

## IDENTIFICATION (B1, C4, G2)

(01 / 05 / 2020, © Monfort, Dicostat2005, 2005-2020)

La notion d'**identification** est un concept central en **Statistique** : on dit qu'un **modèle statistique** est un **modèle identifiable** ssi la **propriété d'identification** est vérifiée par la **famille** des lois décrivant ce modèle. Par extension, cette notion peut aussi porter sur une **caractéristique légale** des lois en question, notamment la **relation fonctionnelle**, la **fonction de régression** ou la **fonction d'interdépendance** associées à ces lois.

Identifier une loi, au sein d'une **famille de lois** donnée, est une finalité importante de l'**inférence statistique** : cette finalité consiste à déterminer la « **vraie** » loi qui a engendré les **observations**, donc la **vraie valeur** du **paramètre**, dans le cas d'une **représentation statistique** paramétrique (ou la vraie valeur de la **caractéristique légale**).

(i) Soit  $(\mathcal{X}, \mathcal{B}, P_\theta^X)_{\theta \in \Theta}$  un **modèle image**. On dit que  $\theta'$  et  $\theta''$  sont des **paramètres équivalents** (du point de vue de l'**observation** X) ssi :

$$(1) \quad P_{\theta'}^X = P_{\theta''}^X.$$

En notant  $\sim$  cette relation (d'équivalence), on dit que  $\Theta$  est un **ensemble de paramètres identifiable** ssi :

$$(2) \quad \forall (\theta', \theta'') \in \Theta^2, \theta' \sim \theta'' \Rightarrow \theta' = \theta''.$$

On dit aussi que la famille  $(P_\theta^X)_{\theta \in \Theta}$  est une **famille de lois identifiable** ssi elle vérifie (2).

Autrement dit, l'application  $\theta \mapsto P_\theta^X$  est **injective** (cf aussi **valeur identifiable d'un paramètre**), ie :

$$(3) \quad P_{\theta'}^X = P_{\theta''}^X \Rightarrow \theta' = \theta'',$$

ou encore :

$$(4) \quad \theta'' \neq \theta' \Rightarrow P_{\theta''}^X \neq P_{\theta'}^X.$$

(ii) Plus généralement, si  $(\Gamma, \mathcal{B}_\Gamma)$  est un **espace probabilisable** auxiliaire,  $\mathcal{B}_\Theta$  une **tribu** sur  $\Theta$  et :

$$(5) \quad g : \Theta \mapsto \Gamma$$

une application  $(\mathcal{B}_\Theta, \mathcal{B}_\Gamma)$ -mesurable, on dit que  $g$  est une **fonction identifiable** du paramètre  $\theta$  (ou que  $\tau = g(\theta)$  est identifiable) ssi :

$$(6) \quad \forall (\theta', \theta'') \in \Theta^2, \theta' \sim \theta'' \Rightarrow g(\theta') = g(\theta'').$$

Autrement dit, l'application  $g(\theta) \mapsto P_\theta^X$  est **injective** :

$$(7) \quad P_{\theta'}^X = P_{\theta''}^X \Rightarrow g(\theta') = g(\theta'').$$

La définition (6) (resp (7)) peut se ramener à la définition (2) (resp (3)) en posant  $(\Gamma, \mathcal{B}_\Gamma) = (\Theta, \mathcal{B}_\Theta)$  et  $g = \text{id}_\Theta$ . Elle est cependant souvent utilisée sous cette dernière forme (eg dans l'étude du **modèle d'interdépendance**) (cf **identifiabilité**).

Si  $(\mathcal{Y}, \mathcal{C})$  est un espace probabilisable auxiliaire, on appelle parfois **fonction identifiante** ou **statistique identifiante**, ou encore **fonction d'identification** ou **statistique d'identification**, toute application :

$$(8) \quad S : \Theta \mapsto \mathcal{Y}$$

qui est à la fois  $(\mathcal{B}_\Theta, \mathcal{C})$ -mesurable et tq :

$$(9) \quad \forall (\theta', \theta'') \in \Theta^2, \theta' \sim \theta'' \Rightarrow S(\theta') = S(\theta'').$$

Autrement dit, l'application  $S(\theta) \mapsto P_\theta^X$  est **injective**. Par suite, si  $(\Gamma, \mathcal{B}_\Gamma)$  est un espace probabilisable donné et  $g : \Theta \mapsto \Gamma$  une application mesurable donnée,  $g$  est identifiable ssi il existe une application mesurable  $h : \mathcal{Y} \mapsto \Gamma$  tq  $g = h \circ S$ .

(iii) Lorsque le paramètre  $\theta$  contient des **caractéristiques légales**, la terminologie peut être précisée. Ainsi, on parle :

(a) **d'identification au premier ordre** s'il s'agit d'une caractéristique de **centralité** : eg **espérance** ou **paramètre de position**. Dans le cas d'une espérance, cela implique que les variables considérées soient intégrables (ie appartiennent à des espaces de type  $L^1$ ) ;

(b) **d'identification au second ordre** s'il s'agit, à la fois, d'une caractéristique de centralité et d'une caractéristique de dispersion ou d'échelle (cf **paramètre d'échelle**). Dans le cas d'une espérance et d'une variance, cela implique que les variables considérées soient intégrables à l'ordre 2 (ie appartiennent à des espaces de type  $L^2$ ) ;

(c) etc (**identification à l'ordre p** et espaces de type  $L^p$ ).

Ainsi, le modèle de **régression** linéaire multiple standard (écrit dans l'**espace d'observation**  $\mathbb{R}^N$ )  $y = Xb + u$ , avec  $E u = 0$  et  $V u = \sigma^2 \cdot I_N$ , n'est pas (en général) un modèle paramétrique, sauf lorsque eg  $y \sim \mathcal{N}_N(Xb, \sigma^2 \cdot I_N)$ . Il est « identifiable au second ordre » ssi l'application  $(b, \sigma^2) \mapsto (E y, V y)$  est injective, donc ssi  $(b, \sigma^2) \mapsto (Xb, \sigma^2 \cdot I_N)$  l'est, donc ssi  $\text{rg } X = K$ . Ce modèle n'est donc pas identifiable s'il est singulier (ie tq  $\text{rg } X < K$ ) (cf **singularité**).

(iv) L'importance du concept d'identification s'apprécie à travers les remarques suivantes.

Soit  $\theta^*$  la **vraie valeur d'un paramètre**, ie celle associée à la **loi** qui régit effectivement le **phénomène** aléatoire considéré, donc le « comportement » de l'observation  $X$ .

Si  $\theta^*$  était connu (eg en cas de **simulation**), l'ensemble du phénomène serait connu, du moins « à travers » le modèle censé le représenter. La propriété selon laquelle la famille  $(P_{\theta}^X)_{\theta \in \Theta}$  est identifiable assurerait donc, en théorie, l'identification (ie le « repérage ») de  $P_{\theta^*}^X$ , la « vraie » **lp** de  $X$ .

Or  $\theta^*$  n'est pas, en général, connu. On ne peut (au mieux) que chercher à définir un **estimateur** (eg ponctuel)  $T = t(X)$ , jugé adéquat (eg **estimateur sans biais**, **estimateur convergent**, etc), de  $\theta^*$ . Par suite, en pratique, on ne peut identifier que la loi  $P_T^X$  : cette loi sera « proche », au sens d'une **topologie** définie sur  $(P_{\theta}^X)_{\theta \in \Theta}$ , de  $P_{\theta^*}^X$  ssi  $T$  est « proche » (au sens du biais, ou de la convergence, etc, considérés) de la valeur  $\theta^*$ .

(v) L'**identifiabilité** d'une lp assure donc l'unicité de sa détermination approchée lorsqu'on connaît seulement des estimateurs de son paramètre.

La notion se relie aussi à celle de **robustesse** et à celle de **spécification de modèle**.