



HAL
open science

Identification de données partiellement occultées en RdF statistique

Barbara Romaniuk, Michel Desvignes, Marinette Revenu, Marie-Josèphe Deshayes

► **To cite this version:**

Barbara Romaniuk, Michel Desvignes, Marinette Revenu, Marie-Josèphe Deshayes. Identification de données partiellement occultées en RdF statistique. *Revue des Nouvelles Technologies de l'Information*, 2003, 1, pp.261-272. <hal-00843125>

HAL Id: hal-00843125

<https://hal.science/hal-00843125v1>

Submitted on 10 Jul 2013

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.



HAL Authorization

Identification de Données Partiellement Occultées en RdF Statistique.

Barbara Romaniuk*, Michel Desvignes**
Marinette Revenu*, Marie-Josèphe Deshayes***

* Laboratoire GREYC IMAGE, 6, Bvd Mal Juin, 14050 Caen cedex 4
{Barbara.Romaniuk, Marinette.Revenu}@greyc.ismra.fr

** Laboratoire LIS, 961, Rue de la houille blanche, BP 46 St Martin d'Herès
michel.desvignes@lis.inpg.fr

*** Société Télécrâne Innovation
deshayes@mail.cpod.fr
<http://www.cranexplo.net>

Résumé. Dans cet article nous nous intéressons au problème de modélisation de la variabilité de formes et de points dans le cadre de la reconnaissance de formes statistique. Nous proposons un modèle statistique non linéaire appris sur un ensemble ordonné de points. Le formalisme de l'Analyse en Composantes Principales composé avec notre modèle nous permettent de résoudre le problème d'identification de données partiellement occultées. Cette étude s'applique au problème de repérage de points céphalométriques sur des radiographies de crâne de jeunes enfants.

1 Introduction

La reconnaissance de formes statistique est confrontée au problème de modélisation d'un objet à partir d'une population d'objets connus, appelée ensemble d'apprentissage. Souvent cette modélisation ne s'intéressait qu'à l'objet moyen. Dans cet article nous proposons un modèle non linéaire permettant d'apprendre ce dernier, ainsi que la variabilité de la population et les relations spatiales existant entre les différents éléments constituant l'objet appris. Ce modèle est ensuite utilisé dans la résolution du problème d'identification des données manquantes.

L'ensemble de ces travaux a été validé en céphalométrie, dont le but est d'élaborer un diagnostic sur le rangement dentaire d'un patient à partir de points anatomiques positionnés sur des radiographies crâniennes. Ces points anatomiques sont définis par rapport à un ensemble de structures anatomiques. Nous avons donc appris l'ensemble de points et de structures anatomiques. Nous avons ensuite "reconnu" les structures dans l'image, pour en déduire la position des points en utilisant notre méthode d'identification de données partiellement occultées.

2 Modélisation de la variabilité des formes : état de l'art

La définition de la variabilité des formes que nous allons utiliser correspond à celle de (Kendall 1984) : la variabilité d'une forme par rapport à un modèle est la différence de forme restant lorsqu'elle est alignée au mieux (élimination des transformations du groupe des similarités) sur le modèle.

Cela sous entend la définition de la représentation de la forme, d'alignement et d'invariance, ce qui nous mènera à la variabilité. La description des formes utilisée par la suite consiste à la réduire à un ensemble fini de points appelés les points caractéristiques de la forme.

2.1 Analyse de Procrustes : invariance

L'alignement des formes, via des ensembles de points, peut être assuré par l'analyse de Procrustes (Bookstein 1997)(Sclaroff et Pentland 1995), qui aligne des formes deux à deux. L'algorithme généralisé de Procrustes a été précisément décrit par (Goodal 1991).

Les données se trouvent alors projetées dans un espace de formes invariant par les transformations du groupe des similarités. Cependant, cet espace (appelé variété de Procrustes) n'est pas Euclidien. Dans le cas où la variabilité de la forme est faible, il est plus intéressant de travailler dans l'espace tangent à l'espace des formes au niveau de la forme moyenne. Les propriétés Euclidiennes de l'espace tangent sont souvent plus adéquates statistiquement que les propriétés non-Euclidiennes de l'espace des formes (Dryden 1997).

2.2 Modélisation de la variabilité des formes

Les méthodes d'extraction de caractéristiques et de modélisation de la variabilité des formes consistent à déterminer un sous-espace de dimension n' de l'espace des caractéristiques d'origine de dimension n ($n' \leq n$) (Cootes et Taylor 2001). Elles peuvent être regroupées en 2 classes : les méthodes linéaires et les méthodes non linéaires.

2.2.1 Les méthodes linéaires.

Les transformations linéaires telles que l'Analyse en Composantes Principales (ACP), l'analyse factorielle et l'analyse linéaire discriminante ont beaucoup été utilisées dans le domaine de la reconnaissance des formes aussi bien pour l'extraction des caractéristiques, que pour la réduction de la dimension de l'espace des caractéristiques. La méthode la plus répandue pour l'extraction des caractéristiques est l'ACP.

On dispose de N ensembles de points caractéristiques $X^{(i)} = \{x_j^{(i)}\}_{j \in \{1, \dots, k\}}$, $i \in \{1, \dots, N\}$, centrés dans un espace de formes commun de dimension n . Ces vecteurs forment une distribution dans l'espace $n \times k$. Si on arrive à modéliser ou estimer cette distribution, il sera possible de décider si une nouvelle forme inconnue correspond à la classe de formes apprises. L'ACP permet de calculer les axes principaux du nuage de

points formé par les données. Les axes principaux permettent d'approximer tout point de l'ensemble d'origine en utilisant un modèle défini.

L'ACP se résume en trois étapes: Calcul des données centrées; Calcul de leur matrice de covariance S ; Calcul des vecteurs propres ϕ_i et des valeurs propres λ_i de la matrice S , avec $\lambda_i \geq \lambda_{i+1}$. Soit Φ la matrice des t premiers vecteurs propres de ϕ_i . Une forme X de l'ensemble d'apprentissage est approximée par: $X = \bar{X} + \Phi b$, où b est le vecteur correspondant aux t paramètres de variabilité de la forme.

2.2.2 ACP à noyau

Il existe plusieurs approches non linéaires pour l'extraction des caractéristiques. Parmi elles l'ACP à noyau (Campbell 2000)(Schölkopf et al. 1999) dérive directement de l'ACP. L'idée de base est de transférer les données dans un nouvel espace de caractéristiques F à l'aide d'une fonction non linéaire φ , puis d'appliquer une ACP linéaire dans ce nouvel espace. F est souvent un espace de grande dimension noté n' . Pour ne pas expliciter φ , on utilise ici les noyaux de Mercer. Ils permettent de traduire le problème de projection par une matrice: $K(X, Y) = \varphi(X) \cdot \varphi(Y)$.

Les noyaux efficaces incluent les noyaux gaussiens: $K(X, Y) = e^{-\frac{\|X-Y\|^2}{c}}$, ainsi que les noyaux polynômiaux: $K(X, Y) = (X \cdot Y)^d$. L'ACP à noyau est surtout utilisée comme outil de classification. La projection inverse dans l'espace d'origine étant difficile, les noyaux sont peu utilisés pour modéliser la variabilité des formes.

3 Modélisation non linéaire de la variabilité pour la reconnaissance de formes

3.1 Idée générale

Dans le domaine de la reconnaissance de formes, une forme a souvent été représentée par sa moyenne, conduisant à une modélisation gaussienne implicite. Depuis quelques années la variabilité, deuxième paramètre de cette modélisation, fait l'objet de nombreux travaux.

Nous développerons dans la suite la modélisation que nous avons adoptée. Quatre points clés ont dirigé cette modélisation: l'invariance aux transformations affines grâce à un espace non linéaire; la représentation de la variabilité des points et des relations spatiales entre ces points; un formalisme général permettant l'introduction de courbes; l'utilisation à des fins de reconnaissance de formes.

La figure 1 illustre l'approche adoptée. A l'origine nous disposons d'un ensemble de données expertisées. Ces données sont ensuite projetées dans un espace de caractéristiques garantissant leur invariance par transformations affines. Un modèle statistique lié au nouvel espace permet d'apprendre la position moyenne de chaque objet et la variabilité associée. L'objet moyen permet d'estimer la position de nouvelles données et peut servir d'initialisation dans un processus de recalage. Toute modification de position devra alors vérifier les contraintes apprises sur les variations autorisées autour du modèle moyen. Dans cet article nous supposons l'existence d'un référentiel commun à toutes les images étudiées. Trois modèles différents ont été mis en place: un linéaire

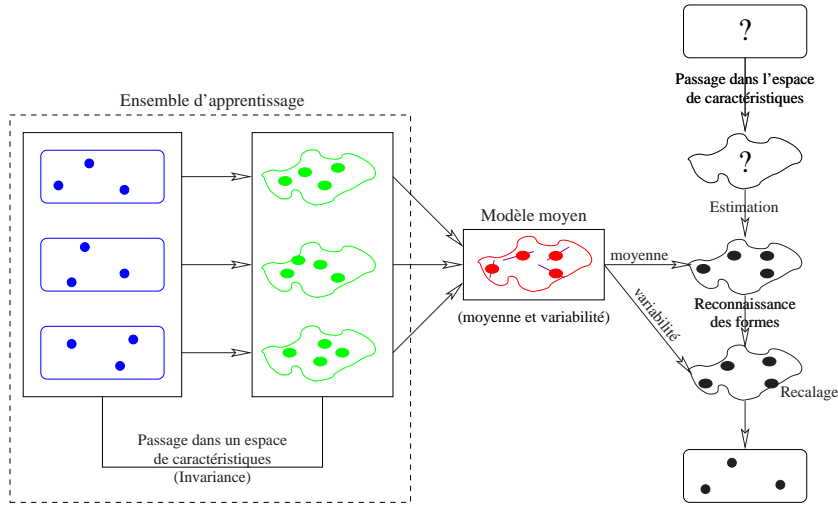


FIG. 1 – Vue globale sur le processus de modélisation de la variabilité de forme

et deux non linéaires (Romaniuk et al. 2002). Seul le dernier va être présenté. D'un point de vue théorique, ce modèle de forme prend en compte les non linéarités locales.

3.2 Définition de l'espace des caractéristiques

La première étape consiste en une détection de la forme de référence, échantillonnée en p points équi-répartis sur son contour. L'espace des caractéristiques non linéaire est formé par le rapport des surfaces de triangles construit à partir de l'échantillonnage précédent (figure 2).




FIG. 2 – Projection par aires algébriques. Les triangles possibles sont : $P_0P_1P_2$, $P_0P_1P_3$, $P_0P_2P_3$ et $P_1P_2P_3$.

Les coordonnées d'un point $M(x, y)$ de l'image sont définies à l'aide des coordonnées β , γ et δ , celles-ci étant calculées pour chaque triplet possible de la manière suivante :

$$\beta = \frac{\overline{P_jMP_k}}{\overline{P_iP_jP_k}} \quad \gamma = \frac{\overline{P_kMP_i}}{\overline{P_iP_jP_k}} \quad \delta = \frac{\overline{P_iMP_j}}{\overline{P_iP_jP_k}}$$

où $\overline{P_i P_j P_k}$ est l'aire algébrique du triangle $P_i P_j P_k$. Ces coordonnées vérifient alors :

$$\beta \times \overrightarrow{MP_i} + \gamma \times \overrightarrow{MP_j} + \delta \times \overrightarrow{MP_k} = \vec{0}$$

En supposant que l'on ait n triplets possibles entre les points P_i , les nouvelles coordonnées d'un point M de l'image sont :

$$X' = [\beta_1 \gamma_1 \delta_1 \dots \beta_n \gamma_n \delta_n]^t = A' X,$$

où A' est la matrice de passage du repère cartésien à notre nouveau repère.

3.2.1 Modèle de la variabilité et des relations spatiales

L'apprentissage est effectué sur une base de N images expertisées. Pour chacune des images la forme de référence est détectée puis échantillonnée. Nous disposons pour chaque image i de l'ensemble d'apprentissage des points $\{P_k^i\}_{k \in \{1, \dots, p\}}$, de la matrice A^i et de l'ensemble des q coordonnées de points caractéristiques $\{X_j^i\}$. Durant cette phase d'apprentissage nous calculons la position moyenne de chaque point caractéristique. Soit ϑ^i le vecteur représentant un point caractéristique de l'image i dans le nouveau repère. La position moyenne de chacun de ces points est donnée par :

$$\hat{\vartheta} = \frac{1}{N} \sum_{i=1}^N \vartheta^i.$$

La variance $\hat{\sigma}$ des vecteurs ϑ^i est aussi calculée. Elle définit la matrice de pondération P :

$$P = \begin{pmatrix} \frac{1}{\hat{\sigma}_1} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \frac{1}{\hat{\sigma}_{3n}} \end{pmatrix}.$$

Lorsque l'échantillonnage de la forme de référence génère un nombre important de points, seuls certains sont informants. Nous proposons donc de réaliser une ACP sur la matrice de covariance des vecteurs ϑ^i . Seules les d' composantes les plus informantes sont conservées. Ces composantes correspondent aux valeurs propres les plus fortes et forment une base de vecteurs Φ . Grâce à cette représentation nous modélisons la position moyenne des points, leur variabilité, mais aussi les relations spatiales entre points à travers la matrice de covariance. Cet aspect sera plus particulièrement exploité dans le cadre des données partiellement occultées.

3.2.2 Reconnaissance des formes : localisation des points

Soit ϑ le vecteur représentant un point caractéristique X . Nous savons que : $\vartheta = A' X$. Retrouver le point caractéristique X sur une nouvelle image consiste à résoudre le système surdimensionné : $\hat{\vartheta} = A' X$, où $\hat{\vartheta}$ est le vecteur moyen appris, A' la matrice définie par la nouvelle image. La résolution est effectuée par la méthode des moindres

carrés pondérés. La position estimée \tilde{X} d'un point caractéristique X dans une nouvelle image est donnée par l'équation :

$$\tilde{X} = (A'^t P^t \Phi \Phi^t P A')^{-1} A'^t P^t \Phi \hat{\vartheta}.$$

Cette procédure permet de reconnaître sur une nouvelle image l'ensemble des points du modèle (modèle moyen) lorsque aucune autre information n'est disponible.

4 Identification des données partiellement occultées

Dans de nombreux cas, il existe cependant des informations indisponibles. En particulier, certains points du modèle peuvent être apparents et d'autres masqués. La figure 3 présente le problème. Les points noirs sont les points à reconnaître. Sur la deuxième image certaines données sont manquantes (rectangles). Le but est de retrouver à partir des points visibles (triangles) les points caractéristiques (rectangles). L'objectif fixé est alors d'utiliser le modèle de la variabilité afin de mieux contraindre le modèle moyen à la confirmation de ce qui est visible. La solution proposée utilise l'ACP et exploite de manière élégante et uniforme les relations spatiales apprises lors de la modélisation de la variabilité.




FIG. 3 – *Identification des données occultées. L'image (a) illustre un ensemble complet de donnée (apprentissage). L'image (b) présente un exemple de données réelles : on arrive à retrouver les triangles. On cherche à en déduire la position des rectangles.*

4.1 Apprentissage : modélisation par Analyse en Composantes Principales

Soit p le cardinal de l'ensemble d'apprentissage et \bar{T} la forme moyenne du patron. En reprenant le formalisme proposé au paragraphe 2.2.1, soit S la matrice de covariance des données centrées de taille $(m+n) \times (m+n)$. Soient ϕ_i les vecteurs propres de la matrice S , associés aux valeurs propres λ_i et ϕ la matrice définie par ces vecteurs ϕ_i : $\phi = (\phi_1 | \phi_2 | \dots | \phi_t)$. Cette matrice est de taille $(m+n) \times t$ où t correspond aux t plus grandes valeurs propres de S . Soit b un vecteur de dimension t défini par : $b = \phi^T (T_i - \bar{T})$. Nous pouvons alors écrire : $T_i \approx \bar{T} + \phi b$. Le vecteur b est une bonne approximation de l'ensemble d'origine. Tout ensemble de $(m+n)$ points peut alors être "presque" représenté et retrouvé à travers les $t_{\{t < m+n\}}$ composantes du vecteur b .

4.2 Détermination des données manquantes sur une nouvelle image

4.2.1 Invariance : recalage rigide avec le modèle

Le traitement d'une nouvelle image consiste à détecter la forme de référence. Afin de pouvoir comparer cette forme avec le modèle de référence, nous l'alignons avec ce dernier. La transformation Q qui permet d'aligner les n points (c_{x_i}, c_{y_i}) avec les points $(c_{x'_i}, c_{y'_i})$ du modèle est définie grâce à la méthode des moindres carrés.

4.2.2 Détermination du vecteur b

Après recalage rigide, le problème à résoudre est le suivant : connaissant une partie des informations présentes dans l'image, comment retrouver la position des données manquantes.

Supposons $t = n$ points connus, les m points restants peuvent être retrouvés en utilisant une ACP, sous l'hypothèse que les n valeurs propres de la matrice de covariance représentent la presque totalité de l'ensemble d'apprentissage. Soient $C = (c_x, c_y)$ l'ensemble des n points connus et $X = (x, y)$ les m points à retrouver. Sans aucune approximation, nous pouvons alors écrire :

$$\begin{pmatrix} C_1 \\ \vdots \\ C_n \\ X_1 \\ \vdots \\ X_m \end{pmatrix} = \begin{pmatrix} \bar{C}_1 \\ \vdots \\ \bar{C}_n \\ \bar{X}_1 \\ \vdots \\ \bar{X}_m \end{pmatrix} + \begin{pmatrix} \phi_{1,1} & \cdots & \phi_{1,m+n} \\ \vdots & \ddots & \vdots \\ \phi_{m+n,1} & \cdots & \phi_{m+n,m+n} \end{pmatrix} \begin{pmatrix} b_1 \\ \vdots \\ b_n \\ b_{n+1} \\ \vdots \\ b_{m+n} \end{pmatrix}.$$

Ce système linéaire est un système à $m + n$ équations mais $n + 2m$ inconnues : $X_1, X_2, \dots, X_m, b_1, \dots, b_{m+n}$ et ne peut donc pas être résolu. Nous savons qu'il est possible de représenter l'ensemble des données avec moins de valeurs en écartant les vecteurs propres ϕ_i qui apportent peu d'information (λ_i faibles). En supposant $t \leq n$ nous pouvons alors reformuler le problème sous forme d'un système à $m + t$ équations et $m + t$ inconnues en remplaçant b par le vecteur b' composé des n premières composantes de b . C'est un système soit linéaire ($t = n$), soit surdéterminé (t, n). Dans la suite, nous avons considéré le cas extrême $t = n$.

4.2.3 Les données manquantes

Nous pouvons déterminer le vecteur des paramètres de variabilité de la forme b' par les n premières équations du système :

$$\begin{pmatrix} b_1 \\ \vdots \\ b_n \end{pmatrix} = \begin{pmatrix} \phi_{1,1} & \cdots & \phi_{1,n} \\ \vdots & \ddots & \vdots \\ \phi_{m+n,1} & \cdots & \phi_{m+n,n} \end{pmatrix}^{-1} \left(\begin{pmatrix} C_1 \\ \vdots \\ C_n \end{pmatrix} - \begin{pmatrix} \bar{C}_1 \\ \vdots \\ \bar{C}_n \end{pmatrix} \right).$$

Dans le cas où $t < n$ nous nous retrouvons avec un système surdéterminé, et une méthode d'inversion au sens des moindres carrés permet alors de résoudre le système.

Lorsque nous connaissons les valeurs de b' , les m dernières équations du système d'origine permettent de résoudre le problème grâce à un système de m équations et m inconnues :

$$\begin{pmatrix} X_1 \\ \vdots \\ X_m \end{pmatrix} = \begin{pmatrix} \bar{X}_1 \\ \vdots \\ \bar{X}_m \end{pmatrix} + \begin{pmatrix} \phi_{1+n,n} & \cdots & \phi_{1+n,n} \\ \vdots & \ddots & \vdots \\ \phi_{m+n,1} & \cdots & \phi_{m+n,n} \end{pmatrix} \begin{pmatrix} b_1 \\ \vdots \\ b_n \end{pmatrix} \quad (1)$$

Dans ce cadre, une approximation linéaire des relations spatiales entre les points connus et les points caractéristiques est définie à partir des vecteurs propres de la matrice de covariance. De la même façon sont approximées les relations spatiales entre les différents points caractéristiques.

5 Résultats

L'évaluation des résultats de cette méthodologie a été effectuée dans le cadre de la céphalométrie. L'un des objectifs de ce projet est d'explorer les possibilités d'automatisation du repérage des points céphalométriques sur une base de données conséquente. Ces points ont tous une définition anatomique : leur position est relative à des structures : os ou sutures. Les connaissances *a priori* de l'expert nous permettent, pour chaque point céphalométrique, de définir un ensemble de structures anatomiques nécessaires à sa localisation. Les structures anatomiques recherchées se traduisent dans l'image par des courbes continues par morceaux. Ces courbes sont approximées par des courbes de Bézier composites et constituent ici les données non occultées dans l'image.

L'intérêt essentiel des courbes de Bézier est leur mode de représentation par leurs points de contrôle. Ceci permet donc d'apprendre une courbe de Bézier à travers ses points de contrôle, avec le même formalisme que celui des points céphalométriques. Nous disposons donc du positionnement de la courbe moyenne dans une nouvelle image. Un recalage itératif du modèle des structures sur les structures de l'image à la manière des contours actifs de Cootes nous permet de disposer des coordonnées "réelles" des points de contrôle de nos courbes. Nous disposons donc automatiquement de la position finale des structures. Nous retrouvons alors facilement la position réelle de chaque point céphalométrique, grâce à la méthode proposée dans cet article. Cette étude se base sur l'exemple de la reconnaissance de la selle turcique et du positionnement des points céphalométriques nommés TPS¹ et CLP².

5.1 Modélisation de la selle turcique

La modélisation de la selle turcique requiert plusieurs étapes, dont les principales sont l'expertise de la selle turcique, son approximation à l'aide des courbes de Bézier,

1. *Définition* : Le point TPS correspond au décrochement entre la gouttière optique et le versant antérieur de la selle turcique.

2. *Définition* : Le point CLP se trouve sur la limite postéro-supérieure de la lame quadrilatère.

et enfin l'apprentissage de la selle. Cette modélisation nous permet de disposer d'un modèle statistique de la structure, qui ensuite sera déformé et déplacé afin de coller au mieux à la structure réelle dans l'image.




FIG. 4 – *Tracé de l'expertise de la selle turcique*

La première étape consiste à effectuer un apprentissage de la courbe. La figure 4 illustre l'expertise de la selle turcique. La selle turcique a ensuite été découpée en quatre segments de courbes. Les différents morceaux de courbes sont alors approximés à l'aide de courbes de Bézier composites. La figure 5 présente cette approximation où la courbe est représentée par 28 points de contrôle.




FIG. 5 – *Points de contrôle des courbes approximant la selle turcique*

5.2 Apprentissage




FIG. 6 – *Détection du contour externe du crâne (forme de référence)*

Pour apprendre la position et la forme moyenne de la selle turcique nous apprenons la position de ses points de contrôle ainsi que des points céphalométriques lui étant relatifs. Cet apprentissage s'effectue par rapport à la forme de référence, qui dans le cadre de l'application à la céphalométrie est le contour extérieur du crâne. La détection de ce contour est effectuée automatiquement (figure 6).




FIG. 7 – Position du modèle (noir) par rapport à l'expertise (blanc) sur deux images

L'apprentissage est effectué sur un ensemble de 40 images expertisées. Les résultats sont présentés par la figure 7, sur laquelle nous avons reporté en blanc l'expertise de la selle turcique et en noir le modèle moyen de la selle sur deux images différentes.




FIG. 8 – Reconnaissance de la selle turcique

Le recalage est itératif et repose sur la similarité entre les segments de contours et le modèle. Cette similarité dépend de l'amplitude et de l'orientation du gradient ainsi que de la proximité du modèle. Dans une première étape, le modèle est attiré par la moyenne pondérée (similarité et longueur) de tous les contours voisins au modèle. Dans une seconde étape, seul le segment le plus long et/ou similaire influence le modèle. Après recalage du modèle moyen sur les segments de contours présents dans l'image dans la limite des variations autorisées, nous disposons de la position réelle de la structure anatomique recherchée (figure 8).

La reconnaissance de la selle turcique dans l'image détermine le vecteur des paramètres de variabilité b de celle-ci. Ceci permet alors d'identifier des points TPS et CLP, par l'équation (1). Un exemple de résultat obtenu est présenté par la figure 9. Chacune des images correspond à une radiographie différente. En blanc nous avons représenté la selle expertisée, en vert la selle reconnue, en bleu les points expertisés et en rouge les deux points obtenus. La détection de la selle turcique est bonne pour les deux premières images, la position des points TPS et CLP est alors bonne. Dans le troisième cas l'identification des points a conduit à un échec. La reconnaissance de la selle turcique est assez mauvaise, à cause de la qualité des traitements d'images antérieures. Les points TPS et CLP sont alors mal localisés.




FIG. 9 – Reconnaissance des points TPS et CLP

La partie recalage de cette méthode est sensible au bruit de l'image car elle est fondée sur la détection des contours. Sur les radios présentées pour lesquelles le rapport signal/bruit est mauvais, cette détection de contour est souvent de mauvaise qualité. Sur cet exemple utilisant la forme de la selle turcique, lorsque la détection de contour est acceptable, la précision des résultats est de l'ordre de 1.2 mm. Les évaluations quantitatives sont en cours, mais les résultats utilisant le modèle moyen donnent une précision de l'ordre de 2.5 mm.

6 Conclusion

Dans cet article, nous avons étudié le problème de la modélisation statistique de la variabilité d'un ensemble d'objets. Pour ceci nous avons proposé un modèle non linéaire englobant trois aspects : l'objet moyen, la variabilité autorisée autour de ce modèle moyen et les relations spatiales existant entre les différentes caractéristiques de l'objet. Ce modèle garantit aussi l'invariance de l'objet par transformations affines en projetant les données dans un espace de caractéristiques défini par rapport à une forme de référence. Nous avons ensuite appliqué ce modèle pour résoudre un problème plus vaste : l'identification de données partiellement occultées. L'ensemble de ces travaux a été validé en céphalométrie, et plus particulièrement sur l'exemple de reconnaissance de la selle turcique et de la localisation des points TPS et CLP. Les résultats obtenus sont prometteurs, cependant l'application dans le cadre de la radiographie pose de nombreux problèmes dont le plus important est le fort bruit de l'image au niveau de la base du crâne, région où la majorité des points sont à localiser. L'originalité de l'approche proposée est d'unifier dans un même formalisme la notion de modélisation de la variabilité de formes (points ou lignes) et de relations spatiales entre ces items, ainsi que l'identification de parties occultées d'un objet. Ces travaux se poursuivront en cherchant à fiabiliser la reconnaissance des structures anatomiques. Une extension en 3D est par ailleurs envisageable. L'approximation se ferait alors par des surfaces de Bézier, permettant ainsi de réduire une surface à un ensemble fini de points.

Remerciements

Les auteurs remercient la société TCI pour les données, l'expertise, la disponibilité et l'aide précieuse qu'elle nous a apportées.

Références

- Cleveland W.S. (1993), Visualizing data, Hobart Press, 1993.
- Bookstein F. L. (1997), Landmark methods for forms without landmarks: Morphometrics of group differences in outline shape, *Medical Image Analysis*, pp. 225–244, 1997.
- Campbell C. (2000), Kernel Methods: a Survey of Current Techniques, 2000.
- Cootes T.F., Taylor C.J., Statistical Models of Appearance for Computer Vision, Report, 2001.
- Dryden I. (1997), L. General Shape and Registration Analysis, W. S. Kendall, O. Barn-dorffNielsen, and M. N. M. van Lieshout (Eds.), SEMSTAT 3, London. Chapman and Hall, 1997.
- Goodall C. (1991), Procrustes methods in the statistical analysis of shape, *J. Royal Stat. Soc. B*, vol. 53(2), pp. 285-339, 1991.
- Kendall D.G. (1984), Shape manifolds, Procrustean metrics and complex projective spaces, *Bulletin of the London Mathematical Society*, Vol. 16, pp. 81-121, 1984.
- Romaniuk B., Desvignes M., Robiaille J., Revenu M., Deshayes M.J. (2002), Une approche non linéaire pour la reconnaissance des formes statistique: application à la céphalométrie, RFIA 13e Congrès Reconnaissance des formes et intelligence artificielle, Angers, Vol. III, pp. 829-838, Janvier 2002.
- Schölkopf B., Mika S., Burges C., Knirsch P., Muller K.-R., Ratsch G., Smola A. (1999), Input space vs. feature space in kernel-based methods, *IEEE Trans. Neural Networks*, Vol. 10(5), pp. 1000-1017, 1999.
- Scalaroff S. Pentland A. P. (1995), Modal Matching for Correspondence and Recognition, *IEEE Transactions on PAMI*, Vol. 17(6), pp. 545-561, Juin 1995.

Summary

In this paper, we solve the problem of modelling of the variability of a set of shapes and points in statistical pattern recognition. We propose a statistical non linear model learned on an ordered set of points. The formalism adopted by the Principal Component Analysis mixed with our model, allow us to solve the problem of identification of partially occulted data. This study is applied on the problem of cephalometric points localization on radiographs of young children.