

Identification de défauts du bois par règles linguistiques floues

C. MAZAUD¹

V. BOMBARDIER¹

P. LHOSTE¹

¹Centre de Recherche en Automatique de Nancy, CNRS, UMR 7039
Faculté des Sciences - Bd des Aiguillettes - BP 239 - 54506 Vandoeuvre les Nancy Cedex

Vincent.Bombardier@cran.uhp-nancy.fr

Pascal.Lhoste@cran.uhp-nancy.fr

Résumé – Cet article présente une méthode de reconnaissance de défauts sur des planches de bois basée sur un mécanisme de raisonnement par inférence floue de type Larsen. Le raisonnement flou nous permet de prendre en compte la variabilité intrinsèque des défauts, car ils sont qualifiés subjectivement et leur frontière est définie de façon imprécise dans l'image. L'utilisation de ce mécanisme flou améliore le taux de reconnaissance de façon significative, autorise une plus grande variabilité intra classe des défauts et facilite la phase de réglage en proposant un apprentissage automatique à partir d'un faible nombre d'échantillons.

Abstract – This article presents a method of defect recognition on wooden boards based on a mechanism of reasoning by a Larsen fuzzy inference. The fuzzy reasoning allows taking into account the intrinsic variability of defects, because they are qualified subjectively and their border is defined in a vague way in the image. The use of this fuzzy mechanism improves in a significant way the rate of recognition, authorizes a higher variability of will intra class of defects and facilitates the phase of adjustments by proposing an automatic training even with a low number of samples.

1. 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, de transformer la Connaissance en Information, d'autre part, d'extraire l'Information à partir de Données numériques prélevées sur le système et, enfin, d'intégrer ces Informations d'origines différentes en un seul référentiel d'Information Système.

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'amélioration d'un système de reconnaissance par vision de défauts sur des planches de bois. L'analyse des planches s'effectue en temps réel sur une ligne de production dont la vitesse peut atteindre 5 mètres par seconde. Les planches présentent au maximum 200 défauts par mètre, ce qui fixe les

contraintes de temps du système pour l'identification d'un défaut.

Le mécanisme de reconnaissance se base sur l'exploitation d'un vecteur caractéristique formé de paramètres calculés sur l'image des défauts (surface d'un défaut, orientation, couleur, ...). Les travaux que nous présentons ne concernent que la partie des traitements de haut niveau et s'affranchissent des défauts de classification de l'étape de segmentation.

Les difficultés spécifiques à ce problème de reconnaissances de formes proviennent de deux sources différentes. D'une part, nous avons des problèmes d'imperfections liés à l'étape de segmentation, car la limite réelle entre les défauts et le bois sain n'est pas stricte, mais plutôt progressive. Nous obtenons donc un vecteur caractéristique imprécis. D'autre part, les classes de défauts sont, par nature, non disjointes car il existe, par exemple, une variation graduelle entre un petit noeud noir et un grand noeud noir. En outre, ces classes sont définies par des experts métier et le classement peut être subjectif, en ce sens où une personne peut nommer un défaut « noeud sain » et une autre appeler ce même défaut « noeud noir ». Enfin, la généralisation à d'autres essences de bois est également difficile.

Pour pallier ces problèmes, nous avons choisi d'utiliser des mécanismes issus de la théorie des ensembles flous et plus particulièrement les règles linguistiques floues pour implémenter le mécanisme de raisonnement. Nous avons donc pris le parti d'utiliser un moteur d'inférence à base de règles linguistiques floues pour traiter le vecteur caractéristique. Pour obtenir le modèle numérique, nous nous basons sur la méthode de Nozaki –Tanaka [7] [8].

Ce travail fait partie d'une étude plus importante visant à l'amélioration du système d'identification des défauts par intégration des connaissances « métier ». Afin d'intégrer ces connaissances, nous formalisons les connaissances des experts métier sur la définition des défauts ainsi que sur les paramètres de vision utilisés, que ceux-ci fournissent en langage naturel. En effet, nous avons entrepris une modélisation symbolique des informations portées par la connaissance métier [6] en utilisant la méthode NIAM/ORM [3] [4] [5].

L'intégration de ces trois modèles, le modèle symbolique « expert procédé bois », le modèle symbolique « expert vision » et le modèle numérique, exprimant chacun un point de vue particulier sur le système étudié doit permettre d'élaborer un référentiel d'information unique et cohérent dans le domaine spécifique étudié. Ainsi, nous avons pu qualifier chaque défaut en terme de caractéristique « vision ».

2. Le 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 rouges, 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.

La figure 1 résume le principe d'acquisition de l'image par le système de vision.

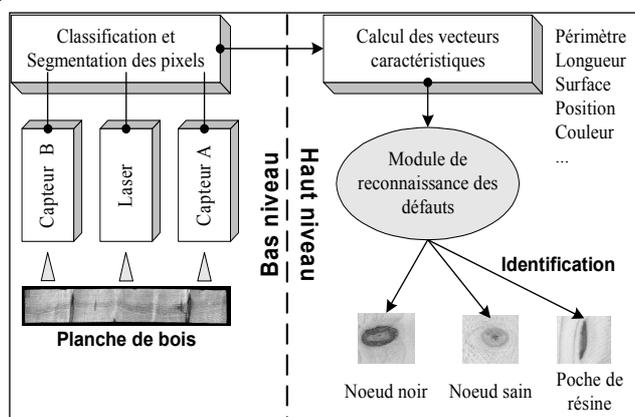


FIG. 1 : système de vision

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 zones dites « saines ».

Un ensemble de paramètres est calculé sur ces régions pour fournir le vecteur caractéristique utilisé par l'étape d'identification qui a pour objectif de donner un nom au défaut : « noeud noir », « noeud sain », « poche de résine », « fentes », ...

3. Le modèle numérique

Contrairement aux valeurs numériques fournies par le processus de traitement d'images, les classes de défauts sont fournies par des Humains à partir desquels nous avons définis des modèles symboliques. Ces modèles sont une généralisation qualitative de la connaissance.

Afin de pouvoir faire un lien entre quantitatif et qualitatif, nous procédons à une fuzzification des caractéristiques qui permet d'associer à chaque valeur numérique une valeur symbolique qui qualifie cette donnée. Cette méthode s'appuie sur la théorie des sous-ensembles flous permettant de supporter des raisonnements qualitatifs [9]. Ce processus est essentiel pour comparer les informations expertes (en langage naturel) avec la réponse du système (données floues). En effet, par analyse du modèle numérique obtenu lors de l'apprentissage, nous pouvons comparer les règles générées avec celles délivrées par les experts et ainsi corriger le modèle numérique.

Nous exposons dans la suite la méthode choisie pour supporter au mieux les données à traiter (figure 2).

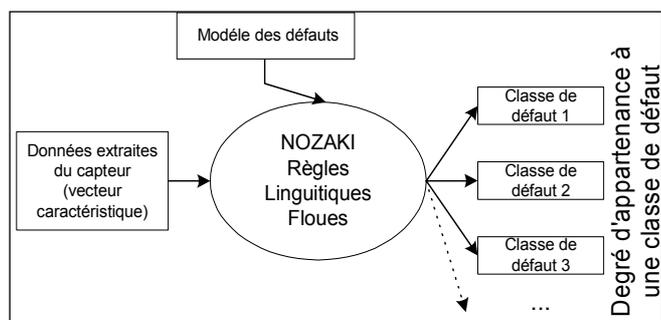


FIG. 2 : modèle numérique

3.1 La méthode de Nozaki-Tanaka

Comme nous l'avons vu précédemment, nous utilisons un module de reconnaissance basé sur la logique floue. Notre choix s'est porté sur la méthode de Nozaki-Tanaka [7] [8] que nous avons modifiée et adaptée à notre problème. Cette méthode de reconnaissance est une méthode itérative, mettant en œuvre un mécanisme d'apprentissage supervisé. Elle permet de générer des règles floues du type « Si ... alors ... » définissant les défauts. Par exemple : « SI surface (petite) ET SI couleur (foncée) ALORS défaut (noeud noir) ».

Généralement, lorsqu'on utilise un mécanisme de raisonnement flou de type Larsen, les règles sont données par

un expert. Un des avantages de la méthode retenue est de fournir automatiquement ces règles par apprentissage.

La méthode de Nozaki-Tanaka se déroule en trois étapes : la fuzzification des entrées, la génération des règles floues et l'ajustement. Le jeu de règles obtenu est ensuite utilisé pour effectuer la reconnaissance.

3.1.1 Fuzzification des entrées

Cette étape permet de passer du domaine numérique au domaine symbolique, dans lequel on attribue un degré d'appartenance à chaque sous-ensemble flou correspondant aux termes linguistiques associés à la variable.

Ces termes sont choisis en rapport avec le vocabulaire utilisé par l'expert. L'intensité peut prendre le qualificatif « sombre » ou « claire », la surface peut être « petite », « moyenne » ou « grande ».

Le choix du nombre de termes pour qualifier une variable est souvent empirique. Généralement, on retient une équirépartition des termes et un nombre de termes impair, relativement faible (trois ou cinq) pour ne pas avoir un nombre de règles trop important.

Dans notre cas, la décomposition est effectuée de deux manières. D'une part par des connaissances exprimées par les experts. Par exemple, il y a trois types de noeud « petit, intermédiaire et grand » qui conduisent à une décomposition des paramètres de vision associés à la taille en trois termes.

D'autre part, nous centrons les noyaux des fonctions d'appartenance à partir d'une analyse du lot d'apprentissage. L'adaptation des termes aux données permet, sinon d'améliorer la reconnaissance, du moins de diminuer le nombre d'itérations de la méthode.

La figure 3 illustre une fuzzification d'un paramètre en trois termes.

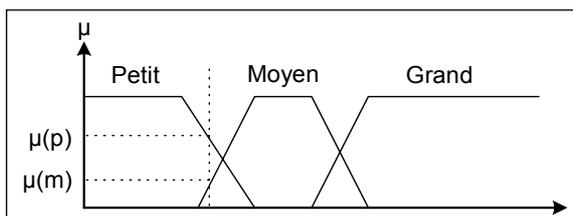


FIG. 3 : Fuzzification d'une entrée en trois termes

3.1.2 Génération de règles floues

Cette deuxième étape permet la génération de règles floues de type « Si ... alors ... ». Dans le cas où nous avons deux paramètres x_1 et x_2 en entrée et une donnée de sortie x_3 , la forme générale de la règle floue est :

SI x_1 est A_i **ET SI** x_2 est A_j **ALORS** x_3 est dans la classe de défaut C_i

Avec : A_i et A_j les sous-ensembles flous (par exemple 'petit' et 'grand') et C_i la classe du $i^{\text{ème}}$ défaut

A partir de l'ensemble des points du lot d'apprentissage, un calcul prend en compte l'ensemble des degrés d'appartenance à la classe C_i par rapport à celui des autres classes. En fonction du résultat, on affecte à chaque règle un degré de confiance CF.

Chaque règle délivre une conclusion partielle qui est ensuite agrégée aux autres pour fournir la conclusion finale. L'inférence repose sur le modèle de Larsen [1] qui utilise comme opérateur de pseudo implication floue la composition max-produit.

3.1.3 Ajustement

L'ajustement représente la partie itérative de l'algorithme. Il consiste à tester, à partir du même lot de données, chaque défaut. Si la classe de défaut obtenue en appliquant les différentes règles correspond à la classe réelle du défaut, alors le coefficient de vérité de la règle est renforcé. Dans le cas contraire, on le diminue. Ce mécanisme permet au système d'ajuster le découpage de l'espace de représentation. Les fonctions d'appartenance sont ensuite pondérées en fonction du degré de confiance accordé à la règle.

Il est à noter que la méthode de Nozaki-Tanaka propose une phase supplémentaire d'affinage qui vise à augmenter le degré d'appartenance à la classe d'appartenance maximale en modifiant les pentes des fonctions d'appartenance. A l'extrême, cette phase permet d'avoir une représentation binaire. Nous n'utilisons pas cette étape car nous voulons conserver la gradualité des réponses. En effet, nous préférons ne pas classer un défaut dont le degré d'appartenance à la classe maximale est faible, plutôt que de faire une mauvaise identification.

Dans ce sens, nous nous rapprochons de la notion de rejet en ambiguïté [2] d'un classificateur bayésien. Néanmoins, l'idée de lever ultérieurement cette ambiguïté par l'utilisation d'un module de niveau supérieur, exploitant, par exemple, une vue plus générale de la planche (mise en correspondance des faces, proximité des défauts du même type, ...).

3.2 Exemple de construction de l'Inférence

Dans cette partie, les résultats sont obtenus à partir d'un moteur d'inférence comportant onze paramètres en entrée et quatorze classes de défauts en sortie. Sachant qu'en moyenne chaque paramètre est décomposé en trois termes, nous aboutissons à 3^{11} règles floues générées. Les paramètres retenus comme prémisses des règles linguistiques floues ont été choisis à partir des modèles linguistiques

Pour des raisons de confidentialité, nous ne pouvons pas vous présenter le modèle dans sa totalité, cependant voici un exemple d'inférence unique visant à différencier trois défauts (noeud noir, petit noeud noir et noeud noir en bord de planche).

Grâce aux connaissances « métier » recueillies et formalisées, nous avons pu déterminer que les caractéristiques de taille et de position permettent de différencier ces trois défauts. Les paramètres de vision associés à la taille sont

Larg_re, *Long_re*, *Pt_axe*, *Surf* et celui associé à la position est *C4*.

Le moteur d'inférence unique visant à identifier ces trois défauts est représenté par la figure 4.

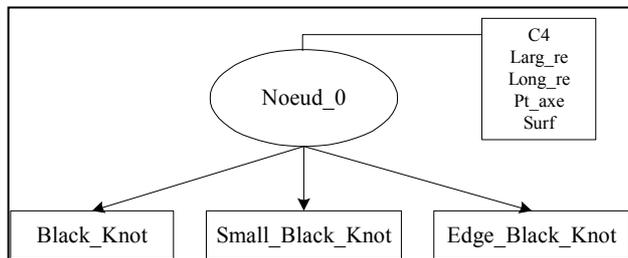


FIG. 4 : moteur d'inférence visant à identifier trois défauts

Les résultats de l'identification obtenus sont résumés dans les tableaux 1 et 2.

TAB. 1 : résultats de l'identification sur le lot d'apprentissage

Nombre d'échantillons	Pourcentage de bien classé	Nom du défaut
10	100.0	Black Knot
4	100.0	Small Black Knot
10	90.0	Edge Black Knot
Pourcentage global d'identification :		95.9 (23 sur 24)

TAB. 2 : résultats de l'identification sur le lot de généralisation

Nombre d'échantillons	Pourcentage de bien classé	Nom du défaut
4	100.0	Black Knot
20	100.0	Small Black Knot
2	50.0	Edge Black Knot
Pourcentage global d'identification :		96.2 (25 sur 26)

3.3 Résultats

Les résultats obtenus par l'application de cette méthode sont probants. Le taux de reconnaissance global avoisine les 65%, pour une fuzzification des caractéristiques en trois termes équirépartis. Néanmoins le temps d'identification d'un défaut est trop important. Il est aujourd'hui d'environ 6 ms.

Nous obtenons de meilleurs résultats avec une fuzzification adaptée aux variables caractéristiques puisque le taux de reconnaissance global atteint 85%. De plus, en diminuant le nombre de termes pour certaines variables, nous avons abaissé le temps moyen d'identification à 2 ms par défaut.

En comparaison, la méthode utilisée sur les systèmes existants donne un taux global de reconnaissance moins bon puisque celui-ci atteint les 72%.

Ces essais ont été menés sur un lot de 89 défauts mis à notre disposition par la société Luxscan Technologies. Aux vues du nombre relativement faible d'échantillons, nous avons utilisé la méthode du « laissé pour compte » [2] pour calculer le taux de reconnaissance totale. Ce taux représente l'association du taux de mémorisation et du taux de généralisation.

4. Conclusion et perspectives

Les essais réalisés montrent que le modèle numérique fournit des résultats comparables aux méthodes essentiellement bayésiennes utilisées sur les systèmes existants. Il offre, en outre, une facilité de paramétrage avec la phase d'apprentissage en simplifiant la phase d'installation.

Un des problèmes majeurs étant le faible nombre d'échantillons disponibles pour l'apprentissage et la difficulté d'obtenir des probabilités a priori significatives par exemple.

Néanmoins, bien que les résultats obtenus soient très satisfaisants, cette méthode à l'inconvénient majeur de ne pas respecter la contrainte de temps industrielle fixée à 2 ms pour l'identification d'un défaut. En effet, nous obtenons environ 6 ms (sur un Pentium 4 cadencé à 2 GHz).

C'est pourquoi, nous devons encore effectuer des essais visant à simplifier le modèle, en supprimant par exemple les règles inactives pour l'identification des défauts.

De plus, nous développons une forme arborescente de la méthode de Nozaki-Tanaka qui permet une réduction des temps de calcul en réduisant le nombre de caractéristiques utilisé à un niveau donné. Ceci nous donne alors un modèle numérique performant aussi bien du point de vue du temps d'identification que du point de vue du taux de reconnaissance.

Références

- [1] B. Bouchon-Meunier, « la logique floue et ses applications », Addison-Wesley, 1995.
- [2] B. Dubuisson, « Diagnostic, intelligence artificielle et reconnaissance des formes », édition Hermès, 2001.
- [3] H. Habrias, « introduction aux spécifications », édition Masson, Paris, ISBN n°2-225-82768-0, 368 p., 1993.
- [4] T.A. Halpin, "Object Role Modeling (ORM/NIAM)", *Handbook on Architectures of Information Systems*, 1998.
- [5] T.A. Halpin, "Information Modelling and Relational Databases", published by Morgan KAUFMAN edition, 2001.
- [6] C. Mazaud, V. Bombardier et P. Lhoste, « Modélisation de connaissances pour l'identification de défauts sur des planches de bois », *ORASIS 2003, Journées Francophones des Jeunes Chercheurs en Vision par Ordinateur*, Gérardmer, France, pages 269-277, 2003.
- [7] K. Nozaki, H. Ishibuchi and H. Tanaka, "Trainable Fuzzy Classification Systems based On Fuzzy If-Then Rules", *Proc. Of the 3rd IEEE Int. Conf. On Fuzzy Systems*, Orlando, USA, pages 498-502, 1994.
- [8] K. Nozaki, H. Ishibuchi and H. Tanaka, "A Simple but powerful heuristic method for generating fuzzy rules from numerical data", *Fuzzy sets and systems 86*, pages 251-270, 1997.
- [9] L.A. Zadeh, "The concept of linguistic variable and its application to approximate reasoning" *Information sciences*, Vol. 8, p199-249, 1975.