



HAL
open science

Modélisation de connaissances “ métier ” pour le paramétrage d’un Système Flou d’identification de défauts sur des planches de bois.

Cyril Mazaud, Vincent Bombardier, Pascal Lhoste, Raphaël Vogrig

► To cite this version:

Cyril Mazaud, Vincent Bombardier, Pascal Lhoste, Raphaël Vogrig. Modélisation de connaissances “ métier ” pour le paramétrage d’un Système Flou d’identification de défauts sur des planches de bois.. e-STA Sciences et Technologies de l’Automatique, 2006, 3 (1), pp.Revue électronique. hal-00120314

HAL Id: hal-00120314

<https://hal.science/hal-00120314>

Submitted on 14 Dec 2006

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.

Modélisation de connaissances « métier » pour le paramétrage d'un Système Flou d'identification de défauts sur des planches de bois.

CYRIL MAZAUD^{1,3}, VINCENT BOMBARDIER¹, PASCAL LHOSTE² et RAPHAËL VOGRIG³

¹ Centre de Recherche en Automatique de Nancy (CRAN), CNRS, UMR 7039,
Faculté des Sciences – Bd des Aiguillettes – BP 239 – 54506 Vandœuvre lès nancy Cedex

² Ecole Nationale Supérieure en Génie des Systèmes Industriels de l' Institut National Polytechnique de Lorraine (ENS-GSI-INPL), 8 rue Bastien Lepage – BP 647 – 54010 NANCY Cedex

³ LuxScan Technologies, ZARE Ouest – L 4384 Ehlerange – Luxembourg

vincent.bombardier@cran.uhp-nancy.fr, cyril.mazaud@cran.uhp-nancy.fr, Pascal.Lhoste@ensgsi.inpl-nancy.fr, vogrig@luxscan.lu

RESUME

Cet article expose une démarche de modélisation et d'intégration de connaissances expertes issues de deux domaines d'expertise visant à améliorer un système de reconnaissance de défauts sur des planches de bois. Les domaines d'expertise concernés sont le métier du bois et la vision industrielle. L'extraction et la modélisation de ces connaissances sont basées sur la méthode NIAM et le formalisme ORM, les formalisant à partir de leur expression en langage naturel. Pour améliorer le système de reconnaissance existant, nous proposons d'intégrer ces connaissances métiers pour construire en partie le modèle numérique. Ce modèle est créé selon une structure arborescente où chaque moteur d'inférence est constitué d'un Système d'Inférences Floues reposant sur un mécanisme à base de règles linguistiques floues. Les connaissances expertes précédemment modélisées permettent de configurer chaque nœud de l'arborescence ainsi créée. Les résultats obtenus sur un lot de production montrent l'amélioration du taux de reconnaissance par rapport à la méthode en place dans l'entreprise.

MOTS CLES : modélisation de connaissances, méthode NIAM, formalisme ORM, identification de défauts, système d'inférences floues.

INTRODUCTION


L'accroissement du niveau d'Information dont on peut disposer sur un système est essentiel pour l'amélioration de la maîtrise de ce système et des processus qui y sont intégrés (automatisation, maintenance, relations avec l'environnement, ...). Deux sources principales permettent l'accès à cette Information : d'une part, à partir de *connaissances* d'experts humains (experts en procédés, en produits, en normes, ...) qui donnent une information plutôt qualitative sur ce qu'est le système étudié, et, d'autre part, par acquisition de *données* directement sur le système, donnant plutôt une information quantitative

sous la forme de mesures. Le rapprochement de ces sources d'informations aussi différentes que complémentaires doit alors contribuer à une modélisation de l'information plus complète et plus cohérente permettant une intégration plus forte des processus composant le système. En ce sens, l'étude proposée cherche à définir une méthodologie de modélisation et d'intégration permettant, d'une part, d'extraire la connaissance de l'information experte, d'autre part, d'extraire la connaissance révélée par les Données numériques prélevées sur le système et, enfin, d'intégrer ces connaissances d'origines différentes en un seul référentiel cognitif. Cette méthodologie est appliquée au domaine de la reconnaissance de formes et, en particulier, à celui de l'identification de défauts sur des planches en bois par système de vision industrielle. Elle pourrait être généralisée à l'ensemble des domaines sectoriels concernés par l'existence parallèle d'une connaissance experte qualitative et de données quantitatives sur un même objet.

CADRE APPLICATIF

Les travaux présentés se situent dans le cadre d'une collaboration université – entreprise entre le CRAN et la société luxembourgeoise Luxscan Technologies et concernent l'élaboration d'un système de reconnaissance par vision de défauts sur des planches de bois à événements discrets. C'est sur une ligne de production que s'effectue en temps réel l'analyse des planches dont la vitesse de déplacement peut atteindre 3 à 5 mètres par seconde en considérant un maximum de 200 défauts par mètre. Après le contrôle qualité de la planche effectué par le système de vision, chaque planche est ensuite dirigée soit vers une ligne de tri qualitatif (au moins trois qualités sont alors attribuées), soit vers une ligne de découpe visant à purger les parties de planches indésirables. Dans ce cas, les scies optimisent la quantité et la qualité du produit final selon les désirs du client.

La (figure 1) illustre une ligne de production ainsi que le positionnement du système de contrôle qualité vision



dans celle-ci.

Figure 1: Ligne de production

Le système industriel de contrôle par vision illustré par la (figure 2) fonctionne de la manière suivante.

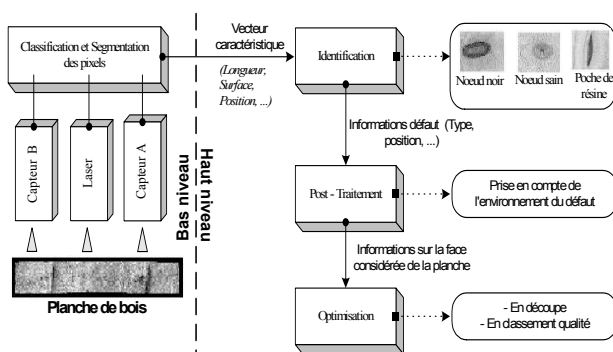


Figure 2: Système de vision

L'acquisition de l'image de la planche de bois s'effectue par des capteurs linéaires qui peuvent être utilisés individuellement ou combinés. Ils sont principalement de deux types : couleur fournissant les canaux rouge, vert et bleu ; lasers qui renvoient une mesure tridimensionnelle de la surface du bois, une mesure de densité et d'orientation, et deux mesures de luminosité en rouge et infrarouge.

Les signaux, délivrés par ces capteurs, sont échantillonnés au rythme de 2000 lignes par seconde et sont quantifiés sur 1024 niveaux. Les images ainsi obtenues sont ensuite pré-traitées et labellisées pour fournir une information ne comportant plus que six classes de pixels. Ces classes définissent la classe de pixels « noir », « brun clair » (correspondant au bois sain), « brun foncé », « orange », « bleu », et « fentes ».

Cette étape de classification est réalisée soit par un classificateur bayésien, soit par un classificateur à seuil dont les paramètres sont réglés empiriquement. La segmentation, réalisée à partir de l'image labellisée, consiste en l'agrégation de pixels connexes n'appartenant pas à la classe de pixels « brun clair » définissant le bois sain. Elle permet donc d'extraire les régions dites « défectueuses » des régions dites « saines ».

Un ensemble de paramètres (surface d'un défaut, orientation, couleur, ...) est calculé sur ces régions pour four-

nir le vecteur caractéristique utilisé par l'étape d'identification qui a pour objectif de donner un nom au défaut : « noeud noir », « noeud sain », « noeud cerné », « poche de résine », « bleuissement », « fentes » ...

METHODOLOGIE PROPOSEE

Pour nos travaux, deux orientations ont été retenues pour rapprocher les connaissances exploitables en identification de défauts sur des planches de bois par vision : celles provenant du système de vision et celles provenant de l'expert « métier du bois ».

Nous disposons de données numériques sous la forme d'un vecteur qui caractérise le défaut à identifier au travers d'une relation que nous appelons dans la suite de l'article « modèle numérique ». L'utilisation d'une méthode mettant en oeuvre les outils de la théorie des ensembles flous et plus particulièrement de la logique floue [1], se justifie par trois raisons. Premièrement, les défauts à détecter sont intrinsèquement flous, il n'existe pas toujours une frontière stricte entre un défaut et un bois sain. La phase de segmentation, qui ne prend pas en compte cette imprécision, peut fournir un vecteur caractéristique inexact. L'utilisation de la logique floue vise à rendre le système d'identification moins sensible à ces imprécisions. Deuxièmement, les classes de défauts en sortie ne sont pas toutes disjointes. En effet, la limite entre un « petit noeud noir » et un « grand noeud noir » n'est pas forcément stricte. Troisièmement, les termes linguistiques utilisés par les experts pour définir les défauts (petit noeud, grand noeud, à peu près circulaire) sont souvent vagues et imprécis. Nous représentons ces termes sous la forme de termes flous caractérisés par leur fonction d'appartenance. Ces termes sont ensuite traités par un mécanisme à base de règles. Nous avons donc choisi d'implémenter ce modèle numérique à l'aide d'un Système d'Inférences Floues (SIF) utilisant un système de règles linguistiques floues afin de faciliter l'interprétation du mécanisme d'identification et de pouvoir en extraire la connaissance portée par le vecteur caractéristique et la formaliser ; contrairement à un classificateur basé sur des réseaux de neurones supervisés ou non supervisés [2] [3] [4] agissant comme une boîte noire. Pour obtenir le modèle numérique, nous utilisons un algorithme générant automatiquement les règles floues par apprentissage.

D'autre part, nous avons la connaissance des défauts à identifier qui est exprimée en langage naturel en des termes métier. Nous avons entrepris une modélisation symbolique de cette connaissance métier en utilisant la méthode NIAM [8] permettant une approche de validation formelle contrairement aux systèmes de jeu de règles heuristiques [9] [10] [11] classiquement utilisés dans le domaine de conception de systèmes experts utilisant une expertise humaine et une expertise vision. Dans la suite de l'article, nous appelons « modèle symbolique » cette modélisation de la connaissance issue de l'expert « métier du bois ». Pour illustrer de manière simplifiée nos propos et notre démarche de modélisation et

d'intégration, nous ne considérerons dans la suite que les défauts de type « nœud », c'est-à-dire les nœuds noirs, les nœuds cernés et les nœuds sains.

Le but de cette modélisation et de cette intégration est de déterminer de manière non empirique et systématique les meilleurs paramètres en entrée de chaque nœud décisionnel de notre modèle numérique, en d'autres termes, le vecteur caractéristique optimal pour chaque moteur d'inférence [12]. La (figure 3) illustre notre démarche.

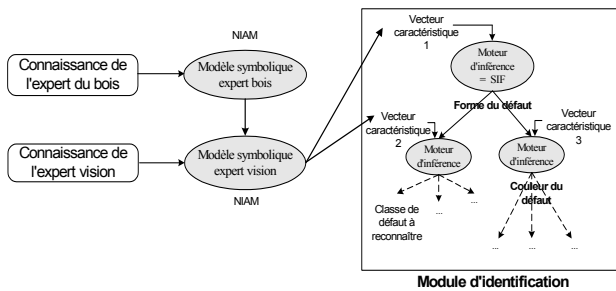


Figure 3: Principe de la démarche proposée

MODELISATION DE CONNAISSANCES METIER

Le modèle symbolique concerne la formalisation des connaissances expertes dans le domaine du bois ainsi que dans le domaine du procédé d'identification de défauts (système de vision). La méthode d'analyse retenue pour élaborer ce modèle est la méthode NIAM (Nijssen Information Analysis Method) [8]. Nous utilisons un de ses formalismes dérivés, ORM (Object Role Modeling) [13] [14], pour représenter les résultats de cette analyse.

Méthode NIAM et formalisme ORM

La méthode NIAM repose sur une analyse linguistique de texte. A partir de l'expression de faits observables mettant en cause des *objets*, cette méthode permet par une généralisation de la connaissance du domaine étudié de distinguer des types d'objets non lexicaux (NOLOTS) et des types d'objets lexicaux (LOTS) ainsi que les types de faits qui les relient. La figure 4 illustre quelques éléments syntaxiques du formalisme NIAM/ ORM permettant de représenter ces objets et leurs relations.

Pour plus d'informations concernant la méthode NIAM et le formalisme proposé par NIAM/ORM, le lecteur peut se référer à [13] [15].

Cette méthode présente un intérêt significatif car elle repose directement sur une expression de faits énoncés en langage naturel. Le modèle d'informations en résultant peut aussi être soumis à validation par l'expert sous une forme compréhensible, c'est à dire en Langage Naturel Binaire (LNB), transcription du modèle d'information appelée aussi « paraphrasage ». La méthode permet par ailleurs de compléter progressivement le modèle en posant à l'expert des questions précises induites par la méthode et, là aussi, en langage naturel (par exemple : un défaut possède t-il une ou plusieurs couleurs ?). Nous obtenons alors un modèle complété par des contraintes dites entre autres de totalité et d'unicité.

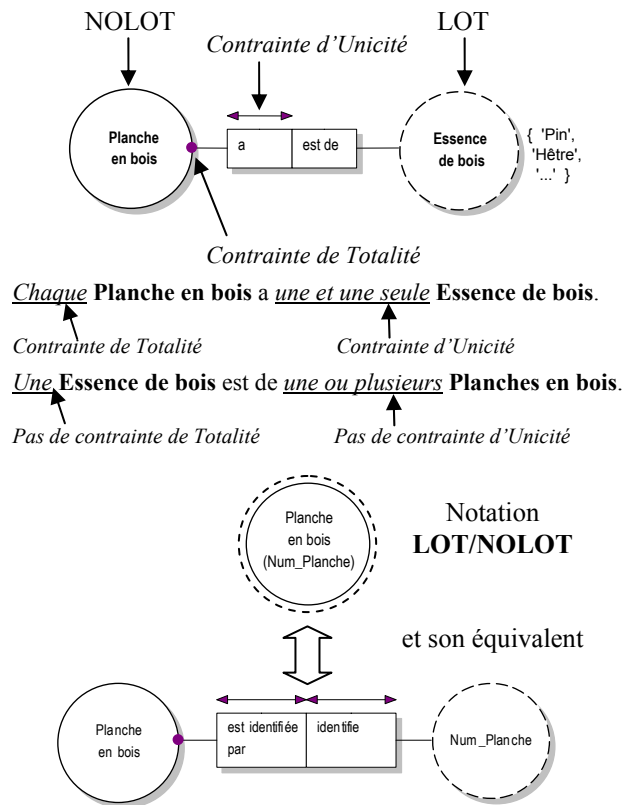


Figure 4: Eléments de Formalisme NIAM/ORM

Modélisation Des Connaissances Du Bois

Afin de créer ce modèle, on demande à l'expert du domaine du bois de rédiger une liste, la plus complète possible, en langage naturel, des différents défauts que l'on rencontre sur le type d'essence manipulée. Cette expression est suffisante pour reconnaître, à l'œil nu, n'importe quel défaut énoncé sur un échantillon de bois.

La (figure 5) montre un exemple de modèle symbolique générique en considérant trois type de nœuds (nœud noir, nœud sain et nœud cerné), construit à partir des trois modèles symboliques particuliers décrivant chaque type de défaut.

La validation de ce modèle est effectuée par l'expert qui a émis ces connaissances grâce à sa transcription en Langage Naturel Binaire. Chaque relation entre les objets ainsi que les différentes contraintes qui leurs sont apposées sont transcrites en langage naturel. Par exemple, les (•) représentent une contrainte de totalité exprimant que *chaque* élément constituant l'objet participe à la relation. Les (↔) représentent une contrainte d'unicité exprimant la participation d'*un et un seul* objet dans la relation. L'absence de (↔) exprime la participation d'*un ou plusieurs* objets dans la relation (figure 4). Le résultat de cette transcription est donc un texte proche du langage naturel n'imposant aucune connaissance particulière de la méthode de modélisation utilisée par l'expert du métier du bois.

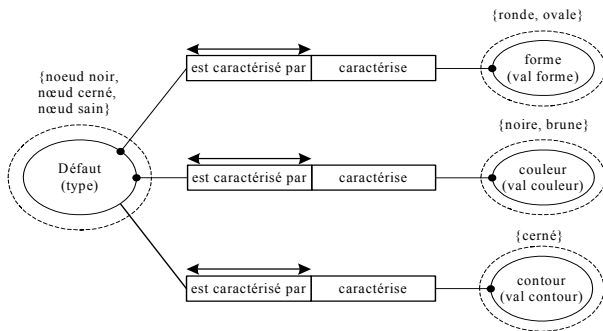


Figure 5: Modèle générique des défauts de type « nœud »
Voici un fragment du texte exposé à l'expert pour validation directement issu de la transcription LNB du schéma de la figure 5 :
Chaque Défaut est caractérisé par une et une seule Forme. Chaque Forme caractérise un ou plusieurs Défauts. Chaque Défaut est caractérisé par une et une seule Couleur...

Modélisation des connaissances du procédé vision

De même que pour le modèle symbolique de l'expert « métier bois », on recense les connaissances de l'expert du procédé de vision. Ces connaissances portent sur le système d'identification de défauts et, plus particulièrement, sur les paramètres utiles à la quantification des caractéristiques du défaut à reconnaître. Nous appliquons le même principe que pour le modèle symbolique de l'expert métier et nous aboutissons à une caractérisation de tous les défauts rencontrés mais, cette fois, du point de vue des paramètres du système de vision.

La (figure 6) représente une formalisation partielle en NIAM/ORM d'un tel énoncé sur la caractérisation de la couleur d'un défaut.




Figure 6: Modélisation partielle de la couleur

Cette modélisation représente le fait suivant, en considérant qu'une couleur est définie par d'autres paramètres que le nombre de pixels noirs : *Une couleur précise est caractérisée par un pourcentage de pixels noirs unique. Mais l'inverse n'est pas vrai : à un pourcentage de pixels noirs donné peut correspondre plusieurs couleurs.* Nous faisons de même pour les caractéristiques de Forme et le Contour. Il est à noter que pour des raisons de confidentialité nous ne pouvons exposer entièrement ces modèles de connaissance experte. C'est pourquoi nous nous limiterons par la suite à ne divulguer qu'un ou deux paramètres pour chaque caractéristique.

MODELE NUMERIQUE DES DONNEES MESUREES

Parallèlement aux connaissances exprimées par les modèles symboliques qui sont imprécises et incertaines car

n'étant qu'une généralisation qualitative de la connaissance, nous disposons de mesures délivrées par la phase de segmentation qui elles sont entachées d'incertitude.

Afin de pouvoir faire un lien entre le domaine symbolique et le domaine numérique, nous utilisons une méthode s'appuyant sur la théorie des sous-ensembles flous [16], permettant de supporter des raisonnements qualitatifs [17]. Ce processus est essentiel pour comparer les informations expertes (en langage naturel) avec la réponse du système numérique (données floues).

Système d'Inférences Floues

Pour notre application, nous avons besoin d'une méthode qui nous permette de manipuler à la fois des informations numériques (données) et des informations symboliques (connaissances) dans un même référentiel. Concernant la partie numérique nous voulons manipuler des données précises mais incertaines, générer des règles automatiquement par apprentissage fonctionnant avec un nombre d'échantillons restreint, interpréter le système de règles obtenu pour le comparer au modèle symbolique. De plus, la méthode doit être simple à mettre en œuvre afin de permettre un temps de calcul compatible avec les contraintes « temps réel » du système industriel.

Il existe de nombreuses méthodes permettant d'obtenir automatiquement les règles floues [1] [16] à partir d'un lot de données [18] [19]. Par rapport aux critères évoqués dans le paragraphe précédent, notre choix s'est porté sur une méthode itérative qui permet la manipulation d'un grand nombre de prémisses.

L'algorithme de base [5] a fait l'objet de plusieurs évolutions. La version que nous utilisons est itérative [7] et favorise la règle de réponse maximale. Cette technique fournit le meilleur résultat lorsque le découpage de l'espace des variables d'entrée est correctement effectué [6]. De plus, nous n'utilisons pas l'étape d'affinage des frontières proposé par l'algorithme pour garder les sorties les plus graduelles possibles.

Cette méthode de reconnaissance permet de générer des règles floues du type « Si... alors... » définissant les défauts. Par exemple : « SI surface (petite) ET SI couleur (foncée) ALORS défaut (nœud noir) ». Elle se décompose en trois étapes : la fuzzification des entrées, la génération des règles floues et l'ajustement. Le jeu de règles obtenu est ensuite utilisé pour inférer la reconnaissance.

La fuzzification permet de passer du domaine numérique au domaine symbolique en affectant à l'espace de représentation de chaque paramètre plusieurs variables linguistiques (par exemple la taille d'un défaut peut être « petite » ou « grande », sa couleur « claire » ou « foncée », ...).

La deuxième phase permet la génération des règles de type « Si ... alors ». Avec cette base de règles floues, la méthode décrit la perception que le système a des défauts qui lui sont présentés. Cette base est générée par apprentissage, grâce à une utilisation conjointe des connaissances expertes (définissant la structure du mo-

dèle et des paramètres à utiliser à partir des modèles symboliques) et des données numériques (lot d'apprentissage prélevé par le système de vision). La base de règles floues est stockée sous la forme d'une matrice numérique composée des paramètres du système, des classes de sorties à reconnaître et d'un degré de confiance [5]. Ce degré, associé à chaque règle, peut être assimilé à un degré de pertinence de la règle en accord avec les données d'entrée. L'ajustement représente la partie itérative de l'algorithme. Il consiste à tester chaque défaut à partir du même lot de données.

Inférence Unique

Modèle classiquement utilisé en reconnaissance de forme, il est néanmoins le plus « basique » et le plus complexe à interpréter dans le sens où le nombre de règles floues générées par ce type de structure est rapidement exponentiel. Par exemple, en considérant 10 paramètres décomposés en 3 termes linguistiques en entrée de la structure, nous aboutissons à environ 59 000 règles. Si nous passons à 11 paramètres, nous arrivons à environ 177 000 règles. D'un côté, cette structure permet de tester rapidement les performances de la méthode sur un lot de données, mais nous ne satisfaisons en aucun cas la contrainte de temps industriel de 2ms pour identifier un défaut (environ 6 ms par défaut) et nous ne pouvons interpréter un tel modèle.

Structure Arborescente

Cette structure est construite grâce à une série d'inférences uniques et est configurée par une intégration des connaissances expertes. L'intégration des connaissances expertes dans le modèle numérique, qui est rappelons-le le siège du traitement des données, ne peut se faire qu'en mettant en relation les connaissances expertes issues des deux domaines de compétences (domaine du bois et domaine de la vision industrielle).

Le mécanisme permettant la mise en relation des deux domaines consiste en la mise en correspondance des modèles symboliques de l'expertise bois et de l'expertise vision permettant ainsi de rapprocher directement un défaut aux caractéristiques visions utilisées par le système pour son identification. Le résultat de ce rapprochement est un nouveau modèle symbolique donnant la possibilité de choisir les meilleurs paramètres pour le vecteur caractéristique visant à identifier ces trois défauts. Pour ces trois types de défaut, la caractéristique commune étant la forme (étant tous trois des nœuds, leur forme est donc similaire), seules les caractéristiques de couleur et de contour sont discriminantes afin de les identifier. La caractéristique de forme permet quant à elle d'identifier des défauts plutôt ronds des défauts plutôt allongés et est utilisée plus en amont dans le modèle. La (figure 7) représente une partie du modèle numérique et plus précisément le moteur d'inférence identifiant les trois types de défauts.

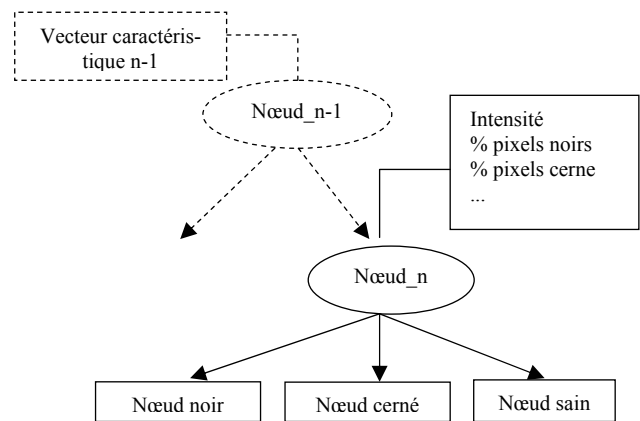


Figure 7: Résultat de l'intégration des connaissances expertes pour le choix du vecteur caractéristique du nœud décisionnel « Nœud_n » au sein de l'arborescence décisionnelle

L'intérêt de l'intégration par un Système d'Inférences Floues basé sur un système de règles linguistiques floues réside en la possibilité d'interpréter linguistiquement chaque inférence du modèle. Il est alors possible de comprendre le comportement du modèle numérique et ainsi vérifier que, d'une part, les connaissances expertes ont bien été intégrées dans le modèle, et d'autre part, qu'il existe bien une cohérence entre les données présentées au modèle et les connaissances utilisées pour le construire. Une différence entre les données et les connaissances peut signifier que les données utilisées ne sont pas réellement représentatives du domaine ou que les connaissances expertes exprimées initialement sont insuffisantes ou incomplètes.

RESULTATS

Les résultats présentés dans le tableau 1 concernent les taux de reconnaissance basé sur le Classificateur Flou (inférence unique et arborescence) ainsi que de la méthode Point, méthode actuellement utilisée par l'industriel. Le lot de données utilisé pour ces résultats est composé de 327 échantillons dont 128 utilisés en apprentissage du Système d'Inférences Floues et 199 en généralisation.

	Méthode Point	Inférence Unique	Arborescence
Taux de reconnaissance en apprentissage	68,8 %	93,0 %	86,7 %
Taux de reconnaissance en généralisation		78,4 %	83,4 %

Tableau 1: Résultat comparatifs des différentes méthodes

Les résultats que nous obtenons en sortie de notre module de reconnaissance se présentent sous la forme d'un degré de similarité [20] à la classe de sortie reconnue. En d'autres termes, nous nous intéressons à la ressemblance de notre objet à identifier avec la classe de défaut la plus proche.

Tout d'abord, nous pouvons remarquer que la méthode basée sur un Système d'Inférences Floues donne de meilleurs résultats que la méthode Point actuellement utilisée, avec au minimum 10 % de gain. En ne se focalisant que sur la méthode floue, nous pouvons noter que le meilleur taux d'identification est réalisé avec un modèle numérique construit sous forme d'une arborescence intégrant les connaissances expertes permettant un gain de 15 % en comparaison avec la méthode Point. Il est à noter que la méthode Point est une méthode non supervisée et non itérative dont le taux globale de reconnaissance est obtenu à partir d'un seul lot de données.

De plus, un autre avantage de la méthode arborescente structurée par rapport à l'inférence unique est de réduire le nombre total de règles mise en œuvre et ainsi d'améliorer également de temps de calcul. A titre de comparaison, l'identification d'un défaut est effectuée en moyenne en 1.3 ms pour la méthode arborescente contre 3.2 ms dans l'autre cas sachant que la contrainte de temps du système est de l'ordre de 2 ms par défaut.

CONCLUSION ET PERSPECTIVES

L'intégration de connaissances que nous proposons permet une meilleure cohérence entre le modèle numérique de traitement des données et les connaissances expertes utilisées pour le construire. Cette intégration permet également l'obtention d'un modèle numérique non empirique dans le sens où les paramètres constituant chaque nœud décisionnel ne sont plus choisis empiriquement mais d'après les connaissances émises par les experts des domaines du bois et de la vision industrielle.

Cette étude démontre que notre arborescence améliore les taux et les temps d'identification permettant ainsi une augmentation non négligeable de la qualité du système et donc de la qualité finale du produit. En effet, effectuant une meilleure reconnaissance des défauts de la planche, nous diminuons le risque de mauvaise identification et par la même, le déclassement intempestif dû à une mauvaise reconnaissance ou la coupe de zones saines d'une planche vues comme déclassantes ou indésirables.

Les travaux à venir visent l'acquisition et formalisation des connaissances non modélisées jusqu'à présent. Ces connaissances concernant la hiérarchie entre les attributs de défauts, c'est-à-dire l'ordre d'importance des attributs pour l'identification d'un défaut. L'expert considère t-il la couleur, la forme, la taille, ... comme étant la caractéristique primaire discriminante ? Ces connaissances permettraient d'affiner la structuration du modèle numérique actuel dans le sens où nous n'aurions plus une structure arborescente empirique mais une arborescence que l'on pourrait qualifier de structurée.

De plus, le formalisme NIAM/ORM actuellement utilisé ne supporte pas suffisamment la restitution de l'imprécision inhérente au langage naturel. Nous pensons donc reprendre et approfondir les travaux effectués par M. Zgorzelski et Z. Zalewski sur *Fuzzy NIAM* [21] pour fournir un cadre unique de modélisation et

d'intégration de connaissances expertes (qualitatives) certaines mais imprécises et de données mesurées (quantitatives) précises mais incertaines.

Par ailleurs, il est possible d'exprimer en UML (Unified Modeling Language) les modèles issus de l'application de la méthode NIAM. Cette expression s'effectue par des équivalences entre les deux formalismes telles que présentées en [22]. Cette possibilité nous permet d'utiliser au mieux la méthode NIAM pour une construction rigoureuse des modèles symboliques en lien permanent avec leur expression en langage naturel et de n'exploiter d'UML que ses formalismes unifiés et standardisés.

BIBLIOGRAPHIE

1. B. BOUCHON-MEUNIER, *La logique floue et ses applications*, Addison-Wesley, 1995.
2. H. KAUPPINEN, H. RAUTIO, and O. SILVEN, *Non-segmenting defect detection and SOM based classification for surface inspection using color vision*, Actes de : Polarization and Color Techniques in Industrial Inspection (SPIE 3826), Munich, Germany, 1999, pp. 270 – 280.
3. J. LAMPINEN, S. SMOLANDER, and M. KORHONEN, *Wood surface inspection system based on generic visual features*, Actes de : International Conference on Artificial Neural Networks ICANN'95, Paris, 1995.
4. D.T. PHAM, and S. SAGIROGLU, *Training multi-layered perceptrons for pattern recognition: a comparative study of four training algorithms*, International Journal of Machine Tools & Manufacture, Vol. N°41, # 3, 2001, pp. 419-430.
5. H. ISHIBUCHI, K. NOZAKI, and H. TANAKA, *Distributed representation of fuzzy rules and its application to pattern classification*, Fuzzy Sets and Systems, Vol. N° 52, 1992, pp. 21-32.
6. H. ISHIBUCHI, K. NOZAKI, N. YAMAMOTO, and H. TANAKA, *Construction of fuzzy classification systems with rectangular fuzzy rules using genetic algorithms*, Fuzzy sets and systems, Vol. N° 65, 1994, pp. 237-253.
7. K. NOZAKI, H. ISHIBUCHI, and H. TANAKA, *A Simple but powerful heuristic method for generating fuzzy rules from numerical data*, Fuzzy sets and systems, Vol. N° 86, 1997, pp. 251-270.
8. H. HABRIAS, *Le modèle relationnel binaire. Méthode I.A. (NIAM)*, éditions Eyrolles, 1998.
9. S.Y. FOO, *A rule-based machine vision for fire detection in aircraft dry bays and engine compartments*, Knowledge-Based Systems, Vol. N°9, 1996, pp 531-540.

10. C.S. WANG, X.K. GONG, *A fuzzy approximate reasoning model for a rule-based system in laser threat recognition*, Fuzzy Sets and Systems 96, 1998, pp 139-146.
11. Z. WEN, Y. TAO, *Building a rule-based machine-vision system for defect inspection on apple sorting and packing lines*, Expert Systems with Applications, Vol. N°16, 1999, pp 307-313.
12. V. BOMBARDIER, C. MAZAUD, P. LHOSTE, *Modélisation et intégration de connaissances métier pour l'identification de défauts par règles linguistiques floues*, TS Traitement du Signal, vol. 31, n° 3, 2004, pp. 227-247.
13. T.A. HALPIN, *Object Role Modeling (ORM/NIAM)*, Handbook on Architectures of Information Systems, 1998, chapitre 4.
14. T.A. HALPIN, *Information Modelling and Relational Databases*, published by Morgan Kaufman edition, 2001.
15. J.C. BLAISE, *Apport d'une modélisation de l'information normative à l'intégration des règles de sécurité des machines en conception*, Thèse d'université, Université Henri Poincaré, NANCY 1, 2000.
16. A. KAUFMANN, *Introduction à la théorie des sous-ensembles flous*, édition Masson, 1975.
17. L.A. ZADEH, *The concept of linguistic variable and its application to approximate reasoning*, Information sciences, Vol. N°8, 1975, pp. 199-249 et pp. 301-357.
18. O. CORDON, M.J. DEL JESUS, F. HERRERA, *A proposal on reasoning methods in fuzzy rule-based classification systems*, Int. Jour. of Approximate reasoning, 20, 1999, p. 21-45.
19. M.R. BERTHOLD, *Mixed fuzzy rule formation*, Int. Jour. of Approximate Reasoning, vol. 32, 2003, p. 67-84.
20. D. DUBOIS, H. PRADE, *The semantics of fuzzy sets*. Fuzzy Sets and Systems, vol. 90, 1997, pp.141-150.
21. M. ZGORZELSKI, Z. ZALEWSKI, *Fuzzy NIAM for real world data modelling*, I.S.A.T.A. 29th International Symposium on Automative Technology and Automation, Florence, 1996.
22. T. HALPIN, A. BLOESCH, *A comparison of UML and ORM for data modeling*, <http://www.orm.net/pdf/orm-emm98.pdf>