

## THÉORIE DES TESTS (1) (I)

(09 / 05 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **théorie des tests** suit, de façon générale, une démarche fondée sur une **table de décision à deux entrées et deux sorties**, parfois appelée **table (entrées-sorties) 2 x 2**, ou simplement **table 2 x 2**. Cette table élémentaire comporte en ligne deux décisions possibles,  $d_1$  et  $d_2$ , et en colonne deux états de la **Nature (événements aléatoires** ou contextes) possibles  $E_1$  et  $E_2$ .

Le **statisticien** peut alors raisonner selon deux approches classiques :

(a) **décision** → **conséquence** (cf tableau ci-après) :

théorie des tests : décisions → conséquences

état décision	$E_1$	$E_2$
$d_1$	$c_{11} (p_{11})$	$c_{12} (p_{12})$
$d_2$	$c_{21} (p_{21})$	$c_{22} (p_{22})$

(a)<sub>1</sub> lorsque l'état  $E_1$  est réalisé et que la décision  $d_1$  est prise, une conséquence  $c_{11}$  survient (avec une probabilité  $p_{11}$  donnée), tandis qu'une conséquence  $c_{12}$  survient (avec la probabilité  $p_{12} = 1 - p_{11}$ ) si la décision  $d_2$  est prise ;

(a)<sub>2</sub> de même, lorsque l'état  $E_2$  est réalisé : la décision  $d_1$  entraîne une conséquence  $c_{21}$  (avec une probabilité  $p_{21}$ ), tandis que la décision  $d_2$  entraîne une conséquence  $c_{22}$  (avec une probabilité  $p_{22} = 1 - p_{21}$ ) ;

(b) **décision** → **risque** (cf tableau ci-après) :

théorie des tests : décisions → risques

état décision	$E_1$	$E_2$
$d_1$	$p_{11} = 1 - p_{12}$	$p_{12}$
$d_2$	$p_{21}$	$p_{22} = 1 - p_{21}$

(b)<sub>1</sub> si la décision  $d_1$  est prise alors que l'état  $E_2$  est réalisé, le statisticien subit un risque  $p_{12}$ , tandis que ce risque est  $1 - p_{12}$  si l'état  $E_1$  est réalisé ;

(b)<sub>2</sub> de même, si la décision  $d_2$  est prise alors que l'état  $E_1$  est réalisé, le statisticien subit un risque  $p_{21}$ , tandis que ce risque est  $1 - p_{21}$  si l'état  $E_2$  est réalisé.

C'est cette seconde approche qui est suivie en théorie des tests :  $d_1$  y est notée  $d_0$  et  $d_2$  notée  $d_1$  ou  $d_a$  ;  $p_{12}$  est notée  $\beta$  et  $1 - p_{12}$  est notée  $1 - \alpha$  ; enfin,  $p_{21}$  est notée  $\alpha$  et  $1 - p_{21}$  est notée  $1 - \beta$  ou  $\eta$  (puissance du test) (cf tableau ci-après) :

théorie des tests : décisions  $\rightarrow$  risques

état décision	$E_1$	$E_2$
$d_0$	$1 - \beta$	$\beta$ seconde espèce
$d_1$ ou $d_a$	$\alpha$ première espèce	$1 - \alpha$

Un **problème de test** est ainsi un **problème de décision** statistique dans lequel l'ensemble des décisions possède deux éléments (cas des tests à deux décisions usuels).

Il mobilise les concepts de base suivants : **risque de première espèce**, **risque de seconde espèce**, **fonction de test** (pure ou mixte), **fonction puissance**, **statistique de test** (définie à partir de l'échantillon  $X$  et dépendant de la propriété sujette à hypothèse), comparaison des fonctions de test à l'aide d'un **préordre** adéquat, et de **région de rejet** (ou **région critique**).

(i) Disposant d'un **modèle statistique**  $(\Omega, \mathcal{F}, \mathcal{P})$  et d'un **espace d'observation**  $(\mathcal{X}, \mathcal{B})$ , le **statisticien**, qui observe un échantillon  $X : \Omega \mapsto \mathcal{X}$ , doit souvent rechercher si l'**hypothèse** plus « précise »  $H_0$ , selon laquelle le « vrai » modèle statistique gouvernant le **phénomène** étudié est  $(\Omega, \mathcal{F}, \mathcal{P}_0)$ , avec  $\mathcal{P}_0 \subset \mathcal{P}$  et  $\mathcal{P}_0 \neq \mathcal{P}$ , est vérifiée.

La **théorie des tests d'hypothèses**, ou simplement **théorie des tests**, a pour objet une telle vérification.

Plus généralement, elle peut aussi avoir pour objet de vérifier si le « vrai » modèle statistique satisfait à l'hypothèse :

$$(1) \quad H_0 : (\Omega, \mathcal{F}, \mathcal{P}) = (\Omega, \mathcal{F}, \mathcal{P}_0), \quad \text{avec } \mathcal{P}_0 \subset \mathcal{P} \text{ et } \mathcal{P}_0 \neq \mathcal{P},$$

tout en s'assurant qu'il ne satisfait pas une autre hypothèse :

$$(2) \quad H_1 : (\Omega, \mathcal{F}, \mathcal{P}) = (\Omega, \mathcal{F}, \mathcal{P}_1), \quad \text{avec } \mathcal{P}_1 \subset \mathcal{P} \text{ et } \mathcal{P}_1 \neq \mathcal{P}.$$

Dans un **problème de test**, les sous-familles  $\mathcal{P}_0$  et  $\mathcal{P}_1$  de  $\mathcal{P}$  peuvent être :

(a) disjointes ( $\mathcal{P}_0 \cap \mathcal{P}_1 = \emptyset$ ), auquel cas on parle d'**hypothèses disjointes**, ou non disjointes ( $\mathcal{P}_0 \cap \mathcal{P}_1 \neq \emptyset$ ) (**hypothèses non disjointes**). On parle encore d'**hypothèses « séparées »** ;

(b) emboîtées ( $\mathcal{P}_0 \subset \mathcal{P}_1$  ou  $\mathcal{P}_1 \subset \mathcal{P}_0$ ), auquel cas on parle d'**hypothèses emboîtées**, ou non emboîtées (**hypothèses non emboîtées**).

Le cadre général précédent est sous-jacent à la plupart des problèmes de **test d'hypothèses**. On dit que l'on teste l'**hypothèse de base** :

$$(1)' \quad H_0 : P \in \mathcal{P}_0,$$

aussi appelée **hypothèse privilégiée**, ou (dans certains **contextes statistiques**) **hypothèse nulle**, contre l'**hypothèse alternative** (ou simplement **alternative**) :

$$(2)' \quad H_1 : P \in \mathcal{P}_1,$$

aussi appelée **hypothèse secondaire** ou **hypothèse concurrente**.

La théorie s'intègre à la **théorie de la décision** statistique. L'ensemble  $D$  des **décisions** est alors en **bijection** avec l'ensemble  $\{\mathcal{P}_0, \mathcal{P}_1\}$  et le choix d'une décision  $d \in D$  équivaut au choix de l'une des deux parties  $\mathcal{P}_i$  ( $i = 0, 1$ ) de  $\mathcal{P}$ .

En pratique, la conduite d'un test d'hypothèses s'effectue, en général, directement sur le modèle  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X)$ , **modèle image** du modèle initial par  $X$  : les hypothèses portent alors sur les familles  $\mathcal{P}_0^X$  et  $\mathcal{P}_1^X$ , images respectives des familles  $\mathcal{P}_0$  et  $\mathcal{P}_1$  par la **va**  $X$ .

Ceci conduit naturellement à formuler un **problème de décision** statistique (cf **théorie de la décision**), appelé **problème de test (d'hypothèses)**. Ce problème peut être :

(a) un **problème de test « statique »** : dans ce cas, l'espace  $(\mathcal{X}, \mathcal{B})$  est un espace produit, et la taille  $N$  de l'échantillon  $X = (X_1, \dots, X_N)$ , est fixée (ou donnée a priori) ;

(b) un **problème de test « dynamique »**, auquel cas on parle de **problème de test séquentiel**, et la taille de l'échantillon  $X$  peut augmenter jusqu'au moment où une condition requise a priori est vérifiée par la procédure de test mise en oeuvre (cf eg **test de WALD**, **test séquentiel**). Dans ce dernier, en effet, l'expérience (ou expérimentation) se poursuit jusqu'à une **décision finale**.

Autrement dit, un test « statique » aboutit à une décision sans faire appel à des observations supplémentaires, contrairement à un test séquentiel pour lequel la **décision finale** est prise au bout d'un certain nombre (de répétitions) d'expériences.

On présente deux approches formalisées de la théorie (statique), selon que le **modèle statistique** considéré se présente sous forme paramétrée ou non.

(ii) Un **problème de test paramétrique** consiste en la donnée :

(a) d'un modèle image  $(\mathcal{X}, \mathcal{B}, (P_\theta^X)_{\theta \in \Theta})$ , ie d'un modèle statistique obtenu comme image d'un modèle statistique initial  $(\Omega, \mathcal{F}, (P_\theta)_{\theta \in \Theta})$  par une **variable aléatoire** (ou **échantillon**)  $X : \Omega \mapsto \mathcal{X}$ , où  $(\mathcal{X}, \mathcal{B})$  désigne un **espace d'observation**. Très généralement,  $\mathcal{X} = \mathbf{R}^K$  (avec  $K \geq 1$ ) et  $\mathcal{B} = \mathcal{B}(\mathbf{R}^K)$  ;

(b) d'un **espace de décisions**  $(D, \mathcal{B}_D)$  tq  $D = \{d_0, d_1\}$  (ensemble à deux éléments), où  $\mathcal{B}_D$  est la **tribu discrète** de  $D$ . L'ensemble  $D$  est défini, de façon biunivoque, à l'aide d'une **partition**  $\{\Theta_0, \Theta_1\}$  donnée de  $\Theta$ , en sorte que :

(1) si  $\theta \in \Theta_1$ , on décide  $d_0$ ,  
si  $\theta \in \Theta_2$ , on décide  $d_1$ .

(c) d'une **fonction de perte**  $L : D \times \Theta \mapsto \mathbf{R}_+$ .

Concrètement, il s'agit de choisir, au vu d'une **observation**  $\omega \in \Omega$ , ou d'une **mesure**  $X(\omega) = x \in \mathcal{X}$  faite sur elle (eg « résultat d'une **expérience** »), entre deux **hypothèses statistiques** : l'une, généralement notée  $H_0$ , est l'hypothèse selon laquelle  $\theta \in \Theta_0$ , l'autre, notée  $H_1$ , est l'hypothèse selon laquelle  $\theta \in \Theta_1$ . On appelle **hypothèse (statistique)** le fait pour  $\theta$  d'appartenir soit à  $\Theta_0$ , soit à  $\Theta_1$ .

On dit alors que :

(a) l'hypothèse  $H_0 : \theta \in \Theta_0$  est l'**hypothèse de base**, ou **hypothèse fondamentale**, ou **hypothèse privilégiée**, ou **hypothèse principale**, ou encore (dans certaines circonstances) l'**hypothèse nulle** du problème de test ;

(b) l'hypothèse  $H_1 : \theta \in \Theta_1$  est l'**hypothèse alternative**, ou **hypothèse secondaire**, du problème. On note parfois même, par abus,  $\theta \in H_0$  et  $\theta \in H_1$ .

L'hypothèse alternative est parfois notée  $H_a$ , auquel cas  $d_1$  est notée  $d_a$ .

Dans le cadre de la **théorie de la décision**, l'ensemble  $D$  des **décisions** est tq,  $w \in \mathcal{X}$  étant une **partie mesurable** donnée ;

- (2) si  $X \in w$ , on décide  $d_0$  (acceptation de  $H_0$ ),  
 si  $X \in w^c$ , on décide  $d_1$  (acceptation de  $H_1$ ).

La partie  $w \in \mathcal{X}$  est appelée **région critique** car le fait pour l'échantillon  $X$  de tomber dans  $w$  conduit à « refuser » l'hypothèse de base.

Par suite, on appelle, dans ce **contexte** :

(a) **test pur** toute **règle de décision pure** (ou règle de décision non aléatoire), ie toute **application mesurable** :

- (3)  $\delta : \mathcal{X} \mapsto D$ , où  $D = \{d_0, d_1\}$  (ensemble à deux éléments).

Un test pur  $\delta$  est plus souvent noté  $\phi$ , ou  $\psi$ , etc. C'est donc un **test mixte** particulier (cf aussi **fonction de test**).

Cette règle est appelée **test pur**, ou **test non aléatoire**, ou encore **test déterministe** : ainsi, une règle de décision  $\delta$  équivaut au choix d'une partition de  $\mathcal{X}$  selon  $\{w, w^c\}$ . Un **test pur**  $\delta : \mathcal{X} \mapsto D$  est souvent appelé **fonction de test** (ou **fonction-test**), ou encore simplement un **test** ;

(b) **règle de décision aléatoire** t ou **règle de décision mixte** (ou encore **règle de décision « randomisée »**) le résultat d'un tirage aléatoire d'une décision  $d$  dans l'ensemble  $D = \{d_0, d_1\}$  au vu de  $x = X(\omega)$ . Ceci revient à définir une **probabilité de transition**  $m$  de  $\mathcal{X} \times \mathcal{B}_D$  dans  $[0, 1]$  tq, par définition :

$$(4) \quad m_x(d) = \begin{cases} m(x, \{d_0\}) & \text{ssi } d = d_0, \\ m(x, \{d_1\}) & \text{ssi } d = d_1. \end{cases} \quad \forall x \in \mathcal{X},$$

La fonction  $m(x, \{d_0\})$  représente alors la probabilité de rejeter  $H_0$  sachant que  $x$  a été observé.

On qualifie souvent la règle mixte  $m : \mathcal{X} \times \mathcal{B}_D \mapsto [0,1]$  de **test mixte**, de **fonction de test (aléatoire ou mixte)**, ou même simplement de **test**.

(iii) Un **problème de test non paramétrique** consiste en la donnée :

(a) d'un **modèle image**  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X)$ , ie d'un **modèle statistique** obtenu comme image d'un modèle initial sous forme non paramétrée  $(\Omega, \mathcal{T}, \mathcal{P})$  par une va (ou **échantillon**)  $X : \Omega \mapsto \mathcal{X}$  ;

(b) d'un **espace de décision**  $(D, \mathcal{B}_D)$  tq  $D = \{d_0, d_1\}$  (ensemble à deux éléments), où  $\mathcal{B}_D$  est la **tribu discrète** de  $D$ . L'ensemble  $D$  est défini à l'aide d'une partition  $\{\mathcal{P}_0, \mathcal{P}_1\}$  donnée de la famille  $\mathcal{P}$ , en sorte que :

(1)' si  $P^\xi \in \mathcal{P}_0$ , on décide  $d_0$  ;  
si  $P^\xi \in \mathcal{P}_1$ , on décide  $d_1$  ,

$P^\xi$  désignant l'une quelconque des lois de probabilité qui ont engendré (ou qui sont susceptibles d'être suivies par)  $\xi$  ;

(c) d'une **fonction de perte**  $L : D \times \mathcal{X} \mapsto \mathbf{R}_+$  .

Il s'agit alors de choisir, au vu de  $x = X(\omega)$ , entre  $d_0$ , qui correspond à l'hypothèse  $H_0 : P \in \mathcal{P}_0$ , et  $d_1$ , qui correspond à l'hypothèse  $H_1 : P \in \mathcal{P}_1$  .

La terminologie précédente est encore utilisée ici, et l'on définit les notions de **région critique** (associée à un test d'hypothèse) (cf **région d'acceptation**, **région de confiance**), de **règle de décision pure** et de **règle de décision mixte** (ie les tests purs et les tests aléatoires).

(iv) Remarques :

(a) hormi les généralités du début, on a supposé principalement que  $H_0$  et  $H_1$  (ou  $H_a$ ) étaient des hypothèses « disjointes », ie que  $\Theta_0 \cap \Theta_1 = \emptyset$  (resp  $\mathcal{P}_0 \cap \mathcal{P}_1 = \emptyset$ ). La théorie a été développée au cas d'**hypothèses non disjointes** (ie  $\Theta_0 \cap \Theta_1 \neq \emptyset$ ) ou d'**hypothèses emboîtées** (ie  $\Theta_0 \subset \Theta_1$  ou  $\Theta_1 \subset \Theta_0$ ) ;

(b) un problème de test est essentiellement un « **problème de choix** », ou un « **problème d'arbitrage** », entre  $H_0$  et  $H_1$ , ie entre deux éventualités qui peuvent être à l'origine des observations  $X$ . La loi  $P_0^X$  (resp  $P^X$ ) qui engendre  $X$  appartient soit à une sous-famille non vide  $\mathcal{P}_0^X$ , soit à la sous-famille (éventuellement complémentaire) (supposée non vide)  $\mathcal{P}_1^X = (\mathcal{P}_0^X)^c$ , et ceci au vu de la réalisation  $X(\omega) = x$  ;

(c) la **fonction de perte**  $L$  associée à un test pur  $\varphi : \mathcal{X} \mapsto D$  vérifie naturellement (eg cas paramétré) :

$$(5) \quad L(d_i, \theta) = 0, \quad \forall \theta \in \Theta_i, \quad \text{où } i \in \{0, 1\}.$$

La **fonction de risque** associée est donc :

$$(6) \quad R(w, \theta) = \mathbf{1}(\theta \in H_0) \cdot P_\theta(w) \cdot L(d_1, \theta) + \mathbf{1}(\theta \in H_1) \cdot (1 - P_\theta(w)) \cdot L(d_0, \theta),$$

où  $\theta \mapsto \alpha_\theta(w)$  est la (**fonction de**) **risque de première espèce** et  $\theta \mapsto \beta_\theta(w)$  est la (**fonction de**) **risque de seconde espèce** (cf **risque de première espèce**, **risque de seconde espèce**). La fonction de risque  $R(w, \theta)$  définie en (6) est aussi notée  $R_\theta(w)$ .

Le **préordre**  $\geq$  associé au risque  $R$  est donc défini selon :

$$(7) \quad w' \geq w'' \quad \Leftrightarrow \quad \{\alpha_\theta(w') \leq \alpha_\theta(w'') \text{ sur } \Theta_0\} \text{ et } \{\beta_\theta(w') \leq \beta_\theta(w'') \text{ sur } \Theta_1\}.$$

Ce préordre ne permet cependant pas d'obtenir un **test optimal**. Différents principes statistiques (**principe bayésien**, **principe de NEYMAN**, **principe d'invariance**) permettent généralement de résoudre ce problème.

(d) dans le cadre de la **théorie bayésienne**, si  $\mathcal{B}_\Theta$  est une **tribu de parties** de  $\Theta$  et si  $\Pi$  est une **probabilité a priori** définie sur  $\mathcal{B}_\Theta$ , le **risque de BAYES** du test  $\delta$  (ou de sa **région critique** associée  $w$ ) correspondant à  $\Pi$  s'écrit :

$$(8) \quad R_\Pi(w) = \int R(w, \theta) d\Pi(\theta).$$

(v) La notion de **statistique de test** est centrale dans cette théorie. Il s'agit d'une statistique tq  $S = s(X)$  qui « caractérise » l'hypothèse principale (ou, alternativement, l'hypothèse secondaire) et s'interprète en conséquence. Ainsi, une valeur « élevée » de  $S$  peut signifier que l'une des hypothèses est vraisemblable (resp peu plausible), selon l'interprétation.

La **loi de probabilité**, à distance finie ou la **loi asymptotique** (grand échantillon  $X$ , avec  $N \gg 0$ )  $P^S$  de  $S$  peuvent être définies (ou calculées), entièrement ou partiellement (eg moments), au moins sous l'hypothèse de base  $H_0$  : toute **région critique** de **seuil** donné a priori  $\alpha \in ]0, 1[$ , définie à l'aide de  $P^S$ , permet alors de conclure le test.

(vi) En pratique, les **risques d'espèce**, ou « **types** » de **risques**, jouent aussi un rôle important. L'idéal serait de les minimiser tous les deux.

Cependant, à cause de leur caractère antagoniste, la procédure la plus courante consiste à fixer (ou à majorer) a priori le risque de première espèce, puis à minimiser le risque de seconde espèce, ie à maximiser la **fonction puissance**. Cette procédure fonde la **théorie de J. NEYMAN - E.S. PEARSON**. Compte tenu du modèle et des observations, elle aboutit soit à accepter l'hypothèse  $H_0$ , soit à accepter (ie à ne pas refuser) l'hypothèse  $H_1$ . Il s'agit donc d'un « arbitrage par préférence » et non pas d'un « jugement ».

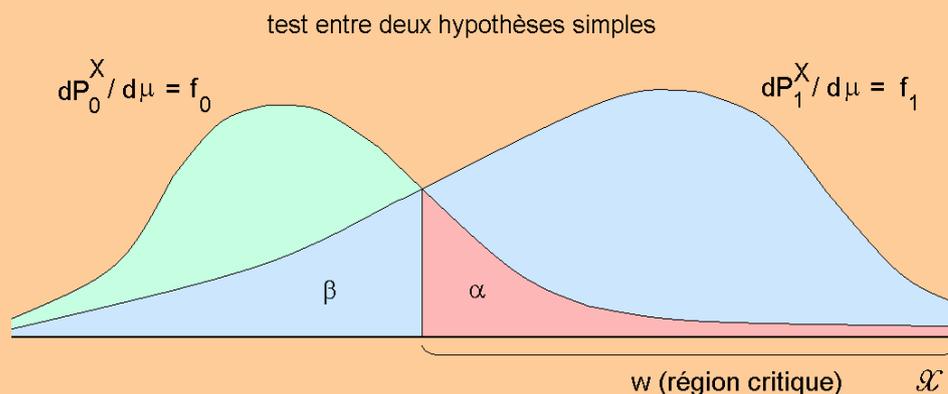
(vi) D'autres procédures de test ont été recherchées, notamment dans le cadre du **problème de décision multiple** :

(a) **tests à plusieurs conclusions**. Les notions de test ci-dessus sont des notions comportant deux « issues » (ou « possibilités »). Il existe des **tests à plusieurs issues**. Ainsi dans un test à trois issues,  $D = \{d_a, d_d, d_r\}$ ,  $d_a$  représente l'**acceptation** de  $H_a$  ( $\theta \in \Theta_a$ , dans le cas paramétré),  $d_r$  l'**acceptation** de  $H_r$  ( $\theta \in \Theta_r$ ) (ou **refus** de  $H_a$ ) et  $d_d$  le « **doute** », ie l'acceptation d'une troisième hypothèse  $H_d : \theta \in \Theta_d$ , où  $\{\Theta_a, \Theta_d, \Theta_r\}$  est une partition donnée de  $\Theta$ ) à laquelle s'associe naturellement une partition  $\{w_a, w_d, w_r\}$  de l'ensemble des observations  $\mathcal{X}$  ;

(b) **problème de classification**. Ce type de **problème statistique** constitue aussi une généralisation à plusieurs issues du test d'hypothèses du type décrit ci-dessus (cf **classification**, **discrimination**, etc).

(vii) Par ailleurs, la théorie des tests entretient des liens étroits avec la **théorie de l'estimation** « ensembliste » (cf **estimateur ensembliste**) : le complémentaire d'une **région de confiance** (dotée d'un **seuil de confiance**  $1 - \alpha$ ) est alors une **région de rejet** (dotée d'un **seuil critique**  $\alpha$ ).

**test d'une hypothèse  $H_0 : P_0^X \in \mathcal{P}_0^X$  contre une alternative  $H_1 : P_1^X \in \mathcal{P}_1^X$**



(vii) Le terme **risque** peut désigner :

(a) selon la terminologie de la théorie des tests, une probabilité tq les  $p_{ij}$  (cf supra) ;

(b) selon une autre acception, le couple  $(p_{ij}, c_{ij})$  associant une probabilité  $p_{ij}$  et une conséquence  $c_{ij}$  (valeur ou magnitude). Cette notion, plus riche, permet de « séparer » ce qui relève d'un contexte aléatoire (eg « hasard ») et ce qui relève d'un contexte exogène (eg économique : budget, assurance, etc). En effet, elle permet de définir des arbitrages entre situations associées aux couples du type précédent : eg arbitrage entre une situation avec probabilité élevée ( $p \gg 0$ ) et conséquence faible ( $c \ll \infty$ ), et une situation inverse, avec probabilité faible ( $p \ll 0$ ) et conséquence élevée ( $c \gg \infty$ ).

Les tables de décision indiquées au début, qui peuvent s'appliquer à d'autres contextes, se généralisent à plusieurs entrées / sorties, dont le nombre n'est pas nécessairement égal (cf tableau  $m \times n$  ci-après).

décisions multiples : décisions  $\rightarrow$  conséquences

état décision	$E_1$	...	$E_n$
$d_1$	$c_{11} (p_{11})$	...	$c_{1n} (p_{1n})$
...	...	$c_{ij} (p_{ij})$	...
$d_m$	$c_{m1} (p_{m1})$	...	$c_{mn} (p_{mn})$

Par suite, la **fonction d'utilité**  $v$  du statisticien peut s'écrire  $C \mapsto u = v(C)$ , avec pour argument la  $(m,n)$ - **matrice**  $C = (c_{ij})_{(i, j)}$  des conséquences. La **décision statistique** (multiple) peut donc se prendre à partir de  $u(C)$  et de la matrice  $P = (p_{ij})_{(i, j)}$  des probabilités, ce qui revient à utiliser la notion d'utilité espérée (espérance de l'utilité calculée avec  $P$ ).