

# Classification par règles linguistiques floues à partir de lots d'apprentissage réduits

Cyril Mazaud\*, Emmanuel Schmitt\*, Vincent Bombardier\*

\* Centre de Recherche en Automatique de Nancy (CRAN), CNRS UMR n°7039

Faculté des Sciences, Bd des Aiguillettes - BP 239

54506 Vandoeuvre-lès-Nancy Cedex, France

[cyril.mazaud@cran.uhp-nancy.fr](mailto:cyril.mazaud@cran.uhp-nancy.fr)

[emmanuel.schmitt@cran.uhp-nancy.fr](mailto:emmanuel.schmitt@cran.uhp-nancy.fr)

[vincent.bombardier@cran.uhp-nancy.fr](mailto:vincent.bombardier@cran.uhp-nancy.fr)

<http://www.cran.uhp-nancy.fr>

**Résumé.** Cet article présente un système de classification supervisé par règles linguistiques floues à partir d'un lot d'apprentissage composé de peu d'échantillons. Le module de reconnaissance FRC (Fuzzy Reasoning Classifier) développé répond à un double besoin industriel pour la classification de singularités et de couleur du bois. D'une part, peu d'échantillons sont disponibles pour l'apprentissage du modèle de reconnaissance ce qui rend les méthodes par compilation comme les réseaux de neurones moins efficaces ; d'autre part, le domaine étant spécifique, nous proposons de spécialiser la méthode en y intégrant les connaissances expertes des domaines mis en œuvre (domaine du bois et domaine de la vision). Dans cet article deux points sont abordés. L'un illustre la capacité de généralisation de notre méthode en comparaison de méthodes telles que les réseaux de neurones, classificateur bayésien ou k plus proches voisins. L'autre montre l'intérêt de la spécialisation aux vues des taux de reconnaissance obtenus.

## 1 Introduction

Les industries manufacturières du bois sont dans un fort contexte concurrentiel demandant des systèmes de vision automatisés de plus en plus performants et de plus en plus adaptés au contrôle qualité du bois (détection de défauts, appariement couleur). Dans ce domaine, la majorité des traitements sont réalisés par des opérateurs humains qui sont détenteurs des connaissances et compétences requises pour ce contrôle qualité. Cependant, comme le souligne une étude menée par (Hubert et al., 1990), le besoin de formalisation de ces connaissances est un point clé pour la configuration d'un système de contrôle par vision, en d'autres termes, les systèmes d'inspection ont donc besoin de traitements spécifiques au problème posé.

Dans un souci de productivité, le temps d'installation des systèmes doit être le plus court possible pour permettre une rentabilité rapide. De plus, certaines singularités à reconnaître sont assez rares et donc peu de représentants sont disponibles pour entraîner un modèle supervisé. Le lot d'apprentissage obtenu est alors inégal dans le sens où le nombre de représentants de chaque singularité est fonction de leur distribution naturelle sur l'essence manipulée. Nous rencontrons, par exemple, beaucoup plus de singularités de type « nœud » que de type

Classification par règles linguistiques floues à partir de lots d'apprentissage réduits

« résine » sur une essence résineuse ; il n'est pas rare d'obtenir un lot composé de 50 « nœuds » pour 4 ou 5 « résines ».

L'article s'organise suivant deux axes. Dans la section 2, nous justifions et expliquons la méthode utilisée pour construire le classificateur et nous étudions la capacité de généralisation de plusieurs d'entre eux en fonction de la quantité de singularités en apprentissage. Dans la section 3, nous expliquons la manière dont la spécialisation du classificateur est effectuée pour la tâche qui lui est attribuée, c'est-à-dire la reconnaissance de singularités du bois.

## 2 Méthode d'identification proposée

Dans le domaine de la classification des planches de bois, plusieurs techniques sont généralement utilisées ; il s'agit essentiellement de classificateurs supervisés basés sur l'utilisation de réseaux de neurones (Lampinen et al., 1995, Pham et Sagioglu, 2001). Cependant, ces derniers possèdent un inconvénient majeur lors de la génération des modèles : le nombre d'échantillons en apprentissage doit être conséquent afin que les neurones puissent converger vers les sorties souhaitées. Malgré les bons résultats exposés dans ces papiers, nous voulons apporter une nouvelle approche utilisant des outils provenant de la théorie des ensembles flous (Zadeh, 1965), et plus précisément basés sur la logique floue (Bouchon-Meunier, 1995). Ce choix se justifie pour plusieurs raisons :

- Les singularités que nous devons classer sont intrinsèquement floues : passage progressif du bois sain au nœud sain ; influence du veinage dans la notion de couleur du bois. Les attributs que nous pouvons extraire des images sont donc incertains (mais calculés précisément). Ainsi, l'utilisation de la logique floue permet de travailler avec cette incertitude.
- Le client exprime ses besoins sous une forme nominale, les classes de sorties du système sont alors subjectives et souvent non disjointes : frontière non stricte entre un bois de couleur « rouge foncé » et « rouge ».
- Les connaissances exprimées par le client ou les opérateurs sont également subjectives et principalement exprimées linguistiquement.

Les raisons exposées précédemment nous ont décidé à utiliser une méthode basée sur la théorie des ensembles flous (Zadeh, 1965, Kaufmann, 1995) et plus particulièrement à partir de règles linguistiques floues (Dubois et Prade, 1992). Ainsi, nous pouvons intégrer la notion de subjectivité dans notre système de décision. L'utilisation de la logique floue et des termes flous améliorent la compréhension humaine des opérateurs se servant de l'outil développé. De plus, en travaillant avec des règles linguistiques floues, il est possible d'interpréter la base de règles générée et donc de confronter les règles utilisées par le modèle reconnaissance avec les connaissances du client et des opérateurs.

### 2.1 Le raisonnement flou

Le système d'inférences utilise un raisonnement flou pour délivrer un résultat final d'identification. Ce raisonnement fait référence aux concepts suivants : la proposition élémentaire floue, la proposition générale floue, les règles floues, les inférences floues et les relations floues.

**La proposition élémentaire floue.** Elle est définie sous la forme « V est A » (Bouchon-Meunier, 1995), où V est associé à une variable linguistique (Zadeh, 1975) permettant de décrire de manière qualitative un paramètre considéré. Par exemple, nous pouvons employer les variables linguistiques « clair » et « foncé » à un paramètre de luminance. Une telle variable est définie par un triplet de valeurs (V,X,Tv) où :

- V est la variable (ex: composante d'un repère colorimétrique);
- X est l'univers de discours de cette variable (domaine de variation des valeurs de V) ;
- Tv est le vocabulaire décrivant de manière symbolique ou linguistique les valeurs de V (clair, moyen, foncé).

Une proposition élémentaire floue est ainsi qualifiée par une phrase du type « V est A ». Ainsi, la valeur de cette proposition est définie à partir de la fonction d'appartenance  $\mu_A$  de A. De cette façon, nous lions les domaines symboliques et numériques à travers cette valeur.

**La proposition générale floue.** Elle est composée de propositions élémentaires floues « V est A », « W est B » (Bouchon-Meunier, 1995) pour les variables V et W supposées indépendantes. La plus simple des propositions générales s'exprime de la manière suivante : « V est A et W est B ».

**Les règles floues.** Elle sont de la forme « Si V est A et W est B alors U est C ». « V est A » et « W est B » sont appelés prémices de la règle. « U est C » représente sa conclusion.

**Les inférences floues.** Une inférence floue entre deux propositions élémentaires floues « V est A » et « W est B » représente une proposition floue entre les variables linguistiques (V,X,Tv) et (W,Y,Tw).

**La relation floue.** La proposition obtenue à partir de l'inférence floue précédemment citée est alors définie par une valeur de vérité donnée par la fonction d'appartenance  $\mu_R$  de la relation floue R entre X et Y. Pour chaque couple (x,y) de  $X \times Y$ , l'expression suivante est vérifiée :

$$\mu_R(x, y) = \Phi(\mu_A(x), \mu_B(y)) \quad , \text{ où } \Phi \text{ est l'opérateur d'inférence floue.}$$

Il existe différents types de règles permettant de définir un moteur d'inférences floues : les règles conjonctives et les règles implicatives qui regroupent respectivement, d'une part, les règles à possibilités et les règles anti-graduelles, et d'autre part, les règles à certitude et graduelles (Dubois et Prade, 1992, 1996). Ces règles sont obtenues de deux manières différentes et le choix d'utiliser l'une ou l'autre dépend des informations dont nous disposons pour les créer : soit à partir des connaissances exprimées par l'expert (règles implicatives), soit par apprentissage à partir d'un lot de données (règles conjonctives).

Dans notre étude, nous avons choisi un mécanisme de règles conjonctives car elles semblent mieux adaptées au traitement de données numériques d'apprentissage. Notre mécanisme d'inférence repose sur une activation parallèle des règles. Chacune d'elles fournit une conclusion partielle qui est ensuite agrégée aux autres conclusions pour donner la conclusion finale. A noter que ce type de règles évite toute redondance et toute incohérence de la base de règles.

## 2.2 Classificateur par Raisonnement Flou (FRC)

Les jeux de règles composant les mécanismes à base de raisonnement flou sont généralement obtenus par expertise dans la mesure où les règles traduisent une connaissance du procédé. Notre méthode de classification s'appuie sur un mécanisme de génération automatique des règles floues à partir d'un lot de données d'apprentissage. Le mécanisme d'inférences floues (Ishibuchi et al., 1992, 1994) suit le modèle de Larsen car l'opérateur **Produit** est mieux adapté que le **Minimum** dans l'utilisation de plusieurs prémisses. L'algorithme de reconnaissance utilisé repose sur une méthode itérative (Ishibuchi et al., 1997) supervisée dont le mécanisme génère des règles floues de type « SI... ALORS... » pour caractériser les différentes classes de couleurs et de singularités. Nous distinguons trois parties : la fuzzyfication des paramètres, la génération des règles floues et l'ajustement du modèle. Une fois ces étapes réalisées, le jeu de règles floues générées est utilisé pour l'identification des objets « inconnus » ou non étiquetés. Il existe une étape supplémentaire dans l'algorithme original : l'étape d'affinage des frontières qui vise à augmenter le degré d'appartenance à la classe d'appartenance maximale en modifiant les pentes de la fonction d'appartenance. A l'extrême, cette étape permet d'obtenir un découpage binaire de l'espace d'entrée ; ce qui est en contradiction avec notre volonté de conserver la gradualité des réponses de notre système. A noter que notre étude est différente comparée à celles qui peuvent être menées dans le domaine du contrôle flou. En effet, les systèmes classiques de contrôle flou délivrent des valeurs numériques en sortie du système alors que notre application fournit des sorties symboliques (une classe de défaut). Ainsi, l'étape de défuzzyfication, habituelle en contrôle, n'a pas lieu d'être pour notre système.

**La fuzzyfication des attributs.** Cette étape consiste à décomposer les attributs en plusieurs termes. Généralement, le nombre de termes est choisi de manière empirique, mais il faut noter que ce nombre a un impact direct sur les taux de reconnaissance (Schmitt et al., 2006). Ce nombre peut être défini par une décomposition équirépartie de l'espace de représentation de chaque attribut ou par une décomposition adaptée aux lots de données utilisés pour générer les modèles. Chaque partie de la décomposition est ensuite associée à un mot du langage naturel permettant de qualifier les variables linguistiques. Par exemple, la nuance d'une couleur peut être « claire », « moyenne » ou « foncée » (figure 1).




FIG. 1 – Fuzzyfication du niveau de luminosité en trois termes trapézoïdaux.

Le graphique de la figure 2 illustre la décomposition du domaine de variation ou univers de discours de la variable « intensité lumineuse » en trois termes. Trois paramètres de la fuzzyfication influent sur les taux de reconnaissance : le nombre de termes, la localisation

des termes (équirépartie ou adaptée) et la forme des courbes. Nous améliorons généralement le taux de reconnaissance d'environ 5% en choisissant une décomposition adaptée au problème considéré (cf. section 3). Sur les données « couleur du bois », nous obtenons 79,5% de bonne classification pour une fuzzyfication équirépartie en 5 termes, alors qu'en adaptant la décomposition en 5 termes aux données en apprentissage, nous obtenons 85,4%. Comme le nombre de termes, la forme des courbes de fuzzyfication a un impact sur le taux de reconnaissance (Schmitt et al., 2006).

**La génération des règles linguistiques.** Comme dit précédemment, l'algorithme génère automatiquement des règles floues « SI... ALORS... ». En fait, le modèle décrit comment le système perçoit les différentes singularités à reconnaître (couleurs et/ou défauts). Pour réaliser cette étape, nous utilisons un ensemble d'échantillons d'apprentissage. Généralement, si nous considérons deux paramètres d'entrée ( $V_i$  et  $V_{i+1}$ ) et une sortie  $Z_k$ , la règle floue associée sera la suivante :

$$\begin{aligned} & \text{SI } V_i \text{ est } A_j \text{ ET SI } V_{i+1} \text{ est } A_{j+1} \\ & \text{ALORS } Z_k \text{ est une forme de la classe } C_n \end{aligned}$$

où  $A_j$  et  $A_{j+1}$  sont des sous-ensembles flous, et  $C_n$  est la nième classe de sortie.

Dans cet exemple, l'opérateur « ET » correspond au produit Cartésien entre les deux variables  $V_i$  et  $V_{i+1}$ . Cette opération est réalisée par la T-Norme **Produit** :

$$T(x, y) = x * y$$

Le moteur d'inférences floues est en fait basé sur l'utilisation des lois de composition **Maximum/Produit**. Les inférences suivent donc le modèle de Larsen (Bouchon-Meunier, 1995) qui implémente un opérateur de pseudo implication représenté par le **Produit**. Finalement, chaque règle retourne une conclusion partielle, qui est ensuite agrégée avec les autres grâce à un opérateur flou de disjonction. Nous utilisons pour cela la valeur maximale définie par Zadeh (1965) :

$$\perp(x, y) = \max(x, y)$$

Le Classificateur par Raisonnement Flou (F.R.C.) possède une étape d'ajustement du modèle (Ishibuchi et al., 1997) qui fait partie intégrante de la phase de génération du modèle. Elle permet d'ajuster le découpage de l'espace des variables d'entrée en attribuant un coefficient de confiance à chaque règle. A chaque itération, chaque échantillon du lot d'apprentissage est à nouveau testé sur la base de règles qui vient d'être générée. Si l'échantillon confirme la règle, le coefficient associé est augmenté, sinon il est diminué.

### 2.3 Influence du nombre d'échantillons d'apprentissage sur les taux de reconnaissance

L'étape d'apprentissage est un des points forts de la méthode. En effet, notre projet s'applique à un domaine dans lequel le nombre de données pour l'apprentissage est faible. En effet, il arrive que des classes de singularités soient représentées par trois ou quatre échantillons. Ainsi, les techniques nécessitant de nombreux échantillons, comme les réseaux de neurones, semblent moins adaptées à notre problème. Aussi, nous avons réalisé une étude de l'impact du nombre d'échantillons en apprentissage sur le taux de reconnaissance pour différentes méthodes. Pour effectuer ces tests, nous avons utilisé une base de données concernant la reconnaissance de couleur constituée initialement de 900 échantillons, soit 150 échantil-

## Classification par règles linguistiques floues à partir de lots d'apprentissage réduits

lons par classe. Pour évaluer l'influence du nombre d'échantillons en apprentissage, nous avons généré aléatoirement des points en bruitant les données réelles avec un bruit blanc gaussien. Cette base finale décrit six classes de sorties composées chacune de 5000 points : Brun Foncé (BF), Brun (B), Brun Clair (BC), Rouge Foncé (RF), Rouge (R), Rouge Clair (RC).

La comparaison des résultats a été faite à partir de plusieurs méthodes de classification : un classificateur bayésien (Bayes), un réseau de neurones (RdN), l'algorithme des k plus proches voisins (kppv), et le classificateur à raisonnement flou (FRC). La figure 2 représente l'évolution des taux de reconnaissance en généralisation des différentes méthodes citées.

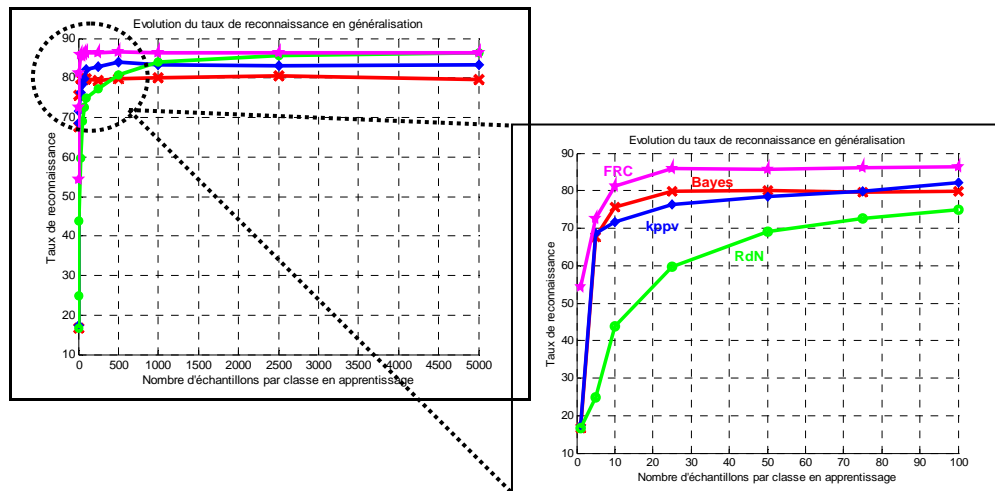


FIG. 2 – Evolution des taux de reconnaissance en fonction du nombre d'échantillons utilisés en apprentissage.

Nous pouvons noter que, plus le nombre de points composant le lot d'apprentissage devient grand, plus le taux de reconnaissance augmente, et ceci, quelque soit la méthode de classification. Nous voyons apparaître une asymptote horizontale (figure 2) pour les différentes méthodes :

- à 80% pour le classificateur bayésien ;
- à 83% pour la méthode des k plus proches voisins ( $k = 5$ ) ;
- à 86% pour le réseau de neurones ;
- à 86% pour le classificateur par raisonnement flou.

Nous notons également que les différentes méthodes convergent plus ou moins vite vers ces asymptotes (zoom effectué sur le graphique de la figure 2). Typiquement, nous constatons que les réseaux de neurones ont besoin d'un très grand nombre d'échantillons en apprentissage pour qu'ils puissent être performants en généralisation. A performances égales en généralisation, le réseau de neurones a besoin de 1000 points par classe contre 25 pour le FRC. Dans notre cas, le nombre d'échantillons demandés par les réseaux de neurones n'est pas envisageable en raison des faibles lots de données réelles dont nous disposons lors de l'installation d'un système de classification chez un client.

Une autre source d'amélioration possible de la qualité de notre module d'identification réside en la modélisation et l'intégration de connaissances expertes des domaines liés à notre étude ; en d'autres termes, la prise en compte des connaissances du produit bois et la prise en compte des spécificités du produit bois dans le procédé vision.

### **3 Amélioration du module FRC par modélisation et intégration de connaissances expertes**

La prise en compte de connaissances supplémentaires est une condition nécessaire pour améliorer un système. Ces connaissances, aussi différentes que complémentaires, ont pour but de spécialiser le système pour la tâche qui lui est assignée. Elles concernent l'objet même étudié (et non le système qui l'étudie) et sont représentatives des différents points de vue que l'on peut avoir de cet objet. Cette représentation est directement issue du **Principe de Matérialité** (Frachet, 1987) qui postule qu'« *un objet du monde réel est porteur de l'ensemble de ses vues et en assure la cohérence* ». En d'autres termes, un objet n'existe dans le monde réel que par la cohérence de ses représentations qui participent chacune à son identification. L'objet est alors l'élément commun aux différentes vues et peut être considéré comme l'élément intégrant ses propres vues.

#### **3.1 Démarche de modélisation et d'intégration de connaissances dans le cadre de la reconnaissance de singularités du bois**

Pour le cas exposé dans cette section, nous nous attacherons à la reconnaissance des singularités du bois par un système de vision industriel. Ces singularités représentent des zones dites « défectueuses » qui selon les clients, sont acceptées ou rejetées. Nous avons montré précédemment l'intérêt de l'utilisation du module FRC en tant que méthode de classification à partir d'un lot d'apprentissage réduit. Cette section a pour but de montrer l'impact de la spécialisation du module en fonction des singularités à reconnaître grâce à l'intégration de connaissances expertes. Pour accéder à ces connaissances complémentaires deux sources sont utilisables :

- l'une provenant d'experts humains fournissant une connaissance plutôt qualitative ;
- l'autre provenant de données directement acquises sur le système fournissant une connaissance plutôt quantitative.

La figure 3 illustre le principe de matérialité appliqué à la reconnaissance des singularités du bois.

Le Produit Bois (et donc les singularités qui le constituent) peut être considéré de deux points de vue différents mais complémentaires :

- d'un point de vue numérique par l'intermédiaire du Procédé Vision ;
- d'un point de vue symbolique par l'intermédiaire de l'Expert Produit.

Il est à noter que nous ne pouvons accéder directement aux connaissances numériques propres au Produit Bois. En effet, ces connaissances sont supposées être les connaissances réelles, exactes et parfaites du produit. Nous ne pouvons accéder à cette connaissance que par l'intermédiaire du Procédé Vision qui restitue une image approximée de ses caractéristiques.

Classification par règles linguistiques floues à partir de lots d'apprentissage réduits




FIG. 3 – Principe d'intégration des connaissances expertes permettant de spécialiser le système de vision pour la reconnaissance de singularités du bois.

La démarche que nous proposons ici est donc l'utilisation conjointe des connaissances symboliques de l'Expert Produit Bois (définissant les singularités du produit) et des connaissances symboliques de l'Expert Procédé Vision afin de configurer notre module FRC pour la reconnaissance des singularités du bois.

**Modélisation des connaissances expertes.** Nous modélisons les deux types de connaissances expertes sous la forme de deux modèles symboliques construits à l'aide de la méthode NIAM (Nijssen et Halpin, 1989) et sous le formalisme ORM (Halpin, 2001). Le choix de cette méthode de modélisation tient en ses propriétés même qui permettent de concevoir un modèle directement à partir d'expression de faits exprimés en langage naturel. De plus, de par sa capacité à traduire en langage naturel binaire le modèle construit (phrase élémentaire du type < sujet>, < verbe>, < complément>), le cycle auteur/relecteur est simplifié puisque la validation du modèle par l'expert se fait à partir de phrases compréhensibles. Le formalisme utilisé n'est donc pas un pré-requis pour l'expert qui doit valider le modèle.

Nous obtenons donc au final deux modèles symboliques reflétant, d'une part les connaissances propres au Produit Bois, et d'autre part, les connaissances liées aux paramètres utilisés par le Procédé Vision.

**Intégration des connaissances expertes.** Le but de cette intégration est de mettre en commun les deux vues que nous avons du Produit Bois afin de spécialiser le système de connaissance. Elle permet d'améliorer le FRC sur trois points :

- choix des attributs pertinents,
- adaptation de la fuzzyfication au lot de données (nombre de termes et localisation de chaque terme),
- structuration hiérarchique du modèle numérique améliorant son interprétabilité.

La démarche adoptée est donc une mise en relation des deux modèles symboliques, et plus précisément une traduction du domaine Bois vers le domaine Vision. La spécialisation influe sur la configuration du modèle numérique (modèle chargé de traiter les données à

**Produit  
Bois**

**Connaissances  
numériques**

**Connaissances  
symboliques**

Exprimées  
par

reconnaître) et plus particulièrement sur la définition des paramètres en entrée du modèle numérique et sur le découpage de ses paramètres (choix du nombre de termes). La figure 4 illustre la démarche.




FIG. 4 – Principe d'intégration des connaissances expertes pour la configuration du FRC.

Il est à noter que l'intégration de connaissances a un impact direct sur la structure et l'interprétation du modèle chargée de la reconnaissance. Jusqu'à présent dans l'article, seule une structure de type inférence unique était utilisée pour reconnaître les singularités. Ce type de modèle considérant l'ensemble des attributs comme paramètres d'entrée du moteur d'inférences pour différencier toutes les classes de sortie mène à un modèle qui n'est pas interprétable.

Par exemple, un modèle comportant neuf attributs en entrée chacun fuzzyfiés en cinq termes conduit à la génération de près de deux millions de règles interdisant toute interprétation du modèle.

La prise en compte des connaissances du Produit Bois permet de simplifier le modèle pour aboutir à un modèle interprétable. Pour ce faire, nous utilisons une structure arborescente dont le principe repose sur une décision multi-niveaux (Bombardier et al., 2007, Mazaud et al., 2006). Les connaissances utilisées pour cette structuration sont encore empiriques et reposent sur le constat suivant : chaque défaut peut être caractérisé selon des critères de forme, de couleur qui sont plus ou moins génériques pour chacun d'eux, le plus générique représentant le premier niveau décisionnel. Chaque niveau représente une partie de la connaissance utilisée pour reconnaître (ou différencier) les singularités. Dans ce cas, le choix des attributs en entrée du modèle numérique est guidé par ces connaissances. A chaque niveau décisionnel, nous déterminons quels sont les paramètres du système de vision qui permettent de reconnaître, soit les caractéristiques propres à chaque niveau décisionnel (différenciation de forme, de couleur...), soit les classes de défauts en sortie d'un niveau décisionnel donné (nœud noir, nœud sain...).

Par exemple, si nous considérons une singularité de type *Nœud Noir*, l'expert Produit Bois définit ce défaut comme étant un défaut *plutôt rond* de *couleur noire*. La traduction vers le domaine Procédé Vision doit permettre de définir la représentation des concepts de *Forme Ronde* et de *Couleur Noire* dans le domaine Vision; en d'autres termes, quels sont les paramètres du procédé de vision qui définissent ces deux concepts comme l'indice de compacité, le grand axe et le petit axe de l'ellipse de la singularité, l'intensité lumineuse...

### 3.2 Résultats de la méthode d'intégration

Les résultats présentés sont issus d'un lot client composé de neuf singularités à reconnaître. Nous avons testés quatre modèles numériques intégrant plus ou moins de connaissances. Ces quatre modèles sont :

- modèle inférence unique (IU) avec une fuzzyfication équirépartie. Pour ce modèle, aucune connaissance n'est utilisée ;
- modèle inférence unique avec une fuzzyfication adaptée (IUA). Pour ce modèle, nous intégrons la connaissance experte pour déterminer le nombre de termes de fuzzyfication de chaque paramètre ;
- modèle à structure arborescente avec fuzzyfication équirépartie (SA). Pour ce modèle, nous intégrons la connaissance experte pour déterminer sa structure ainsi que les paramètres les plus pertinents pour chaque nœud décisionnel ;
- modèle à structure arborescente avec fuzzyfication adaptée (SAA). Pour ce modèle, nous intégrons la connaissance experte pour définir la structure hiérarchique du modèle ainsi que les paramètres les plus pertinents pour chaque niveau décisionnel et enfin le choix du nombre de termes de fuzzyfication de chaque paramètre.

La figure 5 montre les résultats obtenus pour ces quatre modèles.




FIG. 5 – Taux de reconnaissance en généralisation en fonction du degré d'intégration des connaissances.

A partir des résultats obtenus, deux tendances apparaissent clairement. La première est l'apport de l'intégration de connaissances au niveau du choix du nombre de termes de fuzzyfication. En effet, aussi bien pour le modèle IU que pour le modèle SA, l'ajout de connaissances sur le nombre de termes améliore les taux de reconnaissance (+3,1% passage IU à IUA ; +3,8% passage SA à SAA). La seconde est l'apport de l'intégration de connaissances au niveau de la structure du modèle et du choix des paramètres pour chaque niveau décisionnel. En effet, aussi bien pour le modèle IU que le modèle IUA, l'ajout de connaissances sur la structure du modèle améliore les taux de reconnaissance (+1,3% passage IU à SA ; +2% passage IUA à SAA).

Enfin, en considérant un apport total de connaissances, c'est-à-dire en intégrant celles-ci aussi bien au niveau de la fuzzyfication qu'au niveau de la structure du modèle et du choix des paramètres les plus pertinents pour chaque niveau décisionnel, le taux de reconnaissance est amélioré de 5,1% (passage IU à SAA).

## 4 Conclusion et perspectives

Dans cet article, nous avons présenté une méthode permettant une classification par règles linguistiques floues à partir d'un lot d'apprentissage réduit. L'objectif de cette méthode est double. Premièrement, disposant de peu d'échantillons pour l'apprentissage des modèles, nous devons trouver une méthode avec un fort pouvoir de généralisation. L'étude que nous avons menée sur le lot *couleur* montre clairement cette capacité de notre méthode puisque qu'avec seulement 25 échantillons en apprentissage (contre 1000 pour les réseaux de neurones), nous obtenons le meilleur taux de reconnaissance. Deuxièmement, afin d'améliorer le niveau de performances et d'interprétabilité de notre modèle numérique, nous avons montré l'intérêt de l'apport de connaissances expertes pour la construction et la configuration du modèle numérique. En effet, un tel apport permet, d'une part, d'améliorer le taux de reconnaissance (5% de mieux que pour l'inférence unique), et d'autre part, permet une meilleure interprétabilité du modèle numérique (234 règles utilisées au lieu de 3167).

Enfin, trois axes sont à approfondir pour l'amélioration de notre méthode. Le premier consiste en une fuzzyfication adaptée automatique permettant à partir d'une analyse du lot d'apprentissage de générer automatiquement le nombre de termes ainsi que leur position sur l'univers de discours, et ceci pour chaque attribut. Le second s'oriente vers une définition formelle de la structure hiérarchique du modèle décisionnel par le biais d'une modélisation et d'une intégration des connaissances liées à cette étape de construction du modèle numérique. Enfin, nous nous intéresserons plus en avant sur l'exploitation de l'interprétabilité de la base de règles. Notre objectif est de pouvoir la synthétiser sous forme compréhensible par le client ou l'opérateur. A l'inverse, cette étude permettra aussi d'injecter de nouvelles règles dans la base à partir d'un énoncé sous forme linguistique pour modéliser une singularité sans passer par la phase d'apprentissage.

## Références

- Bombardier V., C. Mazaud, P. Lhoste et R. Vogrig (2007). Contribution of Fuzzy Reasoning Method to knowledge Integration in a defect Recognition System, *Computers in Industry Journal*, 58(2).
- Bouchon-Meunier, B. (1995). *La logique floue et ses applications*, Addison-Wesley.
- Dubois, D. et H. Prade (1992). *Fuzzy rules in knowledge-based systems – Modelling gradedness, uncertainty and preference. An introduction to fuzzy logic application in intelligent systems*, 45-68, Kluwer, Dordrecht.
- Dubois, D. et H. Prade (1996). What are Fuzzy rules and how to use them, *Fuzzy Sets and Systems*, 84:169-185.
- Frachet, J.P. (1987). *Une introduction au génie automatique: faisabilité d'une chaîne d'outils C.A.O. pour la conception et l'exploitation des machines industrielles*. Thèse de doctorat d'Etat es-Sciences Physiques, Université de Nancy 1.
- Halpin, T.A. (2001). *Information Modelling and Relational Databases*. Morgan Kaufman edition

## Classification par règles linguistiques floues à partir de lots d'apprentissage réduits

- Huber, A.H., S. Ruddell et C.W. McMillin (1990). Industry standards for recognition of marginal wood defects. *Forest Products Journal*, 40(3):30-34.
- Ishibuchi, H., K. Nozaki et H. Tanaka (1992). Distributed representation of fuzzy rules and its application to pattern classification, *Fuzzy Sets and Systems*, 52:21-32.
- Ishibuchi, H., K. Nozaki, N. Yamamoto et H. Tanaka (1994). Construction of fuzzy classification systems with rectangular fuzzy rules using genetic algorithms, *Fuzzy sets and systems*, 65:237-253.
- Ishibuchi, H., K. Nozaki et H. Tanaka (1997). A Simple but powerful heuristic method for generating fuzzy rules from numerical data, *Fuzzy sets and systems*, 86:251-270.
- Kaufmann, A. (1975). *Introduction à la théorie des sous-ensembles flous*, Edition Masson.
- Mazaud, C., V. Bombardier, P. Lhoste et R. Vogrig (2006). *A fuzzy recognition model based on human skill integration*. 9<sup>th</sup> IFAC Symposium on Automated Systems Based on Human Skill and Knowledge ASBoHS'06, Nancy.
- Lampinen, J., S. Smolander et M. Korhonen (1995). *Wood surface inspection system based on generic visual features*. International Conference on Artificial Neural Networks ICANN'95, Paris.
- Nijssen, G.M. et T.A. Halpin (1989). *Conceptual schema and relational database design*. Prentice Hall.
- Pham, D.T. et S. Sagioglu (2001). Training multilayered perceptrons for pattern recognition: a comparative study of four training algorithms. *International Journal of Machine Tools & Manufacture*, 41:419-430.
- Schmitt, E., C. Mazaud, V. Bombardier et P. Lhoste (2006). *A Fuzzy Reasoning Classification Method for Pattern Recognition*. Fuzzy IEEE, Vancouver.
- Zadeh, L.A. (1965). Fuzzy sets. *Information and control*, 8:338-353.
- Zadeh, L.A. (1975). The concept of linguistic variable and its application to approximate reasoning, *Information sciences*, 8:199-249

## Summary

This article introduces a supervised classification system by fuzzy linguistic rules from a reduced learning sample set. The developed FRC recognition module (Fuzzy Reasoning Classifier) answers to a double industrial need for the classification of wood singularities (colour or defect). On the one hand, few samples are available to train the numerical model (model in charge of the recognition) excluding methods like neural networks; on the other hand, the application field being specific, we propose to specialize the method by integrating the used expert knowledge (wood field and vision field). Two studies are led. The first illustrates the generalization capability of our method in comparison to methods like neural networks, bayesian classifier and k nearest neighbours. The other one demonstrates the interest of the specialization at sights of the obtained recognition rates.