

Économétrie II

Ch. 1. Rappels de Concepts
L3 Économétrie – L3 MASS

Pr. Philippe Polomé, U. Lyon 2

Année 2015-2016

Table des matières

Ch. 1. Rappels de Concepts

Modèle de Régression Linéaire (MRL) formel

Causalité contre corrélation

Distribution d'échantillonnage & propriétés d'un estimateur

Notations

- ▶ $Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \epsilon_i$
 - ▶ $i = 1 \dots I$ indexe les observations
 - ▶ t séries temporelles, n ou i coupes transversales
 - ▶ Y variable endogène, expliquée, dépendante
 - ▶ X_j avec $j = 1 \dots k$ variable explicative ou causale, régresseur
 - ▶ pas nécessairement exogène
- ▶ $E(Y_i) = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}$
 - ▶ (sans le ϵ) **théorie (causale)**
 - ▶ β_j mesure quantitativement l'influence de X_j sur Y
 - ▶ β_j **pente** de la droite selon X_j
 - ▶ β_0 constante, terme indépendant ou intercept
 - ▶ β vecteur de coefficients du modèle

Notations

- ▶ Terme d'erreur ϵ ou μ
 - ▶ Interprétations : erreurs de mesures, régresseurs inobservables ou manquants, facteurs aléatoires...
 - ▶ Tous les modèles économétriques sont **stochastiques**
- ▶ Notation matricielle $Y = X\beta + \epsilon$
 - ▶ On observe Y et X
 - ▶ L'économétrie est un ensemble de techniques pour **estimer** β à partir de Y et de X
- ▶ Chaque technique = une **formule**, qu'on appelle « **estimateur** » et qu'on note avec un chapeau
 - ▶ Exemple « Moindres carrés ordinaire » $\hat{\beta} = (X'X)^{-1} X'Y$
 - ▶ \exists estimateurs « maximum de vraisemblance », « méthode des moments », « variables instrumentales », « moindres carrés généralisés »...

Notations

- ▶ **Prédiction** avec un chapeau \hat{Y} \forall les estimateurs
 - ▶ $\hat{Y} = X\hat{\beta}$ avec MCO p.e.
 - ▶ Toujours erreur de prédiction
 - ▶ $X \in$ échantillon : “**Valeur ajustée**”
- ▶ On n'observe jamais le terme d'erreur ϵ
 - ▶ $(Y, X) \in$ échantillon : calcul du **résidu** $\hat{\epsilon} = Y - \hat{Y} = Y - X\hat{\beta}$
- ▶ Résidu s'écrit parfois e et peut se nommer « erreur »
 - ▶ Porte à confusion

Exemple simple

Table 1: *Ice cream data*

Sales (unit = \$100)

Temperature (unit = 10 degrees)

$$Y_1 = 8$$

$$X_1 = 5$$

$$Y_2 = 10$$

$$X_2 = 7$$

$$Y_3 = 8$$

$$X_3 = 6$$

$$Y_4 = 13$$

$$X_4 = 8$$

$$Y_5 = 15$$

$$X_5 = 10$$

$$Y_6 = 14$$

$$X_6 = 9$$

$$Y_7 = 11$$

$$X_7 = 7$$


$$Y_8 = 9$$

$$X_8 = 8$$

Ce qu'on a et ce qu'on veut faire

- ▶ **Modèle causal stochastique**
 - ▶ S'il fait plus chaud (X : température), la consommation de crème glacée (Y) augmente, toutes autres choses (ϵ) égales
 - ▶ $Y_t = \beta_1 + \beta_2 X_t + \epsilon_t$
 - ▶ pour chaque $t = 1 \dots T$
 - ▶ avec erreurs aléatoires non-observables ϵ_t (pas toute autres choses égales)
 - ▶ Série temporelle courte \simeq coupe transversale
- ▶ On a des données
 - ▶ Variable Y
 - ▶ Une ou plusieurs variables $X_1 \dots X_k$ explicatives
- ▶ On veut
 - ▶ Quantifier l'influence de X sur Y
 - ▶ Prédire Y conditionnellement à certaines valeurs pour X
- ▶ Comment faire ?

Intuition 1 : Droite qui “passe au mieux”



Intuition 1 : Droite qui “passe au mieux”

- ▶ $Y_t = \beta_1 + \beta_2 X_t + \epsilon_t$ pour chaque $t = 1 \dots T$
- ▶ On suppose que c'est une bonne approximation de la relation réelle
 - ▶ ϵ = événement aléatoire **non-mesuré** et non-systématique
 - ▶ ϵ pas corrélé avec X
- ▶ $\hat{\beta}$ de β t.q. la droite $Y_t = \hat{\beta}_1 + \hat{\beta}_2 X_t$ “passe au mieux” dans le nuage de points
 - ▶ C'est du dessin : minimisation des distances euclidiennes
 - ▶ Soit le résidu $\hat{\epsilon} = Y - X\hat{\beta}$
 - ▶ Cherche le vecteur de nombres $\hat{\beta}$ t.q. somme des carrés des résidus $\sum_{t=1}^T (Y_t - X_t \hat{\beta})^2$ est minimale
 - ▶ Réponse $\hat{\beta} = (X'X)^{-1} X'Y$: estimateur **moindres carrés**

Intuition 1 : Logiciels

- ▶ L'exemple dans Tableur [Icecream_inverse_TCD.ods](#)
 - ▶ Dessin
 - ▶ Calcul matriciel
- ▶ L'exemple dans Gretl

Intuition 2 : “Inversion” de $Y = X\beta + \epsilon$

- ▶ Imaginons que $\epsilon = 0$ et que X soit carrée et inversible
 - ▶ Alors $\exists X^{-1}$ telle que $X^{-1}X = I$
 - ▶ $\beta = X^{-1}Y$ s'obtient par inversion
 - ▶ système d'équations linéaires
- ▶ Mais $\epsilon \neq 0$ et X pas carrée \rightarrow « Généralisation » de l'inverse
 - ▶ Prémultiplier par X' , on a $X'Y = X'X\beta + X'\epsilon$
 - ▶ $X'X$ est carrée et “souvent” inversible
 - ▶ À condition d'absence de multicolinéarité
 - ▶ **Hypothèse** : $X'\epsilon = 0$ **covariance zéro**
 - ▶ Alors $X'Y = X'X\beta$ et donc $\beta = (X'X)^{-1} X'Y$
 - ▶ exactement : β et non $\hat{\beta}$

Intuition 2 : “Inversion” de $Y = X\beta + \epsilon$

- ▶ En général, $X'\epsilon \neq 0$ mais
 - ▶ Si on peut supposer que $X'\epsilon \approx 0$ en un sens stochastique
 - ▶ au moins lorsque la taille de l'échantillon $\rightarrow \infty$
 - ▶ Alors on peut écrire $\hat{\beta} = (X'X)^{-1} X'Y$
 - ▶ dans le sens où $\hat{\beta}$ est une approximation de β quand $n \rightarrow \infty$
- ▶ L'inversion est une intuition d'un autre estimateur
 - ▶ **Méthode des moments**

Estimateur Méthode des Moments MM

- ▶ Soit A un estimateur de β , alors on peut écrire $Y - XA = \hat{\epsilon}$
- ▶ Hypothèse exogénéité $E(\epsilon|X) = 0$
 - ▶ $\implies E(X\epsilon) = 0$ (corrélation nulle \forall régresseurs)
- ▶ Stratégie MM
 - ▶ Cette **hypothèse** sur les moments de la pop. est **imposée** aux moments de l'échantillon : on veut A t.q. $X' \hat{\epsilon} = 0$
 - ▶ Donc : $X'(Y - XA) = 0$: CPO des MCO
- ▶ Alors $A = (X'X)^{-1}X'Y = \hat{\beta}$:
 - ▶ Estimateur MM = estimateur MCO pour le MRL $Y = X\beta + \epsilon$
 - ▶ $X' \hat{\epsilon} = X' \left(Y - X (X'X)^{-1} X' Y \right) = 0$ par construction
 - ▶ Mais la méthode des moments s'applique pareillement à des modèles non linéaires $Y = g(X, \beta) + \epsilon$
 - ▶ Et le principe est très différent

Prédiction & effet marginal

- ▶ Un objectif était de prédire au mieux les ventes de crème glacée en fonction de la température
- ▶ La prédiction se trouve sur la droite : $\hat{Y} = X\hat{\beta}$
 - ▶ Aussi bien pour MCO que pour MM dans ce cas-ci
- ▶ Un 2nd objectif était la quantification de l'influence de X sur Y
 - ▶ $\partial Y / \partial x_1$ estimé = $\hat{\beta}_1$ = coefficient estimé de X_1 = pente de la droite
 - ▶ β_1 = effet (constant) d'un changement marginal de x_1 sur y

Table des matières

Ch. 1. Rappels de Concepts

Modèle de Régression Linéaire (MRL) formel

Causalité contre corrélation

Distribution d'échantillonnage & propriétés d'un estimateur

Causalité contre corrélation

- ▶ Modèle causal : X cause Y , X influence Y , $X \rightsquigarrow y$
 - ▶ Pas le contraire
- ▶ Ce n'est pas la même chose qu'une corrélation
 - ▶ X corrélé à $Y \Leftrightarrow Y$ corrélé à X
- ▶ Dans l'exemple des ventes de crème glacée, la température cause les ventes
 - ▶ Un accroissement de température provoque un accroissement de demande
 - ▶ Ce n'est pas parce que les gens mangent plus de glaces que la température va augmenter

Simultanéité


Dans des modèles plus sophistiqués, causalité pas évidente

- ▶ En macro, le taux de change agit-il sur la balance commerciale ou est-ce l'inverse ?
- ▶ En marketing, au niveau de la firme, les ventes et les dépenses de publicité sont dites simultanées
 - ▶ chacune est cause de l'autre
- ▶ La demande d'un produit (quantité) dépend du prix, mais l'inverse est vrai aussi (simultanéité)

Régression inverse

- ▶ La régression ne mesure **que des corrélations**
 - ▶ Ne peut que **confirmer ou infirmer** un modèle théorique
 - ▶ Uniquement dans un sens statistique : pour un certain jeu de données, le modèle est confirmé/infirmé
 - ▶ \exists tests de causalité applicables dans certaines circonstances
 - ▶ Certaines données (panel p.e.) permettent d'être plus sûr de la causalité
 - ▶ Changements expliquent changements
- ▶ Exemple de régression inverse dans le cas des crèmes glacées :
$$X_1 = \gamma_1 + \gamma_2 Y + \epsilon$$
 - ▶ Tableur [Icecream_inverse_TCD.ods](#)

Exemple des cigognes



- ▶ Fisher, 1936
- ▶ Copenhagen, décennie post WWI
- ▶ En réalité : constructions importantes et migration des campagnes
- ▶ Exemple de régression **fallacieuse** spuriuse (spurious)

Pq les cigognes sont-elles associées aux bébés ?

- ▶ Oiseau migrateur européen
- ▶ Part à l'automne et revient en Europe centre & nord début avril
 - ▶ Soit 9 mois après le solstice d'été (21 juin / Saint Jean) environ
- ▶ Le solstice d'été était un important festival païen, où les gens se mariaient beaucoup



Les moyennes conditionnelles

- ▶ Exemple de tableau croisé dynamique / Pivot table dans Excel
 - ▶ Google “Excel 25 easy PivotTable reports”
 - ▶ Tableur [Icecream_inverse_TCD.ods](#)
- ▶ Les moyennes conditionnelles sont des moyennes (arithmétiques simples) calculées **par groupe** dans l'échantillon
 - ▶ P.e. les ventes moyennes par vendeur dans une entreprise
- ▶ Il est facile de croire que les différences entre moyennes conditionnelles sont dues aux “conditionneurs”
 - ▶ P.e. les ventes de Smith sont plus élevées que celles de González parce que Smith est meilleur vendeur que González
- ▶ Mais il ne s'agit que d'une corrélation, pas d'une causalité
 - ▶ P.e. les ventes de Smith sont plus élevées parce qu'il est sur un plus grand territoire
 - ▶ Pas “toutes autres choses égales” / *ceteris paribus*

Causalité : conclusion

- ▶ L'économétrie, les moyennes conditionnelles, les corrélations ne servent qu'à **quantifier**, pas à expliquer
- ▶ De telles quantifications peuvent confirmer ou infirmer une théorie dans un sens probabiliste
- ▶ Il ne faut pas accepter n'importe quel résultat juste parce qu'il a été obtenu par des méthodes sophistiquées
- ▶ L'hypothèse de causalité
 - ▶ Est commune à tous les modèles économétriques
 - ▶ La tester est l'objectif principal de l'économétrie

Table des matières

Ch. 1. Rappels de Concepts

Modèle de Régression Linéaire (MRL) formel

Causalité contre corrélation

Distribution d'échantillonnage & propriétés d'un estimateur

Chaque échantillon est aléatoire


- ▶ Exemple de la vente de crème glacée sur la plage
 - ▶ Un autre vendeur sur autre plage aurait récolté des données différentes
 - ▶ La méthodologie présentée auparavant est applicable de même
 - ▶ Le modèle est le même ... mais les valeurs des coefficients seront différentes dans les deux cas !
- ▶ Échantillon aléatoire $\Rightarrow \hat{\beta}$ aléatoire alors que β ne l'est pas !
 - ▶ Quel est le $\hat{\beta}$ correct ? Tous les deux sont corrects
 - ▶ Tous les deux sont entachés d'une marge d'erreur par rapport au « vrai » coefficient β
- ▶ On va illustrer comment fluctuent les $\hat{\beta}$
 - ▶ Distribution d'échantillonnage

Simulation de Monte-Carlo Monte Carlo.ods

- ▶ On génère des données artificielles afin d'illustrer certains outils théoriques dans un cadre contrôlé
- ▶ Fonction `alea()` / `rand()` : crée une valeur tirée d'une v. a. de distribution uniforme entre 0 et 1
 - ▶ `sqrt(-2*ln(alea()))*sin(2*pi()*alea())` crée une valeur $n(0, 1)$
 - ▶ Avec ces fonctions, on génère X et μ
- ▶ Calculer $Y = 2 - 3X + \mu$ (ou tout autre choix de coefficient)
- ▶ Générer ainsi 10 lignes (par exemple)
- ▶ En utilisant Y et X on estime $\hat{\beta}$
 - ▶ On voit bien que $\hat{\beta} \neq \beta$
- ▶ En recommençant l'opération, on crée des vecteurs $\hat{\beta}_i$ qui sont **tous** différents les uns des autres et de β
 - ▶ Les $\hat{\beta}_i$ sont tous aléatoires, β ne l'est pas
 - ▶ ϵ est aléatoire
 - ▶ X est aléatoire, mais l'analyse est conditionnelle à X
 - ▶ Comme si X était constant

Distribution d'échantillonnage

- ▶ $\hat{\beta}$ aléatoire : conséquences
 - ▶ Pas de garantie d'être proche des vraies valeurs
 - ▶ $\hat{\beta}$ suit une **distribution**
 - ▶ La valeur de $\hat{\beta}$ change avec chaque échantillon : **distribution d'échantillonnage**
 - ▶ Comme toute distribution, elle a des **moments** : moyenne, variance,...
- ▶ Selon les valeurs atteintes par ces moments, l'estimateur a des **propriétés** plus ou moins bonnes
 - ▶ Un estimateur sera jugé meilleur qu'un autre si ses propriétés sont meilleures
- ▶ On va voir pour MCO dans le MRL

Distribution d'échantillonnage de $\hat{\beta}_1$ dans Monte Carlo.ods

- ▶ Vraie valeur 1.5
- ▶ Moyenne 1.57...
- ▶ Écart type 4.55...
- ▶ $n=835$

Modèle de régression linéaire : 7 hypothèses

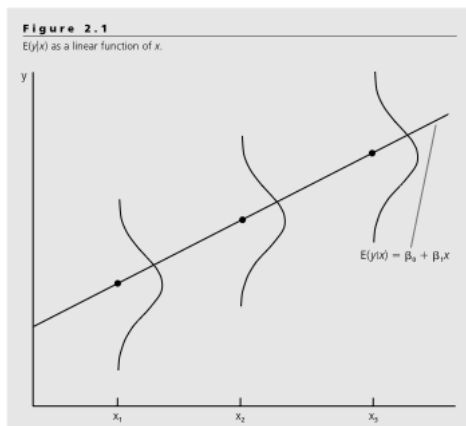
Les circonstances dans lesquelles MCO est un "bon" estimateur

- ▶ Modèle de Régression Linéaire (MRL) $Y = X\beta + \epsilon$
 - ▶ 7 hypothèses classiques (+ celle de causalité)
- ▶ Lorsqu'elles sont vérifiées, l'estimateur MCO possède des propriétés désirables
 - ▶ Dans quels cas ne sont-elles pas satisfaites ?
 - ▶ Conséquences sur l'estimateur ?
 - ▶ Peut-on "réparer" ?
 - ▶ Proposer un estimateur alternatif, transformer les données...

MRL $Y = X\beta + \epsilon$: hypothèses 1-4

1. $E(\epsilon_i) = 0 \forall i$: les erreurs ont une **espérance nulle**
2. $var(\epsilon_i) = \sigma^2 \forall i$: la variance de chaque erreur est la même et est réelle = **Homoscédasticité**
3. $cov(\epsilon_t, \epsilon_s) = 0 \forall t \neq s$: les erreurs sont indépendantes entre elles = **Pas d'auto-corrélation**
 - ▶ 1+2+3 = "Sphéricité des erreurs"
4. $E(\epsilon_i x_i) = 0 \forall i$: il n'y a pas de corrélation contemporaine (même i) entre l'erreur et chaque régresseur = **Exogénéité**

Figure: MRL $Y = X\beta + \epsilon$: Illustration graphique des 4 hyp. sur l'erreur



Tiré de Wooldridge

MRL $Y = X\beta + \epsilon$: hypothèses 5-7

- ▶ 5. X de plein rang
 - ▶ Aucun régresseur ne peut s'écrire comme une combinaison linéaire des autres régresseurs
 - ▶ Sinon : **colinéarité** parfaite des régresseurs
 - ▶ $X'X$ pas inversible
- ▶ 6. MRL correctement spécifié
 - ▶ La réalité est effectivement linéaire en les coefficients β (forme fonctionnelle)
 - ▶ β **non stochastiques**
 - ▶ Il ne manque aucun régresseur **pertinent**
- ▶ 7. Y continue
 - ▶ Pas qualitative : 0/1 ou bien A, B, C, D
 - ▶ Pas discrète : 0,1,2,3...
 - ▶ Pas tronquée/censurée : [3,12] ou [-1,+1]
- ▶ Hypothèses MRL pas respectées \Rightarrow MCO perd certaines/toutes propriétés

MRL $Y = X\beta + \epsilon$: Propriétés de l'estimateur MCO

Table: Propriétés de l'estimateur MCO lorsque toutes les hypothèses du MRL sont respectées

Moment*	n petit	$n \rightarrow \infty$
Espérance	biais	consistance
Variance	efficience	efficience asymptotique

* de la distribution d'échantillonnage

Propriété 1 de MCO dans le MRL : absence de biais

- ▶ L'espérance de l'estimateur $E(\hat{\beta}) = \beta$
 - ▶ L'estimateur est dit **non-biaisé**
 - ▶ Preuve math en annexe
- ▶ **La moyenne des coefficients estimés (sur l'ensemble des échantillons simulés) tend à se rapprocher des vraies valeurs**
 - ▶ « En moyenne, cet estimateur ne se trompe pas »
 - ▶ $E(\hat{\beta}) \approx \text{moyenne}(\hat{\beta})$ lorsqu'il y a beaucoup d'échantillons
 - ▶ Illustré dans [Monte Carlo.ods](#)
- ▶ $\hat{\beta}_{MCO}$ est non-biaisé

Propriété 2 de MCO dans MRL : consistance / convergence

- ▶ **Plus la taille de l'échantillon grandit, plus les coefficients estimés tendent à se rapprocher des vraies valeurs**
 - ▶ L'estimateur est dit **consistant**
 - ▶ Souvent "**convergent**" en français
 - ▶ Lorsque la taille de l'échantillon tend vers l'infini, les coefficients estimés convergent (en probabilité) vers les vraies valeurs
 - ▶ On écrit : $Plim(\hat{\beta}) = \beta$
 - ▶ Preuve math assez compliquée
 - ▶ Plus facile à illustrer dans un Tableur [Monte Carlo.ods](#)
- ▶ $\hat{\beta}_{MCO}$ est consistant

Propriétés 3-4 de MCO dans le MRL : efficacité

- ▶ Théorème de **Gauss-Markov** : $var(\hat{\beta})$ est la plus petite de tous les estimateurs linéaires non-biaisés
 - ▶ $\hat{\beta}_{MCO}$ est **BLUE** = **efficace**
- ▶ Théorème de **Cramer-Rao** : $\hat{\beta}$ est le plus efficace de tous les estimateurs consistants
 - ▶ $\hat{\beta}_{MCO}$ est **asymptotiquement efficace** = atteint la borne inférieure de Cramer-Rao
- ▶ L'efficacité d'un estimateur est sa précision
 - ▶ Inverse de sa variance
- ▶ L'efficacité est **comparative**
 - ▶ Un estimateur $\hat{\beta}$ est plus efficace qu'un estimateur $\tilde{\beta}$ si $var(\tilde{\beta}) - var(\hat{\beta})$ est une matrice sdp

Devoir #1 : Monte-Carlo

- ▶ Réaliser votre propre exemple de Monte Carlo dans un tableur
 - ▶ Avec 2 régresseurs, un distribué uniformément dans $[0, 1]$ et l'autre distribué normalement $n(0, 1)$, une constante et un terme d'erreur distribué $n(0, 1)$
 - ▶ Choisissez les valeurs des coefficients
- ▶ Tout le monde devrait avoir des chiffres différents
- ▶ Calculez les coefficients explicitement avec les formules
 - ▶ $X'X$ sera 3×3 et $\hat{\beta}$ sera 3×1
- ▶ Calculez le R^2
- ▶ Répliquer l'opération avec des tailles d'échantillons croissantes pour monter la consistance de l'estimateur
 - ▶ Les devoirs ne sont ni notés ni corrigés, mais ils sont matières d'examen
 - ▶ Si vous avez des difficultés à les faire, on en discute en cours

Annexe. Démonstration de $E(\hat{\beta}) = \beta$

$$\begin{aligned} E(\hat{\beta}) &= E\left(\left(X'X\right)^{-1} X'Y\right) \\ &= E\left(\left(X'X\right)^{-1} X'(X\beta + \epsilon)\right) \\ &= E\left(\left(X'X\right)^{-1} X'X\beta\right) + E_{X,\epsilon}\left(\left(X'X\right)^{-1} X'\epsilon\right) \end{aligned}$$

► parce que $E(\text{somme}) = \text{somme}(E)$ et X est une v.a.

$$= E(\beta) + E_X\left(E_\epsilon\left[\left(X'X\right)^{-1} X'\epsilon|X\right]\right)$$

► par la loi d'itération des espérances (ci-dessous)

$$\begin{aligned} &= E(\beta) + E_X\left(\left(X'X\right)^{-1} X'E_\epsilon[\epsilon|X]\right) \\ &= \beta \text{ si } E_\epsilon[\epsilon|X] = 0 \end{aligned}$$

Loi d'itération des espérances

$$E[Y] = E_X [E_{Y|X}(Y|X)]$$

- ▶ $E[Y]$ est l'espérance inconditionnelle (ou marginale) de Y
- ▶ $E_X[\]$ est l'espérance inconditionnelle (marginale) par rapport à X (on traite Y comme fixe)
- ▶ $E_{Y|X}(\)$ est l'espérance conditionnelle de Y par rapport à X
- ▶ Y et X appartiennent au même espace de probabilités (ci-dessous)

Preuve dans le cas discret

$$\begin{aligned} E_X [E_{Y|X}(Y|X)] &= \sum_x E_{Y|X}(Y|X) \Pr(X = x) \\ &= \sum_x \left[\sum_y y \Pr(Y = y|X = x) \right] \Pr(X = x) \\ &= \sum_x \sum_y y (\Pr(Y = y|X = x) \Pr(X = x)) \\ &= \sum_x \sum_y y \Pr(Y = y, X = x) \\ &= E[Y] \end{aligned}$$

Car $\Pr(Y = y|X = x) \Pr(X = x) = \Pr(Y = y, X = x)$: la prob conjointe $(Y, X) = \text{prob conditionnelle } (Y|X) \bullet \text{prob marginale } (X)$

Loi d'itération des espérances

Exemple des deux dés (à six faces équiprobables)

$$E(D_{\acute{e}1}) = E_{D_{\acute{e}2}} [E_{D_{\acute{e}1}|D_{\acute{e}2}} (D_{\acute{e}1}|D_{\acute{e}2})]$$

$$E(D_{\acute{e}1}) = \sum_{D_{\acute{e}1}=1}^6 \Pr(D_{\acute{e}1} = d_{\acute{e}1}) d_{\acute{e}1} = \sum_i \frac{1}{6}i = 3.5$$

$$\begin{aligned} E_{D_{\acute{e}2}} [E_{D_{\acute{e}1}|D_{\acute{e}2}} (D_{\acute{e}1}|D_{\acute{e}2})] &= \sum_{D_{\acute{e}2}=1}^6 E_{D_{\acute{e}1}|D_{\acute{e}2}} [D_{\acute{e}1}|D_{\acute{e}2}] \Pr(D_{\acute{e}2} = d_{\acute{e}2}) \\ &= \sum_{D_{\acute{e}2}=1}^6 E_{D_{\acute{e}1}|D_{\acute{e}2}} [D_{\acute{e}1}|D_{\acute{e}2}] \frac{1}{6} \\ &= \sum_{D_{\acute{e}2}=1}^6 \left(\sum_{D_{\acute{e}1}|D_{\acute{e}2}=i}^6 \Pr(D_{\acute{e}1}|D_{\acute{e}2} = i) i \right) \frac{1}{6} \\ &= \sum_{D_{\acute{e}2}=1}^6 \left(\sum_1^6 \frac{1}{6} i \right) \frac{1}{6} = 3.5 \end{aligned}$$

Espace de probabilités

- ▶ On considère une “expérience” aux résultats aléatoires, p.e. un lancer de 2 dés.
- ▶ L'ensemble de tous les résultats élémentaires : $(1,1)$, $(1,2)$... $(6,6)$ constitue l'espace d'échantillonnage Ω
- ▶ Les évènements sont des combinaisons des résultats élémentaires, p.e. “somme des 2 dés = 10”, “au moins un des dés = 3”...
 - ▶ L'ensemble de ces évènements se nomme un σ algèbre et est noté \mathcal{F}
- ▶ La fonction P de mesure de probabilité associe à chaque évènement une probabilité
- ▶ Ces trois composants (Ω, \mathcal{F}, P) constitue l'espace de probabilité