette théorie permet d'atténuer l'influence des contraintes du capteur symbolique, c'est-à-dire les transitions brutales entre les différents symboles. La nature graduelle des transitions entre les symboles peut donc être prise en compte [DUBO-97b]. Plus généralement, la logique floue, introduite par Zadeh [ZADE-65], doit permettre de représenter les imprécisions de chaque symbole ainsi que les incertitudes de la mesure. L'information fournie s'en trouve alors enrichie sans pour autant la rendre plus complexe. Ainsi, une part de la subjectivité peut être prise en compte dans la phase de traitement des données et au niveau du module de décision. La contribution des concepts flous dans le capteur symbolique tient dans la définition des fonctions d'appartenance [DUBO-97a]. Ces fonctions peuvent avoir différentes significations suivant l'utilisation qui en est faite. Des précisions sur la logique floue et ses mécanismes seront données dans la suite de ce mémoire (section 4.1).

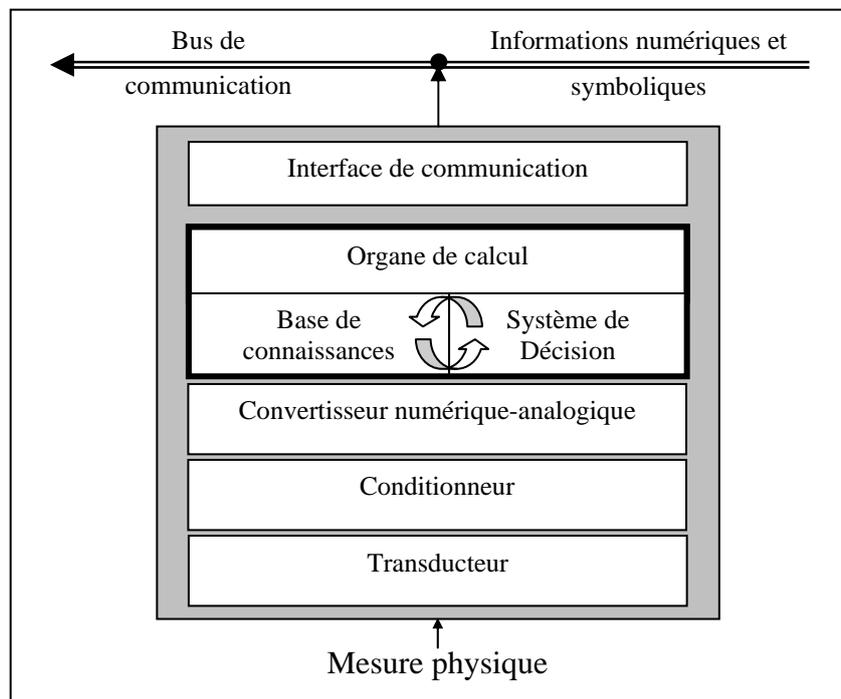


Figure 2.16 : Structure d'un capteur flou

Dans le cadre d'un capteur flou, il faut redéfinir les relations qui lient les deux univers de représentation (univers de discours et univers lexical). Pour un capteur symbolique, ces relations étaient la symbolisation, la traduction et l'interprétation. Pour un capteur flou, ces mêmes relations sont également définies : la symbolisation floue, la traduction floue et l'interprétation floue. Chacune de ces relations est caractérisée par une fonction d'appartenance. Dans le cas du régulateur de température, les fonctions d'appartenance fournissent par exemple un degré d'appartenance aux différentes classes définies par les différents symboles (figure 2.17). Nous nous rendons ainsi compte de la potentialité de cette représentation à traduire une variation graduelle de la mesure sur l'univers de discours. Le capteur flou peut également renseigner l'utilisateur sur le degré d'incertitude des mesures [LEE-05b].

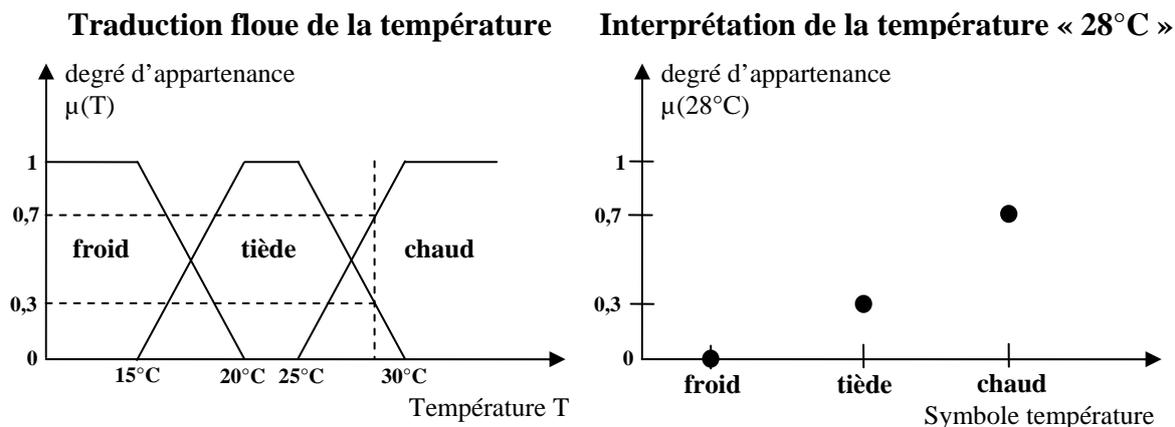


Figure 2.17 : Traduction floue et Interprétation floue de la température

En reprenant les différents organes composant un capteur symbolique et un capteur flou, il existe un grand intérêt à développer, dans le cadre de cette notre étude, un capteur flou couleur adaptée à l'appariement des avivés selon des aspects colorimétriques. En effet, la perception des couleurs par un opérateur est très subjective. Elle fait intervenir des imprécisions et des incertitudes quant à l'interprétabilité de ce qui est vu. En d'autres termes, il peut apparaître un certain nombre de confusions ou de divergences de jugement si nous considérons plusieurs opérateurs. Cependant, en prenant en compte les connaissances *a priori* de ces opérateurs, il est possible de copier en partie les traitements qu'ils effectuent. En ce sens, en reprenant la structure d'un capteur symbolique, ces connaissances peuvent être représentées sous la forme d'un jeu de règles symboliques. Chaque symbole utilisé pour définir des couleurs dans le domaine du bois sont généralement des mots du langage naturel : rouge clair, brun foncé, blanc, ... En appliquant le même principe au capteur développé, il est possible de simplifier l'interprétation des résultats par le biais de règles, mais aussi de réduire le fossé sémantique qui peut exister entre les experts du bois et ceux de la vision en utilisant un vocabulaire compréhensible par tous.

## 2.4. Conclusion

L'étude bibliographique réalisée dans ce chapitre permet de poser les bases de nos travaux concernant l'appariement de pièces de bois selon des aspects esthétiques. Après une analyse d'études similaires, nous avons pu constater que les systèmes développés souffraient d'un manque de cohérence par rapport aux traitements réalisés par l'Homme. En effet, les classificateurs mis en œuvre ne font ni intervenir la connaissance *a priori* des opérateurs humains, ni la subjectivité des exigences « clients ». De plus, avec l'amélioration des capteurs, il est possible « d'embarquer » cette connaissance et d'en tenir compte au sein même des traitements. En intégrant celle-ci, directement au niveau de la chaîne de traitement d'images, il est possible d'envisager une réduction du fossé sémantique existant entre les deux

domaines d'expertise en prenant en compte l'ensemble des imprécisions et incertitudes pouvant intervenir dans le processus de caractérisation de la couleur.

Travaillant à partir de notions incertaines, il nous a semblé évident d'orienter les recherches vers des techniques floues de classification car très proches des raisonnements humains. De plus, les règles linguistiques étant un bon outil pour traduire les connaissances des experts (capteurs symboliques), il est intéressant de rassembler les deux notions afin de définir un système de reconnaissance à base de règles linguistiques floues. Ce système peut ainsi contribuer à répondre aux problématiques liées à notre étude : perception subjective des couleurs, définition linguistique des couleurs par l'utilisateur, connaissance *a priori* des règles de classification, gradualité des classes de sortie (classes non disjointes), bruit de mesure (vieillesse du système d'acquisition, bruit électronique, ...), sensibilité du capteur face à son environnement.

En reprenant les différentes parties qui constituent un capteur flou, nous présentons dans les chapitres suivants les développements réalisés pour notre capteur couleur adapté à l'appariement de planches de bois : du capteur aux mesures fonctionnelles, des mesures fonctionnelles à la décision. Ces différentes parties permettront, en outre, d'explicitier le lien entre l'univers de discours représentant les données numériques fournies par le capteur et l'univers lexical représentant les sorties nominales du capteur flou (figure 2.18).

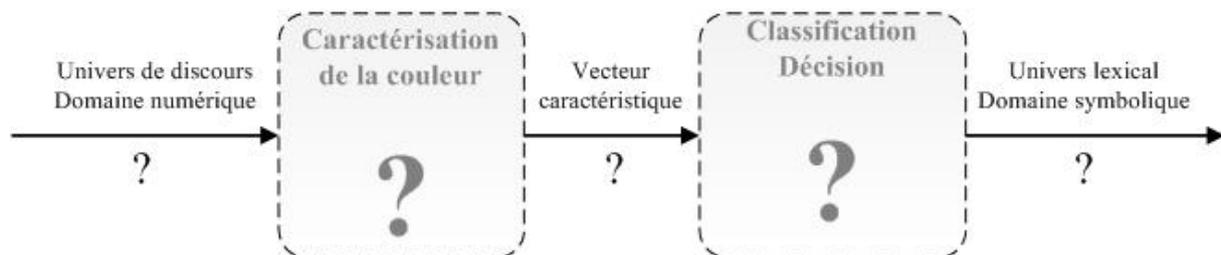


Figure 2.18 : Représentation du lien entre l'univers de discours et l'univers lexical



## **CHAPITRE 3 : DU CAPTEUR AUX MESURES FONCTIONNELLES**

---

### 3. Du capteur aux mesures fonctionnelles

Comme nous avons pu le noter dans le chapitre précédent, un système de vision fait intervenir une chaîne classique de traitement d'images. Notre objectif étant de construire un capteur flou couleur, nous identifions les différents modules du capteur flou en les reliant aux différentes étapes de la chaîne de traitement d'images (figure 3.1). Dans ce chapitre, il s'agit de présenter les données extraites des images, directement liées au système d'acquisition, afin de les conditionner pour qu'elles soient exploitables par l'étape de classification. Ainsi, le rapprochement existant entre la chaîne de traitement d'images et les différentes parties d'un capteur intelligent se limite aux traitements de bas niveau et de niveau intermédiaire. La partie « configuration » ne concerne que le système d'acquisition, alors que la partie « mesure » s'étend au bas niveau et au niveau intermédiaire, le bas niveau fournissant les données brutes corrigées (correction/compensation) et le niveau intermédiaire délivrant la seule information utile aux décisions (chapitre 4). Ce niveau regroupe ainsi les étapes de segmentation, représentation et description des données acquises.

Le premier travail demandé aux systèmes de vision concerne classiquement la prise de mesures afin de caractériser les objets à analyser. En reprenant la structure d'un capteur (section 2.3), il est possible de spécifier les différentes parties intervenant au niveau du conditionnement de l'information acquise. Dans une première partie, nous présentons donc le système physique d'acquisition des images, en précisant l'influence de son environnement d'utilisation sur les mesures réalisées ainsi que les traitements mis en œuvre afin de fiabiliser le système d'acquisition. Ces différents points correspondent respectivement aux parties acquisition et traitement du signal, correction/compensation et configuration du capteur intelligent. Dans un deuxième temps, les mesures brutes fournies par le capteur ne représentant pas des mesures interprétables et fonctionnelles dans le cas des concepts étudiés, il est nécessaire de réduire la complexité et la dimensionnalité de celles-ci afin de construire un vecteur caractéristique représentatif. Cette partie correspond ainsi à la conversion en mesure fonctionnelle existant dans un capteur intelligent.

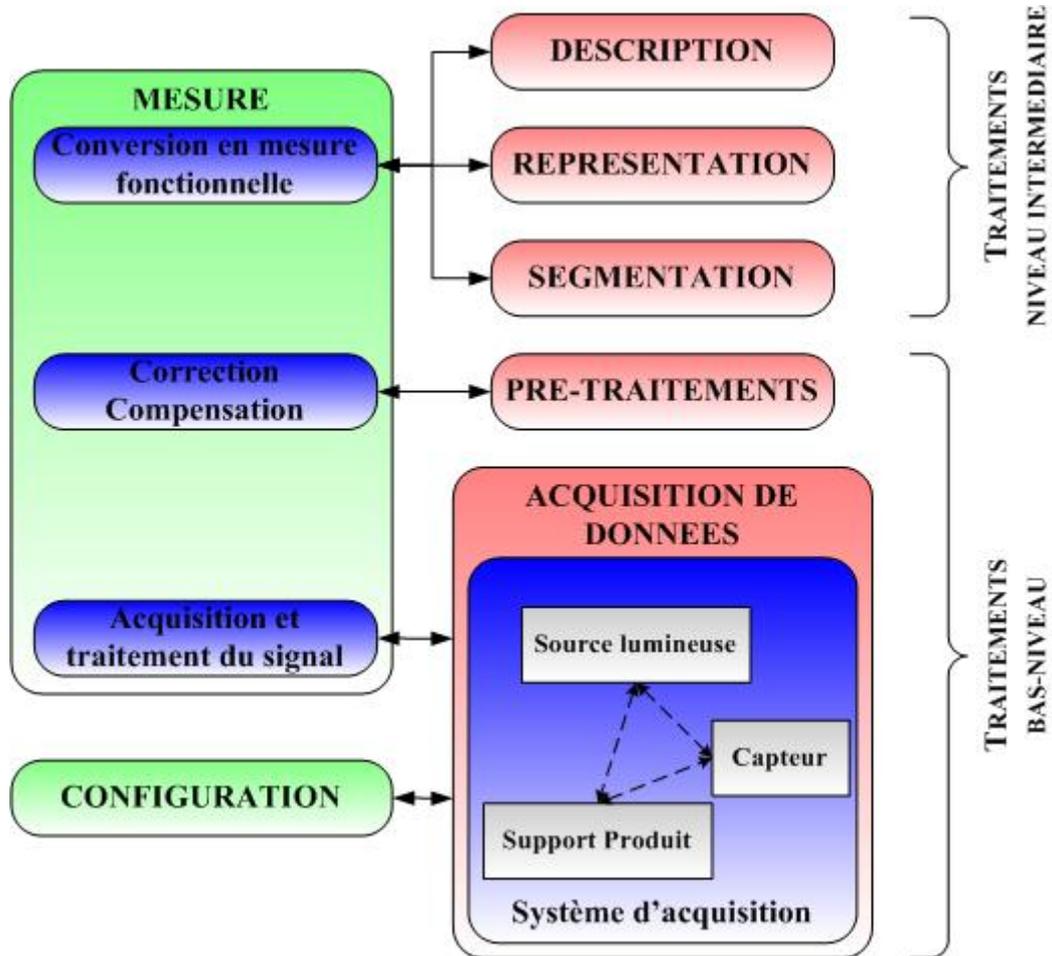


Figure 3.1 : Rapprochement de la chaîne de traitement d'images au fonctionnement d'un capteur intelligent

### 3.1. La mesure

Le système de vision développé pour cette étude est basé sur l'expertise de la société LuxScan Technologies. Il permet d'analyser des avivés selon leur aspect esthétique en temps-réel sur des lignes de production. Ces lignes peuvent atteindre aujourd'hui des vitesses de l'ordre de 220 mètres de bois linéaire par minute. Une fois les données analysées, chaque pièce de bois est envoyée vers une ligne de tri ou de tronçonnage qui permet de répondre aux règles d'optimisation de la production, définies par les utilisateurs. En parlant du tri colorimétrique, ces règles concernent essentiellement l'aspect uniforme des avivés. La figure 3.2 illustre un exemple de lignes de production intégrant les scanners développés. Notre but ici est donc de faire évoluer le capteur existant vers la notion de capteur flou au sein de ces mêmes lignes de production.

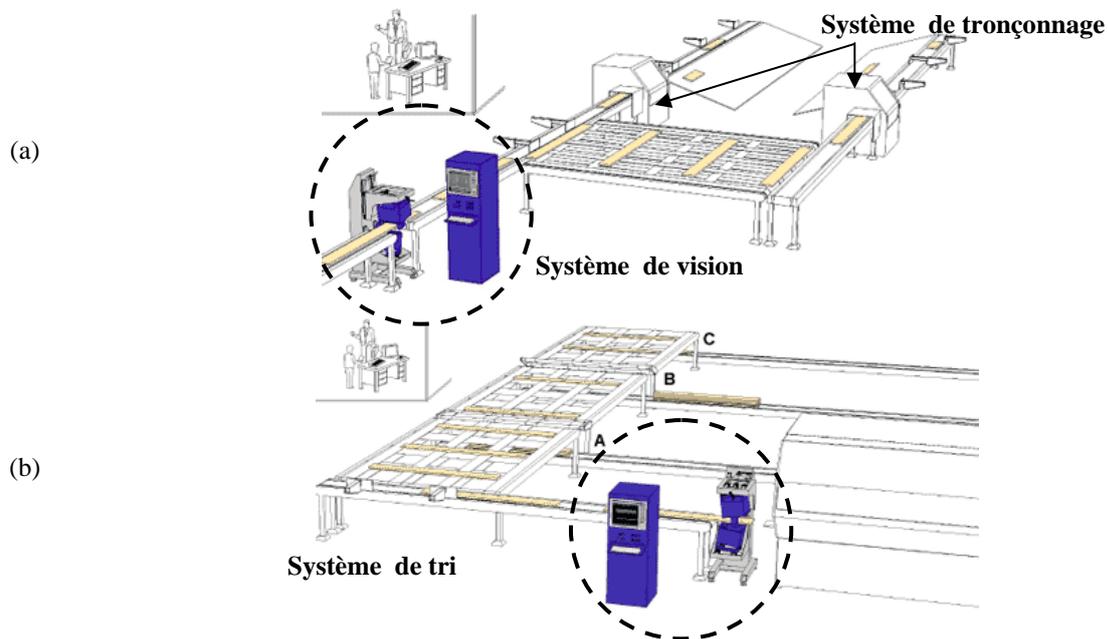


Figure 3.2 : Lignes de production intégrant les systèmes de vision (a- ligne de tronçonnage / b- ligne de tri)

La fiabilisation d'un système de vision, et plus particulièrement d'un capteur flou, nécessite souvent le développement d'un système d'acquisition robuste et pérenne. Dans un contexte industriel et plus particulièrement dans les industries du bois, les conditions d'utilisation de tels outils sont très contraignantes. Ainsi, avant de pouvoir travailler sur les données numériques fournies par le capteur, il est important de s'assurer d'un fonctionnement le plus stable possible du système d'acquisition. Pour mieux comprendre les études menées à ce sujet, il faut présenter en détail ce système tel qu'il a été conçu au sein de la société LuxScan Technologies. Il est ensuite plus simple d'analyser les différents facteurs pouvant perturber le fonctionnement du système. Pour finir, plusieurs études concernant la correction colorimétrique des capteurs sont présentées et nous montrons comment il est possible de les appliquer au système d'acquisition utilisé.

### 3.1.1. Présentation du système d'acquisition

Suivant le cas applicatif concerné, le système d'acquisition est décliné selon diverses configurations :

- Cas applicatif 1 : le système d'acquisition est composé de deux capteurs couleurs permettant d'acquérir les images des rives d'une pièce de bois, et de deux capteurs monochromes permettant l'analyse des singularités présentes sur les faces.
- Cas applicatif 2 : le système d'acquisition est composé de deux capteurs permettant d'acquérir les images des faces d'une pièce de bois.

- Cas applicatif 3 : le système d'acquisition est composé d'un capteur permettant d'acquérir les images de la face supérieure d'une feuille de placage.

Il faut noter qu'un système d'acquisition composé de quatre capteurs pourrait être imaginé afin de scanner les avivés sur leurs quatre faces dans le but de réaliser une étude colorimétrique complète de cet objet. D'ailleurs, la société LuxScan Technologies commercialise déjà des systèmes implémentant cette architecture pour réaliser un contrôle qualité concernant les singularités du bois [BOMB-07a].

Afin de simplifier la présentation du système d'acquisition, seule l'architecture du cas applicatif 2 est décrite. Ce système est composé de deux caméras couleur linéaires mono CCD (Coupled Charge Device) couplées chacune à une source de lumière. La photographie de la figure 3.3 illustre le système d'acquisition développé dans le cas applicatif 2.

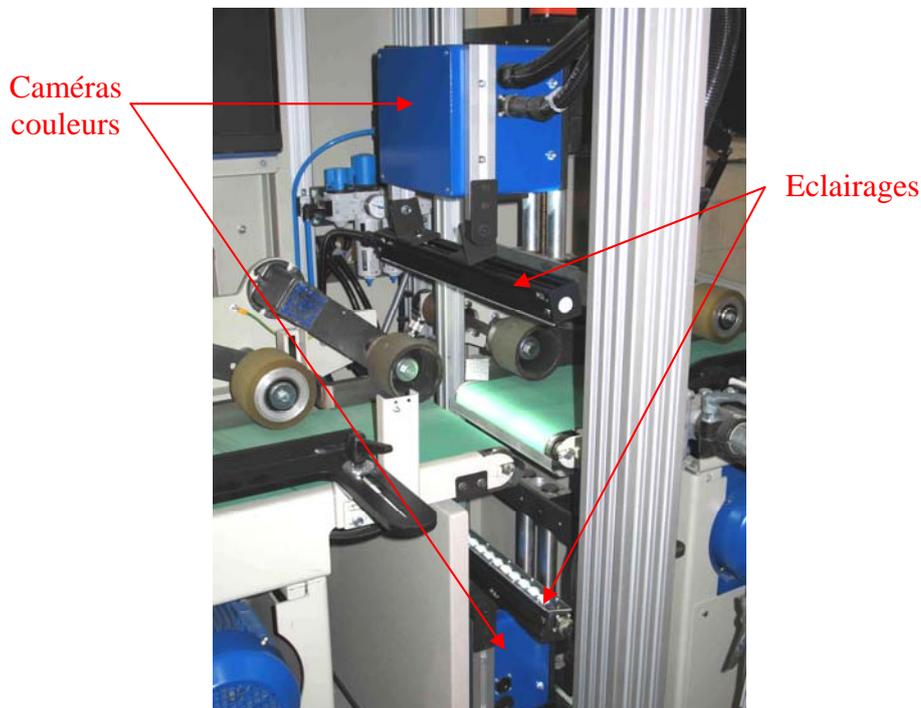


Figure 3.3 : Photographie du système d'acquisition utilisé pour le cas applicatif 2

- **Acquisition et traitement du signal : les caméras couleurs**

Les caméras couleurs utilisées fournissent les signaux des composantes colorimétriques Rouge, Verte et Bleue (RVB), échantillonnés à une cadence de 1500 Hz (soit 1500 lignes par seconde). Chaque ligne acquise est composée de 900 pixels, chacun étant représenté par un triplet {R, V, B} prenant des valeurs entières comprises entre 0 et 255. L'avantage de tel capteur réside dans l'acquisition rapide des données. Il permet ainsi de répondre aux

contraintes temps-réel des systèmes développés. Les résolutions classiquement obtenues sur ces systèmes sont, pour la résolution transversale (largeur ou épaisseur de la pièce de bois) de l'ordre de 0.3 mm/pixel, et pour la résolution longitudinale (longueur de la pièce de bois) de l'ordre de 1.5 mm/pixel. A partir de ces données, il est possible d'évaluer la quantité d'informations à traiter par seconde. Une caméra fournit ainsi au maximum 1 350 000 pixels codés chacun sur 24 bits. Cela représente en moyenne des flux de données d'environ 4 Mo/s. Il n'est cependant pas nécessaire d'acquérir l'intégralité de chaque ligne. En effet, en définissant des régions d'intérêts dans la largeur du CCD des caméras, il est possible de réduire considérablement cette quantité d'information. En considérant des avivés d'une largeur égale à 25 millimètres (cas applicatif 1), seuls 85 pixels contiennent l'information utile. Dans ce cas, la quantité d'information à traiter est environ égale à 382 ko/s.

Les caméras couleurs CCD sont assimilables à la rétine de l'œil [ALLE-99] (cf. annexe A.1). En effet, elles sont constituées d'éléments photosensibles se présentant sous forme linéaire. La partie électronique de ces caméras convertit les signaux électriques fournis par ces photorécepteurs en signal continu analogique. Un convertisseur analogique-numérique (CAN) est ensuite utilisé afin de fournir les composantes R, V et B. La capture des couleurs d'une scène par une caméra mono CCD est assez particulière. Chaque photosite (élément photosensible) obtient l'information d'une seule des composantes colorimétriques RVB, ses voisins recevant les deux autres. La figure 3.4 illustre le positionnement des photosites de la caméra utilisée.

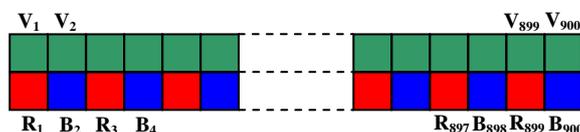


Figure 3.4 : Répartition des photosites sur la caméra couleur utilisée

A partir de cette répartition, nous constatons qu'il existe deux fois plus de données « vertes » que de données « rouges » et « bleues ». En ce sens, afin de réaliser un traitement sur les pixels des images acquises, il est nécessaire de générer les 900 triplets {R,V,B} de chaque ligne de l'image. Le lecteur peut se référer à l'annexe A.2 qui résume la reconstruction des triplets {R,V,B} employée par la société Luxscan Technologies. Cette étape constitue les premiers traitements effectués sur les données fournies par le capteur, soit la partie acquisition et du traitement du signal au sens des capteurs intelligents. La figure 3.5 représente des images couleur recomposées de trois planches de bois.



Figure 3.5 : Images couleurs obtenues à partir du système d'acquisition (a- cerisier / b- chêne / c- érable)

- **Configuration du capteur intelligent : le système d'illumination**

Pour obtenir des images exploitables, la source de lumière doit distribuer une intensité lumineuse uniforme sur toute la ligne d'acquisition de la caméra. L'éclairage du système d'acquisition est placé de manière à obtenir le maximum d'intensité lumineuse sur cette ligne. Il n'est cependant pas toujours aisé d'obtenir un pinceau lumineux homogène sur toute la planche. Initialement, la société LuxScan Technologies intégrait des tubes fluorescents semblables aux éclairages fluorescents domestiques. Ce choix est justifiable de deux manières : faible coût, facilité d'intégration de l'éclairage. Mais, un inconvénient majeur s'est posé lors de la fiabilisation du système d'acquisition. De tels éclairages possèdent des durées de vie très limitées par rapport à de nouvelles technologies présentes sur le marché. De plus, les oscillations provoquées par l'alimentation en 50 Hz peuvent introduire un bruit dans les images acquises. Une étude approfondie a donc été menée sur les systèmes d'illumination afin de comparer les tubes fluorescents à des diodes de nouvelle génération (intensité lumineuse plus importante, durée de vie prolongée, ...) différentes des diodes classiques (diodes électroluminescentes de 5 mm). Ces travaux sont présentés dans la section 3.1.2. de ce mémoire.

En couplant un éclairage à une caméra couleur, il est nécessaire de réaliser une balance de blanc au niveau de la caméra afin d'homogénéiser les plages de variations des différentes composantes colorimétriques R, V et B [ANDR-99]. La balance de blanc est alors jugée

correcte si les histogrammes des trois composantes possèdent la même valeur moyenne. La figure 3.6 illustre l'effet d'une balance de blanc sur les signaux bruts fournis par la caméra présentée.

La balance de blanc réalisée pour les trois cas applicatifs est faite à partir d'une cale de couleur grise. Les signaux sont, dans ce cas, ramenés à une valeur moyenne d'environ 140 sur toute la largeur de la ligne d'acquisition. Cette étape correspond à l'adaptation du capteur au problème posé. Cette étape de configuration du capteur est une partie intégrante de l'expertise de la société LuxScan Technologies. Elle est réalisée à partir du logiciel de calibrage fourni par le fabricant des caméras utilisées.

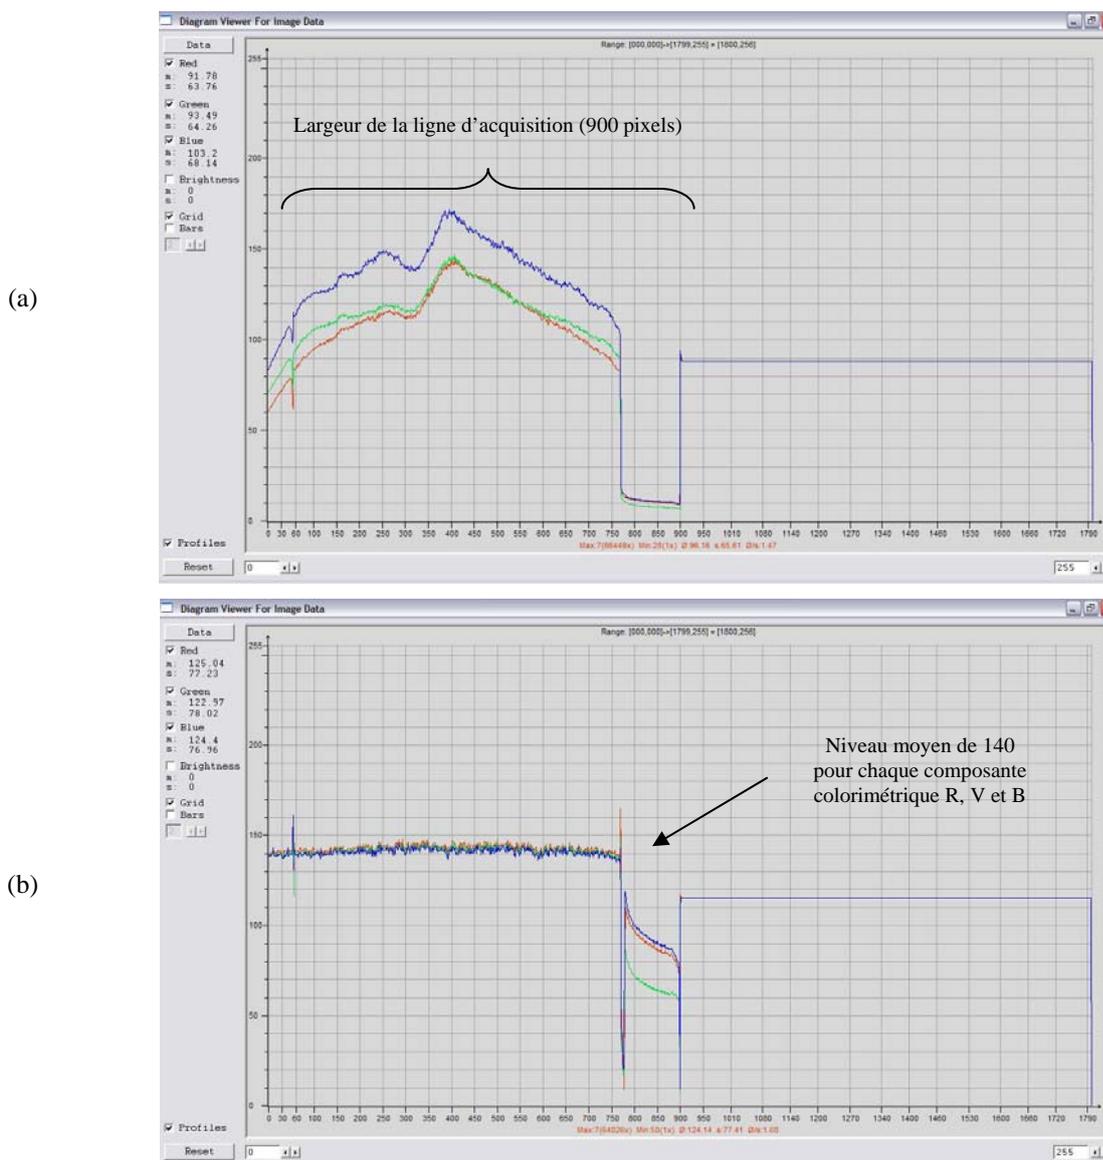


Figure 3.6 : Profils moyens des composantes R, V et B avant (a) et après (b) la réalisation d'une balance de blanc

### 3.1.2. Correction des perturbations lumineuses

Comparée à l'œil humain, une caméra est plus sensible aux variations spectrales de la lumière. Par exemple, l'œil s'adapte plus facilement aux changements de températures d'illumination. La caméra ne disposant pas de ce type d'adaptation, il est important de maîtriser le fonctionnement du système d'éclairage afin de limiter les variations de l'intensité lumineuse mais aussi ses changements de propriétés spectrales [SCHM-05a]. Les éclairages comparés dans cette étude possèdent des spectres lumineux différents (figure 3.7) :

- les tubes fluorescents (a) présentent une forte composante spectrale au niveau des couleurs chaudes (entre 550 nm et 630 nm).
- les diodes blanches (b) présentent une forte composante spectrale au niveau des couleurs froides (entre 410 nm et 460 nm).

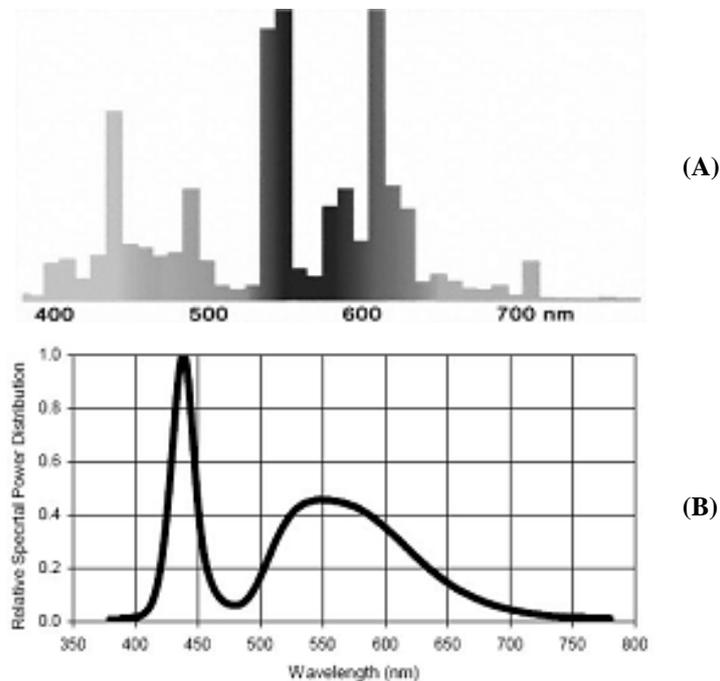


Figure 3.7 : Spectres d'émission des éclairages néons (a) et diodes (b)

Les variations de l'intensité lumineuse sont généralement dues à plusieurs phénomènes, qu'ils soient liés aux procédés (convoyage des pièces de bois), aux propriétés du système d'acquisition (vieillesse des différents organes du système), ou encore aux conditions d'utilisation du système (température par exemple). Deux types de solutions sont envisageables afin de réduire les effets de ces perturbations : soit des solutions palliatives afin de les limiter, soit des solutions correctives afin de les supprimer. Il s'agit donc de décrire ici la partie compensation/correction d'un capteur intelligent.

- **Convoyage des pièces de bois – Solution corrective**

Idéalement, les éclairages illuminent la ligne d'acquisition des caméras. Cependant, les produits scannés ne possédant pas des surfaces parfaitement planes et rectilignes, il arrive qu'une pièce de bois ne soit pas analysée dans sa position de référence. Le schéma de la figure 3.8 illustre le convoyage des avivés dans le cas applicatif 1.

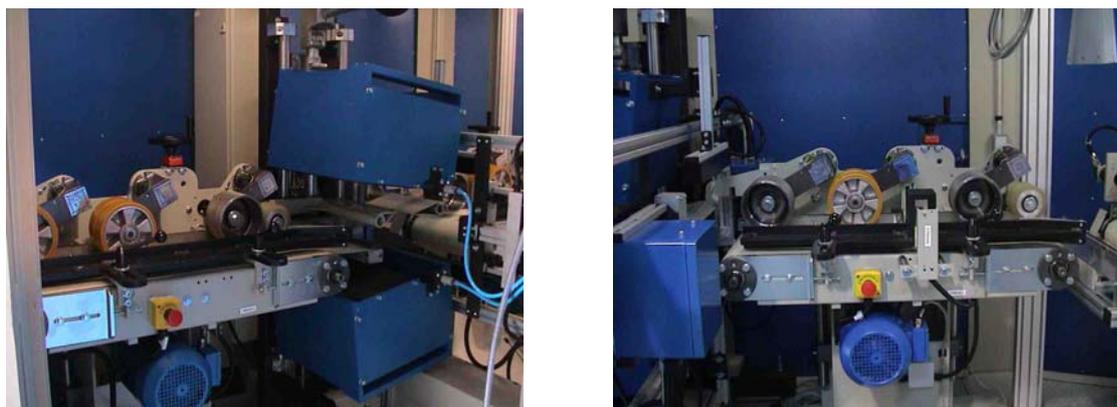
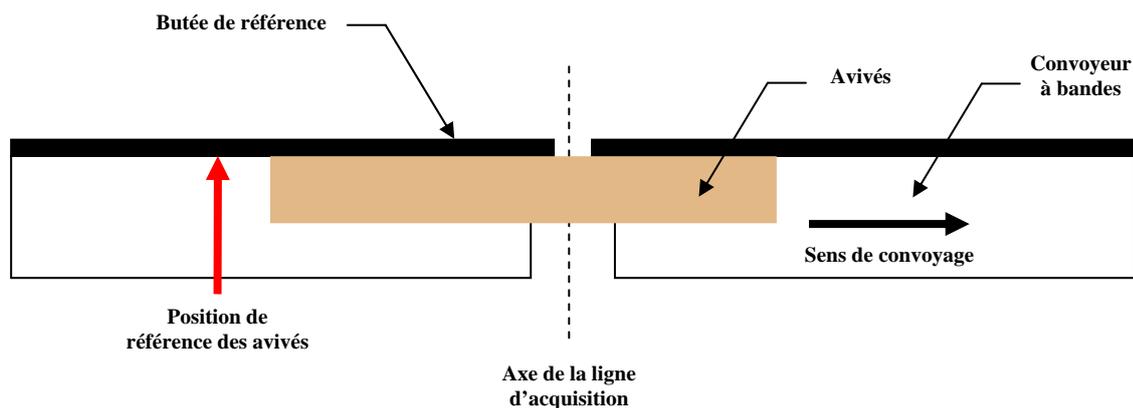


Figure 3.8 : Schéma (vue de dessus) et photographies du système de convoyage utilisé dans le cas applicatif 1

Il est facile à partir de ce schéma d'imaginer une pièce naviguant latéralement sur les bandes des convoyeurs. Les pièces pouvant de plus présenter des déformations géométriques (largeur variable, courbure), la distance de référence entre le capteur et la surface à scanner peut ne pas être respectée. Il est donc important d'évaluer l'impact d'une variation de la distance entre le bois et le capteur  $d_{bc}$  sur les composantes colorimétriques fournies par le système. La figure 3.9 illustre l'impact d'une variation de la distance bois/capteur sur l'intensité lumineuse fournit par l'éclairage.

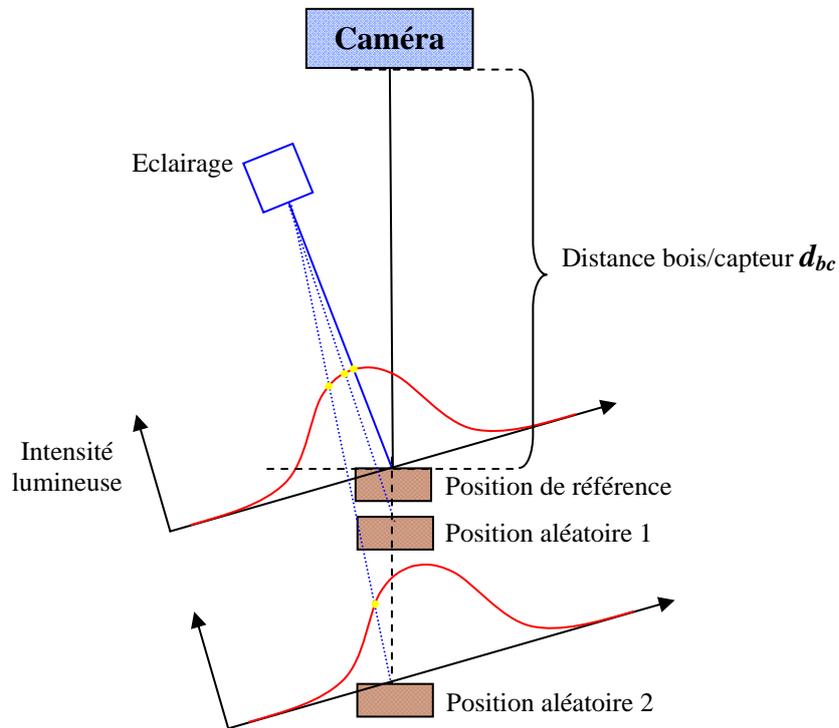


Figure 3.9 : Intensité lumineuse sur une pièce de bois en fonction de la position de la ligne d'acquisition

Pour étudier l'influence du paramètre  $d_{bc}$ , trois échantillons de bois de différentes couleurs ont été sélectionnés. Ayant préalablement évalué les variations maximales de ce paramètre, la plage d'étude concerne un écart de plus ou moins 4 cm autour de la position de référence. Pour des écarts supérieurs à 4 cm, les traitements ne sont pas envisageables aux vues des images acquises, car elles sont totalement floues et présentent un assombrissement trop important pour différencier des couleurs. La figure 3.10 présente l'évolution moyenne des composantes R, V et B fournies par la caméra pour des avivés de couleur différente.

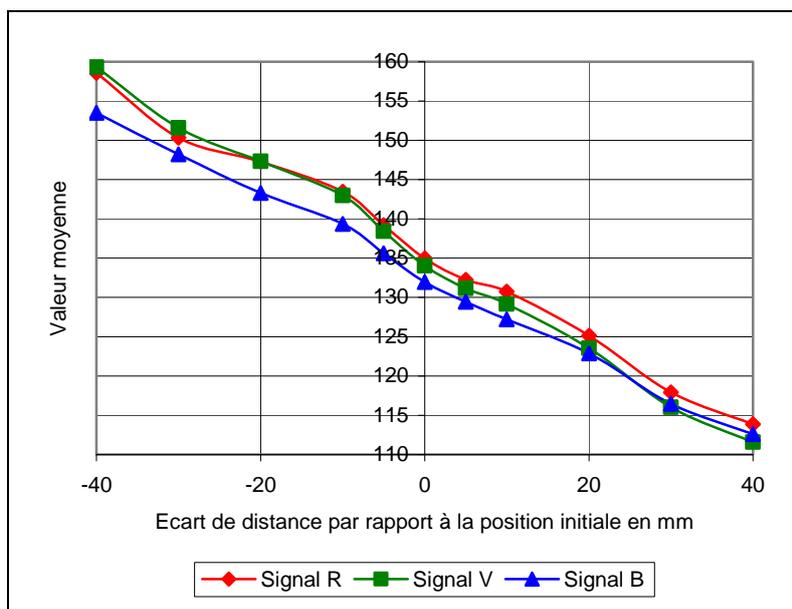


Figure 3.10 : Variation de la moyenne des composantes R, V et B en fonction d'un écart de position autour du point de référence

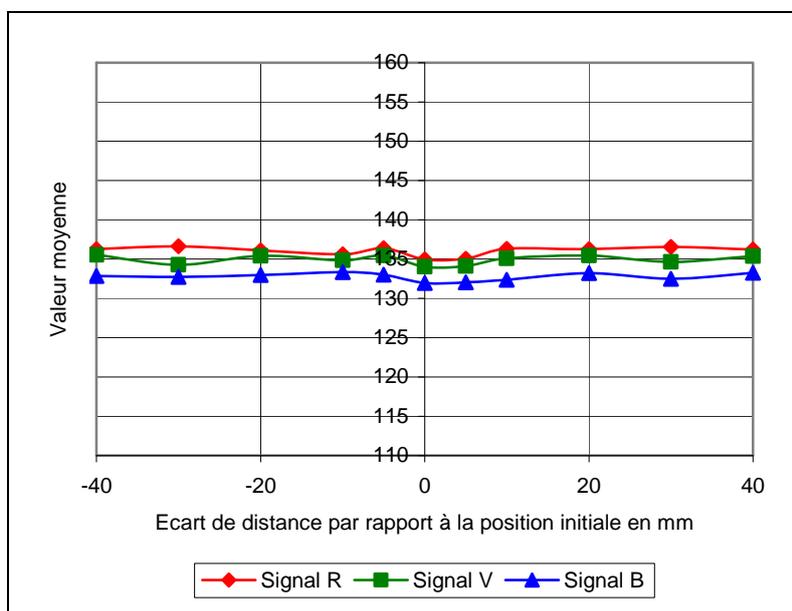


Figure 3.11 : Reconstruction des niveaux colorimétriques à partir des modèles linéaires

A partir de ces résultats, un modèle linéaire (équation 3.1) de correction pour chaque composante colorimétrique peut être défini en fonction de l'écart de position par rapport à la

position de référence des pièces de bois sur les convoyeurs. La figure 3.11 illustre les résultats de la correction linéaire mise en place.

$$X_{ref} = X_{mes} - a.e_{ref} \quad (3.1)$$

où  $X_{mes}$  correspond aux composantes colorimétriques RVB mesurées par le capteur,  
 $X_{ref}$  correspond aux composantes colorimétriques RVB en position de référence,  
 $a$  est le coefficient directeur du modèle linéaire,  
 $e_{ref}$  est l'écart entre la position de référence des avivés et la position de mesure.

Avant correction, nous constatons des variations d'environ 25 niveaux pour des écarts de distance de l'ordre de 40 mm (sur une échelle de 255 niveaux) Après reconstruction, il subsiste un écart type moyen de l'ordre de 0.5 sur les trois composantes.

Cette correction s'applique facilement aux systèmes de vision implémentant quatre capteurs (cas applicatif 1). Il est en effet possible de vérifier le positionnement du produit lors de son convoyage à partir des capteurs de face afin de corriger l'information des rives. La position de référence des avivés est connue dans les images fournies par les capteurs des faces. Un décalage des avivés dans l'image, caractérisé par un nombre de pixels, signifie alors un écart de position par rapport à la référence. Suivant la résolution des capteurs, il est alors simple de calculer le paramètre  $e_{ref}$  (équation 3.1). Pour les systèmes composés uniquement de deux capteurs, nous pouvons imaginer un système d'évaluation de la distance  $d_{bc}$  à partir de capteurs de position qu'ils soient lasers ou ultrasons. Ainsi, la connaissance de la distance de référence entre le capteur et le bois permet de définir la valeur du paramètre  $e_{ref}$  (équation 3.1).

- **Vieillessement du système d'acquisition – Solution palliative**

Comme l'oeil humain, le système d'acquisition et plus particulièrement l'éclairage est sujet à un vieillissement constant. Afin de fiabiliser l'acquisition dans le temps, le vieillissement des deux types d'éclairage cités a été contrôlé sur une période 1200 heures environ. Les figures 3.12 et 3.13 présentent les courbes d'évolution de l'intensité lumineuse transmise par les éclairages.

L'éclairage fluorescent (figure 3.12) présente non seulement une décroissance moyenne de son intensité lumineuse au cours du temps, mais aussi, de nombreuses variations brutales. Elles sont essentiellement dues aux variations de température qui peuvent intervenir durant une journée de travail.

Les diodes blanches, quant à elles, présentent une intensité lumineuse quasi constante au cours du temps. Nous constatons également qu'il n'existe pas de variations brutales dues aux changements de température. Ainsi, les diodes blanches répondent en partie aux critères de stabilité du capteur et permettent de pallier les fluctuations rapides d'intensité lumineuse.

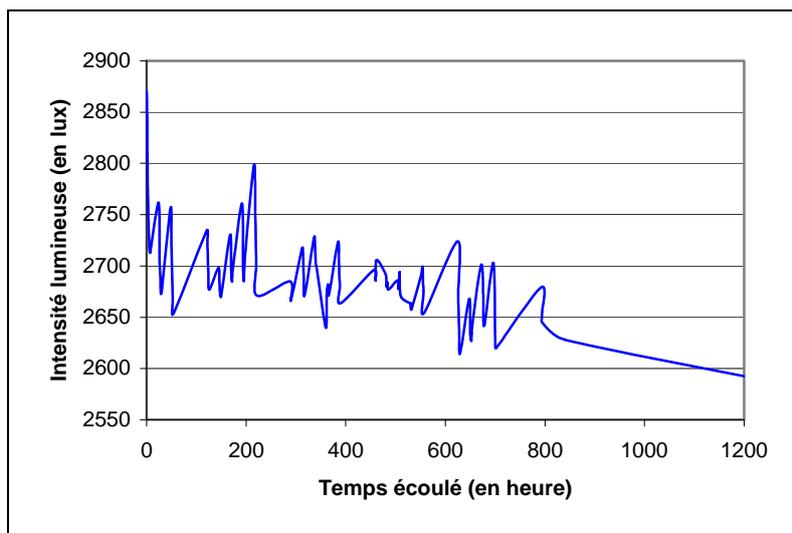


Figure 3.12 : Evolution de l'intensité lumineuse au cours du temps pour un éclairage fluorescent

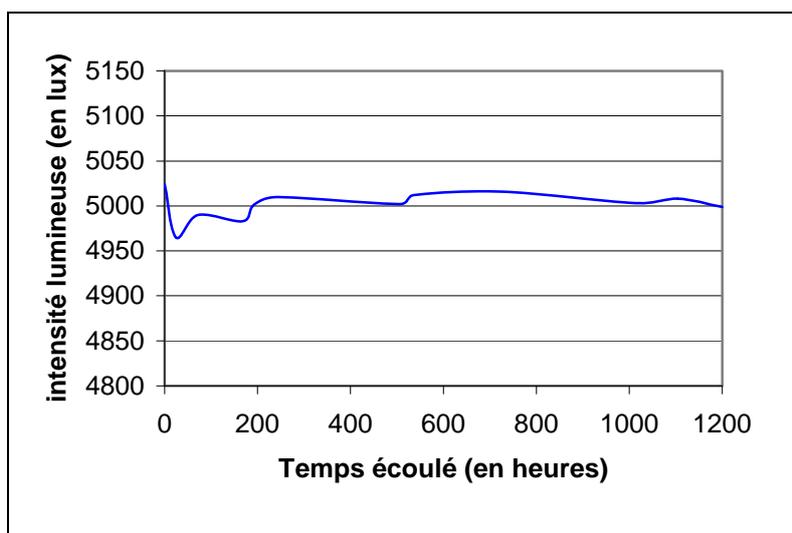


Figure 3.13 : Evolution de l'intensité lumineuse au cours du temps pour un éclairage composé de diodes blanches

Afin de pallier le vieillissement prématuré des éclairages, nous avons donc choisi d'utiliser les diodes blanches, car fournissant une intensité lumineuse beaucoup plus stable dans le temps.

- **Influence de la variation de température ambiante – Solution Palliative**

Dans le contexte industriel de cette étude, les conditions d'utilisation des systèmes de vision développés sont très hostiles. En effet, ces systèmes sont installés dans de grands bâtiments industriels à l'intérieur desquels les paramètres influents ne peuvent pas être maîtrisés (température, humidité, ...). Par exemple, il n'est pas envisageable de climatiser ces halls pour maintenir des températures constantes d'utilisation. Le système d'acquisition doit donc supporter de fortes variations de températures : très froid en hiver et très chaud en été : la plage de variation de température s'étend de  $-5^{\circ}\text{C}$  à  $+50^{\circ}\text{C}$ . Afin de choisir l'éclairage minimisant l'effet de ces variations sur la reconnaissance des couleurs, des tests ont été menés à partir d'un lot représentatif de huit échantillons de bois (figure 3.14).



(de gauche à droite : bois1/Brun Clair, bois2/Brun Foncé, bois3/ Rouge Foncé, bois4/Brun, bois5/Brun Foncé, bois6/Rouge Clair, bois7/Brun Foncé, bois8/Rouge)

Figure 3.14 : Photographie des huit pièces de bois de référence

Pour évaluer la robustesse des éclairages par rapport aux variations de température, nous avons choisi d'exprimer la variation colorimétrique par la métrique  $\Delta E_{RVB}$  (équation 3.2) [SANG-98]. Cette métrique tient compte des composantes colorimétriques R, V et B fournies par le capteur et d'une référence noire représentée par un triplet  $\{R=0, V=0, B=0\}$ . Il s'agit donc de la distance Euclidienne entre le vecteur couleur  $[R,V,B]$  correspondant à un échantillon de bois et la référence de noire.

$$\Delta E_{RVB} = \sqrt{\bar{R}^2 + \bar{V}^2 + \bar{B}^2} \quad (3.2)$$

où  $\bar{R}$ ,  $\bar{V}$  et  $\bar{B}$  correspondent aux moyennes des composantes R, V et B.

Les figures 3.15 et 3.16 illustrent l'évolution de cette métrique pour chaque référence de bois en fonction de la température ambiante. Les températures d'étude sont comprises entre  $14.5^{\circ}\text{C}$  et  $42^{\circ}\text{C}$ .

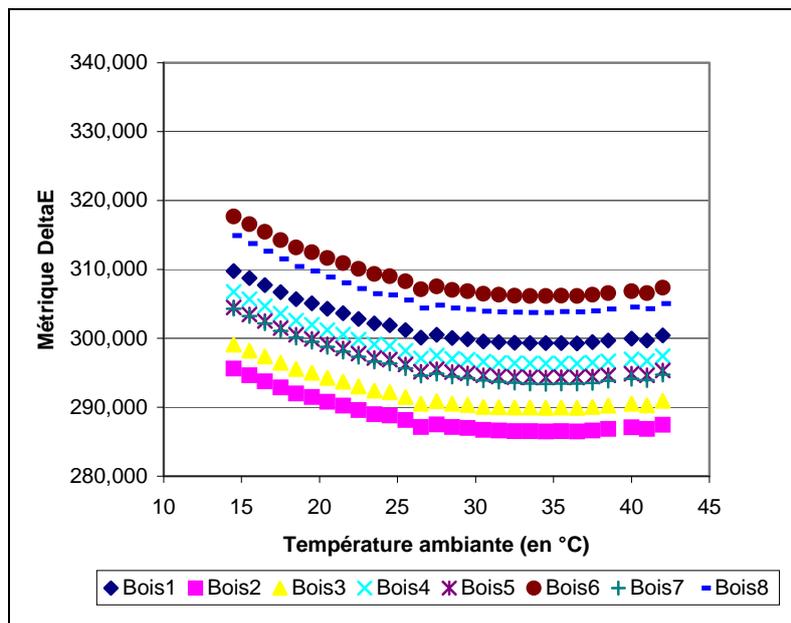


Figure 3.15 : Evolution de la métrique  $\Delta E_{RVB}$  en fonction de la température - éclairage fluorescent

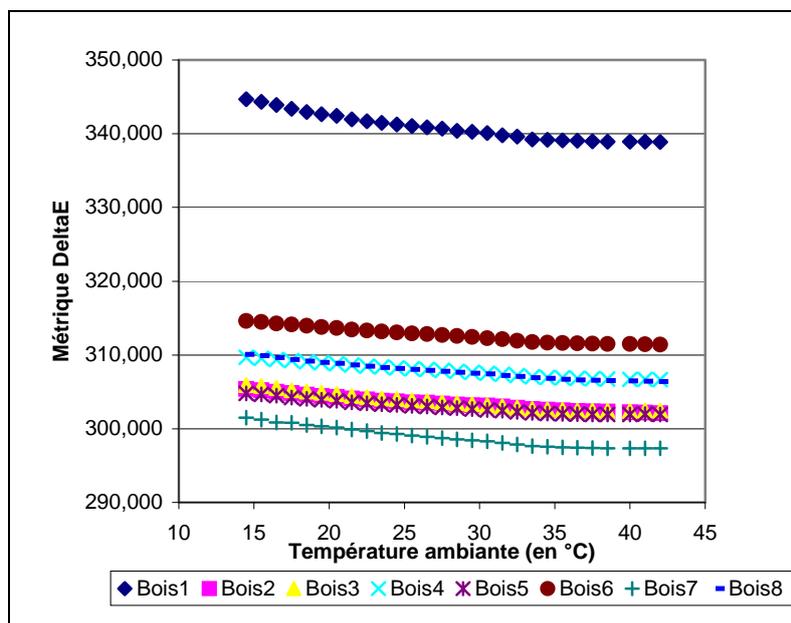


Figure 3.16 : Evolution de la métrique  $\Delta E_{RVB}$  en fonction de la température - éclairage à diodes

Plusieurs conclusions peuvent être tirées de ces expérimentations. Tout d'abord, quelle que soit la couleur du bois, les variations de la métrique sont équivalentes en fonction de la température ambiante et cela pour les deux types d'éclairage. Dans un deuxième temps, l'éclairage fluorescent présente une décroissance de  $\Delta E_{RVB}$  de l'ordre de 10 niveaux alors qu'elle est seulement de 5 niveaux pour l'éclairage à diodes. Cette variation peut avoir des conséquences néfastes quant à la classification des différentes couleurs. En effet, les couleurs à reconnaître sont définies préalablement par l'utilisateur du système de vision. Si cet apprentissage est fait au moment de l'installation du système de vision par une température d'environ 30°C, lorsque la température ambiante descend aux alentours de 10°C, des confusions de teinte entre du Rouge et du Brun sont possibles. Pour exemple, la pièce Bois8 (rouge) se voit confondue avec la pièce Bois1 (brune) si la température passe de 30°C à 20°C pour un éclairage fluorescent.

Au vu des résultats présentés, le choix des diodes blanches est confirmé. En effet, en plus d'une faible variation de l'intensité lumineuse en fonction du temps, ces diodes présentent une faible variation de la discrimination des couleurs en fonction de la température ambiante d'utilisation. La référence de ces diodes blanches ne sont pas données pour des raisons de confidentialité.

### **3.1.3. Correction des données fournies par le capteur**

Malgré un choix judicieux du système d'éclairage, limitant ainsi les variations des signaux fournis par le capteur, il reste des problèmes qui ne peuvent pas être palliés. Afin d'assigner une couleur stable à un objet malgré les variations spectrales de l'éclairage utilisé, nous pouvons employer des techniques de corrections chromatiques [MALO-86]. Un homme possède une certaine faculté à adapter son jugement aux conditions d'illumination d'une scène, chose qui ne paraît pas évident à intégrer au sein d'un système de vision. S'orienter vers le développement d'un capteur intelligent consiste aussi à intégrer au mieux cette capacité d'adaptation vis-à-vis de facteurs perturbateurs (fatigue, baisse de la luminosité, ...). Classiquement, la caractérisation de la couleur d'un objet dépend des signaux fournis par le système (caméra couleur et éclairage dans notre cas), de la réflectivité spectrale de l'objet observé et de la géométrie de l'objet [HEAL-92]. Dans la présente étude, la géométrie est connue, ce qui enlève une dimension au problème de correction chromatique des signaux.

Comme montré dans la section 3.1.2., les signaux fournis par le système d'acquisition sont soumis à de nombreuses perturbations. Il faut cependant différencier les variations à courts termes (variation de la température ambiante, perturbations électriques et/ou électroniques) des variations à longs termes (vieillessement du système, accumulation de poussière). Afin d'atténuer au mieux ces perturbations, il semble préférable de corriger directement les signaux de la caméra par rapport aux conditions d'acquisition plutôt que d'espérer trouver le système d'acquisition « parfait ». Bien entendu, le choix des composants du système reste important afin de limiter au maximum les variations envisageables.

De nombreuses techniques de correction sont recensées dans la littérature. Barnard *et al.* réalisent une comparaison de cinq d'entre elles [BARN-02].

- Les méthodes de correction par niveaux de gris : ces techniques supposent que la réflectivité moyenne des objets observés est connue et peut être assimilée à un niveau de gris.
- Les méthodes basées sur l'estimation de la couleur de l'illuminant : ces techniques cherchent à modéliser la couleur de l'illuminant par un triplet  $\{R,V,B\}$  à partir de la réponse maximale de chaque canal fourni par la caméra. L'inconvénient de telles méthodes tiennent dans la réflectivité de l'objet. Si celui-ci est très spéculaire, c'est-à-dire assimilable à un miroir, la réflectivité maximale est plus grande que la couleur blanche ( $\{255,255,255\}$ ). Au contraire, si l'objet est trop mat, la réflectivité maximale sera inférieure à la couleur blanche. Ainsi, l'échelle de discrimination des couleurs sera réduite.
- Les méthodes dites de « mappage par gamme couleur » : ces techniques supposent une connaissance de l'ensemble des triplets  $\{R,V,B\}$  pouvant être mesurés sur les objets à partir d'un éclairage connu. Il faut ensuite évaluer les mêmes triplets sous un éclairage différent « inconnu » et déterminer la transformation permettant le passage d'un univers à l'autre. Ces techniques sont souvent réalisées à partir d'une interpolation triangulaire des données acquises.
- Les méthodes par corrélation : ces techniques implémentent une matrice de corrélation entre les coordonnées R et V du repère colorimétrique RVB. Elle décrit la compatibilité des sources de lumière par rapport aux images couleur à traiter. En fait, chaque ligne de la matrice correspond à une source de lumière et chaque colonne correspond au niveau chromatique associé à la discrétisation de l'espace R-V. La correction se décompose en plusieurs étapes. Tout d'abord, cette matrice est multipliée par un vecteur constitué des composantes R et V de l'image. Il est alors possible de déterminer l'illuminant adapté aux conditions d'acquisition (estimation du maximum de vraisemblance). Une fois l'illuminant déterminé, il suffit ensuite de corriger les données en fonction de la ligne correspondant à cet illuminant dans la matrice de corrélation.
- Les méthodes par réseaux de neurones : ces techniques permettent d'évaluer la chromaticité d'une image par rapport à un éclairage donné. Elles consistent à utiliser un réseau de neurones composé de deux couches cachées. Les entrées représentent une discrétisation du plan chromatique R-V. Ce réseau de neurones propose deux sorties réelles qui correspondent alors à l'estimation de la chromaticité.

A partir de cet état de l'art, Barnard *et al.* ne se prononce pas sur le choix d'une méthode particulière. En effet, chacune d'entre elles semble posséder ses propres avantages suivant les cas d'utilisation.

Une méthode pourtant semble être adaptée à notre problème. Marszalec et Pietikäinen présente une approche de correction chromatique à partir de l'estimation d'un modèle de la caméra et d'un algorithme de constance de couleurs [MARS-96]. Cette méthode se décompose en deux phases. Tout d'abord, la phase dite « hors ligne » consiste à régler le capteur lui-même. Ensuite, la phase « en ligne » se décline de deux manières :

- soit par l'évaluation des réflectivités spectrales d'un objet par rapport à un illuminant inconnu ;
- soit par l'évaluation d'une matrice de transformation des signaux du capteur à partir de couleurs de références.

Dans les deux cas, la correction intervient au niveau d'un changement de repère colorimétrique basé sur le passage du repère RVB au repère XYZ défini par la CIE. La figure 3.17 illustre le fonctionnement général de ces méthodes de correction.

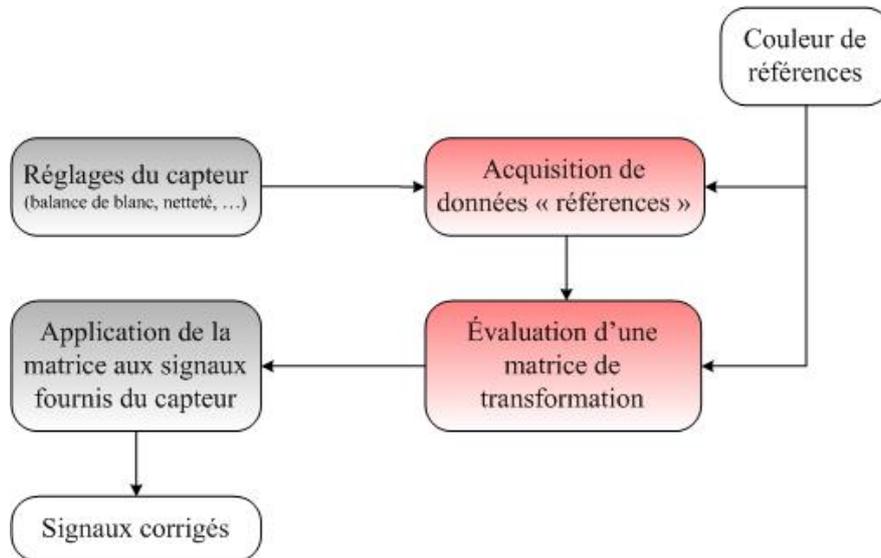


Figure 3.17 : Méthodologie de correction chromatique

La grande différence entre ces techniques concerne les pré-requis. Dans le premier cas, il faut disposer d'un modèle des sensibilités spectrales de la caméra, d'un éclairage uniforme, et d'un jeu de couleurs « références » dont les spectres sont connus. Dans le deuxième cas, seul un jeu de couleurs « références » est nécessaire. Il est cependant plus important que pour la première méthode.

L'algorithme que nous présentons ci-dessous permet de corriger les éventuelles variations au sein du système d'acquisition qui peuvent subsister malgré l'utilisation d'un éclairage à diodes. Il se base uniquement sur l'utilisation d'un jeu de couleurs « références » sans aucune connaissance a priori des sensibilités spectrales de la caméra.

- **Algorithme de correction**

Une fois la caméra étalonnée, les triplets {R,V,B} de plusieurs références couleur sont mesurés. Ces valeurs sont ensuite converties dans le repère colorimétrique XYZ à partir d'une transformation linéaire qui est caractérisée par la matrice  $M_{T_0}$  de dimensions (3 x 3) (équation 3.3). Ces calculs sont effectués durant l'installation du système avant la phase d'apprentissage des couleurs à reconnaître. La matrice  $M_{T_0}$  est donc unique lors de l'initialisation du système d'acquisition.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = M_{T_0} \cdot \begin{bmatrix} R \\ V \\ B \end{bmatrix} \quad (3.3)$$

Une matrice de référence  $M_{\text{Ref}(XYZ)}$  est donc obtenue à partir des valeurs calculées (équation 3.4), n correspondant au nombre de références couleur préalablement choisies.

$$M_{\text{Ref}(XYZ)} = \begin{bmatrix} X_1 & X_2 & \dots & X_n \\ Y_1 & Y_2 & \dots & Y_n \\ Z_1 & Z_2 & \dots & Z_n \end{bmatrix} \quad (3.4)$$

A partir de celle-ci et de l'acquisition de triplets {R,V,B} des références à un instant t, il est possible de définir une transformation polynomiale permettant la correction des signaux fournis par le capteur (équation 3.5).

$$M_{\text{Ref}(XYZ)} = M_T \cdot M_{\text{Ref}(RVB)} \quad (3.5)$$

$$M_T = \begin{bmatrix} t_{11} & t_{12} & \dots & t_{1k} \\ t_{21} & t_{22} & \dots & t_{2k} \\ t_{31} & t_{32} & \dots & t_{3k} \end{bmatrix} \quad (3.6)$$

$$M_{\text{Ref}(RVB)} = \begin{bmatrix} m_{11} & m_{21} & \dots & m_{n1} \\ m_{12} & m_{22} & \dots & m_{n2} \\ \dots & \dots & \dots & \dots \\ m_{1k} & m_{2k} & \dots & m_{nk} \end{bmatrix} \quad (3.7)$$

où la matrice  $M_T$  est une matrice (3 x k) des coefficients du polynôme (équation 3.6) ;

la matrice  $M_{\text{Ref(RVB)}}$  est une matrice (k x n) calculée à partir des composantes R, V et B de chaque référence couleur obtenue par la caméra à un instant t (équation 3.7),  $m_{i1} = R_i$ ,  $m_{i2} = V_i$ ,  $m_{i3} = B_i$ ,  $m_{i4} = R_i.V_i$ ,  $m_{i5} = R_i.B_i$ ,  $m_{i6} = V_i.B_i$  correspondant au modèle de régression choisi.

La correction couleur est ensuite réalisée à partir des valeurs R, V et B (vecteur  $M_{\text{Obj(RVB)}}$ ) mesurées sur l'objet à caractériser (équation 3.8) afin d'obtenir les valeurs corrigées dans l'espace colorimétrique XYZ (vecteur  $M_{\text{Obj(XYZ)}}$ ).

$$M_{\text{Obj(XYZ)}} = M_T \cdot M_{\text{Obj(RVB)}} \quad (3.8)$$

La matrice  $M_T$  dite non constante remplace alors la matrice  $M_{T_0}$  dite constante dans la conversion du repère RVB au repère XYZ. Il faut noter que le choix du degré du polynôme est contraint par la précision souhaitée, le temps de traitement (aspect temps-réel des contrôles qualité présentés) et le coût des erreurs.

- **Résultats de la correction**

Afin de corriger les aberrations chromatiques et d'intensité lumineuse des systèmes d'acquisition utilisés, quatorze références de couleur ont été choisies, proches des couleurs de bois à classer (figure 3.18). Ces références proviennent du nuancier NCS (Natural Color System) qui regroupe une palette de 1950 couleurs [NCS] [SIVI-94]. La figure 3.18 présente les images des références aux instants  $t_0$  (réglage du système),  $t_1$  (après trois mois d'utilisation) et  $t_2$  (après quatre mois d'utilisation). La correction appliquée est basée sur l'utilisation d'un polynôme de degré 2 et la moyenne des composantes R, V et B de chaque référence.

Pour évaluer l'efficacité de la correction, l'erreur quadratique moyenne normalisée (EQMN) a été calculée pour les différents instants par rapport à la référence à l'instant  $t_0$ . Le tableau 3.1 présente les EQMN avant et après correction.

Tableau 3.1 : Erreur quadratique moyenne normalisée avant et après correction sur les références couleur

	Avant correction	Après correction
Instant $t_1$	16.80	<b>0.09</b>
Instant $t_2$	203.03	<b>0.06</b>

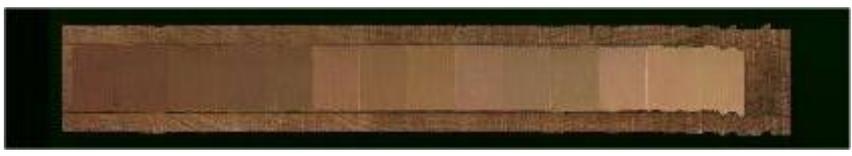
Instant $t_0$	Référence couleur	
Instant $t_1$	Avant correction	
	Après correction	
Instant $t_2$	Avant correction	
	Après correction	

Figure 3.18 : Images des références couleur aux différents instants  $t_0$ ,  $t_1$  et  $t_2$  avant et après correction

Les EQMN obtenues après correction prouvent qu'une telle correction est appropriée aux variations pouvant intervenir aux niveaux des mesures de notre système d'acquisition. Il faut noter que le calcul des matrices de transformation n'est pas effectué « en ligne » au cours de la production. Pour un gain de temps, les calculs se font « hors ligne » et sont implantés en ligne sous la forme d'une LUT (Look-Up Table). Cette LUT évalue directement, lors de l'acquisition de chaque pixel, les valeurs L, a et b associées aux valeurs R, V et B fournies par le capteur. Après un suivi mensuel de l'état du système d'acquisition utilisé dans le cas applicatif 1, il est raisonnable d'envisager une telle correction une fois par trimestre afin de prendre en compte essentiellement les variations saisonnières de température.

La fiabilisation et la stabilisation du système d'acquisition sont des points essentiels dans le développement du capteur intelligent. Le choix des composants (caméras et éclairages) ainsi que l'implémentation d'une méthode de correction permet d'adapter le capteur lui-même à notre problème d'identification des couleurs sur des avivés.

## **3.2. Modélisation de la mesure – Définition du vecteur caractéristique**

A ce stade du développement de notre capteur flou, nous abordons la partie conversion des mesures fournies par le capteur en mesures fonctionnelles qui ont pour rôle de caractériser le plus fidèlement possible la couleur. Pour faire le parallèle avec la chaîne classique de traitement d'images énoncée dans le chapitre 2, la définition du vecteur caractéristique est indispensable avant d'aborder la classification. Ce vecteur représente en fait les attributs inhérents au problème visé. Dans le cadre de cette étude, il est intéressant de choisir les caractéristiques en fonction de leur pouvoir discriminant pour les différentes classes de couleur à identifier.

En référence à la structure d'un capteur intelligent, nous exposons, dans une première partie, le choix d'un repère colorimétrique adapté aux cas abordés. Ensuite, nous exposons l'élaboration du vecteur caractéristique à partir des données statistiques de la couleur et des données spatiales contenues dans les images traitées.

### **3.2.1. Configuration fonctionnelle : choix du repère colorimétrique**

Afin d'adapter notre capteur au problème de reconnaissance des couleurs, il est nécessaire de spécifier le repère colorimétrique dans lequel sont évalués les composantes du vecteur caractéristique.

Le repère colorimétrique utilisé doit être le plus uniforme possible afin que les variations de couleur soient caractérisables de la même manière pour différentes couleurs. La CIE préconise de ne pas utiliser les repères RVB ou XYZ pour différentes raisons :

- les composantes colorimétriques de ces repères ne sont pas indépendantes (voir Annexe A.1), les notions de chrominance et de luminance ne sont donc pas séparées ;
- le repère RVB n'est pas linéaire et ne permet donc pas d'utiliser des critères de distance pour différencier les couleurs.

Ainsi, il est important de choisir le repère colorimétrique pour son pouvoir discriminant sur les classes réelles qui doivent être différenciées. Les repères retenus pour notre étude sont les repères CIE Lab, CIE Luv, CIEDE2000, TLS (Teinte, Luminance, Saturation). Les deux premiers espaces (classiquement utilisé dans des applications industrielles [POIN-81]) ont été développés par la CIE et possèdent l'avantage d'être indépendants des systèmes d'acquisition. Le repère CIEDE2000 est une évolution du repère CIE Lab permettant une meilleure discrimination des couleurs perceptibles par l'être humain pour certaines classes de couleur. Par ailleurs, ces trois repères sont uniformes, c'est-à-dire que des couleurs similaires pour un individu sont très proches dans l'espace de représentation, ce qui facilite leur utilisation. Le repère TLS (ou HLS : Hue-Luminance-Saturation en anglais) est très couramment utilisé en traitement d'images couleurs [SHIH-95]. Seuls les repères TLS et CIE Lab sont présentés, les espaces CIE Luv et CIEDE200 étant très proches de l'espace CIE Lab.

- **Repère colorimétrique TLS**

Le repère TLS est un espace couleur défini en coordonnées cylindriques. Ces composantes sont déterminées à partir des composantes R, V et B. La luminance (composante L représentant l'axe achromatique) est classiquement calculée à partir de la moyenne des composantes R, V et B (équation 3.9).

$$L = \frac{R + V + B}{3} \quad (3.9)$$

La teinte d'une couleur (composante T) représente l'angle entre le vecteur de cette couleur et le vecteur de la couleur rouge [GONZ-02] (équation 3.10).

$$T = \begin{cases} 2\pi - \arccos\left(\frac{R - \frac{1}{2}V - \frac{1}{2}B}{\sqrt{R^2 + V^2 + B^2 + R.V + R.B + V.B}}\right) & \text{si } B > V \\ \arccos\left(\frac{R - \frac{1}{2}V - \frac{1}{2}B}{\sqrt{R^2 + V^2 + B^2 - R.V - R.B - V.B}}\right) & \text{sinon} \end{cases} \quad (3.10)$$

La saturation (composante S) permet de définir la pureté d'une couleur et correspond au module du vecteur chrominance. Les couleurs se trouvant loin de l'axe achromatique étant dites pures. L'équation 3.11 permet d'évaluer cette composante.

$$S = \frac{\sqrt{\frac{2}{3} \cdot (R^2 + V^2 + B^2 - R.V - R.B - V.B)}}{\frac{\sqrt{2}}{2 \cdot \sin\left(\frac{2\pi}{3} - T\right)}} \quad (3.11)$$

La figure 3.19 illustre la forme en double cône du repère colorimétrique TLS.

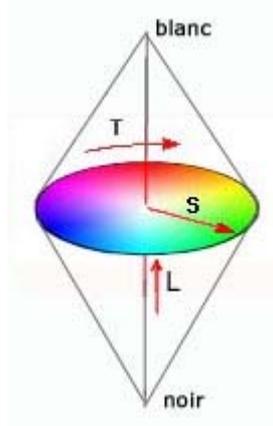


Figure 3.19 : Repère colorimétrique TLS

- **Repère colorimétrique CIE Lab**

Le repère CIE Lab est un repère dont les composantes sont également déterminées à partir des composantes R, V et B. Cependant, ce changement de repère nécessite l'intégration des caractéristiques du système d'acquisition par le passage préalable dans le repère colorimétrique XYZ. La conversion dans le repère XYZ se fait classiquement par une transformation linéaire de l'espace RVB (équation 3.3). Le choix de la matrice de conversion  $M_{T_0}$  se fait essentiellement suivant les caractéristiques de l'illuminant (lumière du soleil, lumière du jour, références prédéfinies, ...) et quatre références de couleur (les primaires pures R, V et B, et une référence de blanc). Notre choix s'est porté sur la référence de blanc  $D_{65}$  qui est utilisée dans le standard Rec. 709 [POYN-97]. En effet, l'illuminant de lumière du jour  $D_{65}$  de la CIE a une température de couleur d'approximativement 6504 Kelvins, et correspond à la température de couleur des diodes blanches utilisées dans notre système d'acquisition (température égale à 6500 Kelvins environ). La matrice de transformation  $M_{T_0}$  est la suivante (équation 3.12).

$$M_{T_0} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} \quad (3.12)$$

Les coordonnées L, a et b permettent de représenter la luminance (composante L – axe achromatique) et la chrominance (composantes a et b – axes chromatiques). Plus particulièrement, la composante a exprime la sensation rouge-verte des couleurs, alors que la composante b exprime la sensation jaune-bleue (figure 3.20). Ces composantes sont calculées d'après les équations 3.13-3.16 suivantes.

$$L = \begin{cases} 116 * \left( \frac{Y}{Y_{blanc}} \right)^{\frac{1}{3}} - 16 & \text{si } \frac{Y}{Y_{blanc}} > 0.008856 \\ 903.3 * \frac{Y}{Y_{blanc}} & \text{sinon} \end{cases} \quad (3.13)$$

$$a = 500 * \left[ f \left( \frac{X}{X_{blanc}} \right) - f \left( \frac{Y}{Y_{blanc}} \right) \right] \quad (3.14)$$

$$b = 200 * \left[ f \left( \frac{Y}{Y_{blanc}} \right) - f \left( \frac{Z}{Z_{blanc}} \right) \right] \quad (3.15)$$

$$f \left( \frac{\omega}{\omega_{blanc}} \right) = \begin{cases} X^{\frac{1}{3}} & \text{si } \frac{\omega}{\omega_{blanc}} > 0.008856 \\ 7.787 * \frac{\omega}{\omega_{blanc}} + \frac{16}{116} & \text{sinon} \end{cases} \quad (3.16)$$

où  $\omega$  correspond aux composantes X, Y et Z ;

$X_{blanc}, Y_{blanc}, Z_{blanc}$  représentent les valeurs X, Y et Z de la référence de blanc obtenues à partir de l'équation 3.2 pour le triplet {R,V,B} valant {255,255,255} si les composantes sont échantillonnées entre 0 et 255.

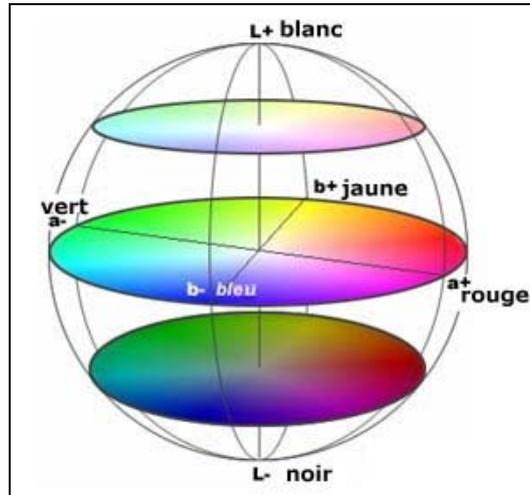


Figure 3.20 : Repère colorimétrique CIE Lab

- **Validation du choix du repère colorimétrique**

Le choix du repère colorimétrique est un aspect crucial dans notre étude. En effet, les couleurs qui doivent être distinguées par le système de vision sont très difficiles à différencier par un œil « non expert ». Il faut donc choisir le repère colorimétrique qui met le mieux en évidence ces différences. Ce choix a été validé en se basant sur l'analyse de l'inertie intraclasse et de l'inertie interclasse (équations 3.17 et 3.18) d'un lot de données préalablement acquis dans le cas applicatif 1. Ces mesures permettent d'évaluer l'homogénéité d'une classe par rapport aux autres classes. Les échantillons préalablement étiquetés par un expert, le repère retenu sera également celui qui est le plus en adéquation avec la perception humaine des couleurs à distinguer.

$$I_{\text{intraclasse}} = \frac{1}{N} \sum_{k=1}^K \sum_{i=1}^{n_k} (d_{\text{eucl}}(X_{ki}, CG_k))^2 \quad (3.17)$$

$$I_{\text{interclasse}} = \frac{1}{N} \sum_{k=1}^K n_k \cdot (d_{\text{eucl}}(CG_N, CG_k))^2 \quad (3.18)$$

où N représente le nombre total de points ;

$n_k$  le nombre de points par classe ;

K le nombre de classe ;

$CG_N$  le centre de gravité de l'ensemble des points ;

$CG_k$  le centre de gravité pour la classe k ;

$d_{\text{eucl}}(X, Y)$  la distance euclidienne entre les vecteurs X et Y ;

$X_{ki}$  le  $i^{\text{ème}}$  point de la classe k.

La figure 3.21 représente les inerties interclasses et intraclasse pour les différents repères colorimétriques. Les critères de sélection consistent à choisir le repère qui maximise l'inertie interclasse et qui minimise l'inertie intraclasse. Les résultats montrent que les repères CIE Lab et CIEDE2000 fournissent les meilleures discriminations pour les cas d'applications visées. Nous pouvons remarquer que le repère CIEDE2000 maximise au mieux l'inertie interclasse, et que le repère CIE Lab minimise au mieux l'inertie intraclasse. Le repère CIEDE2000 étant préconisé pour différencier les couleurs à dominante bleue [LEE-05a], il n'est pas étonnant que le repère CIE Lab soit meilleur pour la minimisation de l'inertie intraclasse. En effet, le bois ne présente que très rarement la couleur bleue sauf lorsqu'il s'agit d'une singularité propre aux essences de résineux (pin, sapin, ...).

Il subsiste cependant un problème lié à l'utilisation de ces deux repères. En effet, le passage des composantes R, V et B au repère CIE Lab ou CIEDE2000 est coûteux en temps de calcul à cause de l'évaluation de la racine cubique. Pour soulager le système d'une telle conversion en temps-réel, nous avons choisi d'appliquer la transformation pour chaque triplet {R,V,B} à l'aide d'une table de transfert (LUT) précalculée. La conversion se fait alors par une simple indexation d'un tableau à trois dimensions.

Notre choix final s'est donc porté sur le repère CIE Lab, car la conversion vers le repère CIEDE2000 nécessite le calcul d'une puissance 7 qui ralentit les temps de conversions.

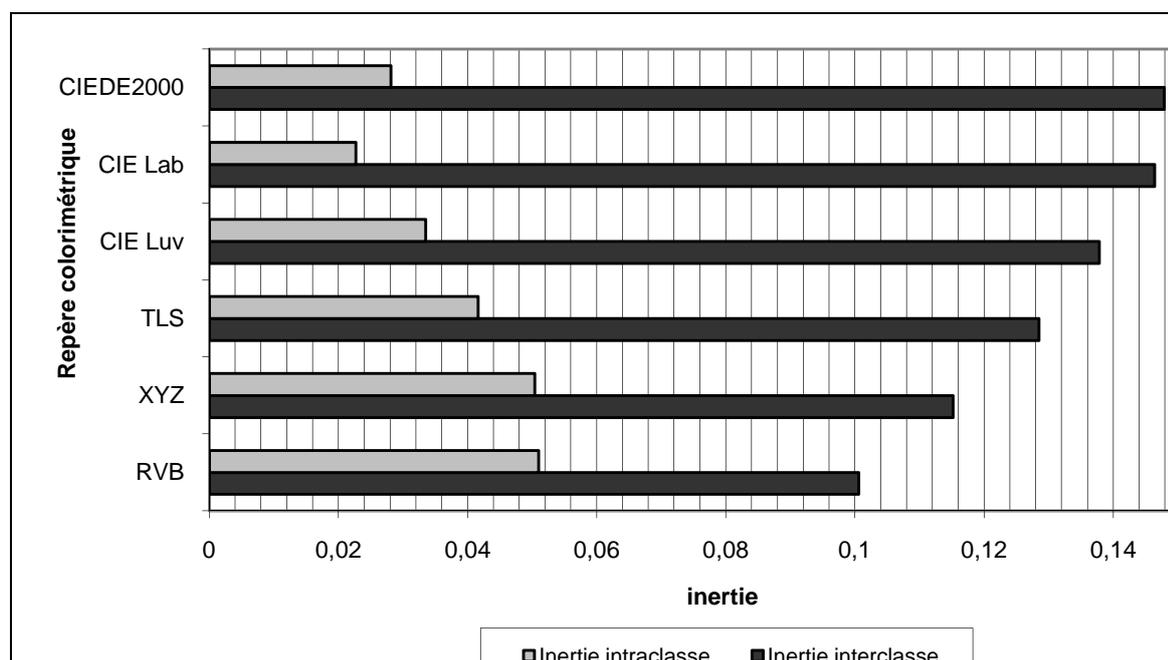


Figure 3.21 : Variation des coefficients d'inerties intra et interclasse pour 5 repères colorimétriques

Le choix du repère colorimétrique définit l'espace dans lequel chaque pixel extrait des images est représenté. Seulement, la caractérisation des couleurs par un être humain ne se fait pas à l'échelle du pixel mais plutôt par zone. Avant de définir des paramètres permettant la reconnaissance des couleurs, il faut donc spécifier ces zones sur les images acquises dans les différents cas applicatifs.

### 3.2.2. Spécification des zones d'intérêts (ROI)

Suivant les cas applicatifs, la caractérisation de la couleur sur les images se fait de différentes manières. Comme nous avons pu le dire, nous ne cherchons pas à identifier la couleur de chaque pixel des images, mais plutôt celle des zones.

Dans le cas applicatif 1, le système de vision s'intègre à une ligne de tronçonnage. Les avivés scannés mesurent en général 3 à 4 mètres de long. Le but des traitements effectués par le système sont multiples : purge totale des singularités et classification colorimétrique des parties dites « saines » (bois sans singularité). Au niveau du processus d'identification de la couleur, nous choisissons donc de travailler à partir de zones d'intérêt (ROI) basées sur la finalité du procédé industriel. En effet, pour définir la taille des ROI (figure 3.22), nous avons pris en compte le cahier des charges du client en terme de longueur minimale des produits tronçonnés.

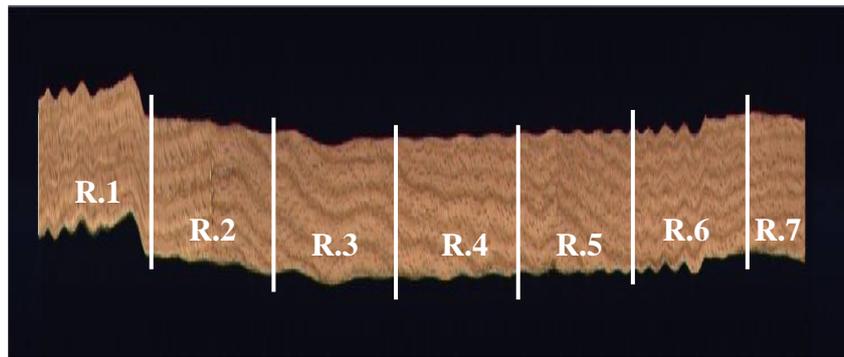


Figure 3.22 : Représentation des 7 ROI sur une image tirée du cas applicatif 1

Sur la figure 3.22, les ROI définies sur les images mesures 150 pixels dans la longueur des avivés, ce qui correspond à environ 225 mm de bois. Cette taille minimale a également été validée à partir des taux de reconnaissance obtenus en fonction de la taille des ROI (tableau 3.2).

Tableau 3.2 : Taux de reconnaissance en fonction de la taille des ROI – Cas applicatif 1

Taille des ROI (en pixel)	50	100	150	200	300
Taux de reconnaissance	77.83%	81.02%	83.10%	83.10%	83.10%

A partir du tableau 3.2, pour des tailles de ROI inférieure à 150 pixels, les taux de reconnaissance diminuent. Cela peut s'expliquer assez simplement, puisque, sur des petites zones, la perception de la couleur est plus sensible à la présence d'un effet texturé (grain du bois). Plus le fenêtrage est grand, plus cette information est lissée par la quantité d'informations présentes. Nous pouvons également noter que les taux de reconnaissance sont les mêmes si la taille des ROI est supérieure ou égale à 150 pixels. Notre choix a donc été spécifié à partir des besoins clients (taille minimale des produits tronçonnés).

Dans le cas applicatif 2, le système de vision s'intègre dans une ligne de tri où ces produits sont tous de longueur fixe et doivent être triés suivant leur couleur globale. De ce fait, nous avons choisi d'utiliser l'ensemble des pixels représentant une planche de bois pour effectuer la caractérisation des couleurs. Là encore, nous nous attachons à respecter les desiderata du client.

### 3.2.3. Aspect statistique de la couleur

La caractérisation de la couleur est fortement liée aux besoins du système de vision et au cahier des charges du client. Dans les trois cas applicatifs les couleurs à distinguer ne présentent pas forcément des différences flagrantes. La figure 3.23 présente quelques images d'avivés de différentes couleurs et provenant du cas applicatif 2. Il ne s'agit pas là de toutes les couleurs à discerner mais plutôt d'un panel permettant d'apprécier la difficulté à classer les avivés. De plus, la notion de couleur au sens du client, peut ne pas être uniquement liée à la notion de couleur pour un expert vision. En effet, il peut introduire des notions de texture liées à la répartition des couleurs au sein d'une même pièce de bois (homogénéité par exemple).

La caractérisation la plus simple des couleurs à identifier utilise les histogrammes des composantes colorimétriques, qu'ils soient à une, deux ou trois dimensions. Mais, pour réduire la complexité des données à traiter, il est intéressant de réduire la quantité d'informations par le calcul de propriétés liées à ces histogrammes. Le choix du repère colorimétrique CIE Lab nous permet de garder indépendantes les notions de chrominance et de luminance. Nous choisissons donc l'utilisation des histogrammes de chaque composante colorimétrique afin d'évaluer ces propriétés. Cependant, dans une telle représentation la notion de chrominance se trouve décomposée car les composantes  $a$  et  $b$  du repère CIE Lab contiennent toute l'information de teinte  $h$  (équation 3.19) et de chroma  $C$  (équation 3.20). Nous avons donc choisi d'évaluer la couleur à partir des composantes  $L$ ,  $a$ ,  $b$ ,  $h$  et  $C$ . L'utilisation conjointe des composantes  $a$ ,  $b$  et  $h$  peut paraître redondante. En fait, la composante  $h$  permet de définir une notion de teinte directement interprétable par un Homme, alors que les composantes  $a$  et  $b$  illustrent plus la proportion des couleurs représentées par ces axes (axe vert-rouge pour la composante  $a$ , axe bleu-jaune pour la composante  $b$ ).

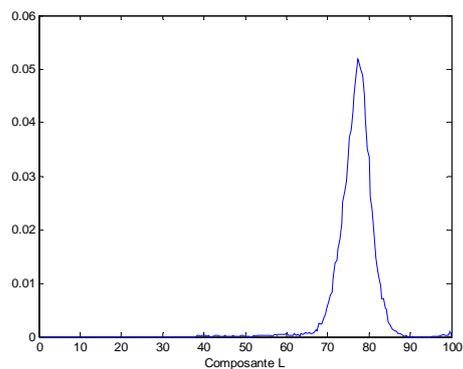
$$h = \arctan\left(\frac{b}{a}\right) \quad (3.19)$$

$$C = \sqrt{a^2 + b^2} \quad (3.20)$$

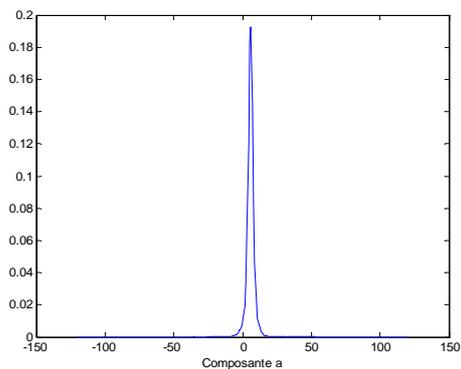


Figure 3.23 : Avivés de 6 différentes couleurs pour plusieurs essences (liste non exhaustive) – Cas applicatif 2

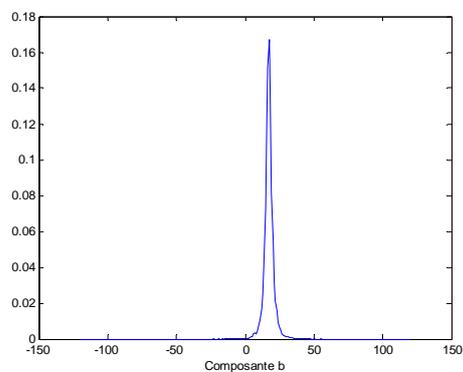
La figure 3.24 illustre un exemple d’histogrammes normalisés de chacune des composantes calculées pour une pièce de chêne rouge de couleur rouge clair.



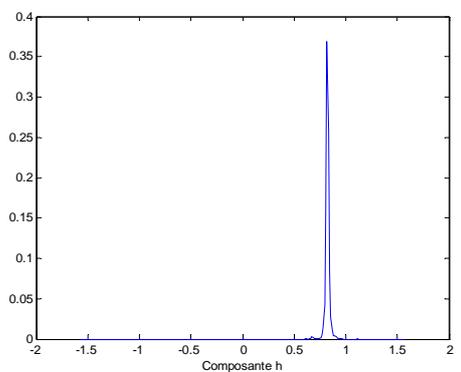
(a)



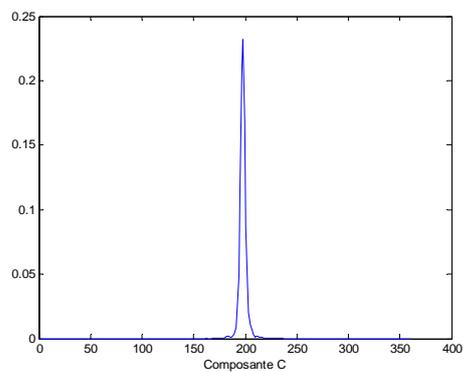
(b)



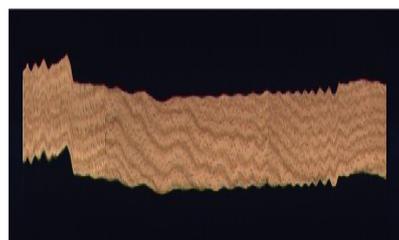
(c)



(d)



(e)



(f)

Figure 3.24 : Histogrammes normalisés des composantes L (a), a (b), b (c), h (d) et C (e) d'un avivé de chêne rouge de couleur rouge clair (f) – Cas applicatif 1

Les techniques de caractérisation de la couleur reprennent classiquement le calcul des moments d'ordre inférieur (0 et 1) des différents canaux colorimétriques [HANB-02] [SATH-01] [DAUL-00] (section 2.2.3.). Nous avons retenu ces paramètres mais également d'autres, plus complexes, extraits des histogrammes afin de pouvoir construire le vecteur caractéristique le plus complet possible. Il est à noter que chacun des paramètres calculés reste interprétable par rapport aux raisonnements humains, car nous souhaitons garder cette propriété dans le développement du capteur flou.

- **Présentation des caractéristiques extraites des histogrammes 1D**

L'ensemble des moments statistiques permet de définir entièrement l'information contenue dans un histogramme. En fonction des détails souhaités sur la répartition des couleurs, il est possible d'approximer les histogrammes de chaque composante par un nombre fini de ces moments. Le calcul des quatre premiers moments (équations 3.21 et 3.22) a été effectués sur les histogrammes. Le vecteur ainsi généré est composé au total de 20 paramètres. Nous avons également déterminé l'entropie de Shannon (équation 3.23) et l'homogénéité (équation 3.24) des histogrammes afin de compléter ce vecteur car ces paramètres correspondent à des notions que le client peut utiliser afin de définir une couleur (notion de couleur et de texture au sens vision).

L'entropie de Shannon permet de déterminer la quantité d'information moyenne de chaque état de l'histogramme et d'en mesurer une incertitude ; sa valeur sera maximale si chaque état est caractérisé par la même quantité d'informations. L'homogénéité doit permettre, quant à elle, d'évaluer les fluctuations de chaque composante sur les images.

Ainsi, le vecteur caractéristique initial  $V_{initial}$  est constitué de 30 attributs définissant la répartition statistique des couleurs au sein des images traitées.

$$m_{1,X} = \frac{\sum_i i \cdot h_X(i)}{\sum_i h_X(i)} \quad (3.21)$$

$$m_{k,X} = \left( \frac{\sum_i (i - m_{1,X})^k \cdot h_X(i)}{\sum_i h_X(i)} \right)^{\frac{1}{k}} \quad (3.22)$$

$$entropie_X = -\sum_i h_X(i) \cdot \log_2(h_X(i)) \quad (3.23)$$

$$homogénéité_X = \sum_i \frac{h_X(i)}{i} \quad (3.24)$$

où  $m_{1,X}$  correspond au premier moment ;

$m_{k,X}$  correspond au  $k^{\text{ième}}$  moment (avec  $k = \{2, 3, 4\}$ ) ;

$h_X(i)$  correspond à la valeur de l'histogramme de la composante  $X$  ( $X = \{L, a, b, h, C\}$ ).

Le tableau 3.3 présente les vecteurs caractéristiques de six avivés de *chêne rouge* de couleur différente tirés d'une base de données industrielle en rapport avec le cas applicatif 1. Nous pouvons constater, par exemple, au vue de la plage de variation des paramètres associés à la composante  $h$  (de l'ordre de  $10^{-2}$  voire  $10^{-3}$ ), que cette composante ne semble pas être très discriminante.

Tableau 3.3 : Vecteur caractéristique de six avivés de *chêne rouge* de couleur différente

Caractéristique	Composante	Couleur des avivés					
		Brun Foncé	Brun	Brun Clair	Rouge Foncé	Rouge	Rouge Clair
Premier moment	L	70.9971	75.1458	77.0475	70.5316	73.3545	76.7432
	a	5.6969	5.9088	5.2003	7.2150	7.6307	5.9265
	b	17.6851	17.4299	17.1814	17.5340	17.5682	17.2395
	h	0.8246	0.8228	0.8248	0.8181	0.8166	0.8221
	C	198.1261	198.0800	197.3814	199.0929	199.4224	197.9538
Deuxième moment	L	4.1710	4.7728	4.0094	4.2187	3.9954	4.6233
	a	3.8401	4.0317	4.2555	3.8254	3.9726	4.2529
	b	3.2811	3.8820	3.4767	3.3024	2.8668	3.8925
	h	0.0197	0.0217	0.0216	0.0194	0.0192	0.0229
	C	3.6649	4.0818	3.9130	3.7010	3.5022	4.0857
Troisième moment	L	3.5696	5.2956	5.7058	2.3295	4.9953	5.9176
	a	6.3457	6.1903	7.4878	6.0972	7.0453	6.4688
	b	1.0890	0.9710	3.4755	2.1452	2.6811	3.0368
	h	0.0255	0.0239	0.0262	0.0226	0.0271	0.0237
	C	3.8537	4.2223	5.6861	4.0606	4.9773	4.5299
Quatrième moment	L	8.6842	9.0823	9.1630	9.0033	8.7814	9.5633
	a	10.0383	9.9836	11.6588	9.7210	11.0499	10.8566
	b	6.1180	7.2578	7.6558	5.9142	6.3728	7.8081
	h	0.0424	0.0432	0.0472	0.0397	0.0436	0.0475
	C	7.6248	8.0779	9.2240	7.5521	8.6335	8.7551
Entropie	L	5.1349	5.3689	4.9023	4.9972	4.9782	5.2924
	a	3.4589	3.5536	3.2759	3.4861	3.1214	3.5288
	b	3.6342	3.8525	3.5170	3.6843	3.2961	3.7948
	h	2.3595	2.5444	2.3011	2.4044	2.1245	2.5407
	C	3.1202	3.2775	2.8978	3.1415	2.6780	3.1873
Homogénéité	L	0.0141	0.0134	0.0130	0.0142	0.0137	0.0131
	a	0.2046	0.1849	0.2208	0.1513	0.1399	0.1883
	b	0.0590	0.0602	0.0602	0.0592	0.0576	0.0604
	h	1.2134	1.2162	1.2133	1.2230	1.2253	1.2174
	C	0.0050	0.0051	0.0051	0.0050	0.0050	0.0051

A partir de tels vecteurs caractéristiques, il est difficile de choisir les seuls attributs utiles à la discrimination des différentes couleurs. Il est donc nécessaire d'analyser ces vecteurs caractéristiques afin d'en réduire la dimension. En fait, par cette réduction, nous voulons conserver un système à taille humaine en termes d'interprétabilité. De plus, le système développé doit fonctionner en temps-réel ce qui impose des contraintes de taille et de temps de traitement.

- **Réduction de la dimension du vecteur caractéristique**

Pour répondre aux contraintes du système de vision (aspect temps-réel des traitements et interprétabilité des résultats), nous avons donc choisi de réduire la dimension du vecteur caractéristique. La base de données « Base\_Couleur\_1 » nous a permis d'effectuer cette réduction de dimension du vecteur caractéristique.

Par ailleurs, les études précédentes [HANB-02][DAUL-00] ainsi que l'expertise des utilisateurs laissent supposer que seuls les moments d'ordre inférieur (0 et 1) portent une information discriminante. Cette tendance a été vérifiée par une analyse en composante principale, dont les résultats montrent que seuls 4 ou 5 paramètres sont pertinents. Pour déterminer ces paramètres, nous avons utilisé un algorithme de sélection d'attributs afin de les identifier. Pour effectuer cette sélection, notre choix s'est porté sur un algorithme adaptatif de mise à l'échelle de l'espace de paramètres utilisé dans un algorithme SVM (Support Vector Machine) [GRAND-02]. Le principe d'évaluation de l'importance des paramètres est basé sur le calcul de l'inertie moyenne de chaque paramètre par rapport à un lot de données. Plus cette valeur est grande, plus le paramètre est pertinent pour distinguer les différentes classes qui composent le lot de données. Cet algorithme a été implémenté dans une boîte à outils Matlab dont nous nous sommes servis pour effectuer les tests [SVM]. Il existe cependant d'autres méthodes de sélection de paramètres basées, par exemple, sur l'utilisation de treillis associés à l'intégrale de Choquet [MAZA-07], mais l'existence et la simplicité de cette boîte à outils de Matlab ont été des points clés de notre choix. Cette analyse sur le choix des paramètres pertinents pourrait être plus approfondie, mais, au vu de l'écart entre les 5 paramètres retenus et les suivants, nous pouvons supposer que d'autres méthodes de sélection de paramètres donneraient la même tendance [PUDI-02].

Les résultats obtenus sur le lot de données fournissent les valeurs d'inertie de chaque paramètre par rapport à la discrimination des différentes classes de sortie (figure 3.25). Le graphique de la figure 3.25 présente en abscisse les différents paramètres constituant le vecteur caractéristique dans l'ordre du tableau 3.3 : l'abscisse 1 correspondant au paramètre  $m_{1,L}$ , l'abscisse 2 correspondant au paramètre  $m_{1,a}$ , ..., l'abscisse 30 correspondant au paramètre homogénéité<sub>C</sub>. Afin de valider la sélection des paramètres, une classification sur ce même lot a été réalisée à l'aide du classificateur FRC dont le principe est détaillé dans le chapitre 4. Nous réalisons alors une validation du système de reconnaissance par la finalité à partir d'un bouclage sur le taux de reconnaissance. Seuls les résultats obtenus avec les meilleurs réglages sont présentés ici.

Le tableau 3.4 résume les résultats obtenus à partir de plusieurs vecteurs caractéristiques. Ces vecteurs caractéristiques, construit à partir des résultats de la phase de sélection des attributs (équations 3.25 à 3.29), sont comparés à un vecteur uniquement composé des premiers moments des composantes L, a et b (équation 3.30). Celui-ci correspond en fait aux données actuellement extraites dans le système industriel en place. Les paramètres constituant ces vecteurs sont choisis en fonction de leur inertie moyenne. Nous prenons tout d'abord les deux plus grandes valeurs et nous ajoutons ensuite les valeurs juste inférieures à celles-ci.

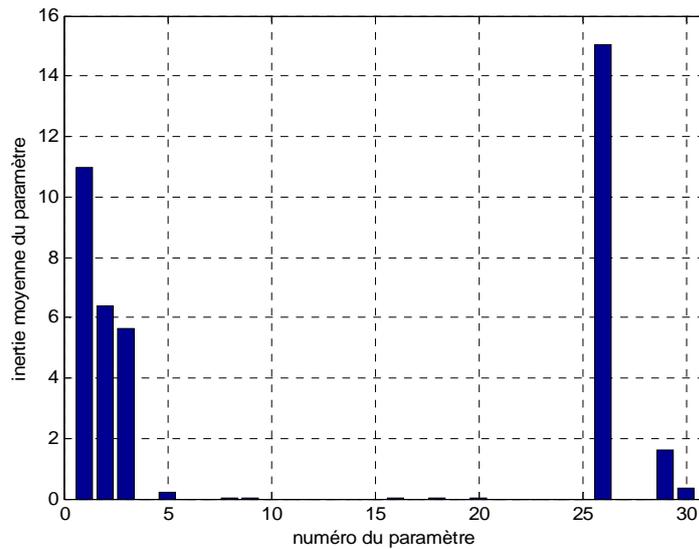


Figure 3.25 : Inertie moyenne de chaque paramètre pour la discrimination des classes

$$V_1 = \begin{pmatrix} m_{1,L} \\ \text{homogénéité}_L \end{pmatrix} \quad (3.25)$$

$$V_2 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ \text{homogénéité}_L \end{pmatrix} \quad (3.26)$$

$$V_3 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \end{pmatrix} \quad (3.27)$$

$$V_4 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \\ \text{homogénéité}_h \end{pmatrix} \quad (3.28)$$

$$V_5 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \\ \text{homogénéité}_h \\ \text{homogénéité}_c \end{pmatrix} \quad (3.29)$$

$$V_6 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \end{pmatrix} \quad (3.30)$$

Tableau 3.4 : Taux de reconnaissance pour différents vecteurs caractéristiques

Vecteurs caractéristiques	$V_1$	$V_2$	$V_3$	$V_4$	$V_5$	$V_6$
Taux de reconnaissance en apprentissage	58.54%	86.08%	89.24%	89.57%	<b>90.19%</b>	87.65%
Taux de reconnaissance en généralisation	55.62%	82.87%	83.53%	<b>84.37%</b>	83.21%	79.58%

En analysant les résultats du tableau 3.4, le vecteur  $V_4$  fournit le meilleur taux de reconnaissance en généralisation. Il faut noter qu'en ajoutant deux paramètres liés à l'homogénéité des couleurs au vecteur  $V_6$  le taux de reconnaissance augmente d'environ 5%. Enfin, nous constatons que les moments d'ordre supérieur à 1 sont inutiles pour différencier les différentes couleurs (la valeur moyenne de l'inertie de ces paramètres est quasiment nulle). Ces conclusions ne sont pas influencées par le choix de la méthode de classification. En effet, des résultats similaires ont été obtenus en utilisant l'algorithme des k plus proches voisins (Annexe B.2).

### 3.2.4. Répartition spatiale de la couleur

Comme nous avons pu le voir dans l'état de l'art des systèmes de vision employé dans le domaine du bois (section 2.1.2.), l'analyse de la texture permet classiquement de différencier

des avivés suivant leur mode de débit dans une grume (dosse, quartier, faux-quartier, cœur). Dans notre cas, nous ne cherchons pas à classer les images suivant la texture, mais au contraire, nous voulons nous servir de l'information pouvant être contenue dans la texture afin d'améliorer la classification colorimétrique des produits. En effet, il est très difficile de faire abstraction de la répartition spatiale de l'information couleur lorsqu'il s'agit de classer un produit. La figure 3.26 illustre parfaitement cette subjectivité de la perception humaine.

Avant que les avivés (1) et (2) ne soient permutés, les deux sont initialement identifiés comme « rouge clair ». Après la permutation, l'avivé (2) est affecté à la classe « rouge ». Cela montre bien la subjectivité de la perception humaine pour la comparaison d'objet en fonction de l'environnement proche.

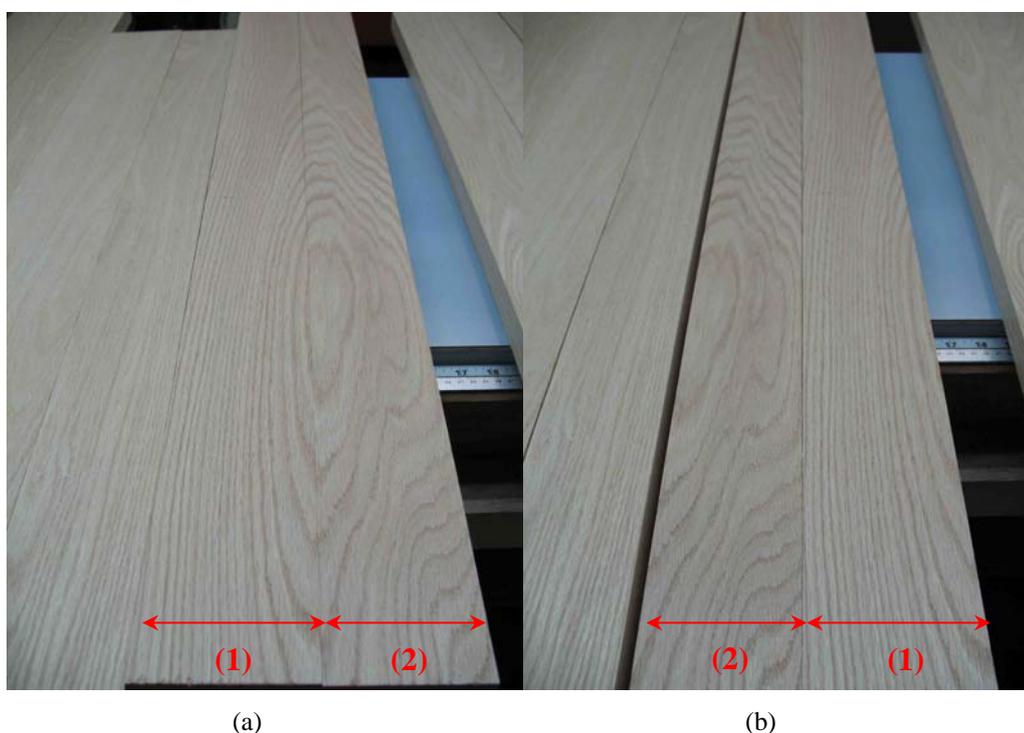


Figure 3.26 : Photographies d'un avivé avant (a) et après (b) une découpe longitudinale

Plusieurs techniques sont généralement employées pour réaliser de la classification de formes selon leur texture [BHAR-04] : transformée en ondelettes [ARIV-03], matrices de co-occurrences [HAUT-99], les intégrales de Choquet [GRAB-96], ...

En revanche, il n'est pas fréquent d'utiliser de telles méthodes pour confirmer ou infirmer une classification colorimétrique des objets. Notre choix s'est porté sur l'utilisation des matrices de co-occurrences des niveaux de gris d'une image afin d'extraire un ensemble d'attributs de texture [BHAR-04] [TURC-00] [HAUT-99]. Ce choix est surtout justifié par l'indépendance et l'interprétabilité des paramètres qui sont extraits de ces matrices. En effet,

dans le cas des transformées en ondelettes, par exemple, les coefficients extraits ne contiennent pas d'informations sémantiques.

Une fois ces attributs extraits, il est alors possible d'effectuer une sélection de paramètres identique à celle présentée dans la section 3.2.3.

- **Présentation des caractéristiques extraites des matrices de co-occurrences**

Les matrices de co-occurrences des niveaux de gris d'une image font ressortir certaines propriétés sur leur distribution spatiale. Le choix du repère colorimétrique CIE Lab étant fait, le calcul des matrices s'effectue sur les cinq images des composantes L, a, b, h et C. La matrice de co-occurrence  $P_d$  d'une image de composante est créée à partir de l'équation 3.31 qui exprime chaque élément  $P_d(i, j)$  de la matrice.

$$P_d(i, j) = \frac{\#\{(r, s), (t, u) \mid I(r, s) = i, I(t, u) = j\}}{N_d} \quad (3.31)$$

où  $I$  correspond à l'image en niveaux de gris ;

$i$  et  $j$  représentent des valeurs de niveaux de gris ;

$(r, s)$  correspond aux coordonnées d'un niveau de gris dans l'image  $I$  ;

$(t, u) = (r + dx, s + dy)$  correspond à un voisin du pixel de coordonnées  $(r, s)$  ;

$N_d$  correspond au nombre total de couples  $((r, s), (t, u))$  répertoriés dans la matrice  $P_d$ .

La dimension de la matrice  $P_d$  dépend de la quantification des niveaux de gris. Si toute l'échelle des niveaux de gris est utilisée (soit 256 niveaux), la matrice contiendra 65536 valeurs. Il est donc possible de sous échantillonner ces valeurs pour réduire le nombre d'éléments de cette matrice.

Un grand nombre d'attributs de texture peuvent être calculés à partir de ces matrices de co-occurrences. Il existe cependant une certaine redondance dans le choix de ces paramètres [BHAR-04] [LATI-00] [TURC-00] [HAUT-99]. Le choix fait durant ces travaux est donc le suivant :

- L'énergie ou second moment angulaire (équation 3.32) est une mesure d'homogénéité spatiale des images. Il s'agit d'une mesure caractérisant des textures désordonnées. Ainsi, plus l'image sera homogène, plus la valeur du paramètre sera petite.

$$ASM = \sum_i \sum_j (P_d(i, j))^2 \quad (3.32)$$

- Le contraste ou inertie (équation 3.33) est une mesure permettant d'évaluer la quantité de variations locales présentes dans une image.

$$Contraste = \sum_i \sum_j (i-j)^2 P_d(i, j) \quad (3.33)$$

- L'entropie (équation 3.34) est une mesure qui définit la complexité d'une texture. Plus sa valeur sera grande, plus la texture sera complexe, c'est-à-dire plus la texture sera composée de beaucoup de motifs différents.

$$Ent = -\sum_i \sum_j P_d(i, j) \cdot \log_2(P_d(i, j)) \quad (3.34)$$

Ce choix se justifie de plusieurs manières. Tout d'abord, nous ne cherchons en aucun cas à extraire toute l'information de texture, notre problématique ne concernant pas l'appariement d'avivés suivant les motifs du grain du bois. Ensuite, toujours dans un souci d'interprétabilité et d'intégration de notre capteur sous la forme d'un capteur flou, seules des notions compréhensibles par un être humain sont choisies ; le classificateur FRC exprimant tout son potentiel dans le cas de paramètres sémantiquement interprétables.

Ces trois paramètres sont donc évalués sur les cinq images de composantes selon quatre orientations ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ) et un pas de déplacement  $d$ . Les images du système d'acquisition n'ayant pas une résolution identique sur les deux axes longitudinal et transversal, les déplacements de la matrice se font de telle manière à respecter la précision qui peut être obtenue à l'œil nu. Pour les trois cas applicatifs, les résolutions valent 0.3 mm/pixel pour la résolution transversale, et 1.5 mm/pixel pour la résolution longitudinale. Les voisinages des pixels étudiés par la matrice de co-occurrences sont définis par un déplacement longitudinal d'un pixel ( $d_x = 1$ ), et par un déplacement transversal de cinq pixels ( $d_y = 5$ ). Ainsi, pour chaque image étudiée, nous disposons d'un vecteur caractéristique composé de soixante attributs, soit douze attributs par images en niveaux de gris.

Le tableau 3.5 présente les caractéristiques extraites des matrices de co-occurrences pour chaque orientation obtenues à partir de l'image de la composante colorimétrique L pour deux avivés. Ces deux avivés sont identifiés dans la même classe de couleur si nous utilisons uniquement le vecteur caractéristique choisi dans la section 3.2.3., alors qu'ils ne sont pas identifiés dans la même classe par le client.

Dans cet exemple, nous constatons que le paramètre *Contraste* semble être discriminant pour faire la différence entre ces deux avivés.

Tableau 3.5 : Caractéristiques extraites des matrices de co-occurrences pour 2 images de composante colorimétrique L

Caractéristiques		
$ASM_{L,0^\circ}$	0.001910	0.002571
$Contraste_{L,0^\circ}$	<b>69.737916</b>	<b>58.516825</b>
$Ent_{L,0^\circ}$	9.502272	9.154571
$ASM_{L,45^\circ}$	0.001959	0.002592
$Contraste_{L,45^\circ}$	<b>62.966795</b>	<b>58.083788</b>
$Ent_{L,45^\circ}$	9.472622	9.145401
$ASM_{L,90^\circ}$	0.003918	0.005285
$Contraste_{L,90^\circ}$	<b>14.686082</b>	<b>11.251006</b>
$Ent_{L,90^\circ}$	8.592276	8.222369
$ASM_{L,135^\circ}$	0.001954	0.002586
$Contraste_{L,135^\circ}$	<b>63.989509</b>	<b>58.295683</b>
$Ent_{L,135^\circ}$	9.477275	9.145283

• **Réduction de la dimension du vecteur caractéristique**

Les caractéristiques de textures extraites des matrices de co-occurrences peuvent être corrélées et/ou redondantes. C'est pourquoi, nous appliquons le même algorithme de sélection des paramètres que précédemment pour ne garder que les paramètres pertinents.

La réduction de la dimension du vecteur caractéristique peut être effectuée à partir de deux ensembles de caractéristiques :

- soit en utilisant un vecteur composé des cinq caractéristiques statistiques sélectionnées précédemment et des soixante caractéristiques de texture (65 caractéristiques) ;

- soit en reprenant le vecteur initial de trente caractéristiques statistiques et en le complétant avec les soixante caractéristiques de texture (90 caractéristiques).

Comme précédemment, une analyse en composantes principales, effectuée en première approche, nous a conduits à considérer 5 ou 6 paramètres comme étant pertinent. Cette tendance confirme notre impression. En effet, pour les cas industriels 1 et 2 présentés en introduction, les informations de texture semblent faiblement caractéristiques. En appliquant l'algorithme de sélection précédemment utilisé, nous pouvons représenter les valeurs d'inertie de chaque paramètre (figure 3.27).

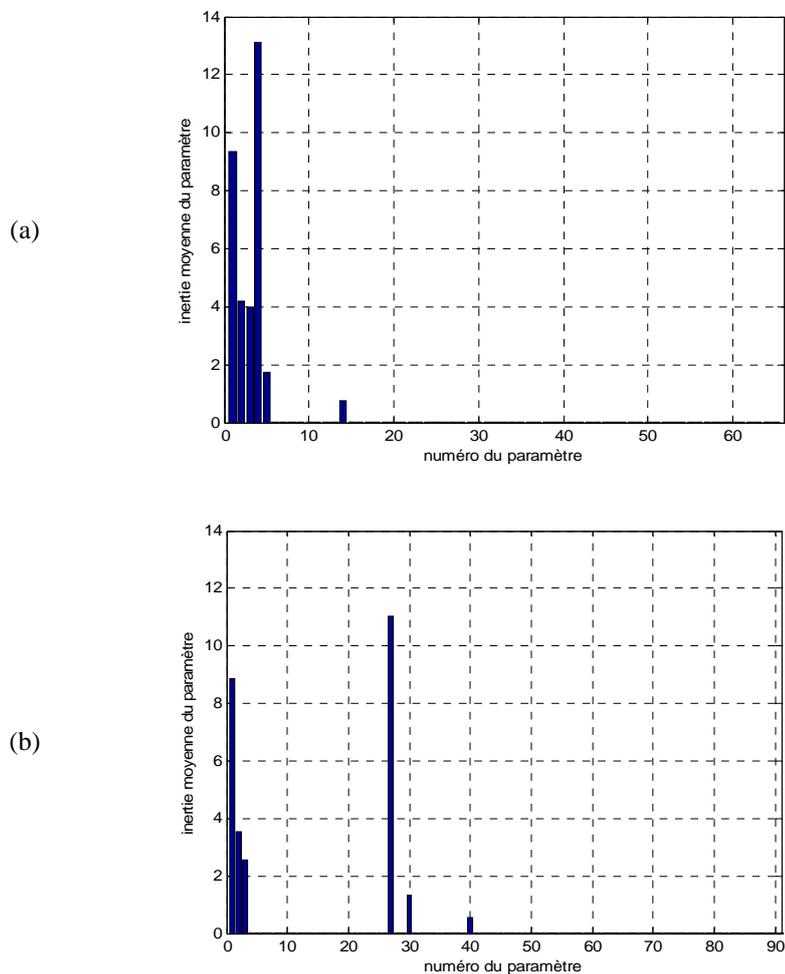


Figure 3.27 : Inertie moyenne de chaque paramètre pour la discrimination des classes (a : 65 caractéristiques, b : 90 caractéristiques)

Le choix des paramètres utiles à la discrimination des différentes classes se fait de la même manière que précédemment. Dans les deux cas présentés (figure 3.29), les mêmes six paramètres semblent être discriminants pour les différentes classes de couleur. Les attributs composant le vecteur caractéristique  $V_4$  (équation 3.28) sont sélectionnés ainsi que l'attribut  $Ent_{L,90^\circ}$ . Afin de valider ce choix, des tests de classification ont été réalisés de la même manière que pour les attributs statistiques de la couleur. Le tableau 3.6 résume les résultats obtenus pour les vecteurs  $V_4$  et  $V_7$  (équation 3.35).

$$V_7 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \\ \text{homogénéité}_h \\ Ent_{L,90^\circ} \end{pmatrix} \quad (3.35)$$

Tableau 3.6 : Taux de reconnaissance pour différents vecteurs caractéristiques

Vecteurs caractéristiques	$V_4$	$V_7$
Taux de reconnaissance en apprentissage	89.57%	<b>89.99%</b>
Taux de reconnaissance en généralisation	84.37%	<b>84.41%</b>

Les taux de reconnaissance obtenus pour les deux vecteurs caractéristiques ne montrent pas d'amélioration significative. Les gains de 0.42 en apprentissage et 0.04 en généralisation ne prouvent pas la pertinence des paramètres supplémentaires. De plus, sachant que l'évaluation des matrices de co-occurrence est très gourmande en temps de traitement, nous proposons de garder le vecteur caractéristique  $V_4$ .

### 3.3. Conclusion

Pour prétendre effectuer un bon contrôle qualité, il est important de définir au mieux le système d'acquisition ainsi que les caractéristiques nécessaires à la discrimination des classes de sortie. L'étude réalisée sur le système d'acquisition et plus particulièrement sur les sources de lumière a permis de réduire considérablement les perturbations pouvant influencer la classification des couleurs. En revanche, il reste quelques variations non corrigées qui peuvent tout de même induire des imprécisions au niveau des mesures. Elles doivent donc être prises en compte durant la phase de classification/décision du système de vision.

Afin de discriminer au mieux les couleurs, nous avons tout d'abord choisi comme univers de discours le repère colorimétrique CIE Lab. En effet, ce repère reproduit au mieux la perception des couleurs par l'œil humain. Il permet de minimiser l'inertie intraclasse et de maximiser l'inertie interclasse. Ensuite, les décisions de notre capteur flou ne doivent pas intervenir à l'échelle du pixel. De ce fait, nous avons défini les zones d'intérêt (ROI) dans lesquelles sont caractérisées les couleurs, toujours en accord avec les desiderata des clients. Enfin, les mesures corrigées, délivrées par le capteur, représentent, dans notre cas, une quantité d'informations trop importante pour effectuer la reconnaissance des couleurs du bois tout en respectant les contraintes temps-réel du système de production. Il a donc fallu réduire la quantité et la complexité de ces mesures. La perception de la couleur étant liée à une représentation statistique et une représentation spatiale, l'extraction de plusieurs paramètres a été faite pour construire un vecteur caractéristique constitué de 90 attributs. En analysant précisément le pouvoir discriminant de chacun d'entre eux sur la différenciation des classes de couleur, la dimension de ce vecteur a été réduite à 5 : moyennes des composante  $L$ ,  $a$  et  $b$ , et homogénéité des composantes  $L$  et  $h$ . Ainsi, les essais montrent que le paramètre d'homogénéité de la composante  $h$ , bien que redondant, apporte une information différente des composantes  $L$ ,  $a$  et  $b$ . Nous pouvons supposer que l'homogénéité de la teinte  $h$ , notion interprétable, peut être exploitée par les règles linguistiques floues du classificateur FRC.

En revanche, l'information spatiale ne se révèle pas discriminante dans les cas applicatifs de cette étude. Cependant, les bases que nous avons développées pourront servir à de futurs travaux concernant la classification d'avivés incluant des notions de texture (dosse, quartier, faux-quartier, cœur).

Dans le cadre du développement d'un capteur flou, l'interprétabilité des paramètres extraits par un opérateur humain a été privilégiée. Le vecteur caractéristique est ainsi composé des premiers moments et des coefficients d'homogénéité des composantes colorimétriques du repère choisi. Les attributs associés à chaque couleur délimitent les différentes classes de couleur « client » dans un espace à 5 dimensions. Les classes sont donc représentées par des hypersphères, des hypercubes, ..., selon le type de classification. Ces représentations géométriques correspondent alors à l'univers de discours du capteur flou (section 2.4.2). Nous définissons également l'univers lexical, soit le vocabulaire pouvant être utilisé par les utilisateurs pour caractériser les couleurs à identifier. Ce vocabulaire correspond donc à la sortie du capteur flou.

Dans le cas applicatif 1, le client a fait le choix de définir les couleurs du *chêne rouge* par le vocabulaire suivant : Brun Foncé, Brun, Brun Clair, Rouge Foncé, Rouge, Rouge Clair. La figure 3.28 illustre ainsi le lien devant exister au sein d'un capteur symbolique entre les deux univers de représentation cités. Le même principe peut être appliqué aux autres cas applicatifs.

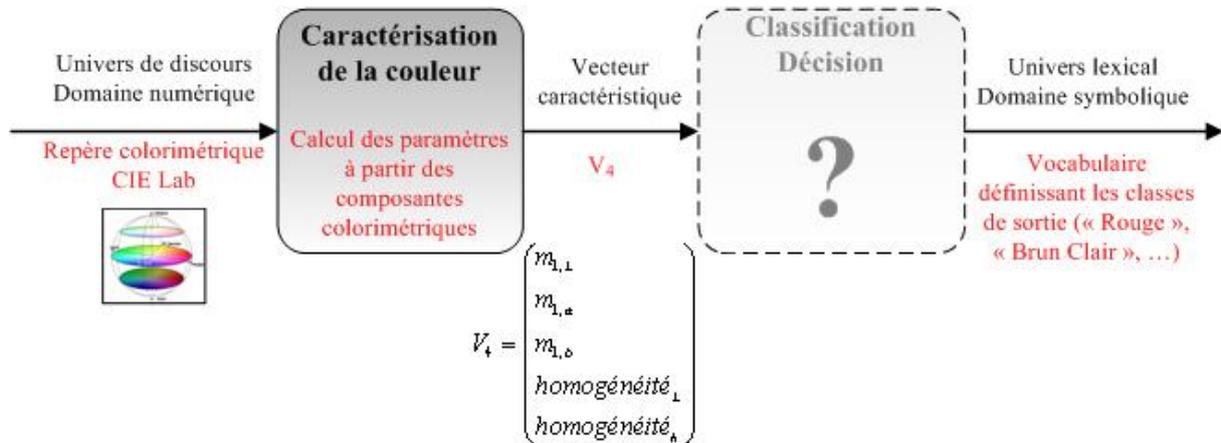


Figure 3.28 : Représentation du lien entre l'univers de discours et l'univers lexical – Caractérisation de la couleur

Comme nous venons de le montrer dans ce chapitre, les mesures brutes fournies par le capteur ne sont pas directement utilisables pour identifier les couleurs. Nous les avons analysées pour obtenir des mesures fonctionnelles qui sont, elles, exploitables pour le module classification/décision du capteur flou. Cette étape sert ainsi à définir le lien existant entre l'univers de discours et l'univers lexical (figure 3.30). Donc, pour finaliser le développement de notre capteur flou, nous présentons et validons, dans le chapitre 4, la méthode de classification FRC que nous avons choisie.



**CHAPITRE 4 : DES MESURES  
FONCTIONNELLES A LA DECISION**

---

## **4. Des mesures fonctionnelles à la décision : vers un capteur flou**

Après avoir réduit la complexité du problème aux simples mesures fonctionnelles utiles à la classification des couleurs (définition du vecteur caractéristique), il faut définir le module de classification/décision correspondant aux traitements de haut niveau de la chaîne de traitement d'images (figure 4.1). Dans le chapitre 3, nous avons identifié les deux premiers niveaux de traitement (bas niveau et niveau intermédiaire) suivant la structure du capteur intelligent. Le module classification/décision qui permet de fournir la réponse du système correspond naturellement à l'interprétation et la décision qui peuvent être effectuées à partir des descriptions des objets (mesures fonctionnelles).

Travaillant à partir de spécifications industrielles énoncées en langage naturel et cherchant à développer notre système sous la forme d'un capteur flou, il est important de pouvoir conserver ces informations dans le système de reconnaissance. De ce fait, il est donc judicieux de s'intéresser aux techniques de classification dérivant de la théorie des ensembles flous, car elle dispose d'une bonne capacité à modéliser et à intégrer les informations exprimées sous une forme linguistique [DUBO-96b].

Cependant, l'utilisation de termes linguistiques implique une prise en compte des imprécisions et incertitudes liées aux connaissances exprimées par les industriels (définition des classes de sortie, expertise liée au contrôle qualité souhaité). Il faut noter que ces imprécisions et incertitudes ne proviennent pas seulement de l'interprétation qui peut être faite des termes linguistiques employés. Elles apparaissent également au niveau du procédé d'acquisition de données qui peut induire des imprécisions de mesure, comme cela a pu être montré dans le chapitre 3. Afin de répondre complètement aux problèmes posés par cette étude, il est donc important de pouvoir spécifier une méthode de classification adaptée aux besoins de l'utilisateur et aux contraintes liées à l'environnement d'utilisation.

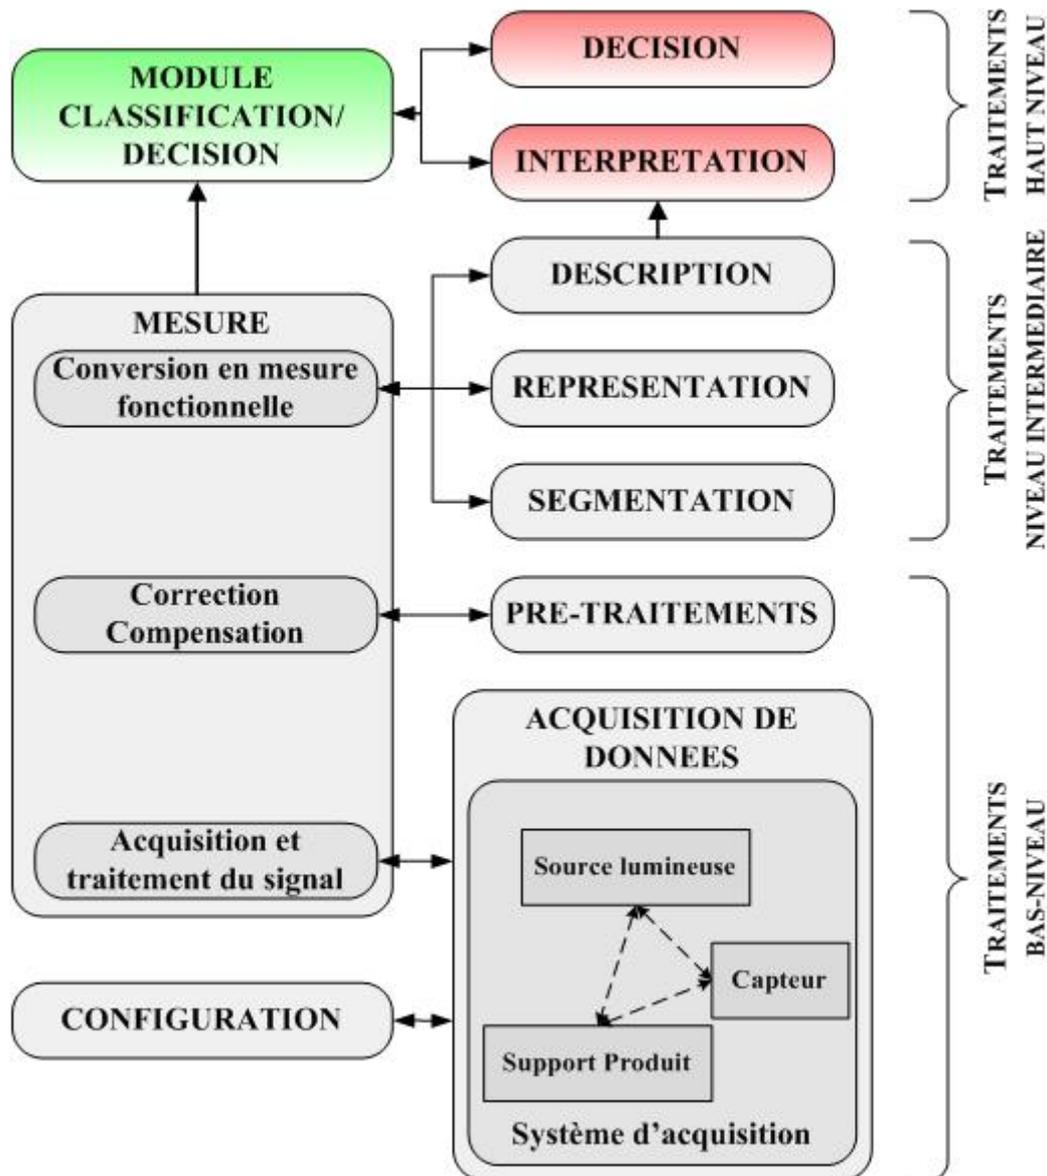


Figure 4.1 : Parallèle entre la chaîne de traitement d'images et la structure d'un capteur intelligent

Dans ce chapitre, une première partie est consacrée à la spécification de la méthode, et plus particulièrement aux concepts intervenant dans les systèmes de reconnaissance à base de règles linguistiques floues. La deuxième section présente ensuite une étude complète sur la méthode de classification retenue. Cette étude permet également d'exposer notre contribution à l'amélioration des phases de réglages du classificateur. Enfin, le cas applicatif 1 nécessitant une prise de décision globale à partir de résultats fournis par plusieurs capteurs, le raisonnement de classification de chaque capteur est étendu à l'utilisation conjointe de

plusieurs capteurs dont nous fusionnons les résultats pour fournir une information unique sous une forme floue.

## **4.1. Systèmes à base de règles linguistiques floues**

Comme nous avons pu le voir dans le chapitre 2, il existe de nombreuses techniques de classification, basées chacune sur des théories différentes : théories probabilistes, statistiques, connexionnistes, possibilistes, des ensembles flous. Dans notre étude, il est nécessaire de se positionner afin de valider notre choix d'utiliser une méthode de classification à base de règles linguistiques floues.

### **4.1.1. Imprécisions et incertitudes des données**

Les imprécisions et les incertitudes, intervenant dans la classification des avivés selon des critères colorimétriques, sont essentiellement portées par deux domaines :

- le domaine symbolique, qui représente la connaissance exprimée en langage naturel par les experts du domaine applicatif ;
- le domaine numérique, qui représente les données significatives fournies par l'analyse des images obtenues par le système d'acquisition.

Keller précise que ces incertitudes et imprécisions s'accumulent tout au long de la chaîne de traitement d'images, de la prise de mesure par le capteur à la prise de décision par la méthode de classification [KELL-97]. Pour simplifier les raisonnements à suivre, ces deux notions peuvent donc être résumées par un même terme : la connaissance imparfaite qu'elle soit numérique ou symbolique. Pour analyser et traiter cette dernière, différentes théories sont employées [BOUC-95] :

- La théorie des probabilités [FABI-96] : il s'agit du premier recours apparu pour traiter les connaissances incertaines. Elle se base sur une appréciation quantitative de l'incertitude soit par l'analyse de la fréquence de réalisation d'un événement particulier pour une même expérience répétée plusieurs fois, soit par l'analyse d'un choix aléatoire effectué sur un ensemble d'événements possibles.
- La théorie de l'évidence (ou théorie des fonctions de croyance) [SHAF-76] : il s'agit d'une généralisation de la théorie des probabilités. Cette théorie permet de représenter l'ignorance concernant un événement à partir des degrés de croyance et de plausibilité, qui sont caractéristiques de la fiabilité d'apparition d'un événement.
- La théorie des ensembles flous : il s'agit d'appréhender les incertitudes et imprécisions grâce à l'utilisation de concepts plus vagues que les nombres précis largement utilisés dans les théories des probabilités et de l'évidence. Ces concepts ont été introduits par Zadeh en 1965 [ZADE-65] afin de traiter les informations de la même manière que la pensée humaine.

- La théorie des possibilités : il s'agit d'une théorie facilitant l'intégration d'un raisonnement approximatif permettant de définir la différence entre deux états de connaissances qui sont uniquement discernables par leur degré de confiance associé aux informations fournies [ZADE-78]. Cette théorie fait intervenir la notion de nécessité qui permet d'évaluer la possibilité et la certitude d'un événement sans connaissance a priori sur la probabilité de ce même événement. Avec la théorie des ensembles flous, issue de la théorie de possibilités représente les bases de la logique floue [BOUC-95].

- **Caractères imprécis et incertains de l'étude**

En considérant le raisonnement humain qui intervient dans la classification des avivés selon leur couleur, il est relativement facile de définir les incertitudes et imprécisions des connaissances émises.

Tout d'abord lors de la définition des classes de sortie, il est difficile de quantifier exactement les objectifs de l'opérateur. En prenant pour exemple le cas applicatif 1, les couleurs ont été définies linguistiquement de manière graduelle : « Rouge foncé », « Rouge », « Rouge clair », ... Les précédentes études concernant le même sujet [LU-97b] [HANB-02] ne tiennent pas compte de cette gradualité des couleurs, et pourtant cette notion est très liée à la perception des couleurs que peut avoir un expert. En effet, les termes linguistiques « clair » et « foncé » sont intrinsèquement vague et imprécis. Il n'existe donc pas de frontières strictes entre les différentes couleurs à classer. La figure 4.2 illustre le recouvrement qu'il peut exister entre les différentes classes couleur de *chêne rouge* définies pour le cas applicatif 1.

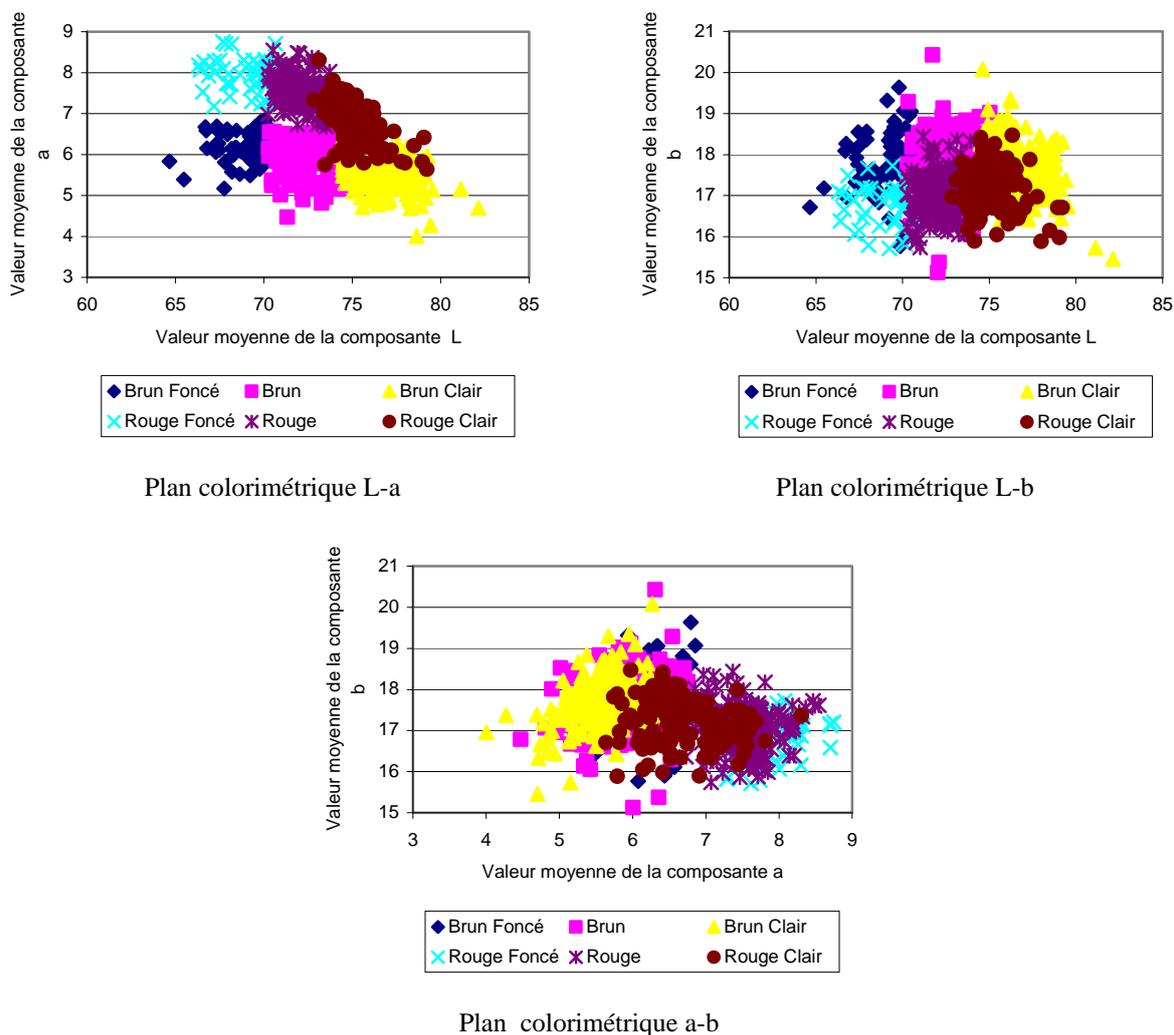


Figure 4.2 : Représentations graphiques de la distribution des points de la base de données Base\_Couleur\_1 dans les différents plans du repère colorimétrique CIE Lab

Un deuxième aspect lié au produit peut introduire de l'imprécision dans les données. Il s'agit de la présence de transitions graduelles de couleur sur une même pièce de bois. La figure 4.3 illustre ce phénomène sur une planche qui a un aspect général « Rouge », mais qui présente un passage très progressif de la couleur « Rouge Clair » à la couleur « Rouge ». De plus, ces imprécisions peuvent être accrues par la présence d'un veinage marqué. Un bois « Rouge Clair » peut paraître plus foncé si le grain du bois est dense et sombre. Le vecteur caractéristique définissant la couleur doit être le plus complet possible pour tenir compte de cette notion de texture inhérente à la couleur (section 3.2.3.).

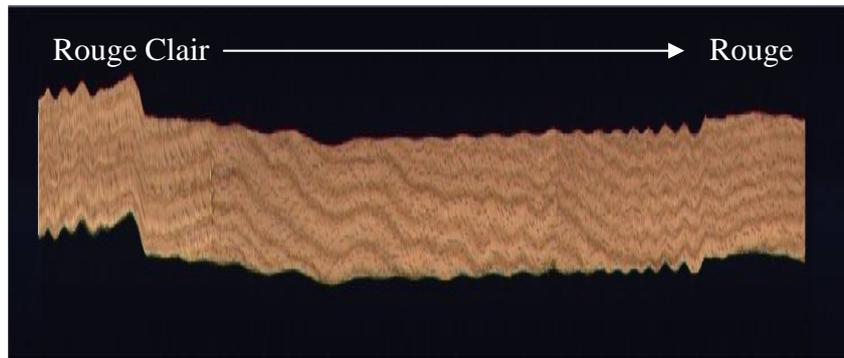


Figure 4.3 : Image d'une pièce de bois présentant un changement de couleur progressif

Outre le manque de précision dans les termes linguistiques utilisés par l'expert pour définir les couleurs à identifier, le capteur lui-même peut introduire des imprécisions et incertitudes de mesures, et cela, malgré l'implémentation de modèles de correction adaptés aux différentes variabilités constatées durant l'analyse du système d'acquisition exposé dans le chapitre 3 (influence de la température, de la distance bois/capteur, vieillissement, ...).

Ces différents points plaident en faveur de l'utilisation d'un outil capable de manipuler et d'intégrer des notions imprécises et incertaines. Nous avons choisi de nous placer dans le cadre de la théorie des ensembles flous et plus particulièrement la logique floue pour concevoir la méthode de classification. Cette conclusion a également un sens au niveau du développement du système sous la forme d'un capteur flou. En effet, il aurait été possible de travailler uniquement à partir des symboles (termes linguistiques définissant les classes de couleur) si ces derniers avaient été parfaitement disjoints, c'est-à-dire que les frontières entre chacun d'entre eux soient totalement binaire (section 2.3.2). La logique floue autorise une certaine flexibilité face à de telles problématiques car elle permet de définir des appartenances non strictes à chacune des classes de sortie [ZADE-65]. Cet aspect est essentiel pour des couleurs situées sur les nombreuses zones de confusion pouvant exister entre les différentes classes (figure 4.2).

Notre volonté de réduire le fossé sémantique entre les définitions expertes vision et bois incite également à nous placer dans le cadre de la logique floue. En tenant compte de ces deux expertises (vocabulaire du métier bois et vocabulaire du métier vision), il existe une différence entre les langages employés par chaque expert (section 2.1.2.). Ainsi, la logique floue permet de définir un espace de représentation et de raisonnement dans lequel ce fossé entre concepts symboliques et valeurs numériques extraites des images est réduit [HUDE-06].

- **Spécifications de la méthode de classification**

Outre la prise en compte de l'imprécision et de l'incertitude liées aux données, se pose le problème de la quantité d'échantillons disponibles pour la phase d'apprentissage. Le bois

étant un produit naturel, il est difficile de disposer du même nombre d'échantillons pour chaque classe à identifier. La figure 4.2 permet de constater la proportion de chaque couleur disponible pour le cas applicatif 1. Le tableau 4.1 reprend ces proportions par rapport à un lot constitué d'avivés (de *chêne rouge*) préalablement étiquetés par un expert.

Tableau 4.1 : Proportion de chaque couleur sur une population de 943 échantillons de bois

Couleur	Proportion
Brun Foncé	8.91%
Brun	18.66%
Brun Clair	27.47%
Rouge Foncé	5.73%
Rouge	20.89%
Rouge Clair	18.34%

De plus, en milieu industriel, il est très difficile d'obtenir de la part d'un client un grand nombre de données réelles afin d'entraîner le système de reconnaissance. La confection du lot de données d'apprentissage, qui nécessite généralement la plus grande attention, est souvent assimilée à un travail fastidieux, synonyme de perte de temps et d'argent. Il faut donc que la méthode de classification envisagée soit la plus robuste possible à partir d'un entraînement réalisé sur un faible lot de données.

Un dernier point reste à intégrer dans la méthode de classification. Il concerne l'expertise des industriels à proprement parler. En effet, dans des domaines hautement spécialisés, l'expert humain arrive à prendre des décisions, et cela quelque soit les conditions de travail. Le système de vision qui doit permettre le contrôle colorimétrique des avivés peut donc être imaginé sous la forme d'un système de décision reproduisant les raisonnements de l'expert humain. D'Aquila *et al.* préconise même l'utilisation de moteurs d'inférences qui permettent, non seulement de travailler à partir d'espace de représentation à  $n$  dimensions, mais aussi de prendre en compte toutes formes d'incertitude et imprécision pouvant intervenir au niveau des mesures, et du traitement [AQUI-02].

La figure 4.4 illustre les différentes imprécisions et incertitudes que la méthode à développer doit prendre en compte pour répondre à la problématique visée.

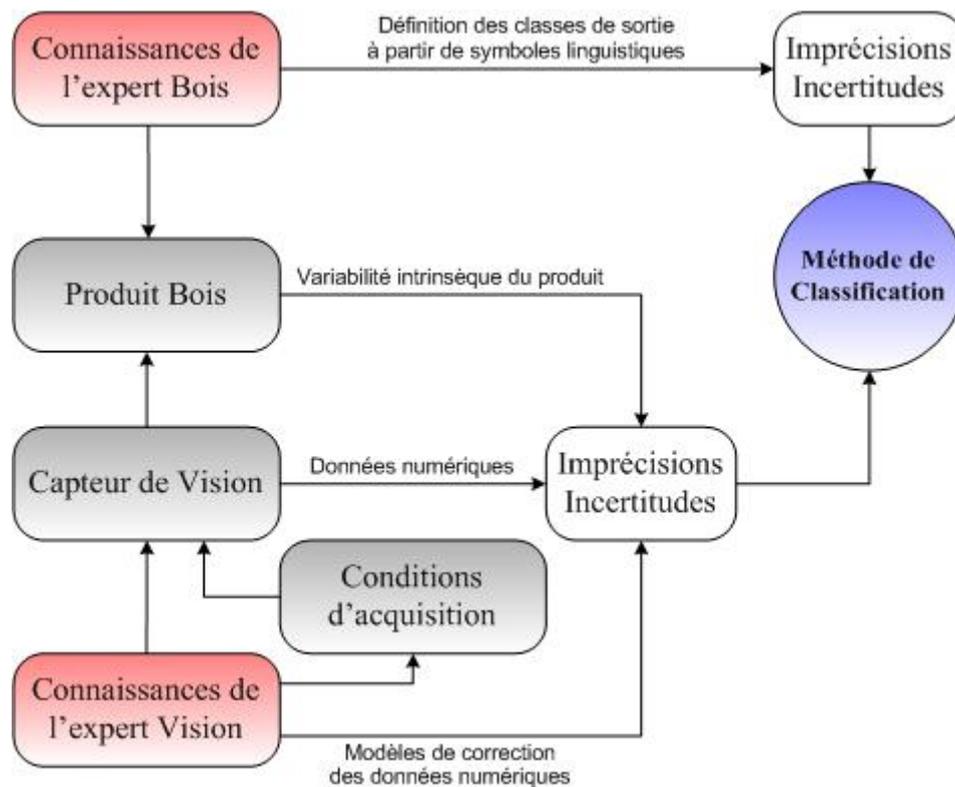


Figure 4.4 : Imprécisions et incertitudes à prendre en compte dans la méthode de classification colorimétriques des avivés

#### 4.1.2. Variables linguistiques – propositions floues – règles floues

Les différentes spécifications évoquées précédemment permettent d'opter pour une méthode de classification basée sur l'utilisation d'un modèle linguistique.

Les systèmes implémentant des modèles linguistiques à base de règles servant à la classification sont des techniques largement utilisées dans le domaine de la vision assistée par ordinateur [KELL-96]. Elles se composent de trois grandes parties : un jeu de règles de type SI...ALORS..., une base de données, et un moteur d'inférences qui permet d'interpréter les différentes règles et fournir le résultat final de la classification. Les mécanismes de fonctionnement de ces systèmes reposent sur l'utilisation de trois concepts faisant partie du raisonnement flou [BOUC-95] : les variables linguistiques, les propositions floues et les règles floues.

- **Les variables linguistiques**

Les variables linguistiques ont été introduites afin de décrire de manière qualitative des phénomènes n'étant pas caractérisables de manière quantitative car trop imprécise [ZADE-

75]. A la différence d'une variable numérique qui fait référence à des valeurs numériques précises, la variable linguistique prend ces valeurs dans un espace composé de mots du langage naturel compréhensibles par des non spécialistes.

De manière plus théorique, une variable linguistique est défini par un triplet  $(V, X, T_v)$  [BOUC-95] où :

- $V$  est la variable : dans la présente étude, il s'agit de chaque paramètre du vecteur caractéristique précédemment constitué ;
- $X$  est l'ensemble de référence ou univers de discours de la variable  $V$  ;
- $T_v = \{A_1, A_2, \dots\}$  est un ensemble, fini ou non, composé de sous-ensembles flous caractérisant les valeurs de la variable  $V$ . Ces sous-ensembles permettent de caractériser linguistiquement les valeurs de la variable  $V$  à l'aide d'un vocabulaire préalablement défini.

L'utilisation du mot « clair » pour caractériser une intensité lumineuse représente une réduction de l'univers de discours de la composante colorimétrique  $L$  aux seules valeurs supérieures à 60. Ainsi, sachant que les mesures de la composante colorimétrique  $L$  sont comprises entre 0 et 100, le terme « clair » sera associé à l'intervalle  $[60;100]$ , intervalle assimilé à un sous-ensemble flou  $A_{clair}$ .

Les sous-ensembles flous d'une variable  $V$  sont définis par des fonctions d'appartenance (4.1).

$$\begin{aligned} \mu_{A_i} : X &\rightarrow [0;1] \\ x &\rightarrow \mu_{A_i}(x) \end{aligned} \tag{4.1}$$

où  $\mu_{A_i}(x)$  correspond au degré d'appartenance de  $x$  au sous-ensemble  $A_i$ .

### • Les propositions floues

Il existe deux types de propositions dans le cadre d'un raisonnement flou : la proposition floue élémentaire et la proposition floue générale. Celles-ci permettent d'analyser respectivement le cas d'une seule variable linguistique, ou d'une composition de plusieurs de ces variables.

D'après la définition de Bouchon-Meunier [BOUC-95], une proposition floue élémentaire permet de traduire dans le domaine symbolique des valeurs exprimées dans le domaine numérique. Elle fait cohabiter les deux domaines à travers une qualification en phrase élémentaire de type «  $V$  est  $A$  ».  $V$  correspond ici à une variable linguistique définie par le triplet  $(V, X, T_v)$ , et  $A$  correspond à un mot du langage naturel appartenant à l'ensemble  $T_v$ . Une fonction d'appartenance  $\mu_A$  de  $A$  représente ensuite cette proposition, afin

de définir le degré d'appartenance  $\mu_A(x)$  d'un élément de  $X$  qui décrit la véracité de la caractérisation de  $A$  par la valeur exacte de  $V$ .

Une proposition générale floue permet une analyse conjointe de deux ou plusieurs propositions élémentaires floues «  $V$  est  $A$  », «  $W$  est  $B$  », ..., utilisant des variables  $V, W, \dots$ , supposées non corrélées. L'analyse conjointe s'exprime en général par une conjonction («  $V$  est  $A$  **ET**  $W$  est  $B$  ») ou une disjonction («  $V$  est  $A$  **OU**  $W$  est  $B$  ») de plusieurs propositions élémentaires floues. Les opérateurs de conjonction et disjonction, respectivement **ET** et **OU**, sont dans ce cas des connecteurs logiques implémentés par des T-normes et des T-conormes. Un cas particulier existe lorsque les variables linguistiques sont identiques. Dans ce cas, l'analyse conjointe se réduit à de simples opérations d'intersection et d'union respectivement implémentées par une T-norme et une T-conorme. De manière générale, pour deux variables linguistiques distinctes et deux propositions élémentaires floues associées, le résultat d'une composition conjointe (relation  $R$ ) sera défini de la manière suivante par une T-norme dans le cas d'une conjonction (4.2) et par une T-conorme dans le cas d'une disjonction (4.3).

$$\mu_R(x, y) = T(\mu_A(x), \mu_A(y)) = \text{x est A ET y est B} \quad (4.2)$$

$$\mu_R(x, y) = \perp(\mu_A(x), \mu_A(y)) = \text{x est A OU y est B} \quad (4.3)$$

- **Les règles floues**

Afin d'élaborer les règles floues, il est nécessaire de définir une fonction d'implication  $I$  (4.4) qui peut être synonyme de l'expression « Si  $A$  Alors  $B$  ».

$$I : A \rightarrow B \quad (4.4)$$

Les règles floues sont généralement constituées à partir des propositions floues définies précédemment. La connexion de ces dernières est réalisée grâce aux opérateurs de conjonction ou de disjonction et peuvent se transcrire en langage naturel (4.5).

$$\text{« Si } V \text{ est } A \text{ ET } W \text{ et } B \text{ Alors } Z \text{ est } C \text{ »} \quad (4.5)$$

où  $V, W$  et  $Z$  sont des variables linguistiques associées à des fonctions d'appartenance  $\mu_A(V), \mu_B(W), \mu_C(Z)$ .

Cette règle peut être décomposée en deux parties : la prémisse formée par le couple de variables linguistiques ( $V, W$ ), et la conclusion formée de la seule variable linguistique  $Z$ . La véracité de l'antécédent, dans ce cas, est évaluée grâce à une fonction d'appartenance notée  $\mu_R$  (4.6).

$$\mu_R(V, W) = T(\mu_A(V), \mu_B(W)) \quad (4.6)$$

Cette relation R peut ensuite être rapprochée de la conclusion à partir d'une implication floue, ce qui donne la règle floue. Celle-ci est associée à une valeur de vérité donnée par une fonction d'appartenance  $\mu_R$ . Dans le cas de l'exemple (4.5), cette fonction d'appartenance est définie comme suit (4.7).

$$\mu_R(V, W, Z) = I(T(\mu_A(V), \mu_B(W)), \mu_C(Z)) \quad (4.7)$$

La fonction d'appartenance ainsi définie pour une règle correspond au lien existant entre l'univers de discours des attributs constituant le vecteur caractéristique et l'univers lexical composé des mots du langage naturel attribués par l'utilisateur à chaque classe de couleur (figure 3.29). Le lien entre le domaine numérique et le domaine symbolique, cœur de la structure d'un capteur symbolique flou, est donc identifié.

D'après Dubois et Prade [DUBO-96a], ce type de règles floues sont réparties en deux groupes : les règles implicatives et les règles conjonctives. Cette dichotomie est effectuée à partir de l'information qui sert à construire les règles. Dans le cas des règles implicatives, il va s'agir de restreindre au fur et à mesure l'espace de valeurs possibles des variables considérées. Elles sont essentiellement issues de raisonnements basés sur la connaissance *a priori* des experts. Quant aux règles conjonctives, elles correspondent plus à une analyse de données et sont régies par les données elles-mêmes. En effet, en tenant compte de chaque association {valeur d'entrée/valeur de sortie} restituée par un lot de données d'apprentissage, les règles sont de plus en plus précises en éliminant toute ambiguïté.

Les règles floues sont généralement réparties en quatre groupes, qui sont des sous-groupes des règles conjonctives et implicatives. Il existe respectivement d'une part, les règles à possibilité et les règles anti-graduelles, et d'autre part, les règles à certitude et les règles graduelles.

- Les règles à possibilité permettent d'évaluer la possibilité d'un événement en déterminant la proximité entre les valeurs associées à cet événement et les valeurs acquises sur un lot de données d'apprentissage.
- Les règles anti-graduelles permettent d'évaluer la taille de l'ensemble des valeurs de sortie à partir du degré d'activation de la règle.
- Les règles à certitude permettent d'évaluer la certitude d'un événement en déterminant la proximité entre les valeurs associées à cet événement et les valeurs acquises sur un lot de données d'apprentissage.
- Les règles graduelles permettent d'évaluer la proximité entre les valeurs de l'antécédent de la règle et les valeurs des conclusions associées.

Généralement, un raisonnement flou est basé sur l'utilisation d'une base de règles notée  $\kappa$ . Cette base regroupe  $N$  règles qui sont activées en parallèle par un mécanisme d'inférences. Chaque règle délivre ainsi une conclusion partielle qui est ensuite agrégée aux autres, à partir d'un opérateur d'intersection ou d'union, pour fournir une conclusion globale au système. Cette agrégation peut s'exprimer d'après les expressions (4.8) et (4.9) suivant le type de règles utilisées (respectivement implicatives ou conjonctives).

$$R^\kappa = \bigcap_{i=1}^N r_i^\kappa \quad (4.8)$$

$$R^\kappa = \bigcup_{i=1}^N r_i^\kappa \quad (4.9)$$

où  $R^\kappa$  représente la relation floue associée à l'agrégation des  $N$  relations floues  $r_i^\kappa$  associées à chaque règle de la base.

Dans le cas des règles conjonctives, l'agrégation correspond à l'implémentation d'un opérateur de disjonction (T-conorme). Dans le cas des règles implicatives, elle correspond à l'implémentation d'un opérateur de conjonction (T-norme) [UGHE-98].

Dans notre étude, plusieurs choix ont été effectués à propos du mécanisme d'inférences et des règles floues utilisées. Evaluant les classes de sorties à partir de données numériques, il est naturel d'utiliser des règles conjonctives à possibilité.

Dans ce cas, l'inférence peut être réalisée par différents modèles parmi lesquels nous citons celui de Mamdani, celui de Larsen ou encore celui de Sugeno. Nous ne retenons pas celui de Sugeno car notre système doit fournir en sortie des réponses nominales et non des valeurs numériques [SUGE-85]. Le modèle de Larsen est, dans notre cas, préférable à celui de Mamdani car l'opérateur Produit cartésien est plus adapté que l'opérateur Minimum pour la manipulation de plusieurs prémisses [BERT-03]. L'inférence est alors une pseudo implication reproduite par une composition des opérateurs **Maximum** et **Produit**. L'agrégation des conclusions partielles associées à chaque règle est ensuite réalisée par l'utilisation de l'opérateur disjonctif **Maximum**. L'utilisation de règles conjonctives possède un avantage majeur, car elle permet d'éviter les incohérences dans la base de règles [DUBO-96a], et permet aussi d'attribuer une classe de rejet à un objet lorsque ce dernier ne répond à aucune règle décrite dans la base.

## 4.2. Classificateur à raisonnement flou

Le raisonnement flou mis en œuvre pour l'application visée est basé sur l'intégration d'un système de règles linguistiques floues. Ces dernières permettent d'approcher les domaines numérique (vecteur caractéristique) et symbolique (lexique associé à chaque attribut du vecteur caractéristique). A partir de ce rapprochement, il est alors possible d'interpréter les

connaissances émises par les experts « vision » et « bois » à travers les règles générées. Il existe de nombreuses méthodes permettant d'obtenir automatiquement ces règles floues à partir de lots de données [CORD-99] [BERT-03]. Cependant, notre choix s'est porté sur l'algorithme développé par Ishibuchi *et al.* qui met en œuvre un modèle de Larsen [ISHI-92]. Cette technique a connu plusieurs évolutions, mais la plus importante concerne le processus itératif d'apprentissage qui permet d'ajuster et d'affiner progressivement le jeu de règles en fonction des données d'entrées à partir d'un coefficient de confiance CF affecté à chaque règle [NOZA-97]. Le lecteur peut se référer à l'annexe B.1 qui détaille l'algorithme.

Dans une première partie, le principe de fonctionnement de l'algorithme est présenté [SCHM-04a] [SCHM-04b] [SCHM-06a]. Nous explicitons ensuite chaque étape de la méthode en insistant sur nos propositions en vue d'améliorer la classification. Ces propositions sont toujours validées à partir de lots de données artificielles (base de données IRIS [UCI]) et réelles (bases de données liées aux cas applicatifs). Enfin, nous validons les développements en comparant nos résultats à un certain nombre d'autres classificateurs de référence.

#### **4.2.1. Principe de la méthode**

L'algorithme de génération des règles se décompose en deux phases : la fuzzification des attributs constituant les entrées du système, et la génération des règles pour définir les sorties du système. A partir des règles générées, il est ensuite possible d'identifier, lors de la phase d'exploitation (aussi appelée phase de généralisation), tout objet non étiqueté caractérisé de la même manière que les objets composant le lot d'apprentissage. La figure 4.5 illustre le principe de la méthode.

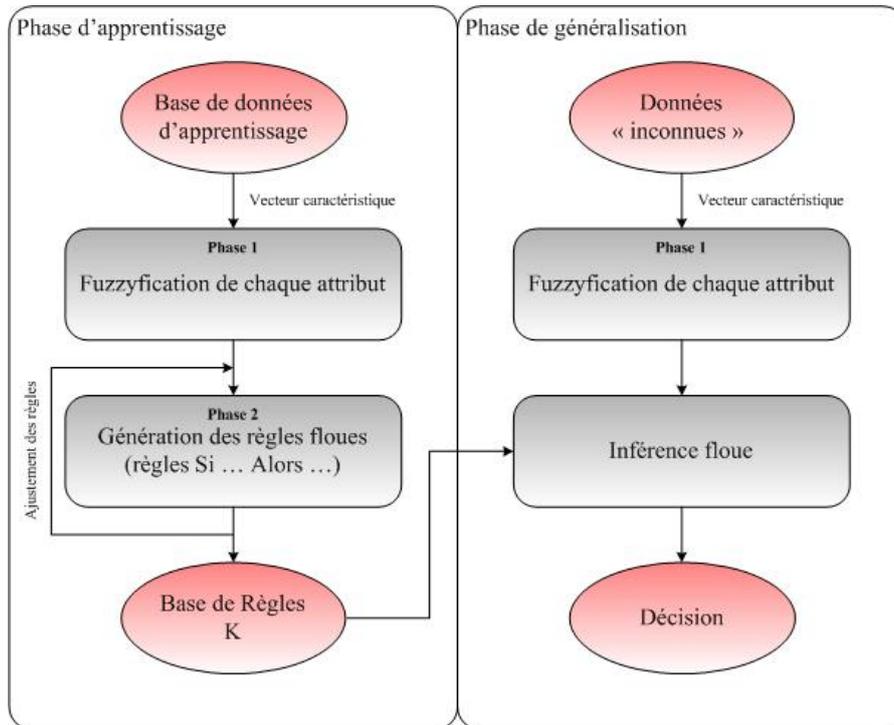


Figure 4.5 : Fonctionnement de l'algorithme durant les étapes d'apprentissage et de généralisation

L'algorithme exposé dans la littérature [NOZA-97] propose une étape supplémentaire d'affinage des frontières. Celle-ci permet d'augmenter le degré de confiance CF de la règle associée à la classe d'appartenance maximale et de diminuer celui de la règle associée à la classe d'appartenance venant en deuxième position. Cette étape est réalisée à partir de chaque échantillon qui compose le lot de données d'apprentissage. A l'extrême, le découpage de l'espace de représentation des données correspond parfaitement aux données d'apprentissage, et le système de reconnaissance peut souffrir d'une restriction trop forte durant la phase d'exploitation. En d'autres termes, il ne permet pas de prendre en compte la gradualité des réponses fournies par la méthode de classification. En fait, ce découpage devient binaire, conduit à un taux de reconnaissance de 100% en mémorisation sur les lots d'apprentissage, mais pose problème en généralisation. Dans notre étude, nous voulons conserver la flexibilité du modèle défini par le jeu de règles afin de conserver son potentiel de généralisation. Nous n'utilisons donc pas cette étape dans notre étude.

Enfin, il existe une grande différence entre nos travaux et ceux réalisés dans le cadre du contrôle flou. En effet, les systèmes de contrôle flou fournissent des valeurs numériques en sortie alors que nous voulons, dans notre cas, fournir des résultats sous une forme symbolique (classes de couleur). Ce passage de la dimension symbolique à la dimension numérique est aussi appelé défuzzification. Cette étape n'est donc pas présente dans notre étude.

### 4.2.2. Fuzzification des attributs du vecteur caractéristique

L'étape de fuzzification consiste à décomposer les univers de discours des variables linguistiques. Elle permet d'associer une partition de cet univers de discours à une valeur numérique. Pour une variable linguistique définie par son triplet  $(V, X, T_v)$ , le vocabulaire  $T_v$  représente les différents sous-ensembles flous de l'univers de discours  $X$  à partir de fonctions d'appartenance. Généralement le vocabulaire associé à une variable est celui employé par l'expert du domaine. Dans le cas de la couleur, et plus particulièrement l'intensité lumineuse, l'espace  $T_v$  peut être structuré autour des mots « clair », « moyen » et « foncé ». Il est même possible d'utiliser le mot « très » pour obtenir cinq catégorisations (ajout des termes « très clair » et « très foncé »). La figure 4.6 illustre un partitionnement équiréparti en cinq termes pour la variable L représentant l'intensité lumineuse d'une couleur.

D'une manière générale, le partitionnement peut s'effectuer de différentes façons. Nous explicitons dans la suite de cette section les types de partitionnement que nous avons retenus : le partitionnement équiréparti, le partitionnement adapté et le partitionnement automatique. Le partitionnement est déterminé par le nombre de termes de fuzzification, leur positionnement et leur forme.

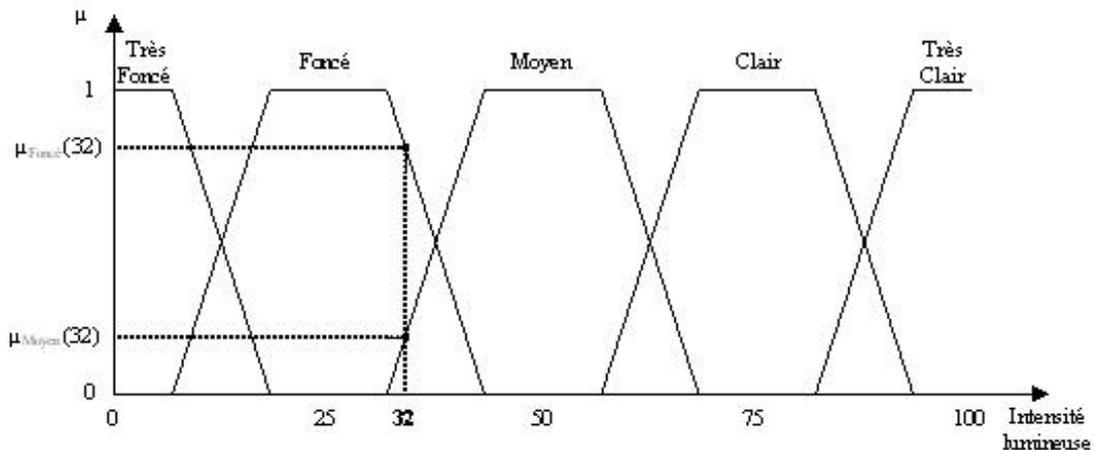


Figure 4.6 : Exemple de partitionnement en cinq termes suivant des courbes trapézoïdales

Outre le nombre de termes de fuzzification, la forme des fonctions d'appartenance peut avoir un impact sur les taux de reconnaissance. Il existe trois formes de base pour les fonctions d'appartenance : triangulaire, trapézoïdale, gaussienne. De plus, il est possible de composer ces formes de base (triangulaire/trapézoïdale, gaussienne/trapézoïdale).

L'étude des différentes manières d'effectuer le partitionnement a pour but de spécifier la méthode de fuzzification répondant au mieux aux critères imposés par notre étude.

- **Partitionnement équiréparti**

Le partitionnement équiréparti est obtenu en fixant directement le nombre de termes. Dans ce cas, l'univers de discours est découpé en termes régulièrement répartis. Des essais sont tout de même réalisés sur les données d'entrées afin de retenir la configuration idéale pour notre application. Généralement, ce nombre est choisi impair et le plus petit possible afin de limiter le nombre de règles.

Afin de choisir la meilleure représentation des sous-ensembles flous à partir des fonctions d'appartenance, des tests de classification ont été réalisés avec la base de données Base\_Couleur\_1. Le tableau 4.2 résume les résultats obtenus à partir d'un partitionnement équiréparti en fonction du nombre de termes et en fonction de la forme de courbes de fuzzification. Notons que l'univers de discours de chaque paramètre du vecteur caractéristique (section 3.2), est décomposé suivant le même nombre de termes. La méthode de classification choisie pour ces tests est celle développée dans cette étude. Mais il faut noter que des résultats similaires ont été obtenus avec d'autres méthodes.

Tableau 4.2 : Taux de reconnaissance obtenus pour différentes formes de fonctions d'appartenance dans le cas d'un partitionnement équiréparti

Nombre de termes de fuzzification	Courbes triangulaires	Courbes trapézoïdales	Courbes gaussiennes	Courbes triangulaires - trapézoïdales	Courbes gaussiennes - trapézoïdales
2	45.30%	47.21%	41.95%	47.21%	44.98%
3	76.56%	77.03%	56.14%	77.35%	64.27%
5	81.82%	82.14%	78.47%	82.78%	79.11%
7	83.25%	83.89%	78.63%	<b>84.37%</b>	79.90%
9	78.47%	78.31%	73.21%	79.90%	74.48%
11	73.52%	73.84%	72.89%	75.28%	73.05%

Pour chaque forme de courbes de fuzzification, nous notons que les meilleurs résultats de classification sont obtenus pour un découpage des paramètres en 7 termes. Une décroissance apparaît ensuite pour des découpages plus importants. Dans ce cas, le découpage est trop fin pour être représentatif des classes à identifier. De plus, les sous-espaces ainsi définis ne correspondent qu'aux sorties apprises à partir du lot d'apprentissage.

En fonction du nombre de termes, il est alors possible d'évaluer le nombre de règles  $Nb\_R$  générées dans le modèle de reconnaissance (4.10). Celui-ci est fonction du nombre de termes  $k$  et du nombre de paramètres  $n$  constituant le vecteur caractéristique (ici  $n$  est égal à 5).

$$Nb\_R = k^n \quad (4.10)$$

A partir de ces tests, nous avons pu valider le choix de la forme des courbes de fuzzification pour l'ensemble de notre étude. En effet, les courbes triangulaires/trapézoïdales fournissent le meilleur taux de reconnaissance (84.37%), et cela quelque soit la décomposition envisagée. Le nombre total de règles générées dans ce cas est égal à 16807. Dans le cas des courbes triangulaires/trapézoïdales, le premier terme et le dernier terme sont représentés par un trapèze alors que les termes intermédiaires sont représentés par un triangle (figure 4.7).

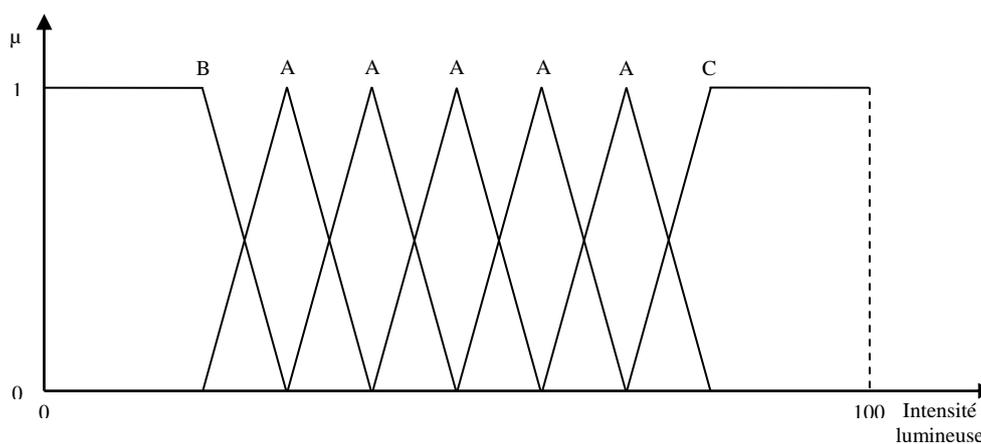


Figure 4.7 : Exemple de partitionnement en sept termes suivant des courbes triangulaires/trapézoïdales

Les mêmes tests ont été effectués sur la base de données Base\_Couleur\_2. Les résultats obtenus sont similaires à ceux du tableau 4.2. A partir d'un partitionnement équiréparti en 7 termes suivant des courbes triangulaires/trapézoïdales, nous obtenons le meilleur taux de reconnaissance en généralisation de 85.76%.

- **Partitionnement adapté**

Le partitionnement adapté est classiquement lié à l'expertise. Dans ce cas, ce choix est fait empiriquement et dépend fortement du Savoir-faire de l'expert qui choisit le nombre de termes et leur positionnement. Cet expert s'appuie sur un certain nombre de connaissances implicites ou non.

Pour les résumer, un modèle de connaissances a été élaboré à partir de la méthode de formalisation NIAM (Natural language Information Analysis Method) introduite par Nijssen et Halpin en 1989 [NIJS-89]. Elle permet d'exprimer les connaissances en langage naturel et le lecteur en trouvera une application détaillée dans [BOMB-07a]. En reprenant les connaissances concernant le cas applicatif 1 et plus particulièrement les classes de couleur présentes dans la base de données Base\_Couleur\_1, deux modèles distincts ont été proposés pour définir respectivement la connaissance de l'expert bois (client) (figure 4.8) et la

connaissance de l'expert vision (intégrateur) (paramètres extraits des images pour qualifier les couleurs à identifier) [SCHM-06b]. En regroupant les modèles ainsi générés (figure 4.9), il est alors possible d'extraire une fuzzification adaptée aux connaissances exprimées par les experts.

Il est à noter que cette étude sur ces modèles contribue à faire le lien entre les domaines Bois et Vision, et ainsi à réduire le fossé sémantique.

A partir de ces modèles, nous sommes capables de définir une décomposition des univers de discours des différents paramètres du vecteur caractéristique. En prenant l'exemple de la valeur moyenne de la composante colorimétrique L, il semble naturel de décomposer son espace de variations suivant trois termes distincts pour représenter les trois nuances de luminosité qui sont définies pour les classes de sortie par le client : claire, moyenne, foncée. En suivant le même raisonnement pour les autres paramètres du vecteur caractéristique (section 3.2.3. : moyennes des composantes L, a et b, homogénéité des composantes L et h), nous obtenons une décomposition adaptée aux connaissances (tableau 4.3). Le positionnement des termes se fait ensuite par l'évaluation des moyennes de chaque paramètre pour les classes de sortie représentées par un même terme. En appliquant des courbes de fuzzification triangulaires/trapézoïdales, les moyennes sont positionnées soit sur les pics des triangles (point A de la figure 4.7), soit sur les extrémités des plateaux des trapèzes (points B et C de la figure 4.7).

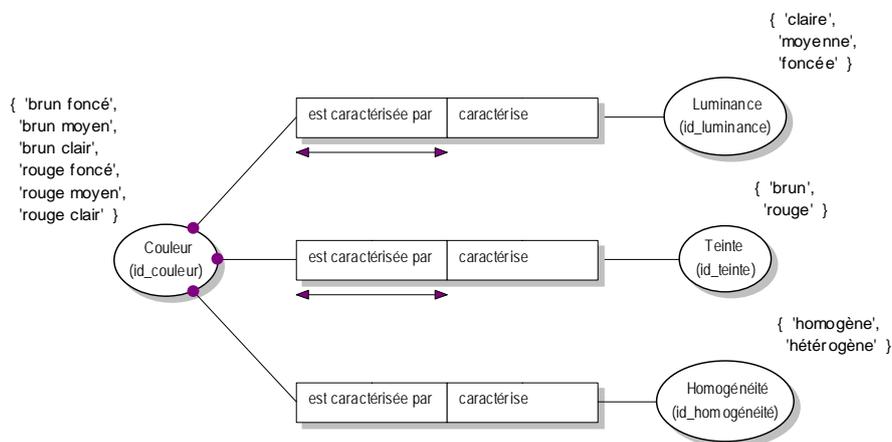


Figure 4.8 : Modèle de l'expert bois associé à la base de données Base\_Couleur\_1

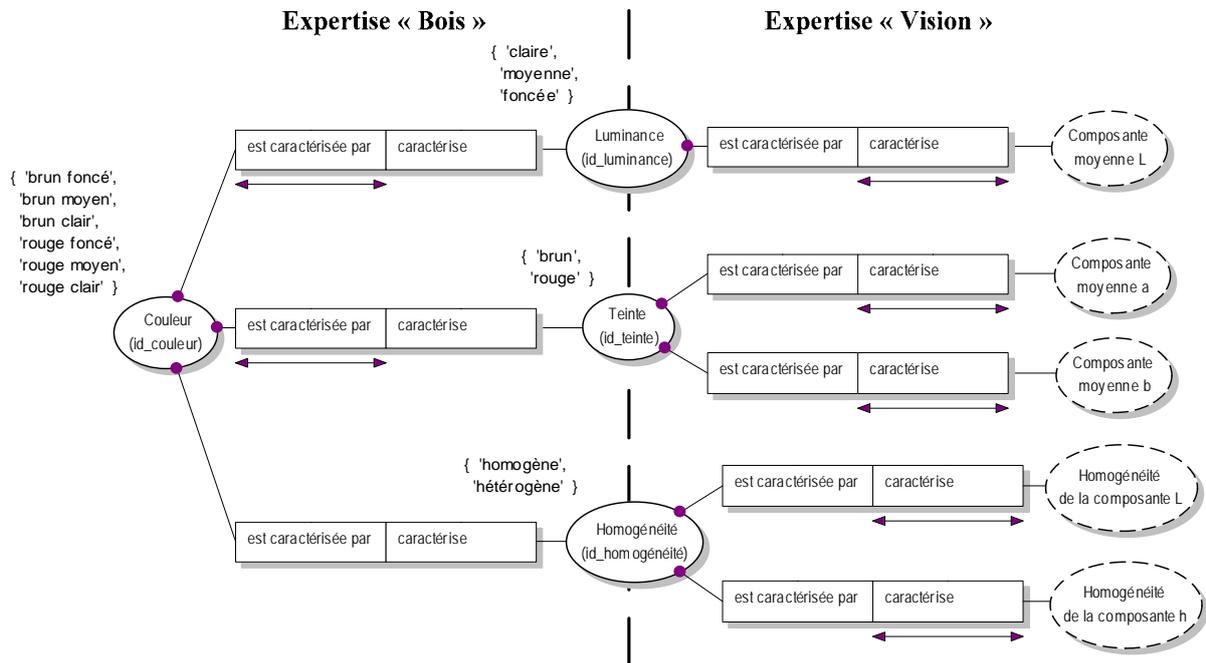


Figure 4.9 : Modèle général des deux domaines d'expertise associé à la base de données Base\_Couleur\_1

Tableau 4.3 : Nombre de sous-espaces obtenus pour chaque paramètre à partir de la connaissance des experts dans le cas de la base de données Base\_Couleur\_1

Paramètre	Composante moyenne L	Composante moyenne a	Composante moyenne b	Homogénéité de la composante L	Homogénéité de la composante h
Nombre de termes	3	2	2	2	2

Tout comme pour le partitionnement équiréparti, il est possible de déterminer le nombre de règles qui sont générées dans le modèle d'identification (4.11).

$$Nb\_R = \prod_{i=1}^n k_i \quad (4.11)$$

où  $n$  est le nombre de paramètres composant le vecteur caractéristique, et  $k_i$  est le nombre de termes pour le  $i$ ème paramètre.

Dans le cas du tableau 4.3, nous obtenons 48 règles. Les taux de reconnaissance obtenus pour ce type de fuzzification sont repris dans le tableau 4.4.

Tableau 4.4 : Taux de reconnaissances en généralisation pour un partitionnement adapté

Base de données	Taux de reconnaissance	Nombres de règles générées
Base_Couleur_1	83.25%	48
Base_Couleur_2	84.46%	108

En comparant directement ces résultats à ceux obtenus à partir d'un partitionnement équiréparti, nous constatons une diminution de l'ordre de 1% des taux de reconnaissance pour les deux bases de données. Cependant, le nombre de règles générées est considérablement diminué (jusqu'à 350 fois moins de règles lorsque nous adaptons le partitionnement aux connaissances des experts). De plus, ces règles sont directement interprétables et traductibles en langage naturel [BOMB-07a]. Elles permettent alors de confronter les résultats obtenus lors de la classification aux connaissances des experts et ainsi de valider les modèles de (re)connaissance. Néanmoins, le principal inconvénient reste la grande dépendance de ces résultats au Savoir-faire de l'expert.

- **Partitionnement automatique**

Le partitionnement automatique est lié directement à l'analyse des données du lot d'apprentissage. Dans ce cas, seules les données numériques sont nécessaires pour évaluer la meilleure décomposition de l'univers de discours des paramètres du vecteur caractéristique. L'avantage d'un tel partitionnement réside dans sa facilité de mise en œuvre. En effet, les utilisateurs des systèmes de classification ne sont des experts ni en « Flou », ni en « Vision », et privilégient la simplicité de configuration du module de reconnaissance. C'est pourquoi, ils définissent la plupart du temps un partitionnement équiréparti même s'il n'est pas adapté au problème (le découpage peut ne pas correspondre aux lots de données et les termes ainsi définis peuvent s'avérer inappropriés).

Il existe plusieurs méthodes pour réaliser la décomposition des espaces de variation. Elles sont classiquement basées sur des méthodes de clustering [KEMP-06] [CARV-07] ou encore des algorithmes génétiques [ISHI-94] [OH-03] [CORD-04].

Pour les algorithmes génétiques, il est très difficile d'obtenir des résultats corrects par rapport aux lots de données dont nous disposons dans notre étude. En effet, tout comme les réseaux de neurones, ces techniques sont connues pour être très consommatrices en nombre de points d'apprentissage.

Après avoir testé quelques méthodes existantes, nous avons choisi de proposer notre propre méthode basée sur l'analyse des scores de typicalité. L'objectif principal est de tenir

non seulement compte des données d'entrée mais également de leur pertinence vis-à-vis de la classification à obtenir en sortie. Notre proposition fait suite à une étude de Forest *et al.* en 2006 sur la génération de prototypes flous à partir de l'analyse des scores de typicalités de différentes classes [FORE-06]. Cette méthode vise à déterminer les paramètres « typiques » pour une reconnaissance. Elle est basée sur l'analyse des données d'entrée.

Pour obtenir un partitionnement automatiquement adapté aux lots de données mais aussi aux objectifs « clients », il est important que ces données soient « typiques » des sous-espaces et des classes de sortie. Pour évaluer cette proposition, une analyse des scores de typicalités pour chaque paramètre du vecteur caractéristique est faite. Ces scores  $T$  (4.12) sont calculés à partir des dissimilarités externes  $D$  (4.13) et des ressemblances internes  $R$  (4.14) de chaque échantillon par rapport aux différentes classes de sortie.

$$T(V_a^u) = \frac{R.D}{R.D + (1-R).(1-D)} \quad (4.12)$$

$$D(V_a^u) = \frac{\sum_{i=1}^m \frac{1}{1-d(V_a^u, V_a^{e_i})}}{m} \quad (4.13)$$

$$R(V_a^u) = \frac{\sum_{i=1}^n \frac{1}{d(V_a^u, V_a^{f_i})}}{n} \quad (4.14)$$

où  $V_a^u$  est la valeur d'un paramètre  $a$  pour un échantillon  $u$

$V_a^{f_i}$  est la valeur d'un paramètre  $a$  pour un échantillon  $f$  appartenant à la même classe que l'échantillon  $u$

$V_a^{e_i}$  est la valeur d'un paramètre  $a$  pour un échantillon  $e$  n'appartenant pas à la même classe que l'échantillon  $u$

$d(x, y)$  est la distance euclidienne entre un échantillon  $x$  et un échantillon  $y$

$n$  est le nombre d'échantillons appartenant à la classe de l'échantillon  $u$

$m$  est le nombre d'échantillons n'appartenant pas à la classe de l'échantillon  $u$

$R$  et  $D$  correspondent respectivement à  $R(V_a^u)$  et  $D(V_a^u)$ .

La figure 4.10 illustre les scores de typicalités de chaque échantillon composant la base de données Base\_Couleur\_1, et cela pour chaque paramètre du vecteur caractéristique.

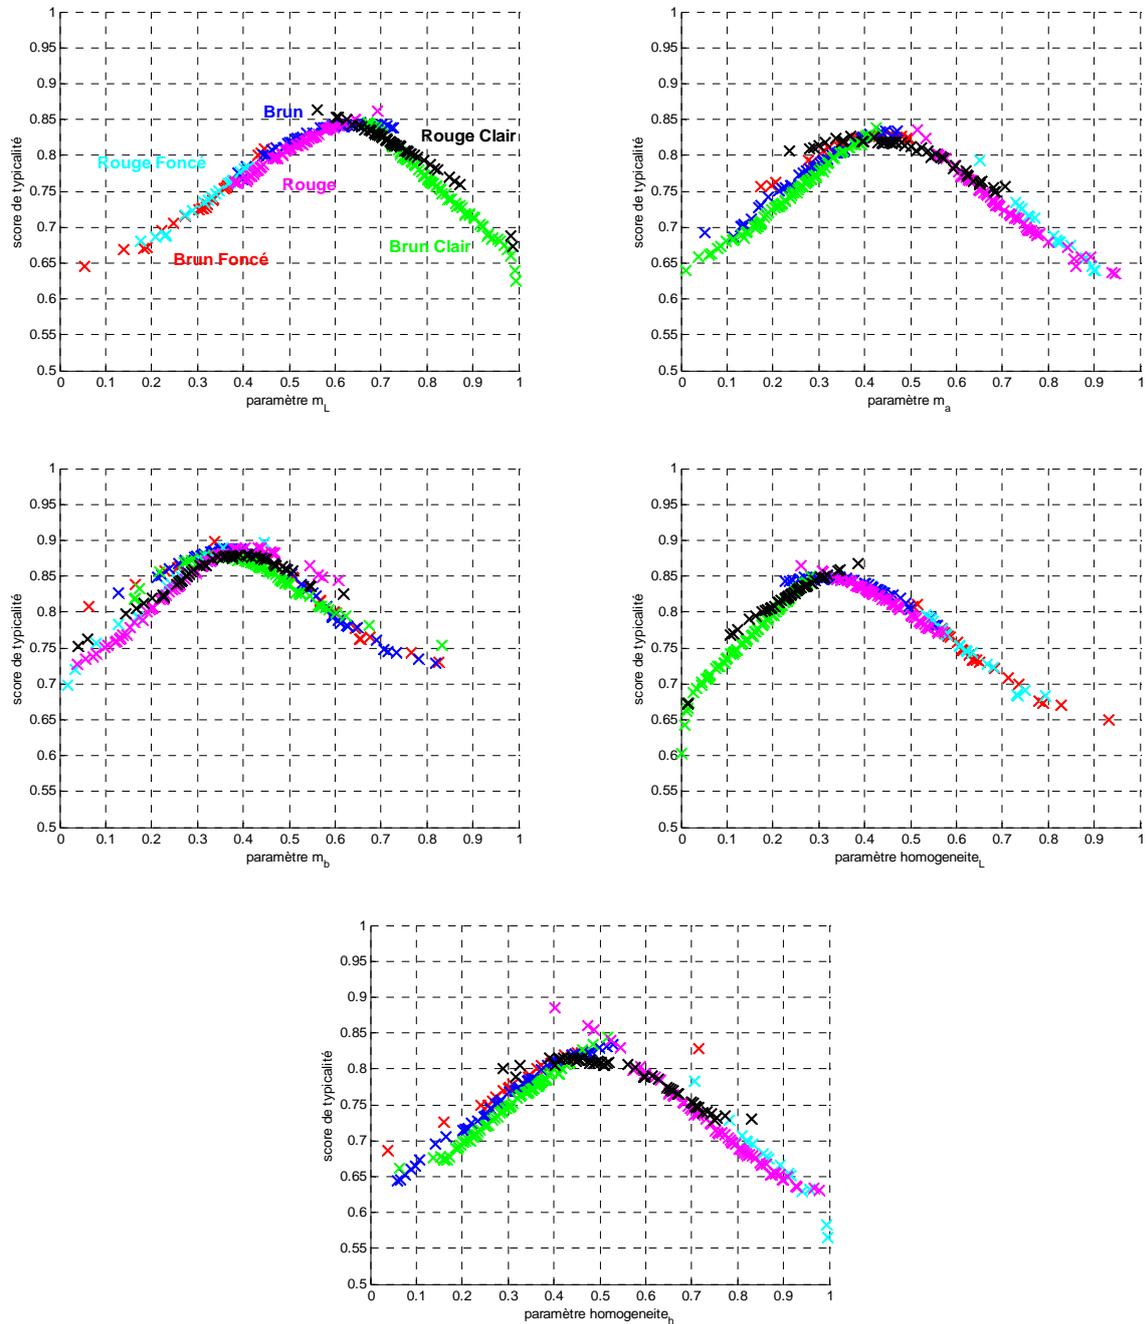


Figure 4.10 : Scores de typicalité pour les échantillons de la base de données Base\_Couleur\_1 pour les différents paramètres constituant le vecteur caractéristique

A partir des graphiques présentés, il est facile de constater que les scores de typicalités forment des courbes qui se chevauchent plus ou moins pour les différentes classes de sortie. Pour le paramètre  $m_L$ , nous constatons que les classes « Brun » et « Rouge » sont quasiment superposées alors que les classes « Brun Foncé » et « Brun Clair » sont bien distinctes. Il est donc intéressant d'évaluer un critère permettant de qualifier ce recouvrement. Pour ce faire, nous avons calculé en parallèle les coefficients de corrélation  $r$  (4.15) des scores de typicalité de chaque classe ainsi que les coefficients de cross corrélation  $r_{cross}$  (4.16) de ces mêmes scores pour toutes les classes deux à deux. De ces coefficients, nous avons calculé le rapport  $\rho_{corr/xcorr}$  (4.17) entre les différents coefficients [SCHM-07a] [SCHM-07b]. Il permet de caractériser à la fois la similarité et le recouvrement qu'il peut exister entre les différentes classes.

$$r(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (4.15)$$

$$r_{cross}^k(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_{i+k} - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (4.16)$$

$$\rho_{corr/xcorr}(X, Y) = \frac{r(X, Y)}{\max_k(r_{cross}^k(X, Y))} \quad (4.17)$$

où  $r(X, Y)$  est le coefficient de corrélation entre les deux populations X et Y constituées chacune de n individus

$r_{cross}^k(X, Y)$  est le coefficient de corrélation croisée entre les deux populations X et Y à l'instant k.

Le tableau 4.5 présente les valeurs du coefficient  $\rho_{corr/xcorr}$  pour chaque couple de classe de sortie pour le paramètre représentant la moyenne de la composante L. Les valeurs négatives obtenues montrent les classes n'ayant aucune similarité. Dans le cas des valeurs positives, plus les valeurs sont grandes, plus les classes considérées se recouvrent.

Tableau 4.5 : Evaluation du coefficient  $\rho_{corr/xcorr}$  pour la composante L et les différentes classes présentes dans la base de données Base\_Couleur\_1

Classes de sortie	Brun Foncé	Brun	Brun Clair	Rouge Foncé	Rouge	Rouge Clair
Brun Foncé	8,07	-0,6	-0,77	-0,89	-0,66	-0,72
Brun	-0,6	2,81	-0,12	-0,73	1,54	0,35
Brun Clair	-0,77	-0,12	2,15	-0,78	-0,54	0,87
Rouge Foncé	-0,89	-0,73	-0,78	10,14	-0,64	-0,65
Rouge	-0,66	1,54	-0,54	-0,64	2,46	-0,33
Rouge Clair	-0,72	0,35	0,87	-0,65	-0,33	2,97

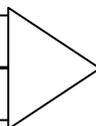
En nous basant sur l'étude de la variation du rapport  $\rho_{corr/xcorr}$ , nous avons élaboré une méthode de partitionnement automatique. Le nombre de termes de fuzzification est déterminé à partir de la valeur maximale des coefficients  $\rho_{corr/xcorr}$ . Si deux classes sont successives (tri croissant de leur valeur moyenne) et si le coefficient  $\rho_{corr/xcorr}$  associées à ces deux mêmes classes correspond à la valeur maximale, ces deux classes sont représentées par le même terme, sinon nous créons un nouveau terme. Pour mieux appréhender la logique de ce traitement, l'algorithme est présenté ci-dessous.

Algorithme de partitionnement automatique (figure 4.11) :

- 1) Calculs des rapports  $\rho_{corr/xcorr}$  pour toutes les classes de sorties
- 2) Tri croissant des classes de sortie en fonction de leur valeur moyenne pour le paramètre étudié

Dans l'exemple du tableau 4.5, le tri croissant est le suivant :

Brun Foncé	Rouge Foncé	Rouge	Brun	Rouge Clair	Brun Clair
Classe C <sub>1</sub>	Classe C <sub>2</sub>	Classe C <sub>3</sub>	Classe C <sub>4</sub>	Classe C <sub>5</sub>	Classe C <sub>6</sub>



3) Initialisation du premier terme avec la classe C<sub>1</sub>

4) **POUR** i = C<sub>2</sub> à C<sub>K</sub>, **SI**

$$\rho_{corr/xcorr}(C_i, C_{i-1}) = \max \left[ \rho_{corr/xcorr}(C_i, C_j) \mid j \in [1, K], j \neq i, \rho_{corr/xcorr}(C_i, C_j) \geq 0 \right] \quad (4.18)$$

**ALORS** C<sub>i</sub> et C<sub>i-1</sub> sont représentés par le même terme

**SINON** le terme en cours ne représente que la classe  $C_{i-1}$ , et un autre terme est créé pour la classe  $C_i$ .

A chaque fois qu'un nouveau terme est créé, le précédent est positionné à partir de la moyenne du paramètre considéré, calculée pour les classes de sortie qui constituent ce terme. En appliquant des courbes de fuzzification triangulaires/trapézoïdales, les moyennes sont positionnées soit sur les pics des triangles (point A de la figure 4.7), soit sur les extrémités des plateaux des trapèzes (points B et C de la figure 4.7).

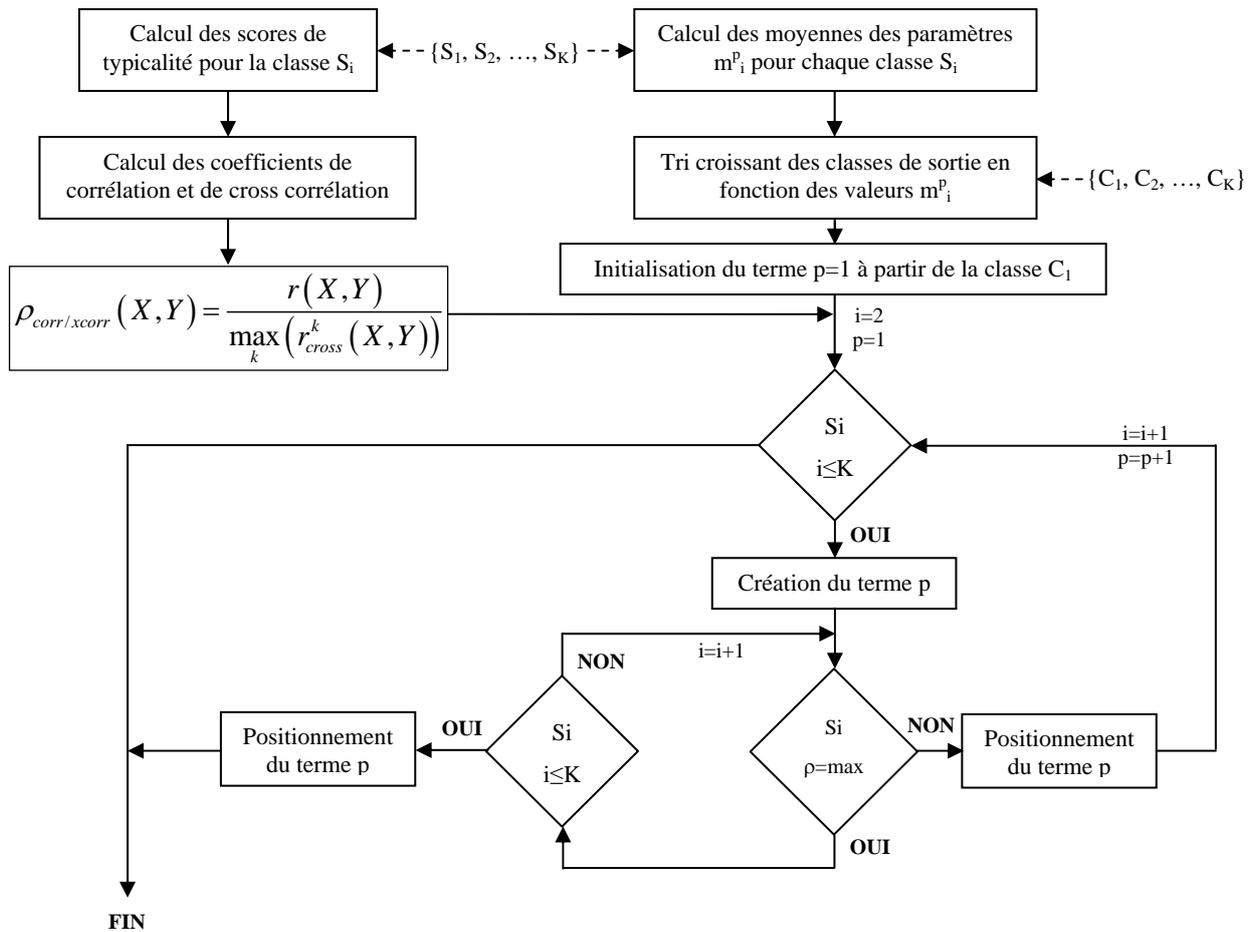


Figure 4.11 : Représentation schématique de l'algorithme de partitionnement automatique

L'application de notre méthode au paramètre  $m_L$  (tableau 4.5) divise son univers de discours en quatre termes (figure 4.12) :

- le premier terme représentant la classe Brun Foncé (BF) ;
- le deuxième terme représentant la classe Rouge Foncé (RF) ;
- le troisième terme représentant les classes Rouge (R) et Brun (B) ;
- le quatrième terme représentant les classes Rouge Clair (RC) et Brun Clair (BC).

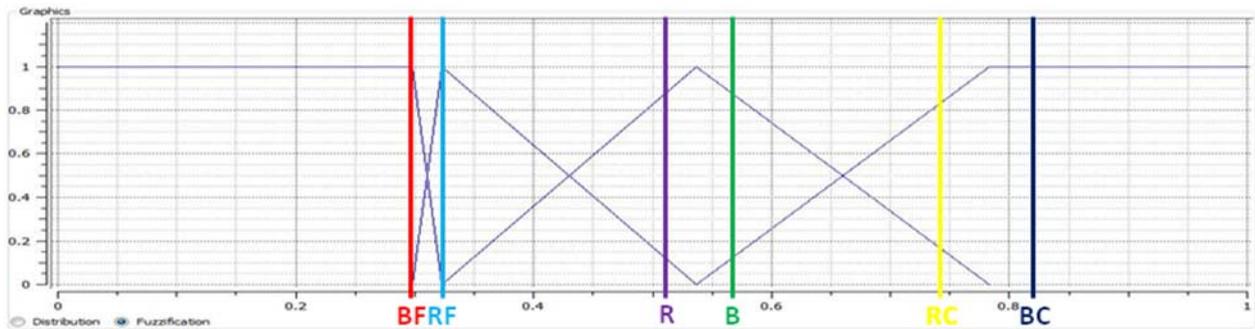


Figure 4.12 : Partitionnement de la composante L de la base de données Base\_Couleur\_1

Le tableau 4.6 illustre la fuzzification de chaque paramètre du vecteur caractéristique pour la base de données Base\_Couleur\_1. Nous obtenons à partir de l'expression (4.11) un total de 720 règles générées.

Tableau 4.6 : Nombre de sous-espaces obtenus pour chaque paramètre à partir du partitionnement automatique dans le cas de la base de données Base\_Couleur\_1

Paramètre	Composante moyenne L	Composante moyenne a	Composante moyenne b	Homogénéité de la composante L	Homogénéité de la composante h
Nombre de termes	4	3	5	3	4

Pour valider notre proposition, nous avons comparé les résultats de classification obtenus par notre méthode à ceux obtenus à partir de techniques plus classiques de clustering [KEMP-06] [CARV-07] ou d'algorithmes génétiques [ISHI-94] [CORD-04]. Ces techniques évaluent le nombre de termes et leur position pour chaque paramètre du vecteur caractéristique en optimisant le taux de reconnaissance sur le lot de données d'apprentissage. Pour ces méthodes, le nombre de règles obtenues est calculé à partir de l'équation 4.11. Le tableau 4.7

résume ces taux de reconnaissance pour les bases de données Base\_Couleur\_1 et Base\_Couleur\_2.

Tableau 4.7 : Comparaison des taux de reconnaissance obtenus à partir de différentes méthodes de partitionnement

Base de données	Méthode de clustering (k-moyennes floues) [KEMP-06]		Algorithme génétique [CORD-04]		Analyse des scores de typicalité	
	Taux de reconnaissance	Nombre de règles	Taux de reconnaissance	Nombre de règles	Taux de reconnaissance	Nombre de règles
Base_Couleur_1	85.17%	1200	84.37%	960	85.65%	720
Base_Couleur_2	85.96%	1920	84.85%	1350	86.92%	1280

En reprenant l'ensemble des résultats obtenus à partir des différentes manières d'effectuer le partitionnement, deux améliorations ressortent de cette étude : celle concernant le taux de reconnaissance et celle concernant le nombre de règles floues générées.

Tout d'abord, en comparant globalement les techniques de partitionnement automatique aux partitionnements équiréparti et adapté, nous notons une amélioration moyenne des taux de reconnaissance de l'ordre de 1 à 2%. Par rapport aux méthodes automatiques seules, notre proposition améliore les taux de reconnaissance d'environ 1%.

Notre méthode se sert des classes de sorties pour effectuer le partitionnement automatique alors que les autres techniques citées se basent uniquement sur l'analyse des lots de données d'entrée (vecteurs caractéristiques). Les termes obtenus semblent donc mieux adaptés à la représentation des sorties qui sont définies par le client.

Enfin, nous notons une diminution du nombre de règles générées par rapport à celui obtenu à partir d'un partitionnement équiréparti. Toutefois, le nombre de règles générées (720 pour la Base\_Couleur\_1 et 1280 pour la Base\_Couleur\_2) reste supérieur au nombre atteint dans le cas adapté (48 pour la Base\_Couleur\_1 et 108 pour la Base\_Couleur\_2). La base de règle est donc plus difficilement interprétable dans notre cas, mais répond mieux aux attentes du client en terme de bonne classification et en terme de simplicité d'utilisation du module de classification.

Notre méthode a été appliquée avec succès sur une autre application industrielle dans le domaine de la reconnaissance de défauts sur du textile (Annexe B.3). Néanmoins, elle ne s'applique actuellement qu'aux classes de sortie de formes convexes qui peuvent être représentées par un terme unique.

### 4.2.3. Génération des règles linguistiques

L'étape de fuzzification définit les variables linguistiques manipulées par les règles. Il est maintenant nécessaire de se focaliser sur la génération même des règles qui constitue le cœur du mécanisme de reconnaissance.

Cette deuxième phase permet de générer des règles  $R_i$  de type « SI... ALORS ... » qui décrivent la perception que le système a des couleurs. Si nous considérons deux paramètres en entrée, notés  $x_1$  et  $x_2$ , et une couleur en sortie notée  $y_1$ , la forme générale des règles  $R_i$  suit l'expression :

« **SI**  $x_1$  est  $A_i$  **ET SI**  $x_2$  est  $A_j$  **ALORS**  $y_1$  est de la couleur  $C_n$  »

avec  $x_1$  et  $x_2$  les données d'entrée ;

$y_1$  la donnée de sortie ;

$A_i$  et  $A_j$  les sous ensembles flous ;

$C_n$  la classe de la  $n^{\text{ième}}$  couleur.

L'algorithme présenté est basé sur un mécanisme d'inférences qui suit un modèle de Larsen (loi de composition de type maximum/produit). Dans notre exemple, la conjonction **ET** est calculée à partir de la T-norme associée au Produit des deux données d'entrée (4.19).

$$T(x_1, x_2) = x_1 \cdot x_2 \quad (4.19)$$

Dans l'algorithme utilisé, cette T-norme se traduit mathématiquement par l'équation suivante (4.20) :

$$\beta_{CT} = \sum_{x \in CT} \mu_i(x_1) \times \mu_j(x_2) \quad (4.20)$$

où  $\mu_i$  et  $\mu_j$  correspondent respectivement au degré d'appartenance des paramètres  $x_1$  et  $x_2$  aux sous-ensembles  $A_i$  et  $A_j$

$\beta_{CT}$  correspond au degré de vérité de la règle associé à la classe de sortie CT pour le sous-espace  $A_i \times A_j$

Les conclusions fournies par chaque règle, correspondant à l'opérateur d'implication « **SI... ALORS...** », sont obtenues pour chaque classe de sortie à partir de la T-norme Produit, implicite dans l'équation 4.20. Nous obtenons alors l'ensemble de valeur  $\{\beta_{C1}, \beta_{C2}, \dots, \beta_{CM}\}$ .

Enfin, chacune de ces règles fournissant une conclusion partielle, est agrégée aux autres par un opérateur disjonctif. Dans notre cas, cet opérateur est la T-conorme Maximum définie par Zadeh [BOUC-95]. Dans l'algorithme utilisé, en considérant  $M$  classes de sortie, cette T-conorme se traduit mathématiquement par l'équation suivante (4.21) :

$$\beta_{CX} = \max \{ \beta_{C1}, \beta_{C2}, \dots, \beta_{CM} \} \quad (4.21)$$

où  $\beta_{CX}$  correspond au degré de vérité maximum de la règle pour le sous-espace  $A_i \times A_j$

A partir de ces degrés de vérité, nous calculons ensuite le degré de certitude de la règle suivant les équations suivantes (4.22 et 4.33) :

$$CF_{ij} = (\beta_{CX} - \beta) / \sum_{T=1}^M \beta_{CT} \quad (4.22)$$

$$\text{où } \beta = \sum_{\substack{T=1 \\ CT \neq CX}}^M \beta_{CT} / (M - 1) \quad (4.23)$$

Nous avons validé le choix du modèle de Larsen à partir d'essais réalisés sur trois bases de données, les bases Base\_Couleur\_1, Base\_Couleur\_2 et Base\_Couleur\_3. Le tableau 4.8 illustre la comparaison entre le modèle de Larsen et celui de Mamdani. Pour effectuer ces tests, nous avons modifié l'algorithme d'Ishibuchi *et al.*.

Tableau 4.8 : Comparaison des taux de reconnaissance obtenus à partir des modèles de Larsen et de Mamdani

	Modèle de Larsen	Modèles de Mamdani
Base_Couleur_1	85.65%	84.69%
Base_Couleur_2	86.92%	85.53%
Base_Couleur_3	83.10%	81.29%

Comme nous pouvons le constater, les résultats obtenus ne présentent pas une très grande différence entre les deux modèles (le modèle de Larsen propose des taux de reconnaissance supérieur de 1% à 2% environ à ceux fournis par le modèle de Mamdani). Cependant, la moindre amélioration de la classification peut être synonyme de profits pour des utilisateurs industriels.

L'algorithme développé dispose d'une phase d'ajustement du modèle. Elle correspond à la partie itérative de la méthode. Elle consiste à ajuster le découpage de l'univers de discours des paramètres d'entrée.

Cet ajustement dépend d'un certain nombre de paramètres : nombre d'itérations, seuil de reconnaissance, constantes d'apprentissage  $\eta_1$  et  $\eta_2$ . Le lecteur peut se référer à l'annexe B.1

qui présente l'algorithme de génération et ajustement des règles, et à l'annexe B.4 pour la justification des choix des valeurs retenues pour les différentes constantes dans notre étude.

L'ensemble des résultats déjà présentés a été obtenu pour les meilleures valeurs de ces paramètres dont le choix a été fait empiriquement. Les valeurs de réglage retenues sont :

$$\eta_1 = 0.4, \eta_2 = 0.004, \text{ nombre d'itérations} = 500, \text{ seuil de classification} = 92\%$$

Le processus d'ajustement des règles est effectué de la manière suivante (figure 4.13) :

- génération d'un premier modèle numérique à partir du lot d'apprentissage ;
- comparaison du taux de reconnaissance obtenu par rapport à un seuil préalablement fixé (92%) ;
- ajustement des coefficients de chaque règle durant la partie itérative pour atteindre ce seuil à partir de l'ensemble des points d'apprentissage.

L'ajustement des coefficients de chaque règle est effectué à partir des équations suivantes (4.24 et 4.25). Quand  $x$  est correctement classé par la règle  $R_{ij}$ , l'ajustement du degré de certitude de la règle s'effectue par :

$$CF_{ij} = CF_{ij} + \eta_1(1 - CF_{ij}) \quad (4.24)$$

Au contraire, lorsque  $x$  n'est pas correctement classé par la règle  $R_{ij}$ , l'ajustement du degré de certitude s'effectue par :

$$CF_{ij} = CF_{ij} - (\eta_2 \times CF_{ij}) \quad (4.25)$$

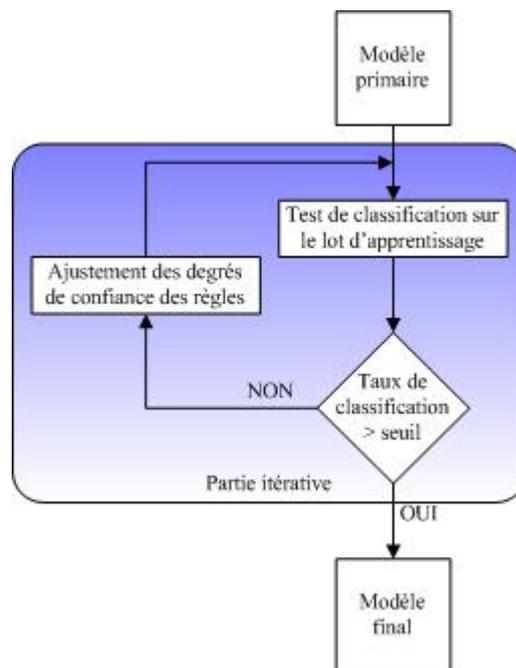


Figure 4.13 : Processus d'ajustement des règles

Enfin, il faut noter qu'il existe de nombreuses techniques automatiques de génération de règles linguistiques. Alcala *et al.* recensent un certain nombre d'entre elles [ALCA-07]. Les algorithmes génétiques sont très souvent utilisés durant cette étape [CORD-99] [CORD-01] [ISHI-03]. Cependant, ces techniques couplent généralement l'étape de fuzzification (ajustement des fonctions d'appartenance) et l'étape de génération des règles comme pour l'algorithme CHC [ESHE-91]. Néanmoins, il existe quelques méthodes spécifiques pour la génération des règles parmi lesquelles nous citerons : l'algorithme de Wang et Mendel [WANG-92], un algorithme basé sur un moyennage pondéré suivant les sorties apprises [ALCA-07], un algorithme génétique mixte basé sur une combinaison de l'algorithme de Wang et Mendel et d'un algorithme de partitionnement flou de l'espace de variation des paramètres d'entrées [ALCA-07].

Nos développements se basant sur un algorithme relativement ancien [ISHI-94], il a semblé judicieux de comparer les méthodes automatiques de génération de règles afin de confirmer notre choix pour l'algorithme d'Ishibuchi *et al.* [ISHI-92]. Les résultats présentés dans le tableau 4.9 ont été obtenus sur les lots de généralisation des trois bases de données précédentes.

Tableau 4.9 : Comparaison des taux de reconnaissance obtenus à partir de différentes méthodes automatiques de générations de règles linguistiques

	Algorithme d'Ishibuchi <i>et al.</i> [ISHI-92]	Algorithme de Wang et Mendel [WANG-92]	Moyennage pondéré des sorties [ALCA-07]	Algorithme génétique mixte [ALCA-07]
Base_Couleur_1	85.65%	81.02%	80.06%	83,73%
Base_Couleur_2	86.92%	82.30%	81.18%	84,85%
Base_Couleur_3	83.10%	79.74%	78.31%	80,38%

Les taux de reconnaissance obtenus montrent un léger avantage pour l'algorithme d'Ishibuchi *et al.* par rapport aux autres techniques de génération des règles. Les résultats obtenus avec les algorithmes présentés par Alcalá *et al.*, moyennage pondéré et algorithme génétique mixte, souffrent respectivement de deux problèmes : le premier est très performant lorsque les classes de sortie sont bien distinctes, le deuxième nécessite quant à lui des lots de données d'apprentissage conséquent. Il faut noter qu'une méthode similaire à l'algorithme d'Ishibuchi *et al.* a été introduite par Tsekouras *et al.* [TSEK-03]. Celle-ci fait intervenir un partitionnement de l'espace des variables d'entrée et une génération de règles à partir de l'algorithme des k plus proches voisins. Les résultats obtenus à partir de celle-ci sont alors similaires à ceux que proposent nos développements.

#### 4.2.4. Résultats comparatifs de classification

Après avoir validé chaque étape constituant la méthode de classification floue proposée, il est intéressant de positionner celle-ci par rapport aux techniques généralement citées dans la littérature : classificateur bayésien, algorithme des k plus proches voisins flou ou non, réseaux de neurones, algorithmes génétiques, algorithmes SVM, ... La comparaison de ces différentes méthodes est réalisée de plusieurs manières afin de valider différentes propriétés. Dans un premier temps, il s'agit de positionner nos travaux en utilisant la base de données IRIS classiquement référencée dans le domaine de la reconnaissance de formes [UCI]. Ensuite, pour confirmer le pouvoir de généralisation de la méthode, nous présentons une étude concernant l'influence de la taille du lot d'apprentissage sur les taux de reconnaissance. Enfin, nous proposons des résultats de classification obtenus sur les trois bases de données issues des cas applicatifs (Base\_Couleur\_1, Base\_Couleur\_2, Base\_Couleur\_3). Il faut rappeler que ces bases n'ont pas été filtrées. En effet, les échantillons constituant les différentes bases peuvent contenir des points aberrants liés à la subjectivité des opérateurs effectuant manuellement l'étiquetage.

##### • Base de données IRIS

Cette base de données est généralement employée pour positionner un classificateur par rapport à l'existant. Le lot de données est composé de 150 échantillons. Ces derniers sont équirépartis suivant trois classes de sorties. Le vecteur caractéristique est constitué de quatre

paramètres de taille (longueur des sépales, largeur des sépales, longueur des pétales, largeur des pétales).

Pour garder le même protocole de tests que pour les essais précédemment exposés, cette base de données a été divisée en deux sous-groupes : le premier constituant le lot d'apprentissage (20 échantillons par classe) et le second constituant le lot de généralisation (30 échantillons par classe). La figure 4.14 présente les résultats en généralisation obtenus à partir de différentes techniques de classification : classificateur bayésien (Bayes), k plus proches voisins (kppv), k plus proches voisins flous (kppv flou), réseaux de neurones (RdN), algorithme génétique (GA), support vecteur machine (SVM), FRC (Fuzzy Reasoning Classifier – Méthode développée).

Pour réaliser une comparaison objective, nous avons effectué de nombreux essais afin de déterminer les « meilleurs » réglages pour chaque méthode de classification. Ainsi, les paramètres suivant correspondent aux réglages conduisant aux meilleurs taux de reconnaissance dans chacun des cas.

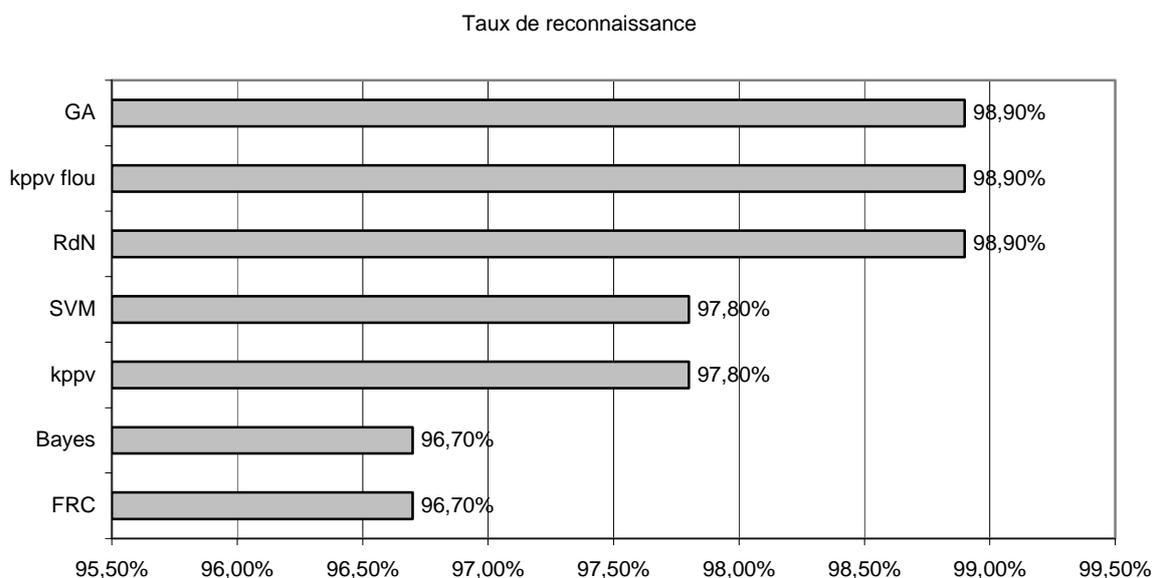


Figure 4.14 : Taux de reconnaissance en généralisation sur la base de données IRIS

#### Paramétrages des méthodes comparées au FRC :

kppv : recherche des 3 plus proches voisins - distance euclidienne

kppv flou : recherche des 3 plus proches voisins

RdN : 4 neurone en entrées, 3 neurones en sortie, 3 couches cachées de 20 neurones chacune, 750 itérations, algorithme de Levenberg-Marquardt

- GA :           taux de reproduction = 0.3, probabilité de mutation = 0.1, 1000 itérations, nombre de bits définissant chaque individu = 8, sélection des individus par ordonnancement
- SVM :         Noyau RBF gaussien, écart-type du noyau = 0.1, C = 50 (erreur de régularisation), pas = 5, tolérance =  $10^{-5}$

Les résultats obtenus montrent des taux de reconnaissance très similaires pour les différentes méthodes présentées (taux supérieurs à 96% dans l'ensemble). Il faut noter que la méthode floue développée se positionne parmi les techniques les moins performantes sur cette base de données. Ces tests permettent de positionner la méthode mais aucun cas de conclure quant à son efficacité. En revanche, si l'étape d'affinage était activée, nous obtiendrions un taux de reconnaissance avoisinant les 100%. La base de données IRIS étant, relativement simple, il est intéressant de valider notre méthode sur les bases de données industrielles qui sont nettement plus complexes.

**• Pouvoir de généralisation de la méthode face à des lots d'apprentissage réduit**

La potentialité à apprendre à partir de peu d'échantillons est un des points forts de notre méthode. Plusieurs tests ont été menés à partir d'un lot de données industrielles composé de 943 échantillons répartis suivant six classes de couleur. Afin d'évaluer et comparer les différents classificateurs, et notamment ceux nécessitant des lots d'apprentissage conséquents, des points ont été générés aléatoirement en bruitant les données réelles à partir d'un bruit blanc gaussien de variance égale à 0,1. Au final, la base de données (Base\_Couleur\_Etendue) servant aux tests est composée de 5000 points par classe pour l'apprentissage et 5000 points par classe pour la généralisation.

La figure 4.15 représente l'évolution des taux de reconnaissance en phase de généralisation en fonction du nombre de points d'apprentissage par classe de sortie. Les résultats présentés ci-dessous correspondent à un moyennage des résultats obtenus après plusieurs répétitions des tests (100 tirages aléatoires des points d'apprentissage sans doublon).

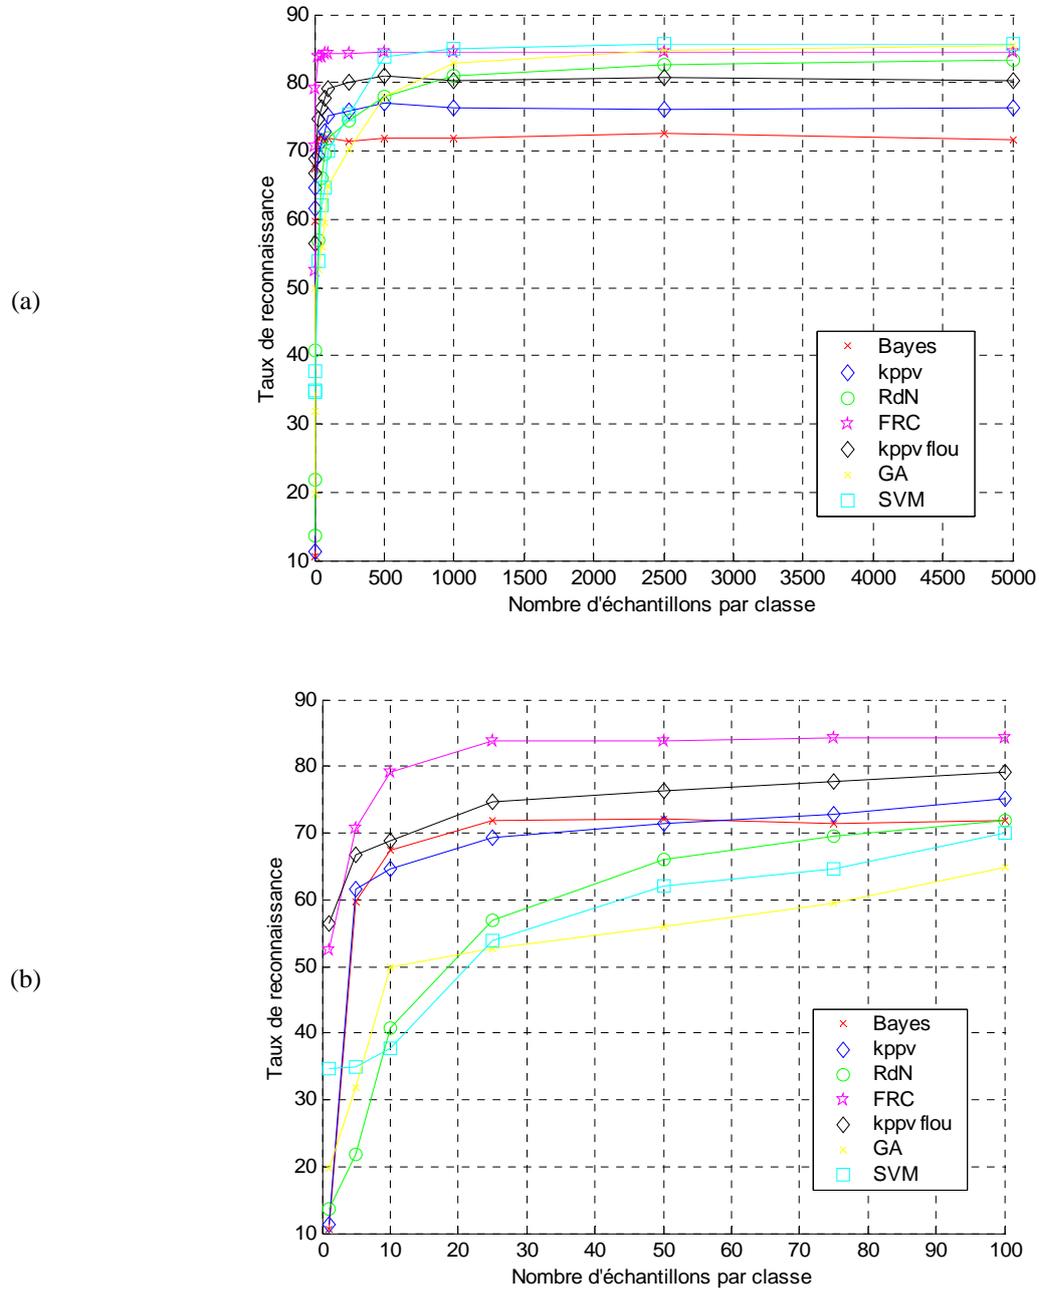


Figure 4.15 : Taux de reconnaissance en généralisation sur la base de données Base\_Couleur\_Etendue

Sur la figure 4.15, nous constatons que le taux de reconnaissance augmente en fonction du nombre de points en apprentissage, et cela quelque soit la méthode de classification choisie. Une asymptote horizontale apparaît même vers :

- 71,5% pour le classificateur bayésien (*maximum a posteriori*);
- 76% pour les k plus proches voisins (k=5) ;
- 80,2% pour les k plus proches voisins flous (k=5) ;
- 83,4% pour les réseaux de neurones (5 neurones d'entrées, 3 couches cachées de 20 neurones, 6 neurones de sorties, 1500 itérations) ;
- 84,4% pour notre classificateur flou (FRC) ;
- 85,4% pour un algorithme génétique ;
- 85,5% pour les SVM.

Nous pouvons constater que le FRC se situe parmi les méthodes les plus efficaces. Cependant, une grande différence existe quant à la vitesse de convergence vers ces maxima. Typiquement, les réseaux de neurones, les algorithmes génétiques et les SVM utilisent beaucoup d'échantillons en apprentissage pour être efficaces en généralisation. Pour des performances équivalentes, ces algorithmes ont besoin de 100 fois plus (RdN et GA) et 25 fois plus (SVM) de points pour que le taux de reconnaissance soit comparable à celui obtenu avec notre méthode. Cet aspect est donc très important, car il n'est pas aisé d'obtenir de grands lots de données dans un environnement industriel. De plus, dans notre contexte applicatif, il est possible que certaines classes de sortie ne soient représentées que par dix ou vingt échantillons (voire moins). Les méthodes nécessitant des lots conséquents sont donc à éviter.

#### • Comparaison des classificateurs sur les bases de données industrielles

Après avoir mis en évidence la potentialité de notre méthode en généralisation, il est intéressant de faire une comparaison similaire mais sur les bases de données industrielles non étendues et non filtrées : Base\_Couleur\_1, Base\_Couleur\_2 et Base\_Couleur\_3. La figure 4.16 présente les taux de reconnaissance obtenus en généralisation pour les différentes méthodes de classification.

Comme pour la comparaison sur la base de données IRIS, nous avons déterminé, pour ces bases de données industrielles, les « meilleurs » paramètres de réglage de chaque classificateur.

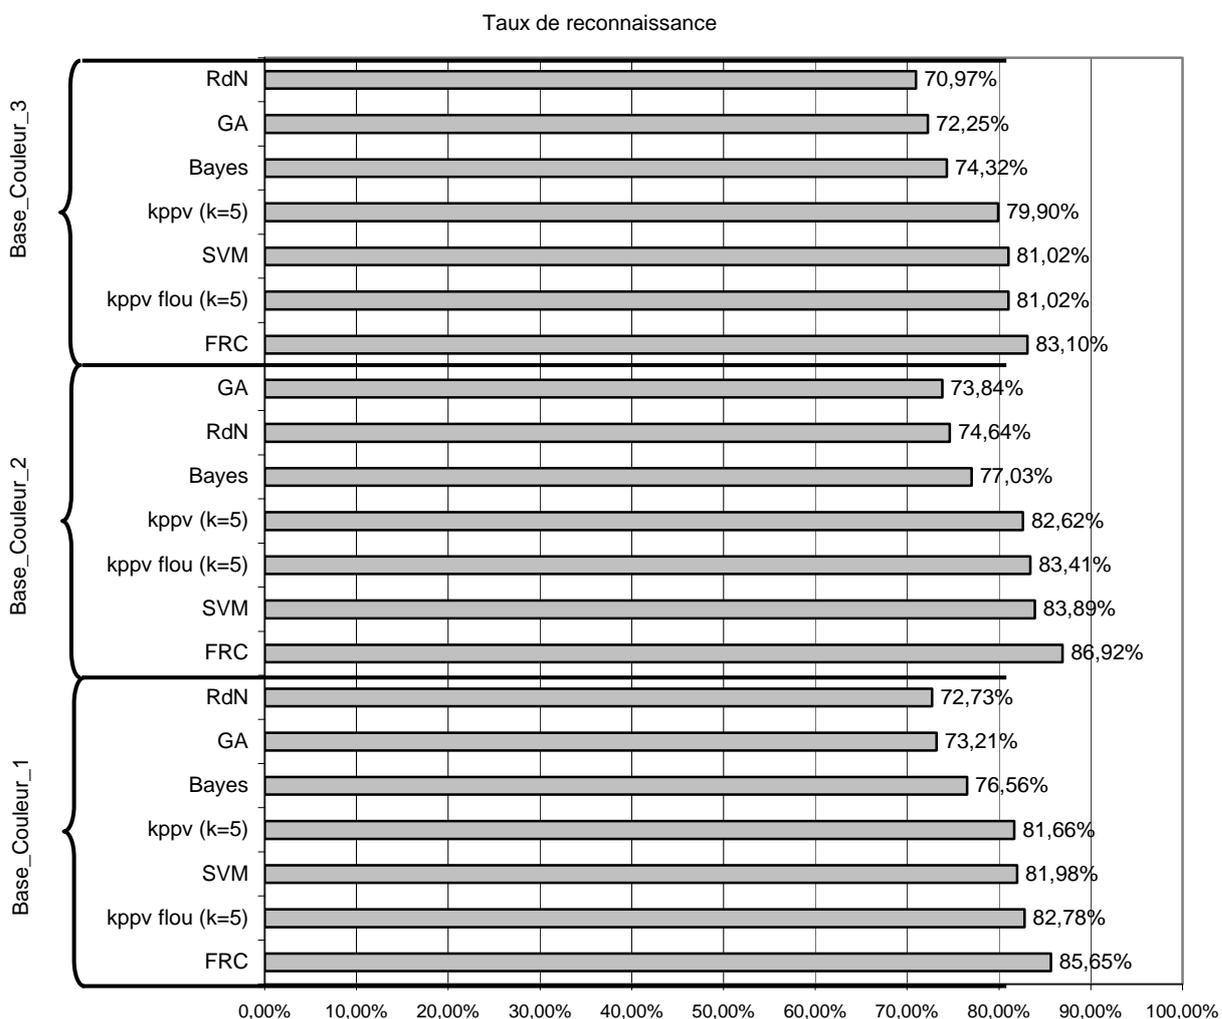


Figure 4.16 : Taux de reconnaissance en généralisation sur les trois bases de données industrielles

Paramétrages des méthodes comparées au FRC :

kppv : recherche des 5 plus proches voisins - distance euclidienne

kppv flou : recherche des 5 plus proches voisins

RdN : 5 neurone en entrées, neurones en sortie : 6 pour Base\_Couleur\_1, 9 pour Base\_Couleur\_2 et 4 pour Base\_Couleur\_3, 3 couches cachées de

	30 neurones chacune, 1500 itérations, algorithme de Levenberg-Marquardt
GA :	taux de reproduction = 0.4, probabilité de mutation = 0.2, 2000 itérations, nombre de bits définissant chaque individu = 8, sélection des individus par ordonnancement
SVM :	Noyau RBF gaussien, écart-type du noyau = 0.01, C = 200 (erreur de régularisation), pas = 5, tolérance = $10^{-10}$

Nous pouvons constater qu'une certaine logique se dégage des différents essais. En effet, l'efficacité des différents classificateurs est toujours la même. Logiquement, les taux les plus faibles (inférieurs à 75% sur les trois bases de données) sont obtenus avec deux méthodes par compilation, efficaces pour des lots de données conséquents (RdN et GA). Les méthodes statistiques, paramétriques ou non, fournissent quant à elles des résultats acceptables avec des taux de reconnaissance allant jusqu'à 80% environ. Les meilleurs résultats sont obtenus avec les méthodes floues (kppv flou et FRC). Nous pouvons aussi noter le bon comportement des SVM qui sont des classificateurs performants dont nous nous servons comme référence pour situer notre méthode.

Quelque soit la base de données industrielles, les taux de reconnaissance proposés par notre méthode sont les meilleurs et valident donc bien nos précédents choix (83.10% pour la Base\_Couleur\_1, 86.92% pour la Base\_Couleur\_2 et 85.65% pour la Base\_Couleur\_3).

Les bases de données utilisées pour valider notre méthode n'étant pas filtrées des points aberrants pouvant être étiquetés par l'opérateur humain, les résultats montrent une certaine robustesse de notre algorithme face à ce type de données.

D'un point de vue industriel, notre étude se basant sur le développement d'un nouveau produit pour la société LuxScan Technologies, il a fallu répondre rapidement aux attentes des clients. En effet, pour permettre une industrialisation rapide (associée au cas applicatif 1), la technique de classification implémentée sur site a évolué au cours du temps. Dans un premier temps, un classificateur bayésien basé sur la recherche du maximum *a posteriori* a été utilisé. Avec des objectifs commerciaux très stricts, et une simplicité d'implémentation à l'environnement logiciel de la société, l'algorithme des k plus proches voisins a été instancié en C++ permettant ainsi une augmentation des taux de reconnaissance de l'ordre de 8%. A l'heure actuelle les systèmes en place fonctionnent tous sur ce principe, l'industrialisation de la méthode floue de classification étant plus longue. Il faut noter que notre méthode est déjà implémentée à l'architecture logicielle de la société, mais uniquement pour effectuer la reconnaissance de singularités [BOMB-07a].

### **4.3. Utilisation conjointe de deux capteurs flous**

La méthode de classification présentée s'applique à chaque capteur d'un système de vision, et fournit donc une sortie nominale quant à la couleur des avivés. Comme nous avons

pu le voir, la décision du classificateur flou mis en œuvre repose sur l'attribution d'une classe de sortie associée à un degré de confiance CF.

Dans le cas applicatif 1, le système de vision composé de deux capteurs flous couleurs doit être intégré à une ligne de tronçonnage. La reconnaissance des couleurs s'effectuant sur les rives, une difficulté supplémentaire intervient car les deux côtés ne sont pas forcément de la même couleur. De plus, lors de l'étiquetage des avivés, il subsiste une forte subjectivité liée au jugement des opérateurs. En effet, ces derniers peuvent se servir des faces pour prendre leur décision, alors que, pour des raisons matérielles, nous ne disposons que de capteurs couleurs sur les rives.

Pour le cas applicatif 1, il s'agit donc de combiner des informations extraites de différents objets (chaque rive des avivés correspondant à un unique objet) provenant de plusieurs capteurs. Ensuite, au vu des enjeux industriels, il est inconcevable d'ignorer la décision d'un capteur. En effet, les produits finaux (les lisses) ne peuvent présenter une hétérogénéité de couleur entre leurs rives. La décision finale du système doit donc satisfaire l'ensemble des décisions de chaque capteur. Nous parlons alors de fusions de données [BOUC-98]. La figure 4.17 illustre la prise de décision sur les avivés du cas industriel cité.

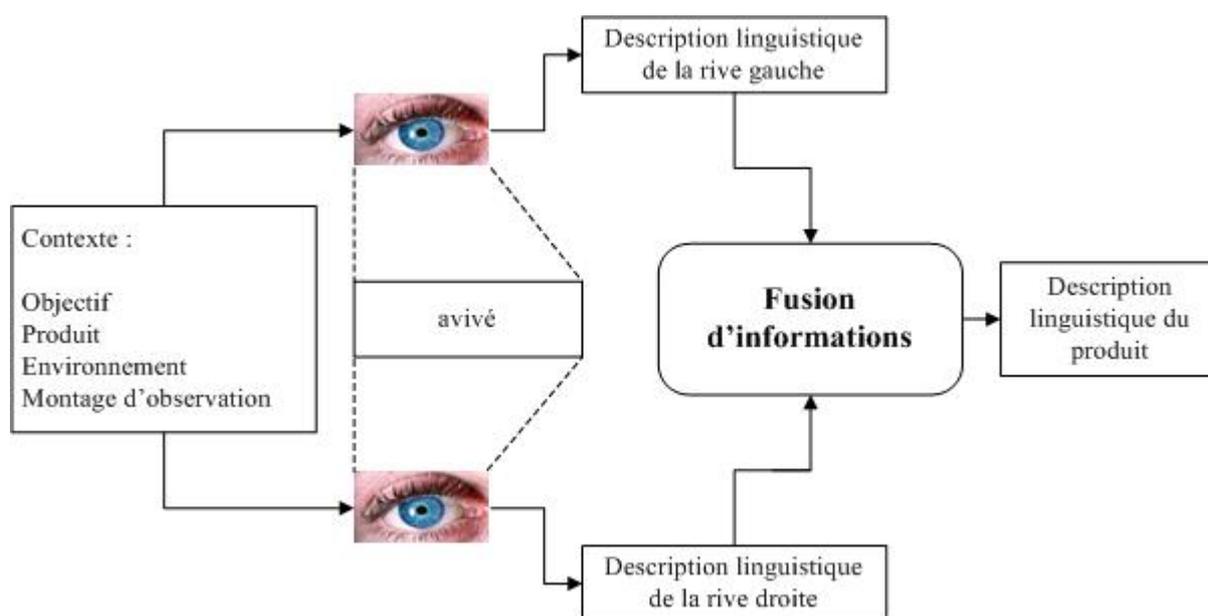


Figure 4.17 : Application de la fusion d'informations au cas applicatif 1

Dans une première partie, nous dressons un bref état de l'art concernant les techniques de fusion de données en insistant sur notre choix. Enfin, nous exposons des résultats comparatifs directement liés au cas applicatif 1.

### 4.3.1. Choix de l'opérateur de fusion

Les problèmes de fusion de données ou de combinaison d'informations ne possèdent pas de solution unique. Dans notre cas, la combinaison des décisions mono capteur doit permettre de prendre en compte les éventuelles incertitudes [DUBO-04]. Ces incertitudes peuvent être évaluées à travers les degrés de confiance associés à chaque décision.

Dans [FAGI-99], l'auteur dresse un état de l'art des différentes techniques permettant de combiner des informations floues provenant de plusieurs systèmes. Il assimile la combinaison des informations à des requêtes pouvant être effectuées dans des bases de données. En prenant pour exemple notre cas applicatif, ses propositions de requête sont de la forme suivante :

(Couleur Rive droite = " rouge ")  $\wedge$  (Couleur Rive gauche = " rouge clair ")

A partir de cette requête, il faut ensuite définir les opérateurs de combinaison des deux informations qui sont considérées chacune dans des sous-espaces flous. Fagin recense alors les normes triangulaires (T-normes) pouvant permettre d'effectuer cette combinaison d'informations.

Dans le cadre des ensembles flous, chaque décision est modélisée par un degré d'appartenance à une classe à partir des fonctions d'appartenance. Pour combiner ce type d'information, les opérateurs T-normes s'adaptent mieux aux incertitudes liées aux décisions. Classiquement, la décision est prise par la valeur maximale d'appartenance. Dans notre processus d'identification de la couleur des avivés, plusieurs voies sont envisageables. La combinaison d'informations peut considérer uniquement l'information symbolique fournie par chaque capteur (classe de sortie décrite de manière nominale) [MAUR-98], ou bien au contraire par l'information floue fournie par le système.

Dans le cas d'une fusion de données symboliques basée uniquement sur les sorties nominales fournies par chaque capteur flou couleur, il est possible de dresser un tableau reprenant l'ensemble des règles pouvant être exprimées directement par l'utilisateur du système (tableau 4.10). Cette méthode de fusion de données est celle actuellement mise en œuvre pour le cas applicatif 1. Le tableau 4.10 représente les règles de fusions définies par l'expert bois.

Tableau 4.10 : Table de fusion de données symboliques associée au cas applicatif 1

	Brun Foncé	Brun	Brun Clair	Rouge Foncé	Rouge	Rouge Clair	Inconnu
Brun Foncé	Brun Foncé	Brun	Rejet	Rejet	Rejet	Rejet	Rejet
Brun	Brun	Brun	Rejet	Rejet	Rejet	Rejet	Rejet
Brun Clair	Rejet	Rejet	Brun Clair	Rejet	Rejet	Rejet	Rejet
Rouge Foncé	Rejet	Rejet	Rejet	Rouge Foncé	Rouge	Rejet	Rejet
Rouge	Rejet	Rejet	Rejet	Rouge	Rouge	Rejet	Rejet
Rouge Clair	Rejet	Rejet	Rejet	Rejet	Rejet	Rouge Clair	Rejet
Inconnu	Rejet	Rejet	Rejet	Rejet	Rejet	Rejet	Rejet

Un grand nombre de cas présentés dans le tableau 4.10 fournissent une décision pénalisante en terme de production. En effet, la classe de rejet est très majoritaire et ne laisse aucune ambiguïté quant aux réponses de chaque capteur. Elles sont toutes considérées comme parfaitement sûres.

Or, les règles décrites par l'expert bois (tableau 4.10) peuvent présenter des incertitudes liées à la subjectivité de la définition des classes de couleur. Il n'est pas toujours simple de faire la différence entre les couleurs du bois. Il est donc plus judicieux d'intégrer les résultats flous de chaque capteur flou, et cela pour réduire la quantité de produits rejetés et ainsi pour mieux valoriser la production des clients.

Bloch propose une classification des opérateurs de fusion d'informations (notés  $F$ ) suivant les trois catégories suivantes [BLOC-96], où  $x$  et  $y$  correspondent aux degrés d'appartenance associées à deux décisions floues.

- Les opérateurs sévères :  $F$  est alors un opérateur conjonctif si  $F(x, y) \leq \min(x, y)$ .
- Les opérateurs indulgents :  $F$  est alors un opérateur disjonctif si  $F(x, y) \geq \max(x, y)$ .
- Les opérateurs prudents :  $F$  est alors défini afin de satisfaire les propriétés suivantes  $\left\{ \begin{array}{l} x \leq F(x, y) \leq y \text{ si } x \leq y \\ y \leq F(x, y) \leq x \text{ sinon} \end{array} \right.$ .

En gardant à l'esprit les enjeux industriels en terme de production, il semble judicieux de s'orienter vers un opérateur prudent qui représente un bon compromis entre les imprécisions des décisions mono capteur et le coût éventuel d'erreur de classification. L'opérateur choisi

est celui développé dans notre équipe par Perez-Oramas [PERE-00] (4.26). Dans la suite, la lettre F correspond toujours à cet opérateur.

$$F(x, y) = \min\left(1, \frac{\min(x, y)}{1 - \min(x, y)}\right) \text{ avec } (x, y) \in [0, 1]^2 \quad (4.26)$$

Cependant, il existe un cas dans notre problème pour lequel l'opérateur de fusion d'informations ne peut fournir une réponse même erronée. Si les deux degrés d'appartenance sont supérieurs à un seuil prédéfini noté  $\mu_s$ , un opérateur indulgent permet d'éviter les erreurs de classification. Il en résulte alors trois cas possibles (4.27-4.29).

$$F(x, y) = \min\left(1, \frac{x}{1-x}\right) \text{ si } x < y < \mu_s \text{ ou } x < \mu_s < y \quad (4.27)$$

$$F(x, y) = \min\left(1, \frac{y}{1-y}\right) \text{ si } y < x < \mu_s \text{ ou } y < \mu_s < x \quad (4.28)$$

$$F(x, y) = 1 \text{ si } x \geq \mu_s \text{ et } y \geq \mu_s \quad (4.29)$$

La figure 4.18 illustre l'évolution des valeurs prises par l'opérateur F pour les différents cas cités pour un seuil  $\mu_s=1/2$ .

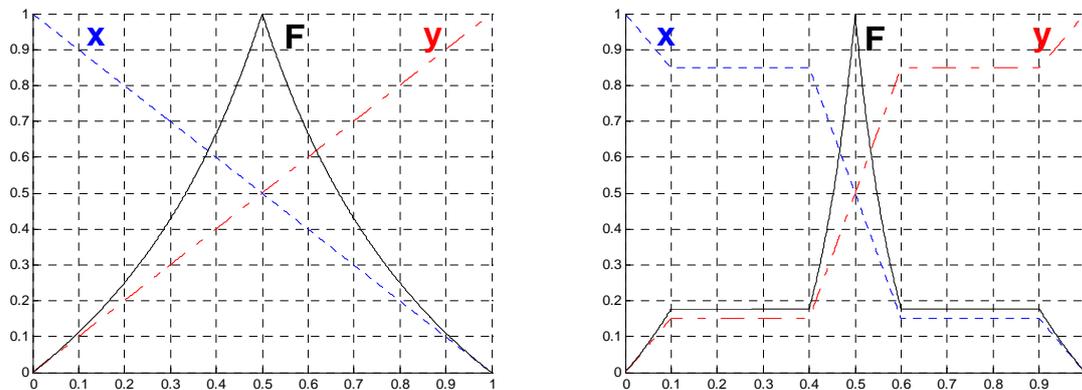


Figure 4.18 : Comportement de l'opérateur F

Le résultat final de la fusion des sorties des deux capteurs flous est obtenu en calculant la réponse maximale de chaque combinaison intermédiaire (4.30).

$$\max_i \left( F \left( \mu_i(x_d), \mu_i(y_g) \right) \right) \quad (4.30)$$

avec  $i$  correspondant aux différentes classes de sortie

$x_d$  et  $y_g$  correspondant respectivement aux réponses des capteurs de rive droite et de rive gauche

Nous pouvons noter que, dans notre cas (sorties nominales), le résultat de la fusion s'apparente à une fusion par règles floues, où seules les règles de la diagonale du tableau 4.10 seraient activées.

### 4.3.2. Résultats comparatifs de classification rive/rive

Afin de valider notre choix d'opérateur de fusion de données, nous avons évalué les résultats de classification liés au cas applicatif 1.

Deux bases de données ont été définies suivant les spécifications de l'industriel :

- la base de données **Base\_Couleur\_Gauche** qui correspond aux données acquises sur la rive gauche des avivés ;
- la base de données **Base\_Couleur\_Droite** qui correspond aux données acquises sur la rive droite des avivés.

Ces deux bases sont constituées chacune de 316 échantillons pour la phase d'apprentissage des modèles de couleurs et de 627 échantillons pour la phase de généralisation. Les couleurs apprises sont celles évoquées dans le tableau 4.10 : Brun Foncé, Brun, Brun Clair, Rouge Foncé, Rouge et Rouge Clair. Les taux de reconnaissance obtenus pour chaque base de données sont les suivants : 85.65% de bonne classification pour la Base\_Couleur\_Gauche et 86.12% de bonne classification pour la Base\_Couleur\_Droite.

L'avantage de l'utilisation d'une fusion d'informations floues plutôt que symboliques peut être illustré par un exemple concret.

- **Exemple d'applications de l'opérateur de fusion**

Considérons deux décisions mono capteur (rive gauche et rive droite) prises sur un même avivé. Le système de reconnaissance fournit pour chacune d'entre elles le coefficient d'appartenance à chaque classe de sortie apprise. Comme nous avons pu le voir précédemment, la qualification de la couleur d'une rive d'un avivé correspond alors à la classe de sortie proposant le degré d'appartenance maximum. Dans le cas applicatif 1, nous disposons donc de 7 degrés d'appartenance par rive (tableau 4.11).

Tableau 4.11 : Décisions prises par chaque capteur et fusion de données

Rive gauche		Rive droite		Couleur de l'avivé après fusion des décisions mono capteur	
Classes de sortie	Degrés d'appartenance	Classes de sortie	Degrés d'appartenance	Classes de sortie	Résultats obtenus pour l'opérateur F
Brun Foncé	0.0000	Brun Foncé	0.0000	Brun Foncé	0.0000
Brun	0.0000	Brun	0.0000	Brun	0.0000
Brun Clair	0.0004	Brun Clair	0.0288	Brun Clair	0.0004
Rouge Foncé	0.0000	Rouge Foncé	0.0000	Rouge Foncé	0.0000
Rouge	0.0027	Rouge	0.0002	Rouge	0.0002
Rouge Clair	0.0334	Rouge Clair	0.0104	Rouge Clair	0.0105
Inconnu	0.0000	Inconnu	0.0000	Inconnu	0.0000

L'échantillon présenté par cet exemple est étiqueté « Rouge Clair » par l'opérateur humain. Or, en utilisant uniquement les réponses maximales obtenues sur chaque rive et la fusion purement symbolique du tableau 4.10, l'avivé en question est identifié comme un produit « rejet ». Cette décision est donc en désaccord avec l'expertise « bois ». Au contraire, en appliquant l'opérateur de fusion de données cité, la valeur maximale est obtenue pour la classe Rouge Clair qui confirme l'étiquetage manuel.

- **Résultats comparatifs**

Dans cette partie, nous présentons les résultats de classification des avivés suivant leur couleur en fusionnant les décisions de chaque capteur. La figure 4.19 illustre les taux de reconnaissance obtenus pour différents opérateurs de fusion de données (opérateur F mis en place, et T-Normes) en comparaison avec une fusion purement symbolique. Les expressions mathématiques des T-Normes utilisées dans la comparaison sont reprises dans le tableau 4.12.

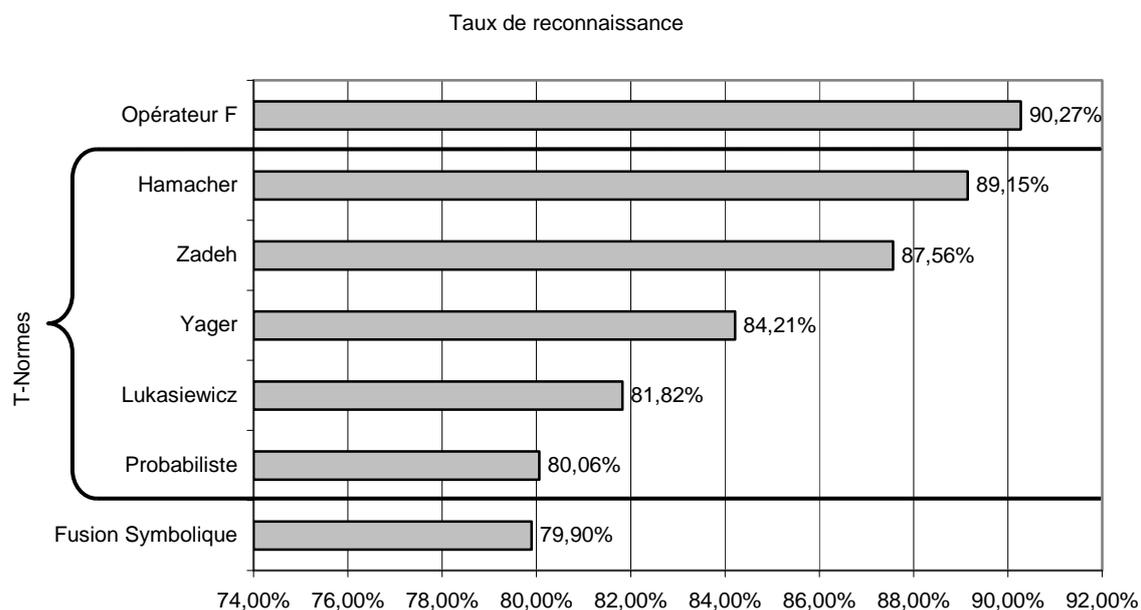


Figure 4.19 : Taux de reconnaissance après fusion des informations mono capteur – Cas applicatif 1

Pour cette comparaison, les résultats intermédiaires de l'application de chaque T-normes sont agrégés par l'opérateur Maximum. Ainsi, les réponses fournies en utilisant la T-norme probabiliste et celle de Zadeh correspondent respectivement à l'implémentation d'un modèle de Larsen et de Mamdani, pour les règles de la diagonale du tableau 4.10.

Tableau 4.12 : Définition mathématique des T-Normes duales étudiées

Nom	T-Norme
Zadeh	$\min(u, v)$
Probabiliste	$u.v$
Lukasiewicz	$\max(u + v - 1, 0)$
Hamacher	$\frac{u.v}{(u + v - u.v)}$
Yager ( $p > 0$ )	$\max\left(1 - \left((1-u)^p + (1-v)^p\right)^{1/p}, 0\right)$

Les résultats montrent que la simple utilisation d'une T-Norme pour effectuer la fusion des données de chaque capteur flou améliore les taux de reconnaissance par rapport à une simple fusion symbolique. En se focalisant uniquement sur les opérateurs de fusion, nous constatons une nette amélioration des performances du système de décision à partir de l'implémentation de notre opérateur F (taux de reconnaissance supérieur à 90%).

#### 4.4. Conclusion

Dans ce chapitre, nous avons exposé le module classification/décision composant notre capteur flou.

Dans un premier temps, nous avons démontré l'intérêt de la logique floue afin de prendre en compte les incertitudes et les imprécisions dans la classification des couleurs. Pour ce faire, nous avons proposé la méthode FRC basée sur l'algorithme d'Ishibuchi et al. qui met en œuvre un mécanisme de règles linguistiques floue sous leur forme conjonctive. Cette méthode permet alors de fournir des réponses nominales à l'utilisateur, faisant ainsi le lien entre l'univers de discours et l'univers lexical introduit dans le fonctionnement du capteur flou (figure 4.20).

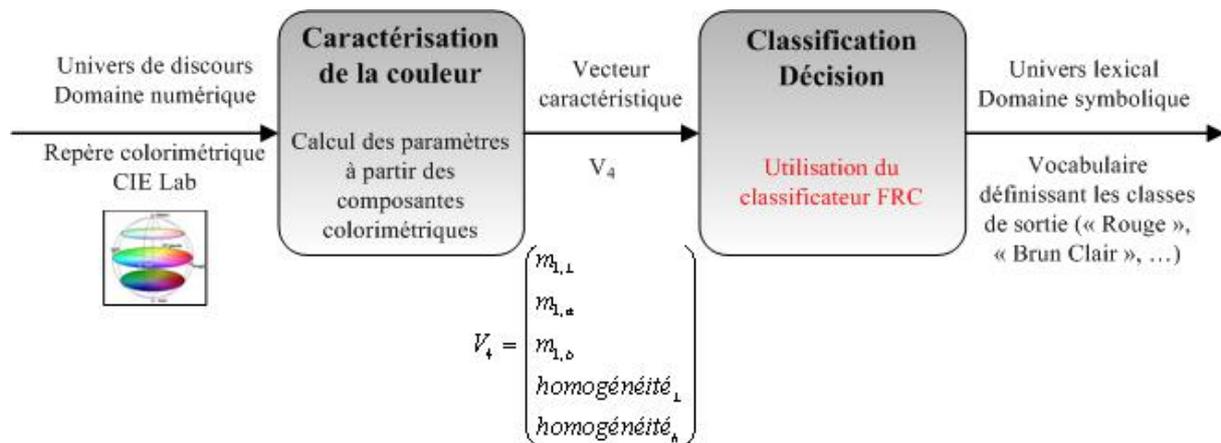


Figure 4.20 : Représentation du lien entre l'univers de discours et l'univers lexical – Classification/Décision

Dans un deuxième temps, en exposant le classificateur développé, nous avons présenté notre contribution à la simplification de l'étape de paramétrage, et plus particulièrement l'étape de fuzzification des entrées du système de reconnaissance, soit les composantes du vecteur caractéristique. Ainsi, nous avons montré que notre proposition permet de travailler à partir de l'expertise des professionnels du bois (définition des classes de couleur par le client à partir d'un lot de données d'apprentissage). Une comparaison des résultats a été réalisée entre les méthodes classiquement utilisées (méthode de clustering et algorithmes génétiques) qui a

montré une amélioration des taux de reconnaissance ainsi qu'une diminution du nombre de règles linguistiques générées.

Par ailleurs, à partir de faibles lots de données d'apprentissage, les taux de reconnaissance de notre méthode convergent rapidement vers un maximum. Nous avons également comparé notre méthode de classification par rapport à des classificateurs de référence en reconnaissance de formes (SVM, réseaux de neurones, ...). Les résultats montrent, quelque soit le lot de données choisi, une amélioration des taux de reconnaissance avec un net avantage pour notre méthode concernant son aptitude en généralisation.

Enfin, outre les traitements effectués sur chaque capteur flou couleur, le cas applicatif 1 de notre étude nécessite une étape supplémentaire de fusion de données afin de fournir au système une décision globale concernant la couleur des avivés. Actuellement basé sur une fusion purement symbolique, les résultats proposent une forte quantité de produits rejetés qui n'est pas acceptable par le client. L'opérateur de fusion présenté dans la dernière partie se démarque largement des normes triangulaires classiquement utilisées pour des problèmes comparables et nous permet d'attendre un taux de classification de 10% supérieur à la fusion symbolique.

## **CHAPITRE 5 : CONCLUSION ET PERSPECTIVES**

---

## 5. Conclusion et perspectives

### 5.1. Conclusion

Dans cette étude, nous avons abordé le développement d'un système de vision adapté à l'identification de couleurs. Ce système élaboré en lien avec la société LuxScan Technologies permet la classification d'avivés à partir de leur couleur. La perception des couleurs est une notion très subjective dans le type d'environnement considéré. Dans le domaine du bois, nous avons pu noter qu'elle n'est pas universelle car fortement liée aux échantillons utilisés et aux conditions d'analyse des avivés. Classiquement réalisée par des opérateurs humains, cette analyse doit être automatisée pour permettre aux industriels de se positionner sur un marché plus que concurrentiel. Afin de répondre à cette problématique, nous avons donc choisi de développer un système automatique de vision suivant la structure d'un capteur flou. L'intérêt majeur de ce type de capteur intelligent réside dans l'intégration des connaissances *a priori* sur le problème et l'interprétabilité des résultats obtenus. Le traitement des images, la reconnaissance de formes et les méthodes de classification sont les principaux thèmes abordés dans ce travail de thèse.

Dans la première partie, nous avons dressé un état de l'art sur les systèmes de vision et de reconnaissances de formes dans un contexte de contrôle qualité. Ainsi, en examinant le champ applicatif de ces travaux, nous avons montré que les techniques existantes n'intègrent pas ou peu de connaissance pour effectuer l'identification de formes. Un état de l'art concernant les techniques de traitement d'images et de reconnaissance de formes a été présenté afin de positionner notre travail.

L'Homme dispose également d'une grande capacité d'adaptation de par les nombreux traitements qu'il peut réaliser. De ce fait, nous avons orienté nos travaux vers le développement d'un capteur flou en intégrant des notions sémantiques aux données numériques. Ceci doit permettre de réduire le fossé sémantique pouvant exister entre les domaines d'expertise bois et vision.

Dans la deuxième partie, nous avons présenté le système d'acquisition ainsi que l'extraction des mesures fonctionnelles en identifiant chaque élément suivant la structure du capteur flou. Tout comme l'être humain, le système d'acquisition est soumis à des

perturbations externes : variation de lumière, changement de température, positionnement du capteur, ... Ces paramètres perturbent tous plus ou moins la reconnaissance des couleurs. Ainsi, après des études de chaque facteur influant, nous avons mis en place des outils de corrections visant à réduire au maximum leurs effets. Cependant, la correction des mesures effectuées par le capteur ne suffit pas à fournir au système de classification des données fonctionnelles adaptées au problème visé. Toujours par souci d'interprétabilité et de reproduction de la perception des couleurs par l'œil humain, nous avons validé ici le choix du repère colorimétrique CIE Lab permettant la meilleure discrimination des classes de couleurs. Nous avons construit un vecteur caractéristique pertinent, constitué de cinq paramètres en nous appuyant sur la finalité de notre étude, le taux de reconnaissance. Ainsi, à partir d'une méthode de sélection de paramètres basée sur l'utilisation des Supports Vecteurs Machines (SVM), nous avons pu obtenir le vecteur caractéristique optimum pour notre problématique.

Dans la troisième partie, les mesures fonctionnelles étant disponibles, nous avons explicité nos travaux concernant l'élaboration d'une méthode de classification basée sur l'utilisation de règles linguistiques floues. Ce type de raisonnement semble naturel pour des traitements liés à des expertises humaines. Ils autorisent, entre autre, la prise en compte des imprécisions et des incertitudes pouvant subsister provenant soit de la définition même des classes de couleur à reconnaître, soit des mesures malgré la correction qui peut être faite.

Un autre intérêt à l'utilisation de règles linguistiques floues réside dans la possibilité de pouvoir créer un modèle couleur, directement à partir de l'expertise métier. Il serait alors possible de reconnaître des couleurs sans acquisition ni échantillons. Bien que n'étant pas utilisée dans ces travaux, cette idée reste très envisageable. Dans un souci de simplification de l'utilisation de notre système, nous avons proposé une méthode originale de paramétrage de l'outil de classification, notamment pour la phase de fuzzification. Celle-ci est basée sur l'exploitation de données « client ». Ainsi, l'analyse des scores de typicalités de chaque paramètre a permis de mettre en avant les ressemblances et recouvrements pouvant exister entre les différentes classes de sortie.

Enfin, nos travaux ont abordé la partie décision du capteur flou. Nous avons montré que notre méthode permet une amélioration des taux de reconnaissance par rapport aux techniques classiquement employées en reconnaissance de formes (SVM, algorithmes génétiques, réseaux de neurones, ...). De plus, avec un fort pouvoir de généralisation de par son aptitude à fonctionner avec peu d'échantillons en apprentissage, l'intégration du classificateur FRC en milieu industriel s'en trouve facilitée. Dans ce cas, le concept de capteur flou présente plusieurs avantages. Premièrement, la logique utilisée permet de prendre en compte la gradualité des classes de sortie définies par l'utilisateur. Deuxièmement, même si nous avons implémenté des modèles de correction dans notre capteur, il semble nécessaire de faire attention aux conditions d'acquisitions. Sans un système stable et robuste dans le temps, les modèles couleur risque de dériver. Il était donc important de développer un système flexible, fiable et efficace. De plus, les données fournies par les capteurs sont représentées en termes linguistiques et sont ainsi interprétables par les utilisateurs dans la phase de calibration ou d'utilisation du système.

Nous avons également montré l'intérêt du développement d'un capteur flou dans la fusion d'informations multi-capteur. En effet, dans ce type de processus, les décisions humaines tiennent compte des représentations linguistiques des couleurs du bois, et se font à partir de règles énoncées en langage naturel. L'implémentation d'un opérateur mathématique permet de rendre plus souples ces décisions. Les résultats obtenus montrent une réduction de la proportion d'avivés rejetés et ainsi des coûts d'exploitation minorés.

Les développements réalisés durant cette thèse se sont organisés autour d'un projet industriel. De ce fait, il a fallu répondre en temps voulu aux contraintes du client (échancier). Nous avons axé ce mémoire vers le capteur flou mais nous avons dû proposer plusieurs solutions intermédiaires et temporaires à l'industriel. En effet, actuellement, le classificateur FRC n'est pas encore implémenté sur site, contrairement à nos propositions sur les corrections des perturbations environnementales. La figure 5.1 illustre les points clés de nos développements durant les quatre années de l'étude.

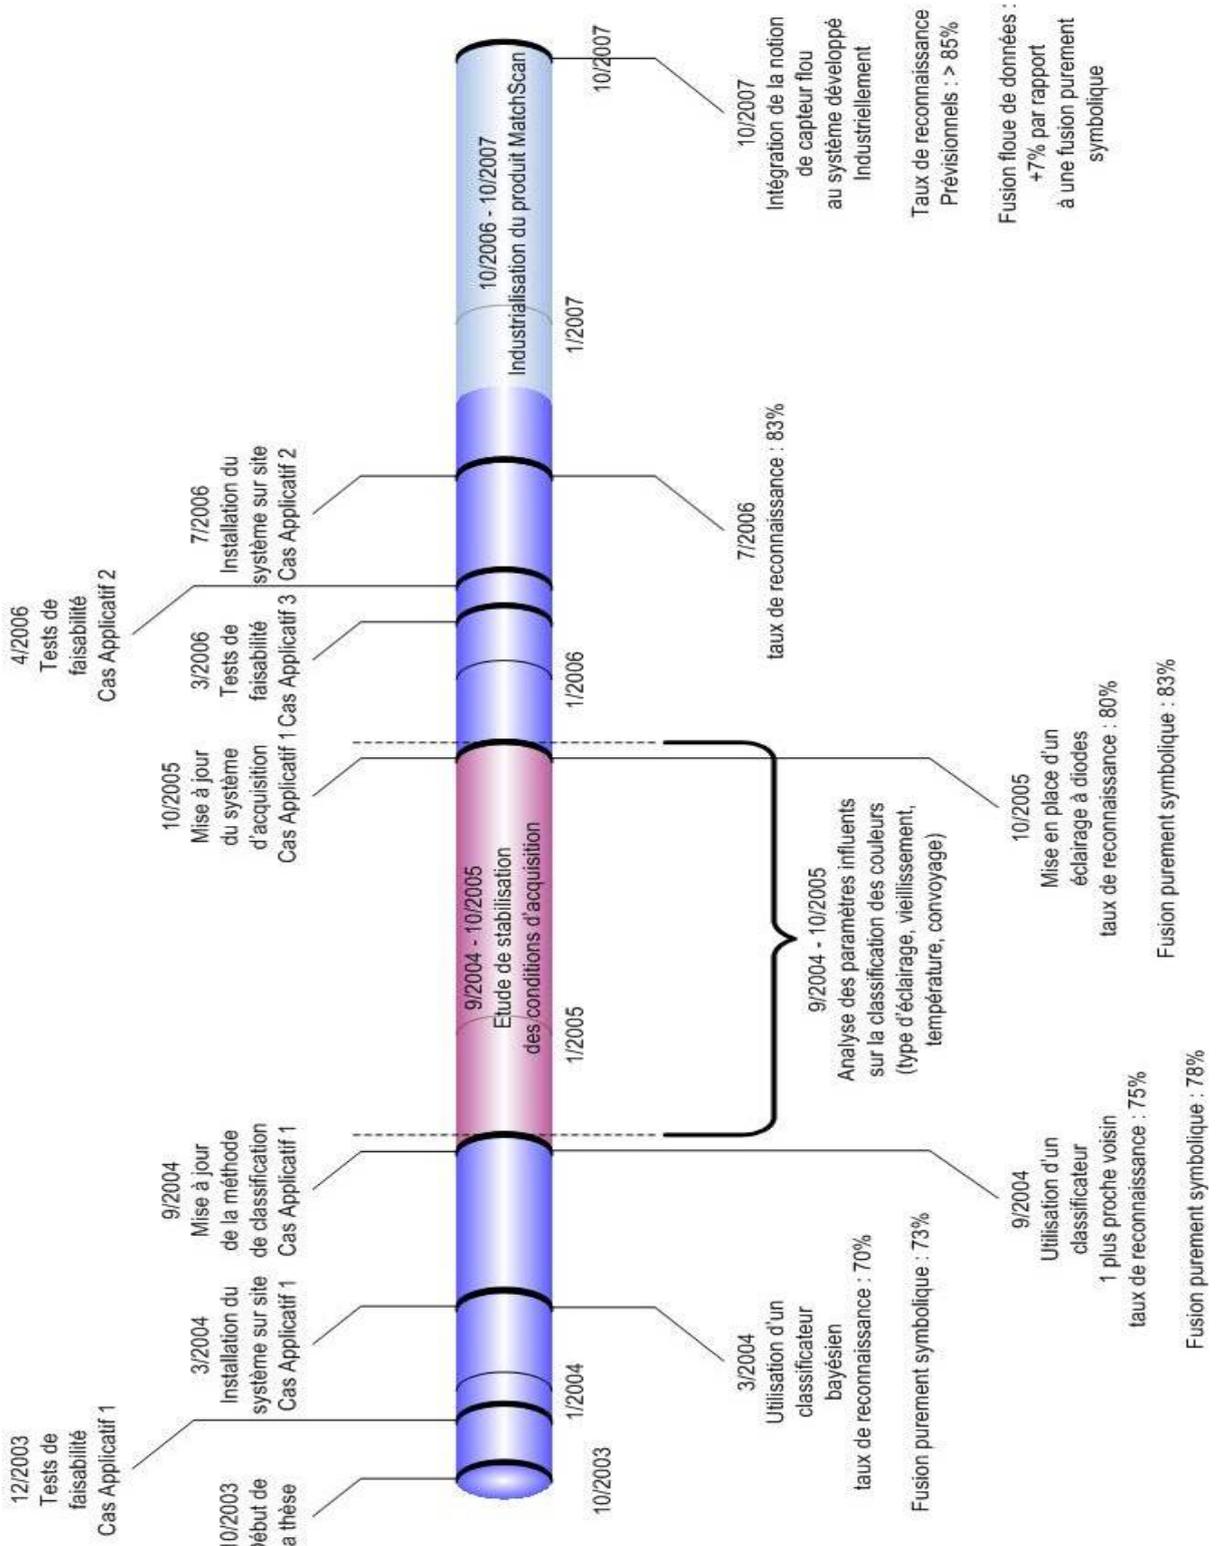


Figure 5.1 : Evolution du projet de développement du capteur flou couleur

La figure 5.2 illustre l'évolution du taux de reconnaissance en fonction des différents points clés énoncés sur la figure 5.1. En prenant pour exemple le cas applicatif 1, nous constatons plusieurs évolutions concernant le taux de reconnaissance. Après l'utilisation d'un classificateur bayésien fournissant des taux de reconnaissance de l'ordre de 70%, l'implémentation des k plus proches voisins a permis une amélioration de 5% de ces taux. Suite aux adaptations et aux corrections environnementales, les résultats ont atteint 80%. Ces résultats concernent les résultats pour un seul capteur. Une évolution similaire est également observée pour les résultats multi-capteurs.

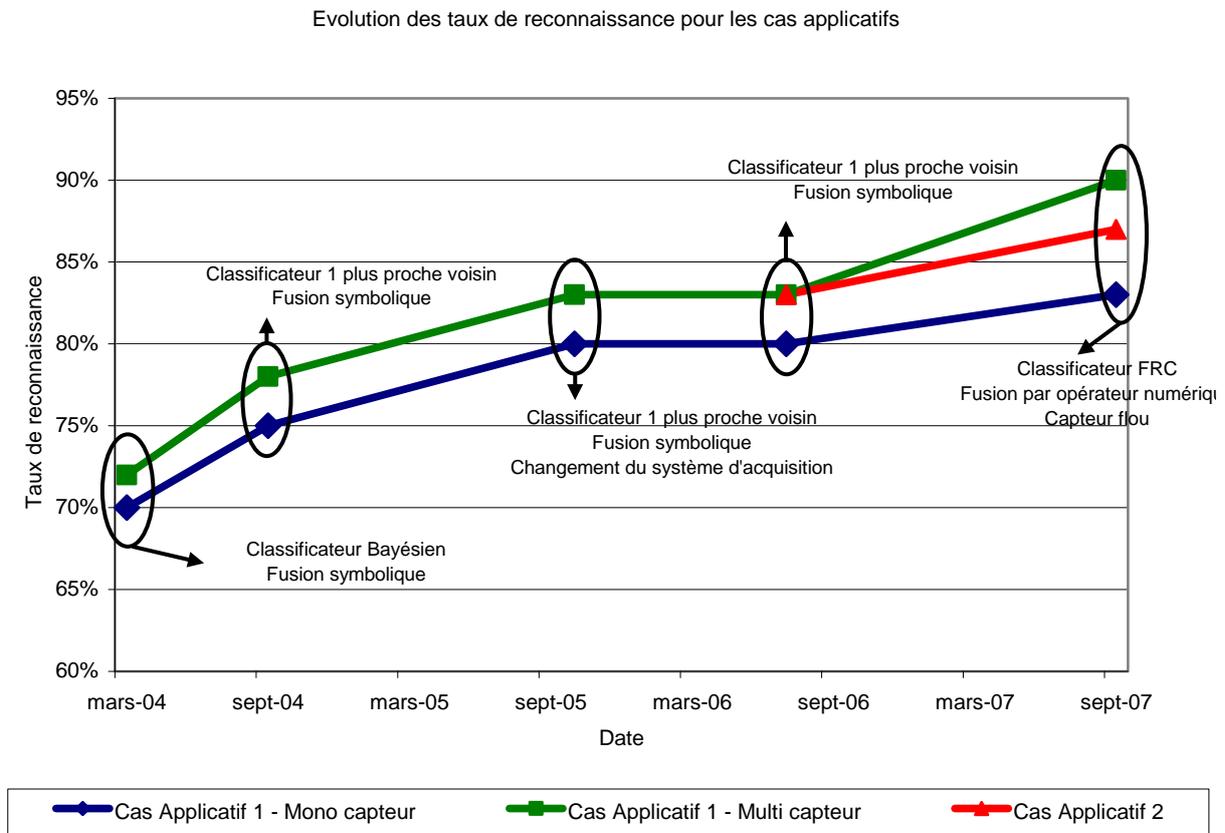


Figure 5.2 : Evolution du taux de reconnaissance pour le cas applicatif 1 durant les travaux de thèse

La figure 5.2 montre une amélioration des taux de reconnaissance tout au long de la collaboration avec la société LuxScan Technologies. L'implémentation sur site du classificateur FRC permettrait encore d'améliorer le taux de reconnaissance de 5% dans le cas mono-capteur et de 10% en utilisant la fusion d'information floue, dans le cas multi-capteur.

## 5.2. Perspectives

Nos travaux ont abouti à plusieurs résultats exploitables. Néanmoins, les perspectives directes ou indirectes sont nombreuses.

Tout d'abord, elles peuvent concerner l'amélioration des techniques proposées : classification et fusion de données. D'un point de vue du paramétrage du module de classification, la fuzzification automatique des paramètres d'entrée semble être prometteuse mais limitée au cas des classes de sortie convexe. En étendant notre méthode aux classes présentant plusieurs modalités, il serait alors envisageable d'attribuer plusieurs termes de fuzzification à une même classe.

Dans un souci de simplification du système, nous pouvons imaginer un couplage de notre méthode de fuzzification automatique à une technique de sélection de paramètres afin d'automatiser la réduction de la dimension du vecteur caractéristique. Une première étude a déjà été effectuée en collaboration avec le laboratoire LORIA de Nancy, sur une problématique de classification de défauts textiles.

Concernant la partie classification de données, nous pouvons essentiellement nous orienter vers une amélioration de la phase de génération automatique des règles floues. Les règles générées favorisent actuellement la classe fournissant la réponse maximale. Une pondération différente pour chaque classe durant la phase itérative d'ajustement des règles permettrait de prendre plus en compte les classes fournissant les deuxièmes réponses maximales. De plus, en analysant plus en détail les règles générées, nous pouvons envisager de réduire leur nombre en supprimant celles qui ne sont pas indispensables à la reconnaissance. L'interprétation des règles pourrait également être améliorée en développant un outil de synthèse à partir des matrices numériques fournies par notre méthode. Cela permettrait de traduire les données numériques en règles linguistiques compréhensibles de tous.

Ensuite, nos travaux ont permis d'appréhender la notion de texture dans la caractérisation des couleurs. En effet, même si elle est inutile pour les cas applicatifs présentés, elle peut avoir un impact sur la perception des couleurs (grain serré, grain épais, grain sombre, ...). De plus, une demande existe pour la classification d'avivés selon l'orientation de leur grain : dosse, quartier, faux-quartier, cœur. L'utilisation des mêmes principes de classification peut alors rendre simple l'intégration d'un capteur flou adapté à l'identification des couleurs et des textures sur des avivés.

Par ailleurs, dans un cadre plus général, les techniques développées durant ces travaux peuvent être appliquées à d'autres domaines d'expertise dans lesquels nous disposons de deux types d'informations symboliques (avis des experts métier et vision) et d'informations numériques issues directement du capteur. Nous pouvons citer le domaine du textile pour la détection de défauts de tissage. En couplant les trois types d'informations, soient celles provenant de la vue numérique du produit, de la vue symbolique vis à vis du capteur (connaissance vision) et de la vue symbolique vis à vis du produit (connaissance métier), les besoins métiers peuvent se traduire en termes de vision afin d'être couplées aux données numériques (figure 5.3). La prise en compte des informations sémantiques permettrait alors de

spécifier les traitements d'images à appliquer au problème donné. Ces travaux permettraient de réduire le fossé sémantique entre les domaines vision et métier.

Enfin, une autre voie à explorer concerne le lien entre le capteur et le système d'information de l'entreprise. Durant la phase de décision, nous pourrions prendre en compte des contraintes de plus haut niveau. Par exemple, si un lot d'avivés est vu comme « rouge » ou « rouge foncé », nous pouvons exploiter cette incertitude en la couplant avec les contraintes de production du client. Si une commande nécessitant des avivés « rouge foncé » est prévue, un lot d'avivés « colorimétriquement proche » pourrait alors être utilisé. Cette perspective entre dans le cadre de la gestion de l'information floue au sein même du système d'informations de l'entreprise.

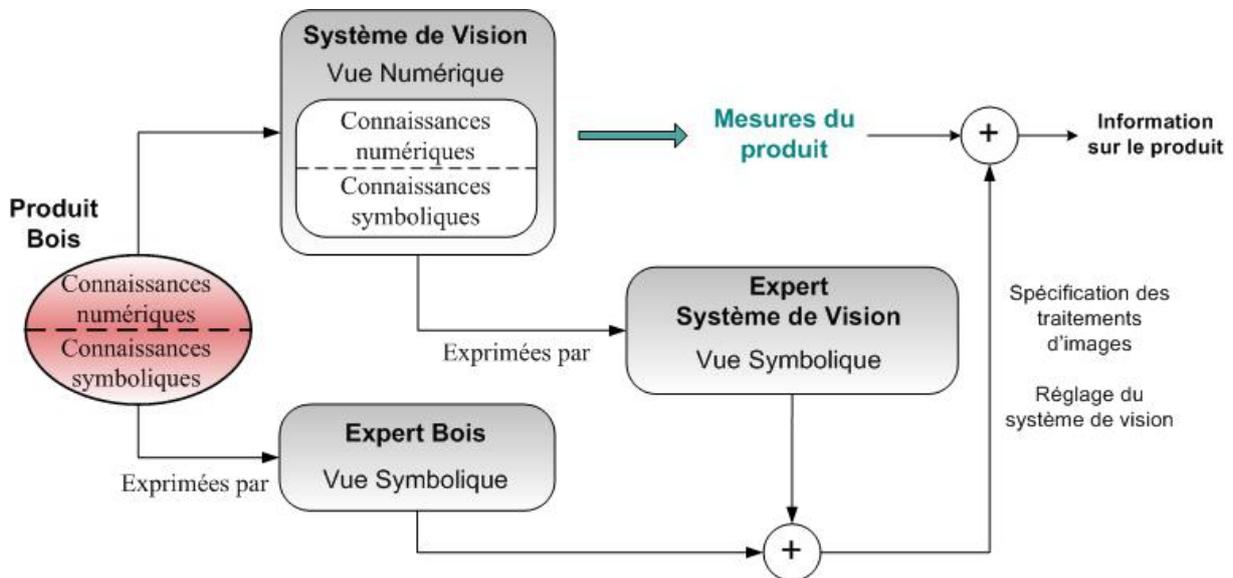


Figure 5.3 : Principe d'intégration des connaissances expertes permettant la spécialisation des traitements d'images – Application Bois

**ANNEXES**

---

## **Annexes A**

### **Annexe A.1 : L'œil humain et la perception des couleurs**

La perception de la couleur a été définie comme un procédé difficile à appréhender de part la complexité de la vision humaine [WRIG-69]. Pour reproduire les capacités de l'œil humain au sein d'un système automatisé de vision, il est nécessaire de préciser quelques caractéristiques de cette perception. Cependant, le champ d'étude étant très vaste, seuls les aspects utiles aux travaux présentés seront abordés, c'est-à-dire la structure de l'œil et son fonctionnement, et la perception des couleurs.

- **Œil humain et vision humaine**

L'œil est l'organe central de la vision humaine. Il est composé de plusieurs éléments (figure A.1) permettant de capturer la lumière incidente, de former les images acquises et d'effectuer les pré-traitements sur une partie des informations obtenues. Certaines parties constituant l'œil requiert quelques explications [CADI-04] :

- l'iris et la pupille qui sont assimilables à un diaphragme permettant un dosage de la lumière absorbée par l'œil lors d'une prise de vue ;
- le cristallin qui est assimilable à une lentille dont la focale est variable en fonction de la position des scènes observées ;
- la rétine qui permet d'obtenir une représentation sous forme d'images de la scène ;
- le nerf optique qui permet le transfert au cerveau des images acquises en vue de leur analyse et leurs traitements.

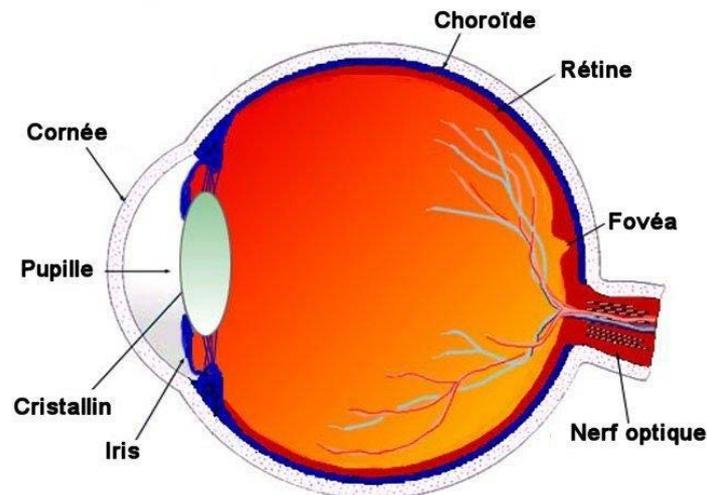


Figure A.1 : Coupe d'un œil humain [KOLB-00]

Les phénomènes visuels attachés à l'œil humain interviennent à plusieurs niveaux : l'acquisition des images sous forme de stimuli, leur transmission vers les organes de traitements via les connexions neuronales, l'interprétation liée aux caractéristiques psychophysiques.

La partie essentielle qui permet de générer les images dans un œil est la rétine. La formation d'images se réalise par l'absorption de la lumière. La pupille s'ouvre et se ferme pour que la quantité de lumière soit toujours constante au niveau de la rétine. Pour comprendre les mécanismes de formation des images, il faut analyser la composition de la rétine au niveau de sa structure. En effet, cette partie est constituée d'un grand nombre de récepteurs et neurones permettant de transférer l'information lumineuse acquise vers le cerveau qui traitera alors les informations optiques. Il existe différents types de récepteur : les bâtonnets et les cônes. Les bâtonnets sont des photorécepteurs très sensibles à la lumière et sont totalement saturés dans un environnement très lumineux. Ce sont eux qui interviennent dans la vision nocturne. Les cônes, quant à eux, sont parfaitement adaptés à la vision en pleine journée et sont les seuls responsables de la perception des couleurs. Cette étude portant essentiellement sur les aspects colorimétriques de la vision, seul la compréhension du fonctionnement des cônes est utile dans les mécanismes de la perception des couleurs. Il existe trois types de cônes sensibles à différentes longueurs d'onde : les cônes rouges, les cônes verts et les cônes bleus. La réponse associée aux différents stimuli des cônes permet la composition de l'information couleur décrite dans la scène observée. Les mécanismes neuronaux, qui interviennent dans les phénomènes de vision humaine, ne représentant pas le cœur de cette étude, le lecteur a la possibilité de s'informer de leurs fonctionnements à travers des écrits plus spécialisés traitant de ce domaine très complexe [FAUG-76] [MARR-76] [LEVI-85] [PALM-02].

- **La perception humaine de la couleur**

La couleur d'une scène dépend essentiellement des propriétés de la lumière incidente et des propriétés physiques des éléments qui composent cette scène [KLUM-94]. Cette lumière est recueillie par l'œil humain et plus particulièrement par les cônes de sensibilités colorimétriques différentes (figure A.2).

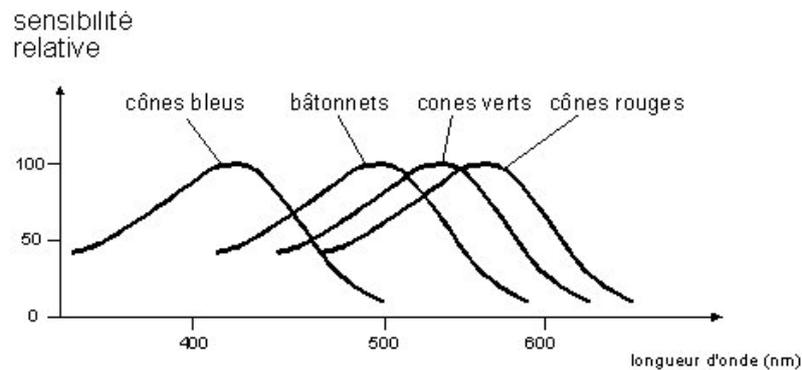


Figure A.2 : Courbes d'absorption des différents photorécepteurs de l'œil humain en fonction de la longueur d'onde

Chaque type de cônes possède sa propre absorption maximale. De nombreuses études ont été menées sur la perception des couleurs prouvant ainsi qu'elle possède une dimension infinie fonction de la longueur d'onde. A partir de ces travaux, il a été montré que la plupart des couleurs peuvent être caractérisées par la combinaison des trois couleurs primaires définies par les cônes de la rétine [GERS-84]. Dans le cas de la vision humaine, la notion de synthèse additive des primaires rouge, verte et bleue est souvent employée (figure A.3/a). Il existe une autre manière de synthétiser les couleurs ; il s'agit de la synthèse soustractive basée sur les primitives cyan, magenta et jaune (figure A.3/b). Ces mécanismes de composition des couleurs se retrouvent très souvent dans les applications industrielles.

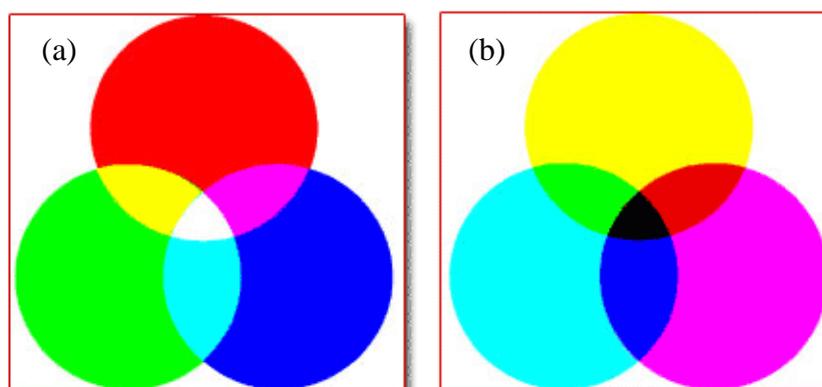


Figure A.3 : Diagrammes des synthèses additive (a) et soustractive (b)

De nombreux modèles mathématiques ont été développés pour caractériser les similarités des couleurs perceptibles par l'œil. Ces modèles reposent tous sur la théorie trichromatique de la couleur qui stipule que toute couleur peut être générée à partir de trois couleurs primaires. Ainsi, les synthèses additives et soustractives s'y retrouvent résumées. Cette théorie a été introduite par la Commission Internationale de l'Éclairage (CIE) en 1931 et fait suite à de nombreux tests prouvant que la vision humaine est bien sensible aux primitives rouge, verte et bleue [CIE-74]. La CIE a normalisé ce système colorimétrique sous le nom CIE RGB 1931 (figure A.4).

L'inconvénient de ce système de représentation concerne les valeurs négatives pouvant être prises par les primaires. La CIE a donc évalué la sensibilité relative de la perception humaine des couleurs. Cette étude a permis de définir le repère colorimétrique XYZ dans lequel il est possible de caractériser des zones de couleur non discernables par l'œil humain (figure A.5). Il s'agit d'un repère caractérisant la notion de chrominance.

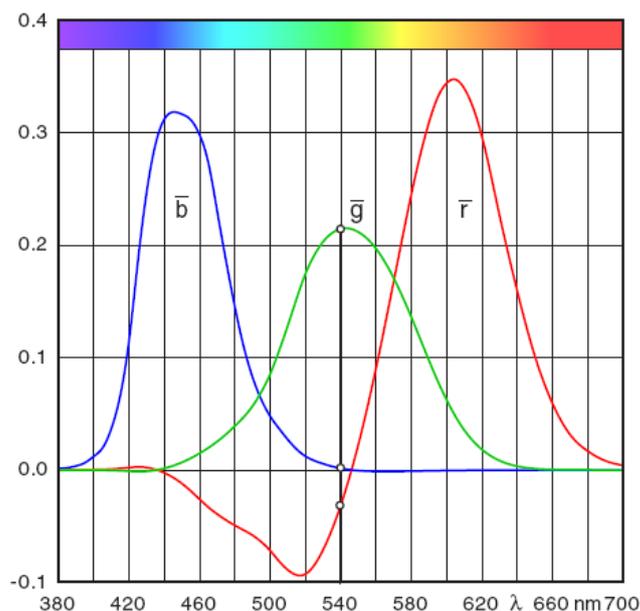


Figure A.4 : Diagramme de sensibilité des primaires nécessaire à la composition des couleurs

Chaque ellipse présente sur le diagramme de la figure A.5 correspond à des couleurs que l'homme ne peut différencier [SILB-45]. De nombreux repères colorimétriques ont été définis par la CIE dans le but de pouvoir discriminer au mieux les couleurs discernables par un être humain : CIE Lab, CIE Luv, TLS (Teinte, Luminance, Saturation), ... Des études très précises

ont été menées sur la perception des couleurs par l'être humain [ALLE-99]. Le lecteur peut y faire référence pour obtenir plus de détails sur le domaine.

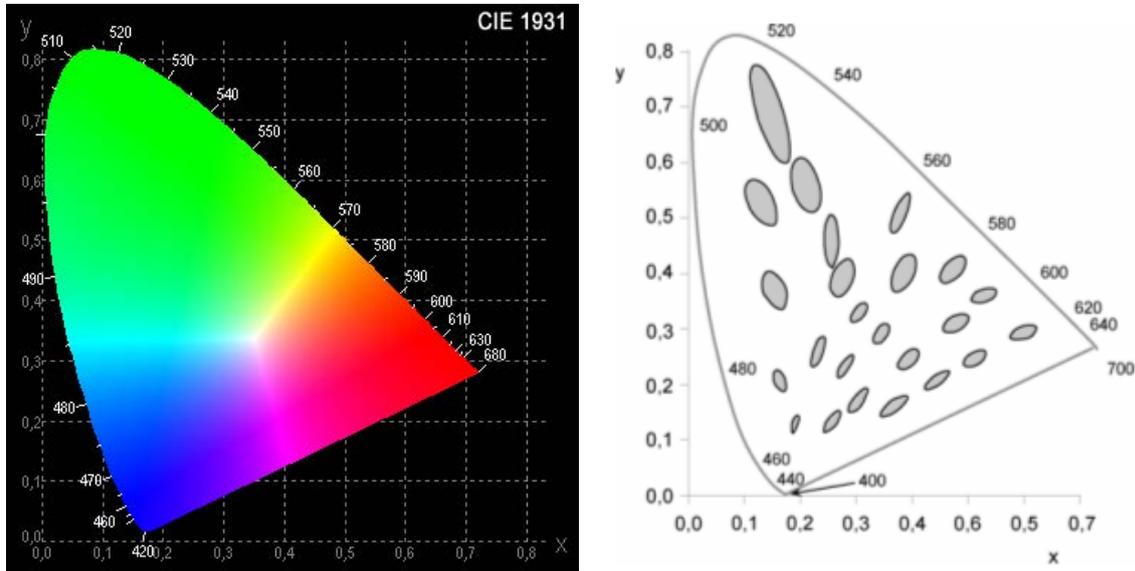


Figure A.5 : Diagrammes de chromaticité de l'œil humain et ellipses de MacAdam

## Annexe A.2 : Recomposition des images couleurs

La caméra mono CCD linéaire couleur utilisée est constituée d'une dalle d'acquisition composée de deux canaux : le premier regroupant les photosites associés à la composante verte, le second regroupant alternativement les photosites des composantes rouge et bleu (figure A.6).

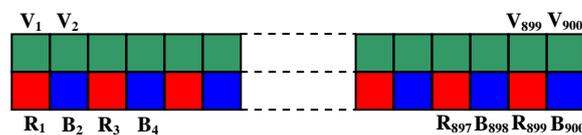


Figure A.6 : Répartition des photosites sur la caméra couleur utilisée

Pour traiter les données acquises, chaque pixel des images doit être caractérisé par un triplet  $\{R,V,B\}$ . Ne disposant que de 450 pixels rouges et 450 pixels bleus contre 900 pixels

verts, la société LuxScan Technologies a mis en place un algorithme de recombinaison des images couleurs à partir des équations suivantes. Nous distinguons les deux canaux en les nommant  $C_0$  le canal composé des photosites verts et  $C_1$  le canal composé des photosites rouges et bleus.

- **Triplet {R,V,B} du premier pixel d'une ligne**

$$R_1 = C_1(1) \quad (\text{A.1})$$

$$V_1 = C_0(1) \quad (\text{A.2})$$

$$B_1 = C_1(2) \quad (\text{A.3})$$

- **Triplet {R,V,B} du dernier pixel d'une ligne**

$$R_{900} = C_1(899) \quad (\text{A.4})$$

$$V_{900} = C_0(900) \quad (\text{A.5})$$

$$B_{900} = C_1(900) \quad (\text{A.6})$$

- **Triplet {R,V,B} pour le  $i^{\text{ème}}$  pixel d'une ligne**

$$Valeur(i) = C_0(i) + \frac{[C_1(i-1) - C_0(i-1)] + [C_1(i+1) - C_0(i+1)]}{2} \quad (\text{A.7})$$

Si  $i$  est impair, le triplet {R,V,B} sera

$$R_i = C_1(i) \quad (\text{A.8})$$

$$V_i = C_0(i) \quad (\text{A.9})$$

$$B_i = Valeur(i) \quad (\text{A.10})$$

Si  $i$  est pair, le triplet {R,V,B} sera

$$R_i = Valeur(i) \quad (\text{A.11})$$

$$V_i = C_0(i) \quad (\text{A.12})$$

$$B_i = C_1(i) \quad (\text{A.13})$$

Le schéma de recombinaison des images couleurs est basé sur le principe d'interpolation du repère Yuv en faisant comme hypothèse que la composante verte est assimilable à la composante Y représentant l'axe achromatique de luminance. Dans ce repère, la composante  $u$  représente le signal chromatique bleu, et la composante  $v$  représente le signal chromatique rouge. Classiquement ces trois composantes sont définies d'après les équations A.14 à A.16 suivantes.

$$Y = 0.3R + 0.6V + 0.1B \quad (\text{A.14})$$

$$u = \frac{B - Y}{2} \quad (\text{A.15})$$

$$v = \frac{R - Y}{2} \quad (\text{A.16})$$

L'approximation faite sur le composante Y peut induire des aberrations chromatiques qui seront cependant compensées par la balance de blanc effectuée sur le capteur (section 3.1.1).

## Annexes B

### Annexe B.1 : Algorithme d'Ishibuchi *et al.*

Pour présenter l'algorithme d'Ishibuchi *et al.* [ISHI-92][ISHI-94][NOZA-97], nous considérons un problème de classification dans un espace à deux dimensions dans lesquels les valeurs sont comprises entre 0 et 1. Il est supposé que  $m$  échantillons  $x_p = (x_{p1}, x_{p2})$ ,  $p = 1, 2, \dots, m$  sont fournis comme données d'apprentissage à partir de  $M$  classes ( $C_1, C_2, \dots, C_M$ ).

Le but de l'algorithme est de générer des règles floues à partir de ces données numériques d'apprentissage. La figure B.1 montre un exemple de problème de classification avec  $M = 2$  et  $m = 32$ ).

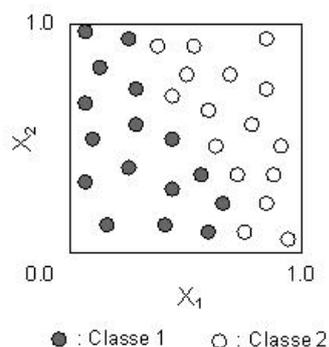


Figure B.1 : Exemple de problème de classification à deux classes

L'algorithme de classification se décompose en trois étapes : la fuzzification des paramètres d'entrées, la génération des règles et la reconnaissance d'un échantillon.

• **Etape 1 : Fuzzification des entrées**

Supposons que chaque axe de l'espace de représentation est divisé en  $K$  sous-ensembles  $\{A_1^K, A_2^K, \dots, A_K^K\}$ . Pour chaque  $A_i^K$ , nous supposons ici une fonction d'appartenance de forme triangulaire définie comme :

$$\mu_i^K(x) = \max \left\{ \min \left\{ 2 - 2 \left| \frac{x - a_i^K}{b^K} \right|, 1 \right\}, 0 \right\}, \quad i = 1, 2, \dots, K \quad (\text{B.1})$$

$$\text{où} \quad a_i^K = (i-1)/(K-1), \quad i = 1, 2, \dots, K \quad (\text{B.2})$$

$$\text{et} \quad b^K = 1/(K-1) \quad (\text{B.3})$$

Divisons l'axe du premier attribut (axe horizontal  $x_1$ ) en  $I$  sous-ensembles flous  $\{A_1^I, A_2^I, \dots, A_I^I\}$  et l'axe du second attribut (axe vertical  $x_2$ ) en  $J$  sous-ensembles flous  $\{A_1^J, A_2^J, \dots, A_J^J\}$ . L'espace de représentation est alors partitionné en  $I \times J$  sous-espaces flous  $\{A_i^I \times A_j^J : i = 1, 2, \dots, I; j = 1, 2, \dots, J\}$ . Pour simplifier la compréhension, nous considérons une décomposition équirépartie de chaque axe en deux et trois sous-ensembles flous ( $I = 2 ; J = 3$ ). L'espace de représentation est alors partitionné en six sous-espaces flous, comme illustré par la figure B.2 (l'étiquette  $R_{ij}^{IJ}$  associée à chaque sous-espace flou est expliquée dans l'étape de génération des règles floues).

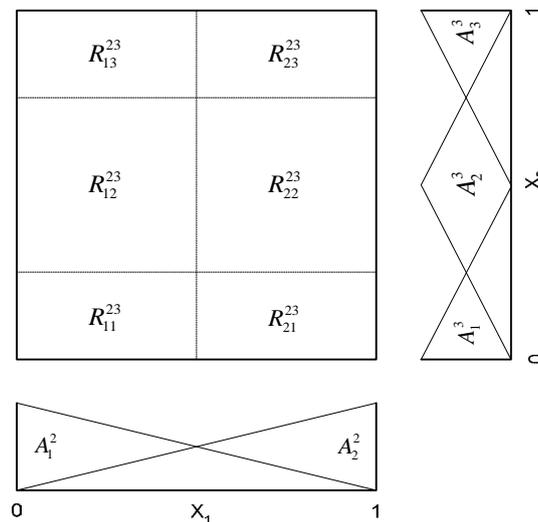


Figure B.2 : Exemple de construction de sous-espaces flous

• **Etape 2 : Génération des règles floues**

Une règle floue  $R_{ij}^{IJ}$  pour un problème de classification à deux dimensions peut être formulée comme suit :

Règle  $R_{ij}^{IJ}$  : si  $x_{p1}$  est  $A_i^I$  et  $x_{p2}$  est  $A_j^J$  alors  $(x_{p1}, x_{p2})$  appartient à la classe  $C_{ij}^{IJ}$

avec le degré  $CF = CF_{ij}^{IJ}$

avec  $i=1, 2, \dots, I$ ;  $I=1, 2, \dots, I_{max}$ ;  $j=1, 2, \dots, J$ ;  $J=1, 2, \dots, J_{max}$

et où  $C_{ij}^{IJ}$  est une des  $M$  classes et  $CF_{ij}^{IJ}$  le degré de certitude accordé à la règle floue  $R_{ij}^{IJ}$

La classe  $C_{ij}^{IJ}$  et le degré de certitude  $CF_{ij}^{IJ}$  résultants de la règle sont déterminés par la procédure suivante :

1) Calculer  $\beta_{CT}$  pour  $T = 1, 2, \dots, M$  comme

$$\beta_{CT} = \sum_{x_p \in CT} \mu_i^I(x_{p1}) \times \mu_j^J(x_{p2}) \quad (\text{B.4})$$

2) Trouver la classe  $X (C_X)$  telle que

$$\beta_{CX} = \max \{ \beta_{C1}, \beta_{C2}, \dots, \beta_{CM} \} \quad (\text{B.5})$$

Si deux classes ou plus prennent la valeur maximale, le  $C_{ij}^{IJ}$  résultant de la règle floue  $R_{ij}^{IJ}$  correspondant au sous-espace flou  $A_i^I \times A_j^J$  ne peut être déterminé de manière unique. Dans ce cas,  $C_{ij}^{IJ}$  est vide pour montrer que la règle  $R_{ij}^{IJ}$  est inactive. Si une seule classe prend la valeur maximale, le  $C_{ij}^{IJ}$  résultant de la règle est déterminé comme étant la classe  $X (C_X)$ . Dans le cas d'une seule classe, le coefficient  $CF_{ij}^{IJ}$  résultant est déterminé comme suit :

$$CF_{ij}^{IJ} = (\beta_{CX} - \beta) / \sum_{T=1}^M \beta_{CT} \quad (\text{B.6})$$

$$\text{où } \beta = \sum_{\substack{T=1 \\ CT \neq CX}}^M \beta_{CT} / (M - 1) \quad (\text{B.7})$$

Dans cette procédure, le  $C_{ij}^{II}$  résultant est déterminé comme étant la classe  $X$  ( $C_X$ ) qui possède la plus forte somme de  $\mu_i^I(x_{p1}) \times \mu_j^I(x_{p2})$  parmi les  $M$  classes. Les règles floues avec une partie résultante vide sont des règles inactives qui n'ont aucun effet sur l'inférence floue pour classer un nouvel échantillon. S'il n'y a aucun échantillon dans le sous-espace flou  $A_i^I \times A_j^I$ , une règle inactive est générée par cette procédure pour ce sous-espace flou.

La définition du degré de certitude  $CF_{ij}^{II}$  est plus compréhensible en considérant un problème à deux classes. Supposons que  $\beta_{C1} > \beta_{C2}$  pour la règle floue  $R_{ij}^{II}$ . La classe résultante  $C_{ij}^{II}$  est donc la classe  $C_1$  et le degré de certitude  $CF_{ij}^{II}$  est  $(\beta_{C1} - \beta_{C2}) / (\beta_{C1} + \beta_{C2})$ . Dans le cas où il n'y a pas d'échantillon de la classe  $C_2$  dans le sous-espace flou  $A_i^I \times A_j^I$ , il en résulte que  $\beta_{C1} > \beta_{C2}$  (où  $\beta_{C2} = 0$ ) et  $CF_{ij}^{II} = 1$  (certitude maximale). D'autre part, si le nombre d'échantillons de la classe  $C_1$  et de la classe  $C_2$  est similaire dans le sous-espace considéré, il en résulte que  $\beta_{C1} \approx \beta_{C2}$  et  $CF_{ij}^{II} = 0$  (certitude minimale).

La génération des règles floues dispose d'un mécanisme d'ajustement de ces règles. Celui-ci consiste en l'ajustement du degré de certitude  $CF_{ij}^{II}$  de la règle floue  $R_{ij}^{II}$  en fonction de la bonne ou mauvaise classification d'un échantillon du lot d'apprentissage. Quand  $x_p$  est correctement classé par la règle  $R_{ij}^{II}$ , l'ajustement du degré de certitude de la règle s'effectue par :

$$CF_{ij}^{II} = CF_{ij}^{II} + \eta_1(1 - CF_{ij}^{II}) \quad (\text{B.10})$$

où  $\eta_1$  est une constante d'apprentissage

Au contraire, lorsque  $x_p$  n'est pas correctement classé par la règle  $R_{ij}^{II}$ , l'ajustement du degré de certitude s'effectue par :

$$CF_{ij}^{II} = CF_{ij}^{II} - (\eta_2 \times CF_{ij}^{II}) \quad (\text{B.11})$$

où  $\eta_2$  est une constante d'apprentissage

Il s'agit là de la partie itérative de l'algorithme dont l'influence des différents critères (constantes d'apprentissage  $\eta_1$  et  $\eta_2$ , nombre d'itérations et seuil de classification) a été étudiée (Annexe B.2).

- **Etape 3 : Classification d'un échantillon**

Afin de classer un échantillon « inconnu » à partir de la base de règles générée  $S$ , deux étapes sont nécessaires.

1) Calculer  $\alpha_{CT}$  pour  $T = 1, 2, \dots, M$  comme

$$\alpha_{CT} = \max \left\{ \mu_i^I(x_{p1}) \times \mu_j^J(x_{p2}) \times CF_{ij}^{IJ} : C_{ij}^{IJ} = \text{Class } T \text{ and } R_{ij}^{IJ} \in S \right\} \quad (\text{B.8})$$

2) Trouver la classe  $X (C_X)$  telle que

$$\alpha_{CX} = \max \{ \alpha_{C1}, \alpha_{C2}, \dots, \alpha_{CM} \} \quad (\text{B.9})$$

Si deux classes ou plus prennent la valeur maximum alors la classification de  $x_p$  est rejetée ( $x_p$  est considérée comme inclassable), sinon  $x_p$  est assigné à la classe  $X (C_X)$ . La classe inférée est alors le résultat de la règle floue qui possède la valeur maximale de  $\mu_i^I(x_{p1}) \times \mu_j^J(x_{p2}) \times CF_{ij}^{IJ}$  parmi toutes les règles floues de  $S$ . S'il n'y a aucune règle floue telle que  $\mu_i^I(x_{p1}) \times \mu_j^J(x_{p2}) \times CF_{ij}^{IJ} > 0$ , l'échantillon  $x_p$  ne peut être classé.

## Annexe B.2 : Validation des choix de paramètres pertinents à partir d'un classificateur kppv

Les résultats présentés dans cette annexe concernent la validation du choix des paramètres pertinents à partir des taux de reconnaissance obtenus pour l'algorithme des k plus proches voisins. Comme nous l'avons indiqué dans la section 3.2.3., l'analyse de la base Base\_Couleur\_1 a permis de construire 6 vecteurs caractéristiques (B.10-B.15) que nous avons ensuite testés à partir du classificateur FRC.

$$V_1 = \begin{pmatrix} m_{1,L} \\ \text{homogénéité}_L \end{pmatrix} \quad (\text{B.10})$$

$$V_2 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ \text{homogénéité}_L \end{pmatrix} \quad (\text{B.11})$$

$$V_3 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \end{pmatrix} \quad (\text{B.12})$$

$$V_4 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \\ \text{homogénéité}_h \end{pmatrix} \quad (\text{B.13})$$

$$V_5 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \\ \text{homogénéité}_L \\ \text{homogénéité}_h \\ \text{homogénéité}_c \end{pmatrix} \quad (\text{B.14})$$

$$V_6 = \begin{pmatrix} m_{1,L} \\ m_{1,a} \\ m_{1,b} \end{pmatrix} \quad (\text{B.15})$$

Afin de valider le choix exposé dans le mémoire, nous avons effectué les mêmes tests de classification à partir de l'algorithme des k plus proches voisins. Nous ne présentons, dans le tableau B.1, que les résultats obtenus en généralisation. En effet, en apprentissage, les taux sont tous égaux à 100% pour 1 plus proche voisin (k=1).

Tableau B.1 : Taux de reconnaissance pour différents vecteurs caractéristiques – Algorithme des k plus proches voisins

Vecteurs caractéristiques	V <sub>1</sub>	V <sub>2</sub>	V <sub>3</sub>	V <sub>4</sub>	V <sub>5</sub>	V <sub>6</sub>
Nombre de voisins (k)	7	7	5	5	<b>5</b>	5
Taux de reconnaissance en généralisation	54.55%	79.74%	80.54%	<b>81.66%</b>	80.38%	78.63%

Les résultats obtenus montrent bien que le vecteur V<sub>4</sub> (B.13) permet de mieux discriminer les classes de sortie à identifier.

### Annexe B.3 : Validation de la méthode de fuzzification automatique pour un autre domaine d'applications

Les résultats présentés dans cette annexe concernent les taux de reconnaissance obtenus pour la détection de défauts sur du textile, dans le cadre d'un projet industriel. Nous avons appliqués notre méthode de fuzzification automatique afin de régler le classificateur FRC. Pour des raisons de confidentialité, nous ne présentons pas en détails les lots de données et les étapes du paramétrage du classificateur FRC.

Nous travaillons sur deux lots de données, un pour l'apprentissage constitué de 570 échantillons, et l'autre pour la généralisation constitué de 618 échantillons. Le vecteur caractéristique est composé de 9 paramètres. Les classes de sortie sont au nombre de 6.

Les résultats présentés dans le tableau B.2 illustrent l'amélioration des taux de reconnaissance à partir d'un paramétrage automatique par rapport à une fuzzification équirépartie des paramètres du vecteur caractéristique. Nous notons également une diminution de règles linguistiques floues générées.

Tableau B.2 : Taux de reconnaissance pour différents types de fuzzification – Lot textile

	Fuzzification équirépartie (7 termes)	Fuzzification automatique
Nombre de règles générées	5967	3739
Taux de reconnaissance en apprentissage	96.14%	98.94%
Taux de reconnaissance en généralisation	88.06%	90.13%

## Annexe B.4 : Etudes des constantes d'apprentissage de l'algorithme d'Ishibuchi *et al.*

Le paramétrage de l'algorithme d'Ishibuchi *et al.* se résume essentiellement à la partie fuzzification et à la partie ajustement du modèle. Dans le chapitre 4, nous avons montré l'importance de la partie fuzzification sur les taux de reconnaissance. Elle n'est donc pas reprise dans cette annexe. Nous nous intéressons uniquement aux paramètres (constantes d'apprentissage, nombre d'itérations, seuil de classification) dont les réglages peuvent avoir une influence sur l'ajustement des règles et le taux de reconnaissance.

Afin de choisir les valeurs de constantes d'apprentissage, nous avons évalué le taux de reconnaissance en généralisation pour différentes valeurs de constantes en fixant le nombre d'itérations et le seuil de classification. Afin de valider ce choix, nous avons réalisé ce test sur deux bases de données différentes afin de valider les valeurs.

Nous avons utilisé comme critères d'arrêt le seuil de classification à 92% et le nombre d'itérations à 2000.

Les figures B.3 et B.4 illustrent les taux de reconnaissance obtenus pour différentes valeurs des constantes d'apprentissage  $\eta_1$  et  $\eta_2$ . Nous avons évalué ces taux pour des valeurs de  $\eta_1$  et  $\eta_2$  comprises entre  $10^{-5}$  et 1.

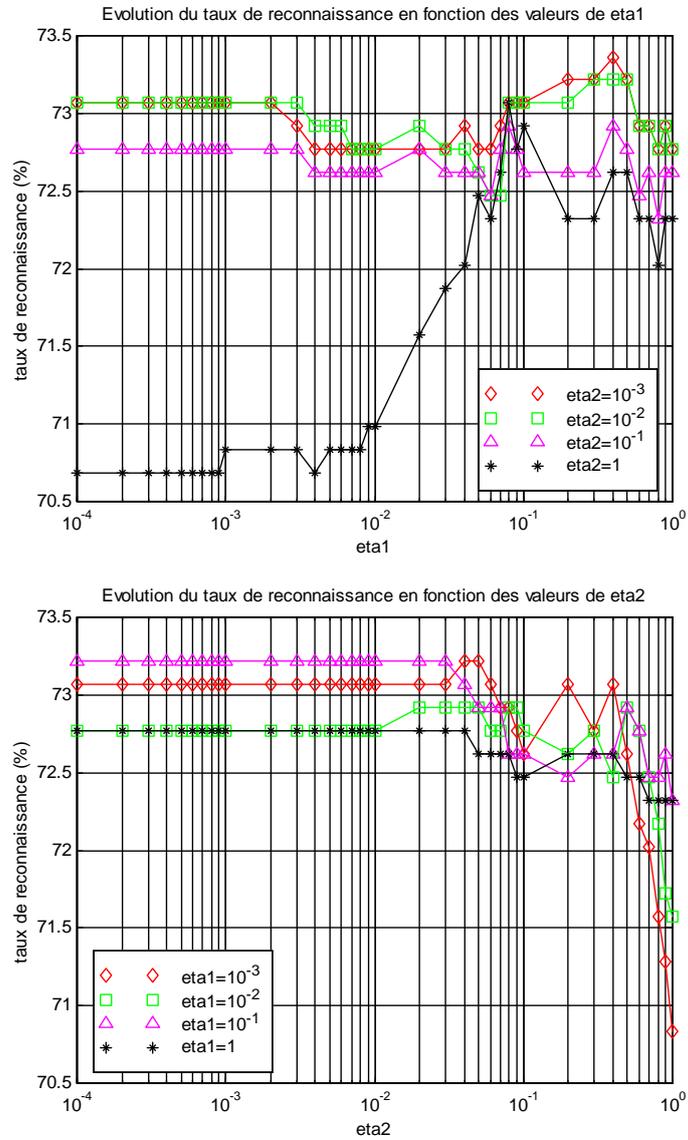


Figure B.3 : Evolution des taux de reconnaissance en généralisation en fonction des valeurs des constantes d'apprentissage  $\eta_1$  et  $\eta_2$  - Base\_Couleur\_1

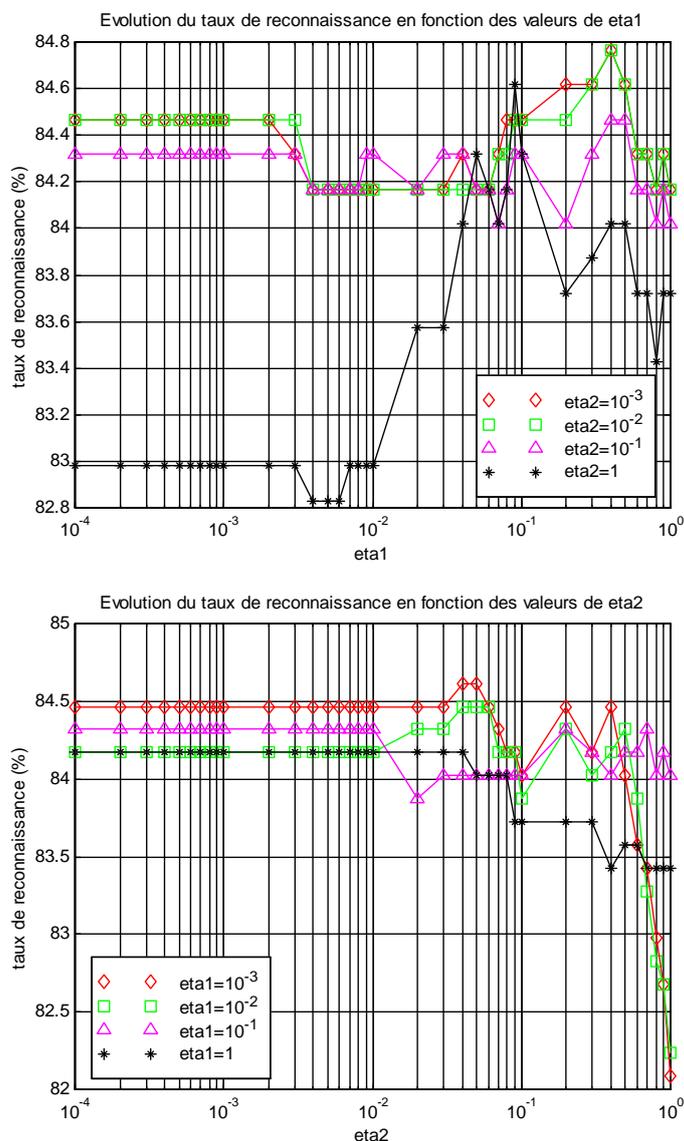


Figure B.4 : Evolution des taux de reconnaissance en généralisation en fonction des valeurs des constantes d'apprentissage  $\eta_1$  et  $\eta_2$  - Base\_Couleur\_2

Après avoir analysé l'ensemble des résultats obtenus, nous avons pu déterminer les valeurs optimales des constantes d'apprentissage. En effet, les taux de reconnaissance en généralisation sont maximaux pour  $\eta_1 = 0.4$  et  $\eta_2 \leq 0.004$ . Sur l'ensemble de ces tests, nous avons également pu constater que le nombre d'itérations utiles pour faire converger le taux de reconnaissance vers le seuil de classification est d'environ 100.

Afin d'évaluer le dernier paramètres pouvant avoir une influence sur les modèles générés, à savoir le seuil de classification, nous avons fixé les trois précédents paramètres aux valeurs suivantes :  $\eta_1 = 0.4$ ,  $\eta_2 = 0.004$  et nombre d'itérations = 500. L'espace de variation du seuil de classification étudié correspond aux taux de reconnaissance en apprentissage supérieurs à 80%. Les figures B.5 et B.6 représentent l'évolution du taux de reconnaissance en généralisation sur les bases de données Base\_Couleur\_1 et Base\_Couleur\_2 en fonction du seuil de classification.

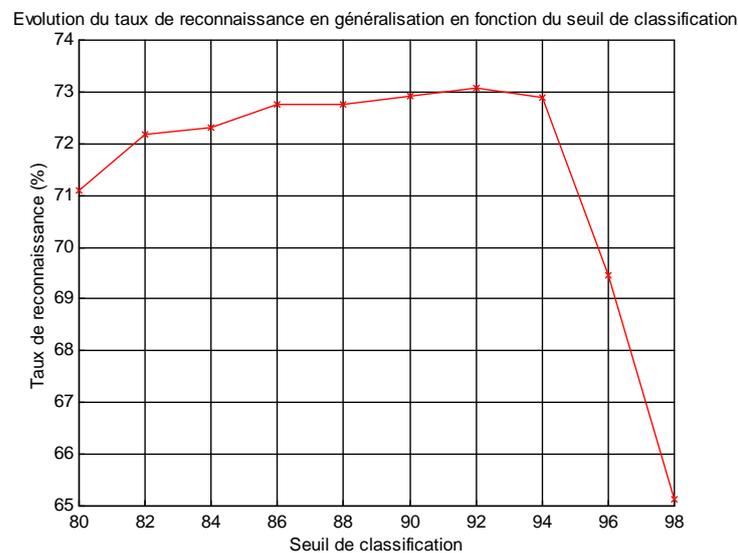


Figure B.5 : Evolution du taux de reconnaissance en généralisation en fonction du seuil de classification - Base\_Couleur\_1

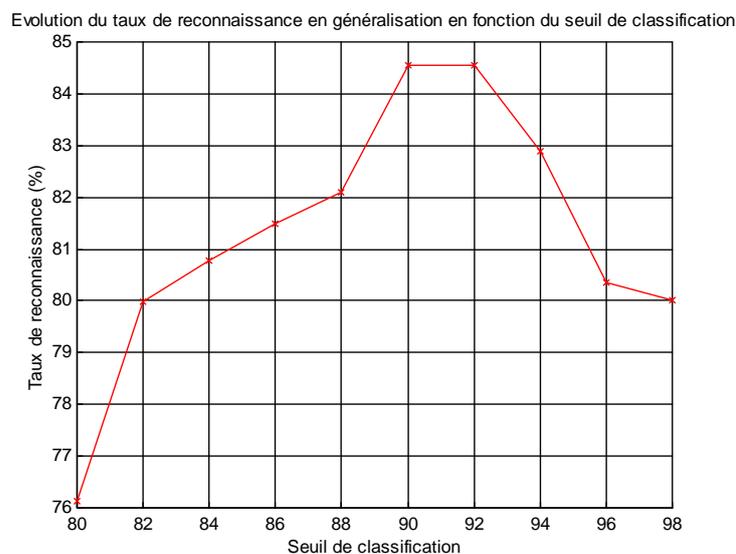


Figure B.6 : Evolution du taux de reconnaissance en généralisation en fonction du seuil de classification - Base\_Couleur\_2

Au vu des résultats présentés sur les figures B.5 et B.6, nous avons décidé de fixer le seuil de classification à 92%. En effet, si nous augmentons ce seuil, le taux de reconnaissance en généralisation diminue. Ceci s'explique simplement par la spécification du modèle face aux données d'apprentissage. Le modèle généré n'est donc pas assez généralisable du problème visé. C'est un modèle appris par cœur.

Le paramétrage du classificateur FRC est donc le suivant pour l'ensemble de ce mémoire :

$$\eta_1 = 0.4, \eta_2 = 0.004, \text{ nombre d'itérations} = 500, \text{ seuil de classification} = 92\%.$$



## **REFERENCES BIBLIOGRAPHIQUES**

---

## Références bibliographiques

- [ACQU-02] D'ACQUILA, R.O., C. CRESPO, J.L. MATE, et J. PAZOS, « An inference engine based on fuzzy logic for uncertain and imprecise expert reasoning. », *Fuzzy Sets and Systems*, Vol. 129, pp. 187-202, 2002.
- [ALBU-91] ALBUS, J.S., « Outline for a theory of intelligence », *IEEE Trans. On SMC*, Vol. 21, pp. 473-509, 1991.
- [ALCA-07] ALCALA, R., J. ALCALA-FDEZ, F. HERRERA, et J. OTERO, « Genetic learning of accurate and compact fuzzy rule based systems based on the 2-tuples linguistic representation. », *International Journal of Approximate Reasoning*, Vol. 44, pp. 45-64, 2007.
- [ALLE-99] ALLEYSON, D., « Le traitement du signal chromatique dans la rétine : un modèle de base pour la perception humaine des couleurs », Thèse de doctorat, Université Joseph Fournier, Grenoble, France, 1999.
- [ANDR-99] ANDREADIS, I., « Modelling and evaluating colour information for robot vision. », *Mechatronics*, Vol. 9, pp. 429-446, 1999.
- [ANTO-04] ANTONELLI, A., M. COCCHI, P. FAVA, G. FOCA, G.C. FRANCHINI, D. MANZINI, et A. ULRICI, « Automated evaluation of food colour by means of multivariate image analysis coupled to a wavelet-based classification algorithm », *Analytica Chimica Acta*, Vol. 515, No. 1, pp. 3-13, 2004.
- [ARIV-03] ARIVAZHAGAN, S., et L. GANESAN, « Texture classification using wavelet transform. », *Pattern Recognition Letters*, Vol. 24, pp. 1513-1521, 2003.
- [BARN-02] BARNARD, K., V. CARDEI, et B. FUNT, « A comparison of Computational Color Constancy Algorithms – Part I: Methodology and Experiments With Synthesized Data. », *IEEE Transactions on Image Processing*, Vol. 11, No. 9, pp. 972-983, 2002.
- [BENB-05] BENBOUDJEMA, D., et W. PIECZYNSKI, « Segmentation non supervisée d'images non stationnaires avec champs de Markov évidentiels », 20ème colloque GRETSI, Louvain-la-Neuve, Belgique, 2005.

- 
- [BENO-91] BENOIT, E., et L. FOULLOY, « Symbolic sensors: one solution to the numerical-symbolic interface », Proc. Of the IMAVS DSS&QR workshop, Toulouse, France, pp. 321-326, 1991.
- [BENO-01] BENOIT, E., et L. FOULLOY, « High functionalities for intelligent sensors, application to fuzzy colour sensor », Measurement, Vol. 30, pp. 161-170, 2001.
- [BERT-03] BERTHOLD, M.R., « Mixed fuzzy rule formation. », Fuzzy Sets and Systems, Vol. 32, pp. 67-84, 2003.
- [BHAR-04] BHARATI, M.H., J.J. LIU, et J.F. MACGREGOR, « Image texture analysis: methods and comparisons. », Chemometrics and Intelligent laboratory systems, Vol. 72, pp. 413-428, 1990.
- [BLOC-96] BLOCH, I., « Information Combination Operators for Data Fusion: A comparative Review with classification. », IEEE Transaction On Systems, Man. And Cybernetics – Part A: Systems and Human, Vol. 26, pp. 1341-1387, 1996.
- [BOMB-07a] BOMBARDIER, V., C. MAZAUD, P. LHOSTE, et R. VOGRIG, « Contribution of fuzzy reasoning method to knowledge integration in a defect recognition system », Computers in Industry, Vol. 58, pp. 355-366, 2007.
- [BOMB-07a] BOMBARDIER, V., et O. NATZ, « Robot – Vision au Pôle AIP-Priméca Lorraine », *Journées thématiques : de la macro vers la micromanipulation*, Besançon, France, 2007.
- [BOUC-95] BOUCHON-MEUNIER, B., « La logique floue et ses applications. », Edition Addison-Wesley, France, 257 pages, 1995.
- [BOUC-98] BOUCHON-MEUNIER, B., « Aggregation and Fusion of Imperfect Information. », Physica-Verlag, New York, 278 pages, 1998.
- [BROC-02] BROCHARD, J., et M. KHOUDEIR, « Histogram Characterization of Colored Textures Using One-Dimensional Moments and Chromaticity Diagram », IAPR International Conference on Vision Interface, Calgary, Canada, 2002.
- [BRUN-90] BRUNNER, C.C., G.B. SHAW, D.A. BUTLER, et J.W. FUNCK, « Using color in machine vision systems for wood processing. », Wood and Fiber Science, Vol. 22, No. 4, pp. 57-71, 2004.
- [BURD-84] BURD, N.C., et A.P. DOREY, « Intelligence transducers », Journal of Microcomputers Applications, Vol. 7, pp. 87-97, 1984.
- [CADI-04] CADIK, M., « Human Perception and Computer Graphics », Postgraduate Study Report, Czech Technical University, Prague, République tchèque, 2004.
- [CARV-07] DE CARVALHO, F.A.T., « Fuzzy c-means clustering methods for symbolic interval data. », Pattern Recognition Letters, Vol. 28, pp. 423-437, 2007.
- [CIAM-87] CIAME AFCET, « Livre blanc : Les capteurs intelligents – réflexions des utilisateurs », 169 pages, 1987.
-

- [CIE-74] CIE Colorimetry Committee, Journal of the Optical Society of America, Vol. 64, 1974.
- [CHAM-92] CHAMBEROD, E., et C. POUPOT, « Intelligence locale et processeur de signal », Capteurs intelligents et microactionneurs intégrés, LASSS-CNRS, Cépaduès Editions, 1992.
- [CHO-91] CHO, T.H., R.W. CONNERS, et P.A. ARAMAN, « A comparison of rule-based, K-nearest neighbour and neural net classifiers for automated industrial inspection », Proc. Of the IEEE/ACM International Conference on Developing and Managing Expert Systems Programs, Washington, Etats-Unis, pp. 202-209, 1991.
- [CLAR-04] CLARYSSE, P., F. FROUIN, M. GARREAU, A. LALANDE, J. ROUSSEAU, D. SARRUT, and C. VASSEUR, « Intégration de connaissances et modélisation en imagerie médicale », ITBN-RBM, Vol. 25, pp. 139-149, 2004.
- [COCQ-95] COCQUEREZ, J.P., et S. PHILIPP, « Analyse d'images : filtrage et segmentation », Edition Masson, Paris, 1995.
- [CONN-92] CONNERS, R.W., T.C. CHO, C.T. NG, et T.H. DRAYER, « A machine vision system for automatically grading hardwood lumber », Industrial Metrology, Vol. 2, pp. 317-342, 1992.
- [CORD-99] CORDON, O., M.J. DEL JESUS, et F. HERRERA, « A proposal on reasoning methods in fuzzy rule-based classification systems. », International Journal Of Approximate Reasoning, Vol. 20, pp. 21-45, 1999.
- [CORD-01] CORDON, O., F. HERRERA, et P. VILLAR, « Generating the knowledge base of a fuzzy rule-based system by the genetic learning of the data base. », IEEE Transaction of Fuzzy Systems, Vol. 9, No. 4, pp. 667-674, 2001.
- [CORD-04] CORDON, O., F. GOMIDE, F. HERRERA, F. HOFFMANN, et L. MAGDALENA, « Ten years of genetic fuzzy systems: current framework and new trends », Fuzzy Sets and Systems, Vol. 141, pp. 5-31, 2004.
- [DAI-96] DAI, M., P. BALYOU, L. HUMBERT, et M. NAJIM, « Image segmentation by a dynamic thresholding using edge detection based on cascaded uniform filters », Signal Processing, Vol. 52, pp. 49-63, 1996.
- [DAUL-00] DAUL, C., R. ROSCH, et B. CLAUS, « Building a color classification system for textured and hue homogeneous surfaces : system calibration and algorithm », Machine Vision and Applications, Vol. 12, pp. 137-148, 2000.
- [DERU-97] DERUYVER, A., et Y. HODE, « Constraint satisfaction problem with bilevel constraint: application to interpretation of over-segmented images », Artificial intelligence, Vol. 93, pp. 321-335, 1997.
- [DUBO-96a] DUBOIS, D., et H. PRADE, « What are fuzzy rules and how to use them. », Fuzzy Sets and Systems, Vol. 84, pp. 169-185, 1996.

- 
- [DUBO-96b] DUBOIS, D., H. PRADE, et R.R. YAGER, « A Manifesto: Fuzzy Information Engineering. », dans *Fuzzy Information Engineering: A Guided Tour of Applications (Hardcover)*, Wiley Publishers, 712 pages, 1996.
- [DUBO-97a] DUBOIS, D., et H. PRADE, « The three semantics of fuzzy sets », *Fuzzy Sets and Systems*, Vol. 90, pp. 141-150, 1997.
- [DUBO-97b] DUBOIS, D., H. PRADE, et R.R. YAGER., « A manifesto fuzzy information engineering », in the book *Information Engineering*, 1997.
- [DUBO-04] DUBOIS, D., et H. PRADE, « On the use of aggregation operations in information fusion processes. », *Fuzzy Sets and Systems*, Vol. 142, pp. 143-161, 2004.
- [DUBU-90] DUBUISSON, B., « Diagnostic et reconnaissance de formes », Edition Hermès, 1990.
- [DUDA-73] DUDA, R.O., et P.E. HART, « Pattern Classification and Scene Analysis. », John Wiley & Sons, New York, 482 pages, 1973.
- [ESHE-91] ESHELMAN, L., « The chc adaptative search algorithm: how to have safe search when engaging in non-traditional genetic recombination. », dans *Foundations of Genetic Algorithms*, Vol. 1, Ed. G. Rawlin, pp. 265-283, 1991.
- [ESTE-03] ESTEVEZ, P.A., C.A. PEREZ, et E. GOLES, « Genetic input selection to a neural classifier for defect classification of radiata pine boards », *Forest Products Journal*, Vol. 53, No. 7, pp. 87-94, 2003.
- [FABI-96] FABIANI, P, « Stratégie de prise d'information pour un système autonome muni de capteurs. », Thèse de doctorat, ENSEA, Toulouse, France, 1996.
- [FAGI-99] FAGIN, R., « Combining Fuzzy Information from Multiple Systems. », *Journal of Computer and System Sciences*, Vol. 58, pp. 83-99, 1999.
- [FAUG-76] FAUGERAS, O.D., « Digital color image processing and psychophysics within the framework of a human visual model », PH. D. Dissertation, University of Utah, Etats-Unis, 1976.
- [FINK-75] FINKELSTEIN, L., « Representation by symbol systems as an extension of the concept of measurement », *Kybernetes*, Vol. 4, pp. 215-223, 1975.
- [FORE-06] FOREST, J., M. RIFQI, et B. BOUCHON-MEUNIER, « Segmentation de classes pour l'amélioration de la construction de prototypes flous : visualisation et caractérisation de classes non homogènes. », *Actes des Rencontres Francophones sur la Logique Floue et ses Applications (LFA 2006)*, Toulouse, pp. 29-36, 2006.
- [FUNC-03] FUNCK, J.W., Y. ZHONG, D.A. BUTLER, C.C. BRUNNER, et J.B. FORRER, « Image segmentation algorithms applied to wood defect detection », *Computers and electronics in agriculture*, Vol. 41, pp. 157-179, 2003.
-

- [GDR-01] GDR PRC ISIS, « Rapport d'activité 2000-2001 du GDR-PRC ISIS », Section 3.3.5, p. 41, 2001.
- [GERS-84] GERSHON, R., « Survey on color: Aspect of perception and computation », Technical Report, University of Toronto, Canada, 1984.
- [GEVE-99] GEVERS, T., et A.W.M. SMEULDERS, « Color-based object recognition », *O Pattern Recognition*, Vol. 32, pp. 453-464, 1999.
- [GONZ-02] GONZALEZ, R.C., et R.E. WOODS, « Digital Image Processing – 2nd Edition », Prentice Hall, 793 pages, 2002.
- [GRAB-96] GRRABISH, M., et F. HUET, « Texture recognition by Choquet integral filters. », 6th Int. Conf. On Information Processing and Management of Uncertainty in Knowledge-Based Systems (IMPU), pp. 1325-1330, Grenade, Espagne, 1996.
- [GRAN-02] GRANDVALET, Y., et S. CANU, « Adaptative Scaling for Feature Selection in SVMs », *Neural Information Processing System*, 2002.
- [GRÖL-95] GRÖLUND, U., « Quality improvements in forest products industry », Rapport interne, Lulea University of Technology, Suède, 1995.
- [HANB-01] HANBURY, A., et F. GARDEUX, « A quantitative description of wood texture », *Proc. Of the International Conference on Quality Control by Artificial Vision*, Cépaduès-Éditions, pp. 200-205, 2001.
- [HANB-02] HANBURY, A., « Morphologie Mathématique sur le Cercle Unité avec applications aux teintes et aux textures orientées », Thèse de doctorat, Ecole Nationale Supérieure des Mines de Paris, Fontainebleau, 2002.
- [HAUT-99] HAUTA-KASARI, M., J. PARKKINEN, T. JAASKELAINEN, et R. LENZ, « Multi-spectral Texture Segmentation Based on the Spectral Cooccurrence Matrix. », *Pattern Analysis and Applications*, Vol. 2, pp. 275-284, 1999.
- [HEAL-92] HEALEY, G.E., S.A. SHAFER, et L.B. WOLFF, « Color, physics-based vision, principles and practice », Jones and Bartlett Publishers, 1992.
- [HUDE-06] HUDELOT, C., J. ATIF, et I. BLOCH, « Ontologie de relations spatiales floues pour l'interprétation d'images. », *Rencontres Francophones sur la Logique Floue et ses Applications – LFA 2006*, Toulouse, France, pp.363-370, 2006.
- [ISHI-92] ISHIBUCHI, H., K. NOZAKI, et H. TANAKA, « Distributed representation of fuzzy rules and its application to pattern classification. », *Fuzzy Sets and Systems*, Vol. 52, pp. 21-32, 1992.
- [ISHI-94] ISHIBUCHI, H., K. NOZAKI, N. YAMAMOTO et H. TANAKA, « Construction of fuzzy classification systems with rectangular fuzzy rules

- 
- using genetic algorithms. », *Fuzzy Sets and Systems*, Vol. 65, pp. 237-253, 1994.
- [ISHI-03] ISHIBUCHI, H., et T. YAMAMOTO, « Effects of three-objective genetic rule selection on the generalization ability of fuzzy rule-based systems. », *Second International Conference on Evolutionary Multi-Criterion Optimization – EMO'03*, Faro, Portugal, pp.608-622, 2003.
- [ISHI-05] ISHIKAWA-NAGAI, S., K. ISHIBASHI, O. TSURATA, et H.P. WEBER, « Reproducibility of tooth color gradation using a computer color-matching technique applied to ceramic restorations », *The Journal of Prosthetic Dentistry*, Vol. 93, No. 2, pp. 129-137, 2005.
- [JOLI-92] JOLION, J.M., et A. MINTANVERT, « The adaptative pyramid: a framework for 2D image analysis », *Computer Vision Graphics Image Processing*, Vol. 55, No. 3, pp. 339-348, 1992.
- [KABI-00] KABIR, M.F., D.L. SCHMOLDT, et M.E. SCHAFER, « Detection of defects in red oak deskboards by ultrasonic scanning », *Proc. Of IPSW 2000 the 4th International Conference on Image processing and Scanning of Wood*, Mountain Lake, Etats-Unis, pp 89-96, 2000.
- [KAUP-99] KAUPPINEN, H., H. RAUTIO, et O. SILVEN, « Non-segmenting defect detection and SOM based classification for surface inspection using color vision », *Conference on Polarization and Color Techniques in Industrial Inspection*, SPIE 3826, Munich, Allemagne, pp. 270-280, 1999.
- [KELL-96] KELLER, J.M., R. KRISHNAPURAM, P.D. GADER, et Y.S. CHOI, « Fuzzy Reul-Based Models in Computer Vision. », dans *Fuzzy Modelling : Paradigms and Practice*, Kluwer Academic Publishers, Dordrecht, pp. 353-371, 1996.
- [KELL-97] KELLER, J.M., « Fuzzy set theory in computer vision: A prospectus. », *Fuzzy Sets and Systems*, Vol. 90, pp. 177-182, 1997.
- [KEMP-06] KEMPOWSKY, T., A. SUBIAS, et J. AGUILAR-MARTI, « Process situation assessment: From a fuzzy partition to a finite state machine. », *Engineering Applications of Artificial Intelligence*, Vol. 19, pp. 461-477, 2006.
- [KIM-94] KIM, C.W., et A.J. KOIVO, « Hierarchical classification of surface defects on dusty wood boards », *Pattern Recognition letters*, Vol. 15, pp. 713-721, 1994.
- [KLEY-05] KLEYNEN, O., V. LEEMANS, et M.F. DESTAIN, « Development of a multi-spectral vision system for the detection of defects on apples », *Journal of Food Engineering*, Vol. 69, pp. 41-49, 2005.
- [KLIN-99] KLINE, D.E., R.W. CONNERS, et P.A. ARAMAN, « Technology to Sort Lumber by Color and Grain for Furniture Parts », *Quality Lumber Drying in the Pacific Northwest*, Seattle, Etats-Unis, pp. 67-73, 1999.
-

- [KLIN-03] KLINE, D.E., C. SURAK, et P.A. ARAMAN, « Automated hardwood lumber grading a multiple sensor machine vision technology », *Computers and electronic in agriculture*, Vol. 41, pp. 139-155, 2003.
- [KLUM-94] KLUMPERS, J., « Le déterminisme de la couleur du Bois de Chêne. Etude sur les relations entre la couleur et les propriétés physiques, chimiques et anatomiques ainsi que des caractéristiques de croissance », Thèse de doctorat, Ecole du Génie Rural, des Eaux et des forêts, Nancy, France, 1994.
- [KOLB-00] KOLB, H., E. FERNANDEZ, et R. NELSON, « Webvision – the organization of the vertebrate retina », <http://webvision.med.utah.edu/> , 2000.
- [KUC-86] KUC, R., et Y.D. DI, « Intelligent sensor approach to differentiating sonar reflection from corners and planes », *Proc. Of Intelligent Autonomous Systems*, Amsterdam, pp.329-333, 1986.
- [LATI-00] LATIF-AMET, A., A. ERTÜZÜN, et A. ERCIL, « An efficient method for texture defect detection: sub-band domain co-occurrence matrices. », *Image and Vision Computing*, Vol. 18, pp. 543-553, 2000.
- [LEE-05a] LEE, Y.-K., « Comparison of CIELAB DE\* and CIEDE2000 color-differences after polymerization and thermocycling of resin composites », *Dental Materials*, Vol. 21, pp. 678-682, 2005.
- [LEE-05b] LEE, P.S. et A.L. DEXTER, « A fuzzy sensor for measuring the mixed air temperature in air-handling units », *Measurement*, Vol. 37, pp. 83-93, 2005.
- [LEMO-90] LE MOIGNE, J.L., « Modelisation of Complex Systems », AFCET Systèmes, Ed. Dunod, Paris, France, 1990.
- [LEVI-85] LEVINE, M.D., « Vision in Man and Machine », Ed. McGraw Hill Series in Electrical and Computer Engineering, New-York, 574 pages, 1985.
- [LIU-02] LIU, J., et T. FURUNO, « The fractal estimation of wood color variation by the triangular prism surface area method », *Wood Science and Technology*, Springer-Verlag, Vol. 36, pp. 385-397, 2002.
- [LU-97a] LU, Q., S. SRIKANTERSWARA, W. KING, T. DRAYER, R. CONNERS, E. KLINE, et P. ARAMAN, « Machine Vision System for Color Sorting Wood Edge-Glued Panel Parts », *Proc. If 23rd International Conference on Industrial Electronics, Control and Instrumentation*, Vol. 3, pp. 1460-1464, 1997.
- [LU-97b] LU, Q., « A Real-Time System for Color Sorting Edge-Glued Panel Parts », Thesis of the Virginia Polytechnic Institute and State University, Blacksburg, Virginia, 1997.
- [LUZE-91] LUZEAUX, D., « Normalizing symbolic reasoning », *Proc. Of the IMAVS DSS&QR workshop*, Toulouse, France, pp. 321-326, 1991.

- 
- [MAEN-03] MAENPAA, T., J. VIERTOLA, et M. PIETIKAINEN, « Optimising Colour and Texture Features for Real-time Visual Inspection », *Pattern Analysis Applications*, Vol. 6, pp. 169-175, 2003.
- [MAEN-04] MAENPAA, T., et M. PIETIKAINEN, « Classification with color and texture: jointly or separately ? », *Pattern recognition*, Vol. 37, pp. 1629-1640, 2004.
- [MALA-03] MALAMAS, E.N., E.G.M. PETRAKIS, M. ZERVAKIS, L. PETIT, et J.A. LEGAT, « A survey on industrial vision systems, applications and tools », *Image and Vision Computing*, Vol. 21, pp. 171-188, 2003.
- [MALO-86] MALONEY, L.T., et B.A. WANDELL, « Color constancy: a method for recovering surface spectral reflectance. », *Journal of the Optical Society of America A*, Vol. 3, No. 1, pp. 29-33, 1986.
- [MARR-76] MARR, D., « Early processing of visual information », *Philosophical Transaction Royal Society of London*, Vol. 275, pp. 483-519, 1976.
- [MARS-96] MARSZALEC, E., et M. PIETIKAINEN, « Some aspects of RGB vision and its applications to industry. », *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 10, pp. 55-72, 1996.
- [MAUR-92] MAURIS, G., « Capteurs ultrasonores intelligents : Application à la représentation symbolique de mesure de distance par codage flou », Thèse de doctorat, Université de Savoie, 1992.
- [MAUR-98] MAURIS, G., E. BENOIT, et L. FOULLOY, « Fuzzy Linguistic Methods for the Aggregation of Complementary Sensor Information. », dans *Aggregation and Fusion of Imperfect Information*, Physica-Verlag, New York, pp. 214-230, 1998.
- [MAZA-07] MAZAUD, C., J. RENDEK, V. BOMBARDIER, et L. WENDLING, « A feature selection method based on Choquet integral and Typicality analysis. », *Proc of the 16th International Conference on Fuzzy Systems (FUZZIEEE'07)*, Londres, Angleterre, 2007.
- [MEHL-04] MEHL, P.M., Y.R.CHEN, M.S. KIM, et D.E. CHAN, « Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations », *Journal of Food Engineering*, Vol. 61, pp. 67-81, 2004.
- [MILG-93] MILGRAM, M., « Reconnaissance des formes : Méthodes numériques et connexionnistes », Société des Nouvelles Editions Liégeoises, Armand Colin Editeurs, 1993.
- [MING-06] MINGOTI, S.A., et J.O. LIMA, « Comparing SOM neural network with Fuzzy c-means, K-means and traditional hierarchical clustering algorithms », *European Journal of Operational Research*, Vol. 174, pp. 1742-1759, 2006.
- [MOSL-67] MOSLEMI, A.A., « Quantitative Color Measurement for Black Walnut Wood », *Southern Forest Experiment Station Library*, 17 pages, 1967.
-

- [NAKO-95] NAKOULA, Y., S. GALICHET, et L. FOULLOY, « Learning of a fuzzy symbolic rule base », Proc. Of 3rd European Congress on Intelligent Techniques and Soft Computing, Aachen, Allemagne, 1995.
- [NCS] Natural Color System, URL: <http://www.nscolor.com>.
- [NEWM-95] NEWMAN, T.S., and A.K. JAIN, « A Survey of Automated Visual Inspection », Computer Vision and Image Understanding, Vol. 61, No. 2, pp. 231-262, 1995.
- [NIJS-89] NIJSSEN, G.M. et T.A. HALPIN, « Conceptual schema and relational database design: a fact oriented approach. », Prentice Hall, France, 356 pages, 1989.
- [NOZA-97] NOZAKI, K., H. ISHIBUCHI, et H. TANAKA, « A simple but powerful heuristic method for generating fuzzy rules from numerical data. », Fuzzy Sets and Systems, Vol. 86, pp. 251-270, 1997.
- [OH-03] OH, S.K., W. PEDRYCZ, et H.S. PARK, « Hybrid identification in fuzzy neural-networks. », Fuzzy Sets and Systems, Vol. 138, pp. 399-426, 2003.
- [PALM-02] PALMER, S.E., « Vision science – photons to phenomenology », The MIT Press, Cambridge, 3rd Edition, 2002.
- [PERE-00] PEREZ ORAMAS, O., « Contribution à une méthodologie d'intégration de connaissances pour le traitement d'images. Application à la détection de contours par règles linguistiques floues », Thèse de doctorat, Université Henri Poincaré, Nancy, 2000.
- [PHAM-01] PHAM, D.T., et S. SAGIROGLU, « Training multilayered perceptrons for pattern recognition: a comparative study of four training algorithms », International Journal of Machine Tools & Manufacture, Vol. 41, pp. 419-430, 2001.
- [PIET-96] PIETIKAINEN, M.K., S. NIEMINEN, E. MARSZALEC, et T. OJALA, « Accurate color discrimination with classification based on feature distributions », 13th International Conference for Pattern Recognition, Vienne, Autriche, pp.883-836, 1996.
- [POIN-81] POINTER, M.R., « A comparison of the CIE 1976 colour spaces. », COLOR Research and Application, Vol. 6, No. 2, pp. 108-118, 1981.
- [POYN-97] POYNTON, C., « Frequently Asked Questions about Color », URL : <http://www.poynton.com/ColorFAQ.html>, 1997.
- [PUDI-02] PUDIL, P., J. NOVOVICOVA, et P. SOMOL, « Feature Selection Toolbox software package. », Pattern Recognition Letters, Vol. 23, pp. 487-492, 2002.
- [ROSE-01] ROSENFELD, A., « From Image Analysis to Computer Vision: An Annotated Bibliography, 1955-1979 », Computer Vision and Image Understanding, Vol. 84, pp. 298-324, 2001.

- 
- [RUZ-05] RUZ, G.A., P.A. ESTEVEZ, et C.A. PEREZ, « A neurofuzzy color image segmentation method for wood surface defect detection », *Forest Products Journal*, Vol. 55, No. 4, pp. 52-58, 2005.
- [SALA-99] SALARI, E., et W. LI, « A fast quadtree motion segmentation for image sequence coding », *Signal Processing: Image Communication*, Vol. 14, pp. 811-816, 1999.
- [SANG-98] SANGWINE, S.J., et R.E.N. HORNE, « The colour image Handbook », Ed. Chapman and Hall, 1998.
- [SATH-01] SATHYANATH, S., et F. SAHIN, « An AIS approach to a color image classification problem in a realtime industrial application », *International Conference on Systems, Man and Cybernetics*, Vol. 4, No. 4, pp. 2285-2290, 2001.
- [SCHM-04a] SCHMITT E., C. MAZAUD, V. BOMBARDIER, P. LHOSTE, P. CHARPENTIER, et R. VOGRIG, « Fuzzy linguistic rules identification system for wood quality », *AISTA 2004 International Conference in Advances in Intelligent Systems – Theory and Applications*, Luxembourg, 2004.
- [SCHM-04b] SCHMITT E., V. BOMBARDIER, P. CHARPENTIER, et VOGRIG R., « Classificateur flou pour l'appariement couleur de pièces de bois », *LFA'04 : 12ème rencontre francophone sur la Logique Floue et ses Applications*, Nantes, France, pp. 165-172, 2004.
- [SCHM-05a] SCHMITT E., V. BOMBARDIER, et P. CHARPENTIER, « Appariement couleur de pièces de bois », *20ème colloque GRETSI sur le traitement du signal et des images*, Louvain-la-neuve, Belgique, pp. 695-698, 2005.
- [SCHM-05b] SCHMITT E., V. BOMBARDIER, et R. VOGRIG, « Fuzzy Linguistic Rules Classifier for wooden board color sorting », *7th International Conference on Advanced Concept for Intelligent Vision Systems - ACIVS 2005*, Antwerp, Belgique, 2005.
- [SCHM-06a] SCHMITT E., C. MAZAUD, V. BOMBARDIER, et P. LHOSTE, « A Fuzzy Reasoning Classification Method for Pattern Recognition », *15th International Conference on Fuzzy Systems, FUZZIEEE'06*, Vancouver, Canada, pp. 5998-6005, 2006.
- [SCHM-06b] SCHMITT E., V. BOMBARDIER, P. CHARPENTIER, et R. VOGRIG, « An appearance fuzzy sensor integrating a knowledge model », *12th IFAC Symposium on Information Control Problems in Manufacturing, INCOM'2006*, Saint-Etienne, France, Vol. 4, pp. 111-116, 2006.
- [SCHM-07a] SCHMITT E., V. BOMBARDIER, et P. CHARPENTIER, « Self-fuzzification Method according to Typicality Correlation for Classification on tiny Data Sets », *16th International Conference on Fuzzy Systems, FUZZIEEE'07*, Londres, Royaume-Uni, 2007.
-

- [SCHM-07b] SCHMITT E., V. BOMBARDIER, et P. CHARPENTIER, « Méthode d'auto-fuzzification par analyse des typicalités sur des lots de données réduits », *21ème colloque GRETSI sur le traitement du signal et des images*, Troyes, France, 2007.
- [SCHM-95] SCHMOLDT, D.L., « Neural networks classifiers to grade parts based on surface defects with spatial dependencies », *Review of Progress in Quantitative Nondestructive Evaluation*, Vol. 14, Edition D.O. Thompson and D.E. Chimenti, Plenum Press, New York, pp. 795-802, 1995.
- [SHAF-76] SHAFER, G., « A Mathematical Theory of Evidence. », Princeton University Press, Princeton, 312 pages, 1976.
- [SHIH-95] SHIH, T.-Y., « The reversibility of six geometric color spaces. », *Photogrammetric Engineering and Remote Sensing*, Vol. 61, No. 10, pp. 1223-1232, 1995.
- [SILB-45] SILBERSTEIN, L., et D.L. MACADAM, « The distribution of color matching around a color center », *Journal of Optical Society of America*, Vol. 25, No. 1, pp. 32-39, 1945.
- [SIVI-94] SIVIK, L., et C. TAFT, « Color naming – a mapping in the NCS of common color terms. », *Scandinavian Journal of Psychology*, Vol. 35, No. 2, pp. 144-164, 1994.
- [SPRO-01a] SPROULL, R.C., « Color matching in dentistry. Part I. The three-dimensional nature of color », *The Journal of Prosthetic Dentistry*, Vol. 86, No. 5, pp. 453-457, 2001.
- [SPRO-01b] SPROULL, R.C., « Color matching in dentistry. Part II. Practical applications of the organization of color », *The Journal of Prosthetic Dentistry*, Vol. 86, No. 5, pp. 458-464, 2001.
- [SRIK-97] SRIKANTESWARA, S., Q. LU, W. KING, T. DRAYER, R. CONNERS, E. KLINE, et P. ARAMAN, « Real-time implementation of a color sorting system », *Proc. Of SPIE Machine Vision Applications, Architectures and Systems Integration*, Pittsburgh, Etats-Unis, Vol. 3205, pp. 170-179, 1997.
- [SUGE-85] SUGENO, M., « An introductory survey of fuzzy control », *Information Sciences*, Vol. 36, pp. 59-83, 1985.
- [SVM] SVM and Kernel Methods Matlab Toolbox, Insa de Rouen, URL : <http://asi.insa-rouen.fr/~arakotom/toolbox/index.html>.
- [SWAI-91] SWAIN, M.J., et D.H. BALLARD, « Color indexing », *Int. Journal Computer Vision*, Vol. 7, No. 1, pp. 11-32, 1991.
- [TAKA-94] TAKAHASHI, K., et S. NOZAKI, « From intelligent sensors to fuzzy sensors », *Sensors and Actuators*, Vol. 40, No. 2, pp. 89-91, 1994.

- 
- [TAN-93] TAN, T.S.C., et J. KITTLER, « Colour texture classification using features from colour histograms », 8th Scandinavian Conference on Image Analysis, Norvège, pp. 807-813, 1993.
- [TSEK-03] TSEKOURAS, G., H. SARIMVEIS, et G. BAFAS, « A simple algorithm for training fuzzy systems using input-output. », *Advances in Engineering Software*, Vol. 34, pp. 247-259, 2003.
- [TURC-00] TURCOTTE, M., « Méthode basée sur la texture pour l'étiquetage des images », Rapport d'obtention du grade Maître ès Sciences, Université de Sherbrooke, Québec, Canada, 2000.
- [UCI] UCI Repository Of Machine Learning Databases and Domain Theories, ftp anonyme, URL: <http://ftp.ics.uci.edu/pub/machine-learning-databases/>.
- [UGHE-98] UGHETTO, L., « Les systèmes à base de règles floues. Vérification de la cohérence et méthodes d'inférence. », Thèse de doctorat, Université Paul Sabatier, IRIT, Toulouse, 1998.
- [WANG-92] WANG, L., et J. MENDEL, « Generating fuzzy rules by learning from examples. », *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 22, No. 6, pp. 1414-1427, 1992.
- [WANG-07] WANG, Y.G., J. YANG, Y. ZHOU, et Y.Z. WANG, « Region partition and feature matching based color recognition of tongue image », *Pattern Recognition Letters*, Vol. 28, No. 1, pp. 11-19, 2007.
- [WRIG-69] WRIGHT, W.D., « The measurement of Colour », Hilger, Bristol, 4th Edition, 1969.
- [ZADE-65] ZADEH, L.A., « Fuzzy sets », *Information and Controls*, pp. 338-353, 1965.
- [ZADE-73] ZADEH, L.A., « Outline of a new approach to the analysis of complex systems and decision processes », *IEEE Trans. On Systems, Man and Cybernetics*, Vol. SMC3, pp. 28-44, 1973.
- [ZADE-75] ZADEH, L.A., « The concept of a linguistic variable and its application to approximate reasoning », *Information Sciences*, Part 1, Vol. 8, No. 3, pp. 199-249, Part 2, Vol. 8, No. 4, pp. 301-357, Part 3, Vol. 9, No. 1, pp. 43-80, 1975.
- [ZADE-78] ZADEH, L.A., « Fuzzy sets as a basis for a theory of possibility », *Fuzzy Sets and Systems*, Vol. 1, pp. 3-28, 1978.
- [ZELL-96] ZELLER, C., « Calibration projective, affine et euclidienne et vision par ordinateur et application à la perception tridimensionnelle », Thèse de doctorat, Ecole Polytechnique, Paris, France, 1996.
- [ZHAN-98] ZHANG, M., L.L. LUDAS, M.T. MORGAN, G.W. KRUTZ, et C.J. PRECETTI, « Applications of Color Machine Vision in the Agricultural and Food Industries », *Conference on Precision Agriculture and Biological Quality*, Boston, Etats-Unis, pp. 208-219, 1998.
-

## REFERENCES BIBLIOGRAPHIQUES

---

- [ZING-91] ZINGALES, G., et C. NARDUZZI, « The role of the artificial intelligence in measurement », 8th International Symposium on Artificial Intelligence based Measurement and Control (AIMaC'91), Ritsumeikan University, Kyoto, Japon, pp. 3-12, 1991.

Monsieur SCHMITT Emmanuel

DOCTORAT DE L'UNIVERSITE HENRI POINCARÉ, NANCY 1

en AUTOMATIQUE, TRAITEMENT DU SIGNAL, GENIE INFORMATIQUE

VU, APPROUVÉ ET PERMIS D'IMPRIMER n° 1427

Nancy, le 23 octobre 2007

Le Président de l'Université

  
J.P. FINANCE



**Résumé :**

Nos travaux portent sur l'étude d'un capteur flou adapté à l'identification couleur d'avivés. La méthode proposée a pour objectif notamment de prendre en compte la subjectivité de la perception des couleurs par l'être humain et de délivrer ses résultats dans le vocabulaire de l'utilisateur. Le domaine d'applications (industrie du bois) impose certaines contraintes. En effet, les classes de couleurs ne sont pas disjointes (frontières non strictes) et sont représentées par peu d'échantillons. Il en résulte alors des imprécisions et incertitudes dans la définition des classes de sortie. Après un état de l'art sur les techniques de traitement d'images, de reconnaissance de formes et sur la structure des capteurs intelligents, nos travaux sont exposés suivant deux axes : du capteur aux mesures, et des mesures à la décision. Tout d'abord, nous avons évalué et corrigé les perturbations liées à l'environnement ambiant du capteur (température, vieillissement, ...). Ensuite, nous avons déterminé l'espace colorimétrique le plus discriminant, et élaboré le vecteur caractéristique composé d'attributs interprétables permettant d'identifier les couleurs. A partir de ces données, nous avons développé le Fuzzy Reasoning Classifier basé sur un mécanisme de règles linguistiques floues agrégeant des règles conjonctives suivant le modèle de Larsen. Enfin, un opérateur flou de fusion de données est utilisé pour des systèmes multi-capteurs. L'exploitation de ce capteur flou a montré le bon comportement du système face aux contraintes temps-réel industrielles ainsi qu'une amélioration des taux de reconnaissance d'environ 10%.

**Mots Clés :** Capteur flou, Classification couleur, Reconnaissance de formes, Règles linguistiques floues, Traitement d'images.

**Abstract:**

Our works concern the study of a fuzzy sensor adapted to the color identification on wooden boards. The proposed method aims particularly to take into account the human subjectivity concerning the color perception and to provide results in the user vocabulary. The application field (timber industry) imposes certain constraints. Indeed, the color classes are not separated (non-strict boundaries) and are represented with few samples. Then, it results from it, imprecisions and uncertainties in the output class definition. After a state of the art on the techniques of image processing, of pattern recognition, and on the structure of intelligent sensors, our works are exposed along two axes: from the sensors to the measurements, and from the measurements to the decision. Firstly, we have evaluated and corrected the perturbations linked to the environment of the sensor (temperature, ageing, ...). Then, we have determined the most discriminating colorimetric space, and generated the characteristic vector composed of interpretable attributes allowing to identify the colors. From these data, we have developed the Fuzzy Reasoning Classifier based on a fuzzy linguistic rule mechanism aggregating conjunctive rules according to the Larsen model. Finally, for the multi-sensor systems, a fuzzy operator of data merging is used. The use of this fuzzy sensor has shown the good behaviour of the system compared to the real-time industrial constraints, and an improvement of 10% of the recognition rates.

**Keywords:** Fuzzy sensor, Color classification, Pattern recognition, Fuzzy linguistic rules, Image processing.