

# Approche hybride de classification à base de treillis de Galois: application à la reconnaissance de visages

Brahim Douar\*, Chiraz Latiri\*, Yahya Slimani\*

\*Unité de recherche URPAH - Faculté des Sciences de Tunis  
b.douar@gmail.com, chiraz.latiri@gnet.tn, Yahya.slimani@fst.rnu.tn

**Résumé.** La recherche dans le domaine de la reconnaissance de visages profite des solutions obtenues dans le domaine de l'apprentissage automatique. Le problème de classification de visages peut être considéré comme un problème d'apprentissage supervisé où les exemples d'apprentissage sont les visages étiquetés. Notre article introduit dans ce contexte une nouvelle approche hybride de classification qui utilise le paradigme d'apprentissage automatique supervisé. Ainsi, en se basant sur le fondement mathématique des treillis de Galois et leur utilisation pour la classification supervisée, nous proposons un nouvel algorithme de classification baptisé CITREC ainsi que son application pour la reconnaissance de visages. L'originalité de notre approche provient de la combinaison de l'analyse formelle de concepts avec les approches de classification supervisée à inférence bayésienne ou à plus proches voisins. Une validation expérimentale est décrite sur un benchmark du domaine de la reconnaissance de visages.

**Remerciements :** Ce travail est partiellement soutenu par le projet Franco-Tunisien Utique 05G1412, "Fouille de données et Parallélisme".

## 1 Introduction et contexte général

Savoir déterminer de manière à la fois efficace et exacte l'identité d'un individu est devenu un problème critique dans notre société. En matière de sécurité, la biométrie ne cesse d'apporter des solutions de plus en plus efficaces. Elle consiste à identifier une personne à partir de ses caractéristiques physiques ou comportementales. Le visage, les empreintes digitales, l'iris, etc, sont des exemples de caractéristiques physiques. La voix, l'écriture, le rythme de frappe sur un clavier, etc, sont des caractéristiques comportementales.

Dans la littérature récente, les recherches portent sur plusieurs problématiques de l'identification biométrique, et surtout sur la reconnaissance de visages qui s'avère une méthode, d'une part, simple pour l'utilisateur puisqu'une brève exposition devant une caméra permet de l'identifier ou de l'enregistrer dans le système et d'autre part, la reconnaissance de visages n'est pas encore un problème résolu comme l'ont montré les évaluations conduites par NIST<sup>1</sup> (Phillips et al., 2003).

---

<sup>1</sup>NIST : National Institute of Standards and Technology

La recherche dans le domaine de la reconnaissance de visages profite des solutions obtenues dans le domaine de l'apprentissage automatique. En effet, le problème de classification de visages peut être considéré comme un problème d'apprentissage supervisé où les exemples d'apprentissage sont les visages étiquetés. Notre article introduit dans ce contexte une nouvelle approche hybride de classification qui utilise le paradigme d'apprentissage automatique supervisé. Il est organisé en cinq sections. Dans la deuxième section, nous présentons brièvement les principales approches de reconnaissance de visages. La section 3 présente un aperçu sur la classification supervisée et les treillis de Galois. En se basant sur le fondement mathématique des treillis de Galois et leur utilisation pour la classification supervisée, nous décrivons un nouvel algorithme de classification baptisé CITREC dans la section 4. Son application pour la reconnaissance de visages et la validation expérimentale sont détaillés dans la section 5.

## 2 La reconnaissance de visages

Les travaux qui se sont intéressés à la reconnaissance de visages dans un environnement sous différentes conditions d'éclairage, d'expressions faciales et d'orientations, peuvent être classés en deux catégories suivant l'approche suivie. Nous allons décrire dans ce qui suit ces deux principales approches sachant qu'une revue détaillée des principales techniques de reconnaissance de visages est donnée dans (Enuganti, 2005).

### 2.1 L'approche géométrique

Elle englobe une famille de méthodes appelées méthodes analytiques ou à caractéristiques locales. Elles sont dites analytiques puisque, en vue de reconnaître un certain visage et le classer, elle procède par son analyse. En effet, il est possible d'attribuer une certaine description du visage humain, et ce, en rappelant ses parties et leurs relations. Nombreuses sont les démarches qui ont essayé de modéliser et de classer les visages en se basant sur des mesures de distances normalisées et d'angles entre des points caractéristiques du visage humain (Kamel et al., 1993). Ce qui rend ces méthodes intéressantes est qu'elles prennent en compte la spécificité du visage en tant que forme naturelle à reconnaître. Elles considèrent aussi un nombre réduit de paramètres (entre 9 et 14 distances (Kamel et al., 1993)).

### 2.2 L'approche globale

Les méthodes dites globales traitent les propriétés globales du visage. Elles sont fondées essentiellement sur l'information pixel, un point singulier dans une image. Le visage est traité comme un tout. Le système (ou classifieur) apprend ce qu'est un visage à partir d'un ensemble d'exemples. Ce type de systèmes de reconnaissance est très efficace, reste que la phase d'apprentissage s'avère lourde à mettre en œuvre (Yang et al., 2002). Parmi les approches les plus utilisées, nous pouvons citer : l'approche de visages propres, l'approche stochastique, l'approche statistique et probabiliste et l'approche connexionniste.

### 3 Classification Supervisée et Treillis de Galois

Une des méthodes les plus utilisées de l'apprentissage automatique est celle de la classification qui consiste à répartir systématiquement de nouveaux objets selon des classes établies au préalable. Classifier un objet consiste à lui faire correspondre une classe marquant sa parenté avec d'autres objets. Une classe désigne un ensemble défini de données et d'objets semblables. Ces données et objets, éléments d'une classe, sont des instances.

Les treillis de concepts formels (ou treillis de Galois) sont une structure mathématique permettant de représenter les classes non disjointes sous-jacentes à un ensemble d'objets (exemples, instances, tuples ou observations) décrits à partir d'un ensemble d'attributs (propriétés, descripteurs ou items). Ces classes non disjointes sont aussi appelées concepts formels, hyperrectangles ou ensembles fermés. Une classe matérialise un concept (à savoir une idée générale que l'on a d'un objet). Ce concept peut être défini formellement par une extension (exemples du concept) ou par une intension (abstraction du concept) (Nguifo et Njiwoua, 2005). Étant donné que, notre approche se base sur l'approche de Xie, nous présentons brièvement dans ce qui suit les systèmes  $CL_{NN}$  et  $CL_{NB}$  présentés dans (Xie et al., 2002).

#### 3.1 Les systèmes $CL_{NN}$ et $CL_{NB}$

L'approche de Xie (Xie et al., 2002) consiste en deux algorithmes qui se nomment  $CL_{NB}$  (Concept Lattices Naïve Bayes) et  $CL_{NN}$  (Concept Lattices Nearest Neighbors). Ces deux systèmes incorporent respectivement un classifieur bayésien naïf (R. Duda, 1973) et un classifieur par plus proches voisins (Dasarathy, 1991) au sein des nœuds du treillis de concepts.

L'idée directrice de cette approche est le fait d'associer à chaque concept du treillis vérifiant certaines contraintes de sélection un classifieur contextuel. L'apprentissage de chacun de ces classifieurs est effectué seulement sur l'extension du concept en question. Ensuite, lors du classement, on vérifie si la nouvelle instance à classer correspond bien à l'intension du concept alors on utilise le classifieur correspondant pour déterminer sa classe. Il est à noter que les deux systèmes ( $CL_{NB}$  &  $CL_{NN}$ ) reposent sur le même principe, tant en apprentissage qu'au classement. L'unique différence réside dans le choix du type du classifieur contextuel utilisé par chacun de ces deux classifieurs. Le treillis de concepts est utilisé pour sélectionner le sous-ensemble d'instances qui sera utilisé par le classifieur contextuel lors de l'apprentissage et du classement (Nguifo et Njiwoua, 2005).

Il ressort des résultats en prédiction présentés par l'auteur dans (Xie et al., 2002), qu'en général, les méthodes  $CL_{NB}$  et  $CL_{NN}$  améliorent respectivement la prédiction des méthodes NB et NN prises individuellement. En outre,  $CL_{NB}$  obtient des résultats en moyenne supérieurs à ceux des trois autres systèmes sur ces jeux de données. Il est à noter que nous distinguons trois limites non négligeables de cette approche, à savoir :

- Approche non incrémentale, ce qui signifie qu'à chaque nouvelle instance ajoutée dans la base, le processus d'apprentissage doit être relancé ;
- Complexité élevée et lourdeur de la phase d'apprentissage ;
- Problème de mise à l'échelle (Scalability), la construction du treillis dépend énormément du nombre d'instances.

Pour pallier certaines de ces limites avec un minimum de compromis, nous proposons dans la section qui suit un nouvel algorithme de classification que nous nommons CITREC et que nous appliquerons dans la problématique de la reconnaissance de visages.

## **4 CITREC : Nouvelle approche hybride de classification à base de Treillis de Galois**

Dans cette section nous allons introduire un nouvel algorithme, baptisé CITREC (Classification Indexée par le TREillis de Concepts), dont l'objectif principal est de pallier les principales limites de l'approche de Xie (Xie et al., 2002).

### **4.1 Principe général de CITREC**

Tout comme l'approche de Xie (Xie et al., 2002), l'idée principale de notre approche demeure le fait d'utiliser le treillis de concepts pour sélectionner le sous-ensemble d'instances qui sera utilisé par un classifieur contextuel lors de l'apprentissage et du classement.

L'originalité de notre approche concerne essentiellement la phase d'apprentissage et plus précisément la construction du treillis qui consiste à le construire à partir d'un contexte réduit contenant seulement une instance représentative de chaque classe et non pas tout l'ensemble d'apprentissage. Ceci va nettement réduire le temps de construction en plus de l'amélioration de la mise à l'échelle (Scalability) sans perte d'informations. Pour chaque nœud du treillis qui satisfait certaines contraintes que nous présentons plus loin dans cette section, un classifieur de base serait entraîné sur les instances de la base d'apprentissage ayant la même classe que celles des instances représentatives dans l'extension du concept.

Quant à la phase de classement, des modifications ont été apportées à l'approche de Xie afin d'utiliser le treillis de concept comme étant un index.

Dans ce qui suit et afin d'illustrer l'explication de notre approche nous utilisons l'ensemble de données IRIS présentée dans (Fisher, 1936).

### **4.2 La phase d'apprentissage**

La phase d'apprentissage est une phase cruciale pour tout système de classification. En effet, la phase de classement ne fera qu'utiliser les données préparées lors de cette phase. Par conséquent, les performances du système en dépendront d'une façon remarquable. Lors de la phase d'apprentissage, CITREC opère en quatre étapes successives que nous décrivons dans ce qui suit.

#### **4.2.1 Prétraitement de la base d'apprentissage**

Cette étape consiste à passer d'une base d'instances d'apprentissage ayant des attributs numériques et nominaux à un contexte avec des attributs binaires uniquement. Les attributs numériques sont plus difficiles à traiter, car leur espace de valeurs est infini, d'où la nécessité de discrétiser ces attributs pour aboutir à la fin à un espace de valeurs fini qui pourra ensuite être traité d'une manière semblable à celle des attributs nominaux. Pour notre approche, et suite à une série d'expérimentations, nous avons opté pour une méthode de discrétisation non supervisée générique qui consiste à diviser l'espace de valeurs de l'attribut sur  $k$  intervalles.




FIG. 1 – Treillis d'index relatif à la base illustrative IRIS

#### 4.2.2 Réduction du contexte global

Après avoir généré le contexte général, l'idée clé de notre approche consiste à créer un nouveau contexte qui va servir à la construction du treillis d'index. Le contexte réduit, contiendra un nombre d'objets égal au nombre des classes des différentes instances de la base d'apprentissage. La taille de ce contexte est par conséquent insensible au nombre d'instances d'apprentissage, ce qui nous fera gagner en matière de temps d'exécution et de complexité lors de la construction du treillis et même lors du classement. L'idée est de sélectionner une instance représentative de chaque classe. Le choix de cette instance est assez délicat, car c'est elle qui servira à déterminer la classe de la nouvelle instance lors de la phase de classement. Nous notons que, pour mener à bien la phase de classement, cette instance devrait minimiser la somme des distances entre elle et le reste des instances de la même classe.

#### 4.2.3 Construction du treillis d'index

Quant à la construction du treillis d'index, nous notons que ce treillis (voir figure 1) sera construit sur la base du contexte réduit généré lors de l'étape précédente. Nous avons opté pour un algorithme incrémental qui est une version améliorée de celui de Godin (Godin et al., 1995). Cet algorithme est implémenté au sein de la plateforme Galicia (Valtchev et al., 2003). Il est à noter que l'incrémentalité est un aspect très important de l'algorithme de construction du treillis utilisé au sein du système CITREC. Ce choix nous permet d'ajouter de nouvelles instances à la base d'apprentissage sans pour autant régénérer le treillis d'index.

#### 4.2.4 Création et affectation des classifieurs contextuels

Une fois le treillis d'index construit, il ne reste qu'à sélectionner les nœuds pertinents et de leur affecter de nouveaux classifieurs. Par nœuds pertinents, nous désignons l'ensemble des nœuds qui satisfont deux contraintes de sélection, à savoir *la contrainte de support* et *la contrainte de non-inclusion*. Dans ce qui suit nous désignons par *CLS* un classifieur contextuel.

**La contrainte de support :** Cette contrainte peut être formalisée comme suit :  
POUR chaque règle contextuelle  $C \rightarrow CLS$ , nous avons :

$$\|Extension(C)\| \geq \alpha \times \|O_{reduits}\|$$

## Approche hybride de classification à base de treillis de Galois

Le paramètre  $\alpha$  désigne le pourcentage d'instances représentatives qui doit exister dans l'extension d'un concept pour le sélectionner et lui affecter un classifieur contextuel. Nous avons fixé ce paramètre à 10% comme valeur par défaut <sup>2</sup>.

**La contrainte de non-inclusion :** La contrainte de non-inclusion permet d'éviter de créer deux classifieurs dont le sous-ensemble d'apprentissage du premier est inclus dans celui du deuxième. Dans ce cas, le premier n'apportera pas de plus par rapport au deuxième.

Ceci peut être formalisé comme suit :

Étant donné deux règles contextuelles  $r_1 : C_1 \rightarrow CLS_1$  et  $r_2 : C_2 \rightarrow CLS_2$ , nous avons :

$$SIExtension(C_1) \subseteq Extension(C_2) \text{ alors } R = R - \{r_1\}$$

### Algorithme CITREC\_learn

**Entrée:** *Instances* : L'ensemble des instances d'apprentissage

**Sortie:**  $\mathcal{R}$  : L'ensemble des règles contextuelles

$\mathcal{R} \leftarrow \{\}$

$O = discretiser(Instances)$

$Contexte_{global} = convertir\_en\_contexte(O)$

$Contexte_{reduit} = reduire\_contexte(Contexte_{global})$

$\mathcal{L} = construire\_treillis(Contexte_{reduit})$

**Pour tout** concept  $C \in \mathcal{L}$  **Faire**

**Si**  $Support(C)$  et  $Non\_inclusion(C)$  **alors**

    Lancer l'apprentissage d'un classifieur CLS sur  $Extension(C)$

$\mathcal{R} = \mathcal{R} \cup \{C \rightarrow CLS\}$

**Retourner**  $(\mathcal{R})$

**Algorithme 1:** L'algorithme d'apprentissage de CITREC

## 4.3 La phase de classement

Lors de cette phase, CITREC reçoit en entrée une instance de classe inconnue et retourne la classe de cette instance après avoir effectué tout un processus de classification. Le processus de classification de CITREC peut être décomposé en trois étapes, à savoir :

1. **Conversion de l'instance**, qui consiste à transformer l'instance à classer de sa représentation d'origine (avec des attributs numériques et/ou nominaux) vers la représentation conceptuelle basée uniquement sur des attributs binaires, en respectant les mêmes attributs considérés lors de l'apprentissage. En d'autres termes, cette conversion devrait respecter les intervalles de chaque attribut défini lors de la discrétisation.
2. **Recherche des classifieurs contextuels activés par la nouvelle instance**. Cette étape consiste à ajouter l'instance dans notre treillis d'index et de marquer les nœuds auxquels cette nouvelle instance a été affectée. Sachant qu'on ne doit marquer que les nœuds

<sup>2</sup>Ce paramètre a été déduit d'une façon empirique. Nous notons cependant que ce paramètre ne doit pas être trop grand pour éviter d'avoir un nombre réduit de nœuds pertinents, ce qui diminue l'efficacité du vote majoritaire. Alternativement, ce paramètre ne doit pas être trop petit pour ne pas avoir trop de nœuds pertinents entraînant ainsi une détérioration de la qualité du vote.

incorporant un classifieur. La façon la plus simple de marquer ces nœuds consiste à parcourir l'ensemble des nœuds incorporant des classifieurs et de sélectionner les concepts dont l'intension de l'instance à classer est incluse dans l'intension du concept à marquer.

3. **Vote majoritaire et décision**, qui consiste à déclencher la classification de l'instance originale (avant la conversion) par les différents classifieurs contextuels concernés par l'instance à classer. Ensuite nous effectuons un vote majoritaire sur les résultats de chacun des classifieurs. La classe ayant eu plus de vote est celle de la nouvelle instance. Nous insistons sur le fait que la classification au sein des nœuds est effectuée avec l'instance brute avant le prétraitement et ceci pour surpasser la perte de précision engendrée par la discrétisation.

#### 4.4 CITREC est incrémental

L'avantage d'un système de classification incrémental est le fait que, lors de l'ajout d'une nouvelle instance à la base d'apprentissage, l'algorithme effectue seulement une mise à jour du modèle et non pas une reconstruction complète. Nous notons que CITREC est incrémental par rapport à l'ajout de nouvelles classes et non pas de nouvelles instances de classe déjà existante à la base d'apprentissage. Autrement dit, pour mettre à jour son modèle de classification, CITREC accepte en entrée un ensemble d'instances d'apprentissage d'une nouvelle classe à inclure dans le modèle. Ce qui lui permettrait de reconnaître de nouvelles classes et non pas l'amélioration de la reconnaissance des classes du modèle de base.

Lors de l'ajout d'une nouvelle classe à la base d'apprentissage, CITREC opère en quatre étapes, à savoir :

1. **Recherche de l'instance centrale.** Etant donné l'ensemble d'instances décrivant la nouvelle classe à prendre en charge, cette étape consiste à trouver l'instance centrale de ce groupe. Ceci est nécessaire, pour pouvoir l'intégrer ultérieurement au treillis d'index. Cette étape sous-entend la conversion de ces instances en une représentation à attributs binaires.
2. **Mise à jour du treillis d'index.** Cette étape nécessite un algorithme de construction du treillis de concept qui soit incrémental. Ce qui justifie notre choix pour l'algorithme de Godin (Godin et al., 1995) qui présente cet avantage. En considérant l'instance centrale déduite lors de la première étape, le treillis d'index sera mis à jour par l'ajout de cette instance.
3. **Mise à jour des nœuds affectés par l'ajout.** Il s'agit de parcourir les différents nœuds du treillis d'index affectés par l'ajout et de sélectionner les nœuds incorporant des classifieurs contextuels pour mettre à jour leurs classifieurs de base respectifs. Un point important est que, le fait de mettre à jour les classifieurs de base, sous-entend l'aspect incrémental de ceux-ci. Pour cela, nous avons opté pour des versions incrémentales de nos classifieurs de bases.
4. **Création et affectation des nouveaux classifieurs contextuels.** Suite à l'ajout de la nouvelle classe au treillis d'index, certains nœuds répondent désormais aux contraintes de *support* et de *non-inclusion*, ceci nécessite alors l'exécution de la quatrième étape de la phase d'apprentissage.

**Algorithme CITREC\_update**  
**Entrée:**  $N\_classe$  : Désigne la nouvelle classe à apprendre  
 $Instances_{N\_classe}$  : Désigne l'ensemble des instances décrivant la nouvelle classe  
**Sortie:**  $\mathcal{R}$  : Désigne l'ensemble des règles contextuelles après la mise à jour  
 $O_{N\_classe} = discretiser(Instances_{N\_classe})$   
 $Contexte_{N\_classe} = convertir\_en\_contexte(O_{N\_classe})$   
 $Instance_{centrale} = reduire\_contexte(Contexte_{N\_classe})$   
 $\mathcal{L} = MAJ\_treillis(Instance_{centrale})$   
**Pour tout** concept  $C \in \mathcal{L}$  avec  $N\_classe \in Extension(C)$  **Faire**  
    **Si**  $\exists \{r_1 : C_1 \rightarrow CLS_1\} \in \mathcal{R}$  avec  $Extension(C_1) \subset Extension(C)$  **alors**  
        Mettre à jour  $CLS_1$  pour tenir compte de  $Instances_{N\_classe}$   
    **Sinon**  
        **Si**  $Support(C)$  et  $Non\_inclusion(C)$  **alors**  
            Lancer l'apprentissage d'un classifieur CLS sur  $Extension(C)$   
             $\mathcal{R} = \mathcal{R} \cup \{C \rightarrow CLS\}$   
**Retourner** ( $\mathcal{R}$ )

**Algorithme 2:** L'algorithme de mise à jour de CITREC

## 5 Application de CITREC dans la reconnaissance de visages

Dans cette section, nous allons présenter l'application de notre approche de classification supervisée CITREC dans la problématique de reconnaissance de visages. Cette approche nous fera profiter de l'union de l'analyse formelle de concepts avec l'apprentissage à partir d'instances (classifieur à PPV (Dasarathy, 1991)) ou la classification bayésienne (classifieur bayésien naïf (R. Duda, 1973)) pour contribuer à la résolution de la problématique de reconnaissance de visages.

### 5.1 Présentation du Benchmark

Notre base de visages expérimentale est la base BioID qui consiste en 1521 images (384 x 288 pixels, niveaux de gris) de 23 personnes différentes et qui a été enregistrée durant plusieurs sessions dans différentes places et conditions d'illumination.

Le groupe de travail FGnet a procédé à l'annotation des visages de la base BioID. Cette annotation consiste à la localisation de 20 points caractéristiques du visage humain (position des yeux, de la bouche, etc.). Dans le cadre de cet article, nous avons étendu l'annotation fournie par FGnet de 20 points à 36 points caractéristiques. Les 16 points que nous avons ajoutés (voir figure 2) ont un impact remarquable sur les résultats, vu leurs emplacements stratégiques. Dans ce qui suit, nous désignons par *annoter un visage* le fait d'en localiser les points spécifiques sur sa photo.

### 5.2 Modélisation du visage humain

Formellement, le modèle du visage n'est autre qu'une traduction de la réalité qui nous permettra de l'utiliser dans le cadre de notre algorithme de classification CITREC. Ce modèle sera construit à partir des points caractéristiques du visage. Nous notons que ce modèle sera basé sur les distances entre les points et non sur leurs positions. Pour nos expérimentations,



nous avons généré en utilisant le modèle du visage et l'annotation étendue que nous avons présenté dans la section précédente, un benchmark qui comporte 30 attributs numériques avec 1521 instances. Ces instances sont réparties sur 23 classes différentes.

### 5.2.1 Formalisation mathématique

Sur un visage, nous considérons qu'un point est représenté par deux coordonnées  $x$  et  $y$ , soit  $pt_i$  un point, nous avons :  $pt_i = \{(x_i, y_i) / x_i \geq 0 \text{ et } y_i \geq 0\}$

Comme nous l'avons déjà présenté dans la section précédente, le modèle du visage se base sur les distances entre les points. Ainsi, nous désignons par  $d_{a,b}$  la distance euclidienne entre deux points  $pt_a$  et  $pt_b$ , nous avons :

$$d_{a,b} = \sqrt{(x_b - x_a)^2 + (y_b - y_a)^2} \quad \text{avec} \quad \begin{cases} 1 \leq a \leq 36 \\ 1 \leq b \leq 36 \\ a \neq b \end{cases}$$

Nous notons que toutes les distances sont normalisées par la distance entre les deux pupilles des yeux (distance entre  $pt_1$  et  $pt_2$ ) pour assurer l'invariance des mesures par rapport à la distance entre l'individu et le dispositif de capture de la photo lors de la prise de vue.

Nous désignons par  ${}^n d_{a,b}$  la distance euclidienne normalisée entre les points  $a$  et  $b$ . De ce fait, nous avons :

$${}^n d_{a,b} = \frac{d_{a,b}}{d_{1,2}} = \frac{\sqrt{(x_b - x_a)^2 + (y_b - y_a)^2}}{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}}$$

Ainsi, nous désignons par  $v$  la représentation d'un visage (voir figure 2) :

$$v = \{c_i / i = 1 \dots 30\} = \begin{pmatrix} c_1 \\ c_2 \\ \cdot \\ \cdot \\ c_{30} \end{pmatrix}$$

Nous passons dans ce qui suit à la validation expérimentale de CITREC dans la problématique de la reconnaissance de visages.

## 6 Validation expérimentale de l'approche CITREC

En vu de valider notre approche hybride de classification supervisée et souligner son apport, nous présenterons une évaluation expérimentale de CITREC. Cette évaluation est enrichie par une suite de comparaisons avec d'autres algorithmes existants dans la littérature, à savoir C4.5 (Quinlan, 1993), CART (Breiman et Friedman, 1984) et BFTree (Haijian, 2007). Les différentes comparaisons sont réalisées par rapport à trois variantes de CITREC qui sont  $CITREC_{PPV}$ ,  $CITREC_{RB}$  et  $CITREC_{BN}$ . Ces variantes incorporent respectivement un classifieur à plus proche voisins (Dasarathy, 1991), un classifieur par réseau Bayésien (Pearl, 1985) et un classifieur Bayésien naïf (R. Duda, 1973). Nous avons aussi comparé chaque variante de CITREC avec son classifieur de base correspondant. Concernant la méthode de validation,

## Approche hybride de classification à base de treillis de Galois

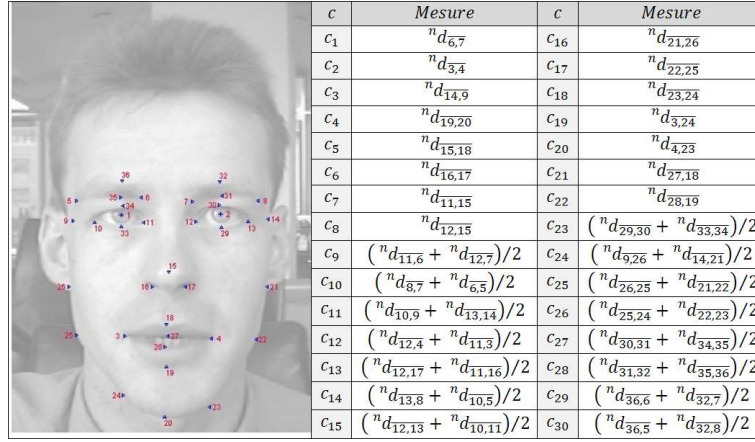


FIG. 2 – Modèle mathématique du visage

nous avons opté pour la validation croisée d'ordre 10 avec la technique leave-one-out pour la sélection des instances.

Afin de fournir des résultats vérifiables, nous avons adapté CITREC pour pouvoir l'intégrer dans l'environnement d'évaluation des algorithmes de datamining nommé WEKA (Witten et Frank, 2005).

### 6.1 Comparaison des résultats

La première étape de nos expérimentations porte sur la comparaison des résultats des différents algorithmes présentés précédemment par rapport à ceux des variantes de CITREC sur le benchmark des visages. Le tableau 1 présente ces résultats en termes de pourcentage de classifications correctes (PCC). Nous constatons un avantage des trois variantes de CITREC par rapport à leurs classifieurs de base respectifs, ainsi qu'un avantage par rapport aux autres algorithmes de la littérature. Ceci confirme expérimentalement l'adaptation de CITREC pour ce type de données, et par conséquent à la problématique de reconnaissance de visages. Nous constatons que la variante à plus proches voisins de CITREC l'emporte en matière de PCC. Ceci est due aux bons résultats de prédiction réalisés par le classifieur à plus proches voisins (Dasarathy, 1991) pour ce type de données.

### 6.2 Impact de l'extension de l'annotation sur les résultats des différents classifieurs

Nous avons présenté dans cet article, l'extension de l'annotation d'origine de la base BioID. Cette extension nous a permis de créer 15 attributs supplémentaires dans le modèle du visage (de  $c_{16}$  à  $c_{30}$  (voir figure 2)). Le tableau 1 présente les résultats relatifs à l'annotation de base et ceux de l'annotation étendue. En comparant l'annotation de base avec l'annotation étendue, nous remarquons une amélioration claire des résultats de tous les algorithmes de classification

Algorithme	Annotation de base (15 att.)	Annotation étendue (30 att.)
C4.5	78,50	79,62
BFTree	77,39	80,34
CART	77,12	80,41
PPV	92,97	96,65
CITREC <sub>PPV</sub>	<b>93,69</b>	<b>96,84</b>
Réseau Bayésien	89,28	94,67
CITREC <sub>RB</sub>	<b>91,32</b>	<b>94,94</b>
Bayésien Naïf	92,24	95,00
CITREC <sub>BN</sub>	<b>92,24</b>	<b>95,07</b>

**TAB. 1** – Comparaison des résultats des différents algorithmes avec l’annotation de base et l’annotation étendue

en utilisant le modèle issue de l’annotation étendue. Cette amélioration est due à la pertinence des attributs ajoutés, qui a augmenté la discrimination entre les personnes.

## 7 Conclusion et perspectives

Dans cet article, nous avons proposé une nouvelle méthode hybride de classification supervisée à base de treillis de Galois que nous avons nommé CITREC (Classification Indexée par le TREillis de Concepts) dont l’originalité provient de la combinaison de l’analyse formelle de concepts avec les approches de classification supervisée à inférence bayésienne (R. Duda, 1973; Pearl, 1985) ou à plus proches voisins (Dasarathy, 1991). Notre approche s’inspire de celle proposée par Xie dans (Xie et al., 2002) en essayant de pallier ses limites majeures tel que l’aspect non incrémental, la lourdeur de la phase d’apprentissage et le problème de mise à l’échelle (Scalability). Nous avons montré empiriquement sur un benchmark du domaine de la reconnaissance de visages que notre approche améliore les résultats de son classifieur de base et devance plusieurs algorithmes cités dans la littérature tels que : C4.5 (Quinlan, 1993), CART (Breiman et Friedman, 1984) et BFTree (Haijian, 2007).

Comme perspective, nous proposons d’étudier la possibilité de recourir à la logique floue pour la représentation des instances centrales des classes, et ce afin de minimiser la dégradation de la précision engendrée par la discrétisation des attributs numériques. Ce choix devrait surtout influencer la phase de génération du treillis d’index.

## Références

- Breiman, L. et J. Friedman (1984). Classification and regression tree. In *Wadsworth International*, California.
- Dasarathy, B. (1991). *Nearest Neighbor (NN) norms : NN pattern classification techniques*. IEEE Computer Society Press.

- Enuganti, P. R. (2005). *Face Recognition using Tensor Analysis*. Literature survey, University of Texas at Austin.
- Fisher, R. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 179–188.
- Godin, R., R. Missaoui, et H. Alaoui (1995). Incremental concept formation algorithms based on galois (concept) lattices. *Computational Intelligence*, 216–267.
- Haijian, S. (2007). *Best-first decision tree learning*. Rapport de master 2 de recherche, University of Waikato.
- Kamel, M. S., H. C. Shen, A. K. C. Wong, et R. I. Campeanu (1993). System for the recognition of human faces. *IBM Systems Journal* 32, 307–320.
- Nguifo, E. M. et P. Njiwoua (2005). Treillis de concepts et classification supervisée. *TSI. Technique et science informatiques*, 449–488.
- Pearl, J. (1985). *Bayesian networks : A model of self-activated memory for evidential reasoning*. Ph. D. thesis, UCLA Computer Science Department.
- Phillips, P. J., P. Grother, J. M. Ross, M. B. Duane, E. Tabassi, et M. Bone (2003). Face recognition vendor test 2002 : Overview and summary. Technical report, National Institute of Standards and Technology.
- Quinlan, J. (1993). *C4.5 : Programs for Machine Learning*. Morgan Kaufmann Publishers Inc.
- R. Duda, Hart, P. (1973). *Pattern Classification and Scene Analysis*. New York : John Wiley and Sons.
- Valtchev, P., D. Grosser, C. Roume, et M. R. Hacene (2003). Galicia : an open platform for lattices. In *11th Intl. Conference on Conceptual Structures*, Ed. Dresde, pp. 241–254.
- Witten, I. H. et E. Frank (2005). *Data Mining : Practical machine learning tools and techniques. 2nd edition*. San Francisco : Morgan Kaufmann.
- Xie, Z., W. Hsu, Z. Liu, et M. Lee (2002). Concept lattice based composite classifiers for high predictability. *Journal JETAI*, 143–156.
- Yang, M. H., D. J. Kriegman, et N. Ahuja (2002). Detecting faces in images : A survey. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*.

## Summary

In the present paper, we propose a new hybrid classification approach based on the paradigm of supervised learning. We present the use of Galois Lattices for supervised classification, by introducing a novel approach of classification and its application for faces recognition. The originality of our approach comes from the combination of the formal concepts analysis with supervised classification methods based on Bayesian inference or nearest neighbors. Carried out experiments on a benchmark of the field of faces recognition confirm that our approach improves the results of its basic classifier and outperforms several algorithms quoted in the literature such as: C4.5, CART and BFTree.