

11.1. Les modèles de régression à variables qualitatives indépendantes ("dummy variable reg. models")

A) Régression sur une seule variable qualitative : ANOVA

Exemple:

$$Y_i = \alpha + \beta D_i + u_i$$

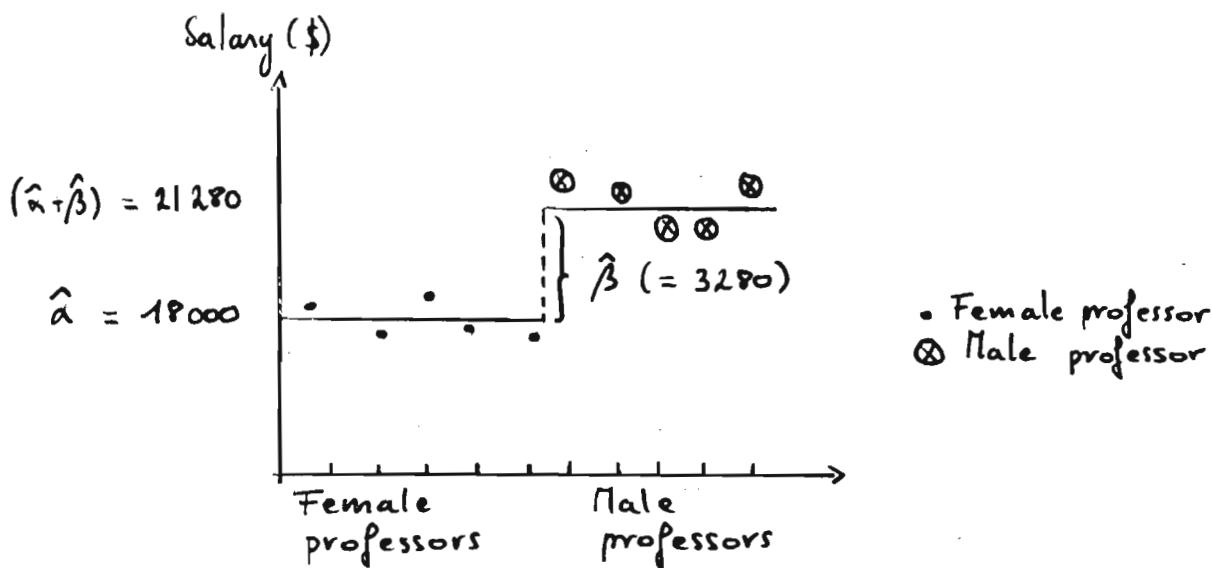
où $\begin{cases} Y = \text{salaire annuel d'un prof. d'université.} \\ D_i = 1 \text{ si professeur est un homme.} \\ \quad = 0 \text{ sinon.} \\ u_i = \text{terme d'erreur.} \end{cases}$

Hypothèse : u_i satisfait aux hyp. du modèle de reg. linéaire classique $\Rightarrow E(Y_i / D_i = 0) = \alpha \equiv \text{salaire moyen f}$
 $E(Y_i / D_i = 1) = \alpha + \beta \equiv \text{salaire moyen m}$

$$\left[\begin{array}{l} Y_i = 18,00 + 3,28 D_i \\ s.e. = (0,32) \quad (0,44) \\ t = (57,74) \quad (7,439) \\ R^2 = 0,8737, \quad n = 10, \quad Y \text{ en millions de \$} \end{array} \right]$$

$$\hat{\alpha} = 18000 \text{ \$}$$

$$\hat{\alpha} + \hat{\beta} = \pm 21000 \text{ \$} \quad (21280 \text{ \$})$$



b) Régression sur une variable qualitative et une variable quantitative : ANCOVA

Variabiles quantitatives des modèles ANCOVA = „covariates“

$$Y_i = \alpha_1 + \alpha_2 D_i + \beta X_i + u_i$$

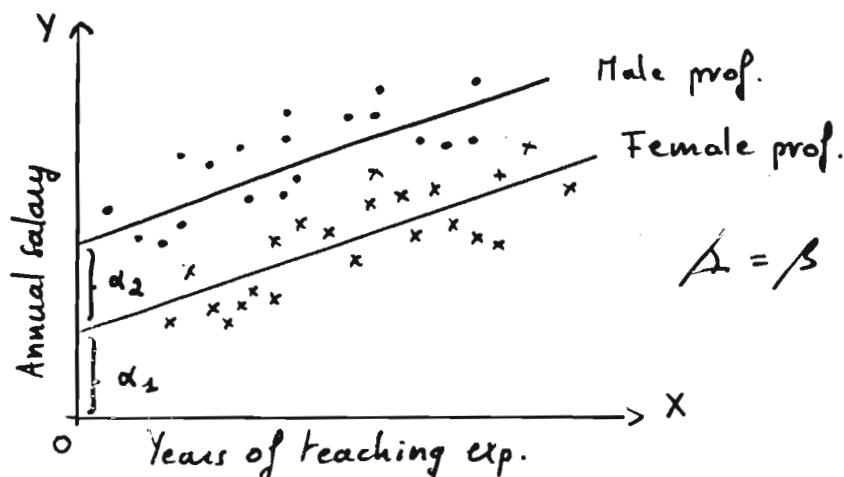
où $\begin{cases} Y = \text{salaire annuel d'un prof.} \\ X_i = \text{nombre d'années d'expérience.} \\ D_i = 1, \text{ si le prof. est un homme} \\ = 0 \text{ sinon} \end{cases}$

$\begin{cases} u_i = \text{terme d'erreur} \end{cases}$

Si $E(u_i) = 0$:

$$E(Y_i | X_i, D_i = 0) = \alpha_1 + \beta X_i \quad \equiv \text{sal. moyen } \varnothing$$

$$E(Y_i | X_i, D_i = 1) = (\alpha_1 + \alpha_2) + \beta X_i \quad \equiv \text{sal. moyen } \delta$$



- Caractéristiques:

- a) Une seule dummy (D_i) pour distinguer les ♂ des ♂.
Quid si une dummy pour chaque sexe?

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \beta X_i + u_i$$

où $\left\{ \begin{array}{l} Y = \text{salaire annuel d'un prof.} \\ X_i = \text{nbre d'années d'exp.} \\ D_{2i} = 1 \text{ si prof. est un homme} \\ = 0 \text{ sinon} \\ D_{3i} = 1 \text{ si prof. est une femme} \\ = 0 \text{ sinon} \\ u_i = \text{terme d'erreur} \end{array} \right.$

Colinéarité p'tte tel D_{2i} et D_{3i} .

Illustration: éch. de 3 prof ♂ et 2 prof. ♀

$\exists \lambda_1, \lambda_2, \lambda_3$ non tous nuls $\lambda_1 + \lambda_2 + \lambda_3 = 0$

Pq? $\lambda_1 = 1$
 $\lambda_2 = -1$
 $\lambda_3 = -1$

		X_1	X_2	X_3	
	Intercepte		D_2	D_3	X
Homme	Y_1	1	1	0	X_1
Homme	Y_2	1	1	0	X_2
Femme	Y_3	1	0	1	X_3
Homme	Y_4	1	1	0	X_4
Femme	Y_5	1	0	1	X_5

$$\Rightarrow X_1 - X_2 - X_3 = 0 \quad D_2 = 1 - D_3 \quad \text{ou} \quad D_3 = 1 - D_2 \quad (1 = \text{intercepte})$$

\Rightarrow multicolin. Estimation par MCO n'est pas possible.

Règle générale: si une variable qualitative comporte m catégories, $(m-1)$ variables dummy doivent être incluses dans la régression

(si règle non respectée : „dummy variable trap“)

2) L'attribution des chiffres 0 et 1 est purement arbitraire.

$$\left. \begin{array}{l} \text{Si } D_i = 1 \text{ si prof } \neq \\ = 0 \text{ sinon} \end{array} \right\} \Rightarrow \begin{aligned} E(Y_i | X_i, D_i = 1) &= (\alpha_1 + \alpha_2) + \beta X_i \\ E(Y_i | X_i, D_i = 0) &= \alpha_1 + \beta X_i \end{aligned}$$

Catégorie de référence / de base !

3) Intercepte mesure valeur moyenne de la catégorie de référence.

4) Coeff. régress. associés aux variables dummy
= différentiels d'intercepte
(„differential intercept coefficients“)

c) Régression sur une variable quantitative et une variable qualitative à plus de 2 catégories.

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \beta X_i + u_i$$

où

$$\left\{ \begin{array}{l} Y_i = \text{dépenses annuelles de santé de l'individu } i \\ X_i = \text{revenu annuel de l'individu } i \\ D_{2i} = 1 \text{ si l'individu } i \text{ a un diplôme du secondaire} \\ = 0 \text{ sinon} \\ D_{3i} = 1 \text{ si l'individu } i \text{ a un diplôme du supérieur} \\ \quad \text{ou un diplôme universitaire} \\ = 0 \text{ sinon} \\ u_i = \text{terme d'erreur stochastique} \end{array} \right.$$

Catégorie de référence = niveau d'éducation primaire ou moins.

α_1 = intercepte catég. de base

α_2 et α_3 indiquent de combien les interceptes des deux autres catég. varient l'intercepte catég. de base.

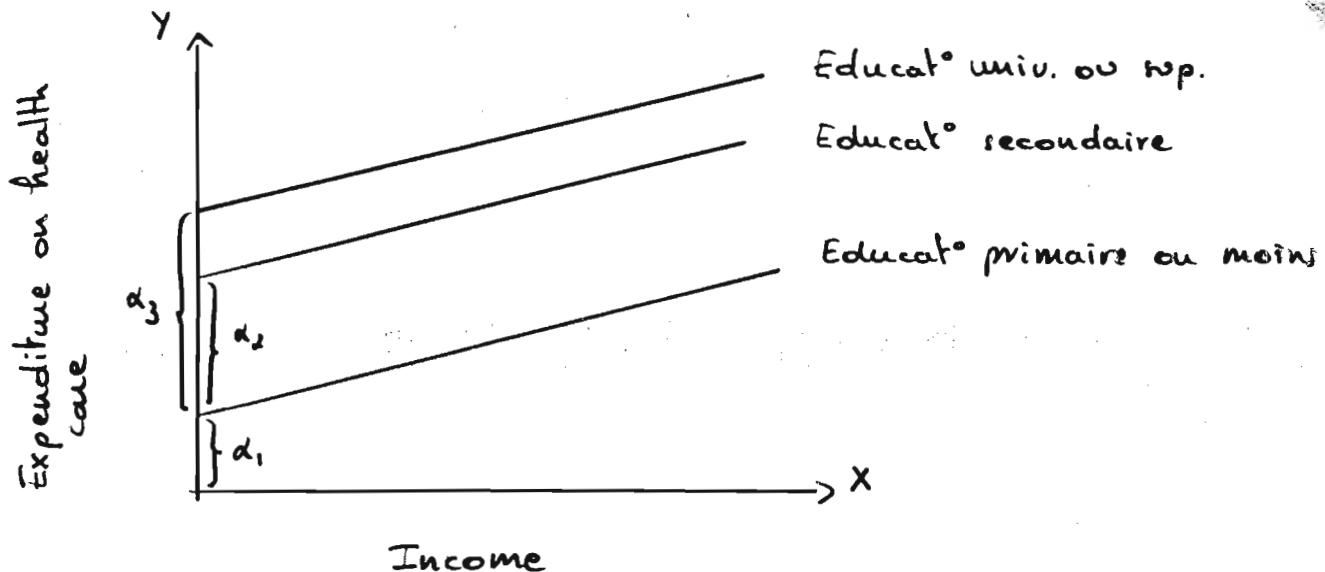
Si $E(u_i) = 0$

$$E(Y_i | D_2=0, D_3=0, X_i) = \alpha_1 + \beta X_i$$

$$E(Y_i | D_2=1, D_3=0, X_i) = (\alpha_1 + \alpha_2) + \beta X_i$$

$$E(Y_i | D_2=0, D_3=1, X_i) = (\alpha_1 + \alpha_3) + \beta X_i$$

si $\alpha_3 > \alpha_2 > 0$



D) Régression sur 2 variables qualitatives et 1 variable quantitative

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \beta X_i + u_i$$

où $\begin{cases} Y_i = \text{salaire annuel de l'individu } i \\ X_i = \text{nombre d'années d'expérience de l'individu } i \\ D_{2i} = 1 \text{ si l'individu } i \text{ est un homme} \\ \quad = 0 \text{ sinon} \\ D_{3i} = 1 \text{ si l'individu } i \text{ est blanc} \\ \quad = 0 \text{ sinon} \\ u_i = \text{terme d'erreur} \end{cases}$

individu = professeur.

Catégorie de référence : professeur féminins noirs

Si $E(u_i) = 0$:

$$E(Y_i | D_2 = 0, D_3 = 0, X_i) = \alpha_1 + \beta X_i \equiv \text{sal. moyen prof } \text{♀ noirs}$$

$$E(Y_i | D_2 = 1, D_3 = 0, X_i) = (\alpha_1 + \alpha_2) + \beta X_i \equiv \text{sal. moyen prof. } \text{♂ noirs}$$

$$E(Y_i | D_2 = 0, D_3 = 1, X_i) = (\alpha_1 + \alpha_3) + \beta X_i \equiv \text{sal. moyen prof } \text{♀ blancs}$$

$$E(Y_i | D_2 = 1, D_3 = 1, X_i) = (\alpha_1 + \alpha_2 + \alpha_3) + \beta X_i \equiv \text{sal. moyen prof } \text{♂ blancs}$$

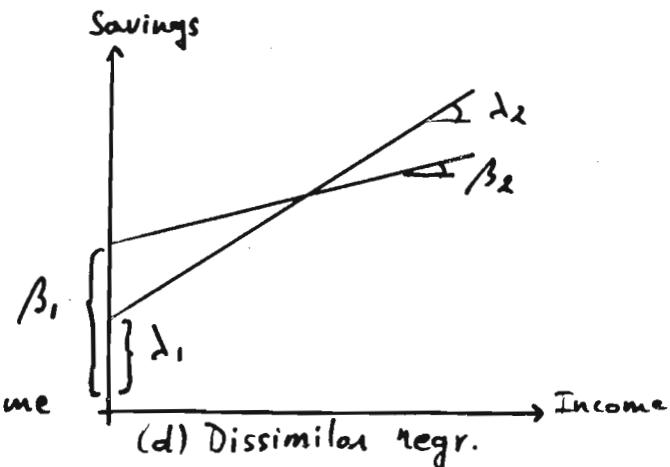
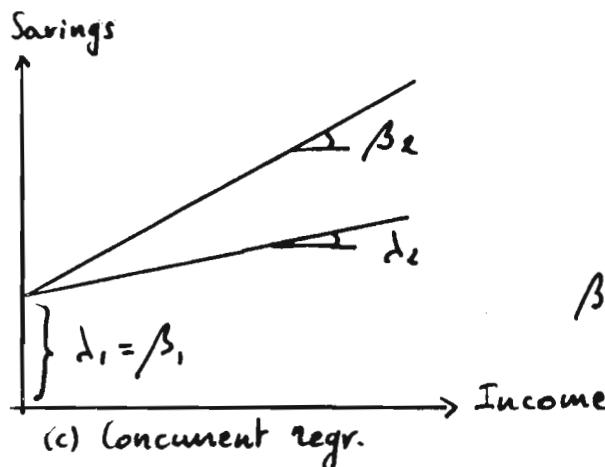
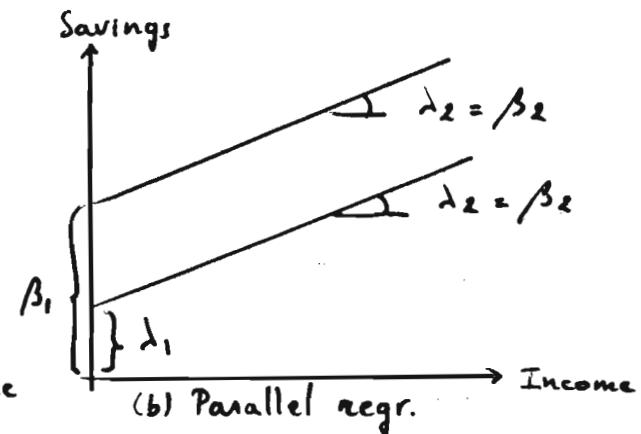
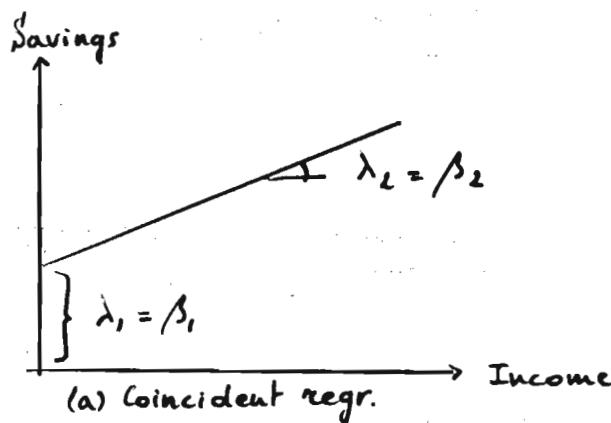
E) Les variables dummy comme alternative au test de Chow

- Rappel : test de Chow pour tester stabilité des paramètres dans relation tel épargne et revenu des ménages sur la période 1970 - 1995 aux USA

$$\text{Période 1970 - 1981 : } Y_t = \lambda_1 + \lambda_2 X_t + u_{1t} \quad (n_1 = 12) \quad (1)$$

$$\text{Période 1982 - 1995 : } Y_t = \beta_1 + \beta_2 X_t + u_{2t} \quad (n_2 = 14) \quad (2)$$

$$\text{Période 1970 - 1995 : } Y_t = \alpha_1 + \alpha_2 X_t + u_{3t} \quad (n = 26) \quad (3)$$



- En pratique, pour déterminer la source de la \neq (et les 2 régressions), on regroupe ens. des obs. et on estime modèle suivant :

$$Y_t = \alpha_1 + \alpha_2 D_t + \delta_1 X_t + \delta_2 (D_t \cdot X_t) + u_t \quad (4)$$

où

Y = Epargne	$D = 1$ pour obs. de la période 1982-1995 $= 0$ sinon
X = revenu	
t = temps	
α_1	
α_2	

δ_1 = terme d'erreur

- Si $E(u_i) = 0$:

$$E(Y_t | D_t = 0, X_t) = \alpha_1 + \delta_1 X_t \equiv \text{Epargne moyenne période } 70-81$$

$$E(Y_t | D_t = 1, X_t) = (\alpha_1 + \alpha_2) + (\delta_1 + \delta_2) X_t \equiv \text{Epargne moyenne période 82-95}$$

- Si ($\lambda_1 = \alpha_1$) et ($\lambda_2 = \alpha_2$) } ($\beta_1 = \alpha_1 + \alpha_2$) et ($\beta_2 = \delta_1 + \delta_2$) } on obtient:

$$\Rightarrow Y_t = \lambda_1 + \lambda_2 X_t + u_{1t} \quad (\text{période 1970 - 1981}) \quad (1)$$

$$Y_t = \beta_1 + \beta_2 X_t + u_{2t} \quad (\text{période 1982 - 1995}) \quad (2)$$

- Dans l'équation (4):

$\alpha_2 \equiv$ différentiel d'intercepte (et 2 périodes)

$\delta_2 \equiv$ différentiel de pente (et 2 périodes)

- Inclusion d'une dummy sous la forme:

- interactive / multiplicative permet de tester des \neq de pentes
- additive permet de tester des \neq d'interceptes

- $\hat{Y}_t = 1,0161 + 152,4786 D_t + 0,0803 X_t - 0,0655 (D_t X_t)$
 $s_e = (20,1648) \quad (33,0824) \quad (0,0144) \quad (0,0159)$
 $t = (5,5043) \quad (4,6090) \quad (5,5413) \quad (-4,0963)$

où $\begin{cases} Y = \text{épargne} \\ X = \text{revenu} \\ t = \text{temps} \\ D = 1 \text{ pour obs. le } 1982 \text{ et } 1995 \\ = 0 \text{ sinon} \end{cases}$

- Fonction de régression de chaque période :

$$\hat{Y}_t = 1,0161 + 0,0803 X_t \equiv \text{regr. épargne - revenu pour } 1970 - 1981$$

$$\begin{aligned} \hat{Y}_t &= (1,0161 + 152,4786) \\ &\quad + (0,0803 - 0,0655) X_t \\ &= 153,4947 + 0,0148 X_t \quad \equiv \text{regr. épargne - revenu pour } 1982 - 1995 \end{aligned}$$

- Avantages "dummy" par rapport test de Chow ?

- 1) On estime 1 seule régression.
- 2) Estimation + précise car + de df.
- 3) Permet de tester de nombreuses hyp :
 - * tester si $\alpha_2 = \delta_2 = 0$ avec F-test
permet de vérifier l'EI d'un changement structurel
 - * tester à l'aide d'un test en t si ce sont les intercepts et / ou les pentes qui sont \neq :
 $(\alpha_2 = 0 \text{ et / ou } \delta_2 = 0)$

ii) Les effets d'interactions en utilisant des dummy

Impact sur la variable dépendante de l'interaction entre plusieurs variables explicatives.

Illustration :

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \beta X_i + u_i \quad (1)$$

où

$\left\{ \begin{array}{l} Y = \text{salaire horaire en \$} \\ X = \text{nombre d'années d'éducation} \\ D_{2i} = 1 \text{ si individu } i \text{ est une femme} \\ \quad = 0 \text{ sinon} \\ D_{3i} = 1 \text{ si individu } i \text{ est ni blanc, ni hispanique} \\ \quad = 0 \text{ sinon} \\ u_i = \text{terme d'erreur} \end{array} \right.$
--

Hypothèses implicites :

- i) α_2 est identique pour individus ayant couleurs de peau \neq
- ii) α_3 est identique pour fem et m

Pas tjs réalistes*. Il est possible que lorsque les 2 variables indicatrices valent 1 qu'il y ait un effet additionnel sur le salaire moyen. (interaction tel D_2 et D_3)

\Rightarrow effet des variables D_2 et D_3 sur salaire moyen n'est pas nécessairement additif comme dans équation (1)
il peut aussi être multiplicatif.

* Il est possible que l'effet du sexe sur la rémunération soit + nég. pour les blancs -1.49% ou les hisp que pour les noirs.

- Prise en compte de l'effet multiplicatif :

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \alpha_4 (D_{2i} D_{3i}) + \beta X_i + u_i \quad (2)$$

$$\Rightarrow E(Y_i / D_{2i} = 1, D_{3i} = 1, X_i) = (\alpha_1 + \alpha_2 + \alpha_3 + \underline{\alpha_4}) + \beta X_i$$

Salaire horaire moyen des q ni blanche, ni hisp. =

α_1 ≡ sal. horaire moyen de la catég. de réf.

(hommes blancs ou hisp.)

α_2 ≡ effet différentiel d'être une q

α_3 ≡ effet différentiel d'être ni blanc, ni hisp.

α_4 ≡ effet différentiel d'être une q ni blanche, ni hisp.

- En l'absence de variables d'interaction (unq. effet additif) :

$$E(Y_i / D_{2i} = 1, D_{3i} = 1, X_i) = (\alpha_1 + \alpha_2 + \alpha_3) + \beta X_i$$

⇒ Introduction des variables dummy sous une forme multiplicative modifie l'effet combiné des variables qualitatives sur la variable dépendante.

Exemple :

$$\hat{Y}_i = -0,2610 - 2,3606 D_{2i} - 1,7327 D_{3i} + 0,8028 X_i$$

$$(1) \quad t = (-5,367) \quad (-5,4873) \quad (-2,1803) \quad (9,9094)$$

$$R^2 = 0,2032, \quad n = 528$$

$$(2) \quad \hat{Y}_i = -0,2610 - 2,3606 D_{2i} - 1,7327 D_{3i} + 2,1289 \underline{D_{2i} D_{3i}} + 0,8028 X_i$$

$$t = (-5,367) \quad (-5,4873) \quad (-2,1803) \quad (1,9802) \quad (9,9095)$$

$$R^2 = 0,2532, \quad n = 528$$

$$\Rightarrow \hat{\alpha}_2 + \hat{\alpha}_3 + \hat{\alpha}_4 = -1,964 \quad \text{compris le } -2,3606 \& -1,7327$$

Interaction tel dummy et variable quantitative

Rendement d'une année d'éducation identique pour les ♀ et le ♂ ?

$$Y_i = \alpha_1 + \alpha_2 D_{2i} + \alpha_3 D_{3i} + \beta X_i + \delta (D_{2i} X_i) + u_i$$

Si $E(u_i) = 0$:

$$E(Y_i | D_{2i} = 1, D_{3i} = 0, X_i) = \alpha_1 + \alpha_2 + (\beta + \underline{\delta}) X_i \quad \text{♀ BH}$$

$$E(Y_i | D_{2i} = 0, D_{3i} = 0, X_i) = \alpha_1 + \beta X_i \quad \text{♂ BH}$$

$$E(Y_i | D_{2i} = 1, D_{3i} = 1, X_i) = \alpha_1 + \alpha_2 + \alpha_3 + (\beta + \underline{\delta}) X_i \quad \text{♀ N}$$

$$E(Y_i | D_{2i} = 0, D_{3i} = 1, X_i) = \alpha_1 + \alpha_3 + \beta X_i \quad \text{♂ N}$$

δ = différentiel de pente (= de redut) pour les ♀

6) L'utilisation des variables dummy de l'analyse saisonnière

Nombreuses séries éco. (p.ex. mensuelles, trimestrielles) présentent des mouvements oscillatoires réguliers (structure saisonnière).

Ajustement saisonnier = processus qui consiste à enlever comp. saisonnière d'une série temporelle.

Méthode des variables dummy pour désaisonnaliser une série temporelle.

- Exemple : Ventes de réfrigérateurs aux Etats-Unis entre 1978 et 1985

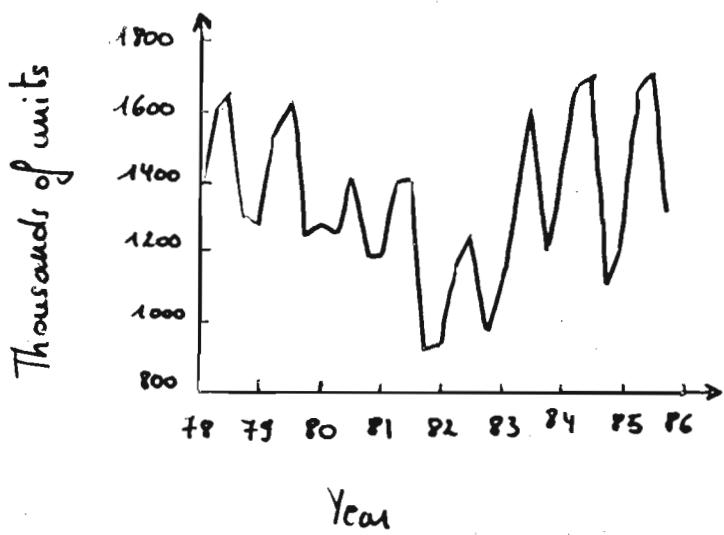


Fig. : Sales of refrigerators 1978 - 1985 (quarterly)

$$Y_t = \alpha_1 + \alpha_2 D_{2t} + \alpha_3 D_{3t} + \alpha_4 D_{4t} + u_t$$

où $\begin{cases} Y = \text{ventes de réfrigérateurs (milliers d'unités)} \\ D_{2,3,4,t} = \text{variables dummy qui prennent valeur 1 (ou sinon) si donnée relative resp. au 2ème, 3ème ou 4ème trimestre} \end{cases}$

$$\Rightarrow \hat{Y}_t = 1222,13 + 245,37 D_{2t} + 347,63 D_{3t} - 62,13 D_{4t}$$

$t = (20,37)$	$(2,89)$	$(4,10)$	$(-0,73)$
---------------	----------	----------	-----------

$$R^2 = 0,53$$

- Obtention d'une série désaisonnalisée ?

$$\hat{u}_t = Y_t - \hat{Y}_t$$

Série désaisonnalisée = résidus \hat{u}_t de la régression des ventes de réfrigérateurs sur une cst et 3 dummy.

Série de résidus = révise initiale - composante saisonnière
 (il reste : composante cyclique, tendance et comp. aléatoire)

- Introduction d'une variable expl. quantitative (covariate) :

$$\hat{Y}_t = 456,24 + 242,50 D_{2t} + 325,26 D_{3t} - 86,08 D_{4t} + 2,77 X_t$$

t = (2,56)	(3,70)	(4,94)	(-1,31)	(4,45)
R ² = 0,729				

où $\begin{cases} Y = \text{ventes de réfrig. (milliers d'unités)} \\ D_t = \text{dummy pour trimestres} \\ X_t = \text{dépenses en biens durables des ménages (milliers de $)} \\ t = \text{temps} \end{cases}$

X_t se caractérise également par une comp. saisonnière ?

- Théorème de Frish - Waugh montre que l'inclusion des variables dummy D₂, D₃, D₄ (qui contrôlent pour la saisonnalité de la variable Y) supprime la composante saisonnière de la variable X.

Vérification :

- 1) Y ~ cst, D₂, D₃, D₄ $\rightarrow S_1$ (variable Y désais.)
- 2) X ~ cst, D₂, D₃, D₄ $\rightarrow S_2$ (var. X désais.)
- 3) S₁ ~ S₂ (+cst) (coeff ass. à S₂ nul que coeff. ass. à X)
 ds régr. Y ~ cst, D₂, D₃, D₄, X

H) La régression linéaire par morceau ("piecewise linear regr.")

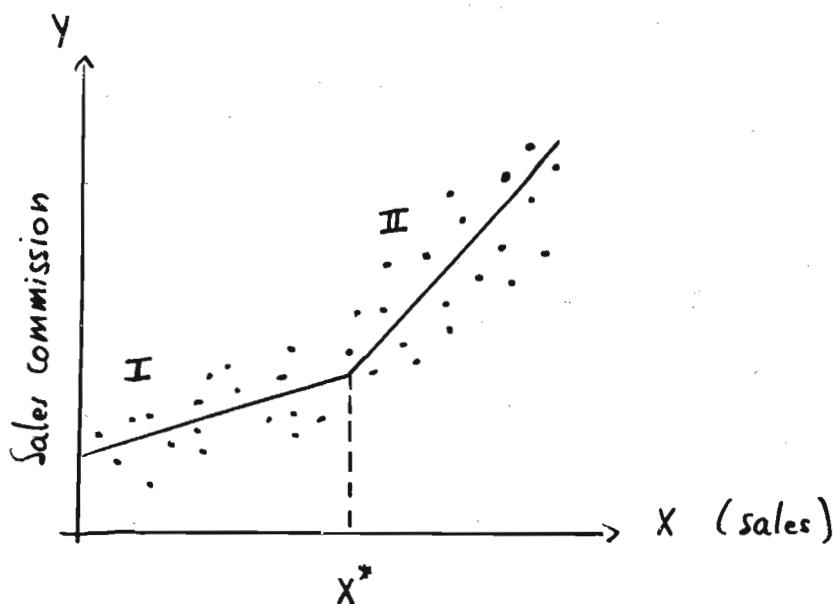


Fig.: Hyp. relationship b/w sales commission and sales volume

Note : The intercept on the Y axis denotes min. guaranteed commission.

- Estimation des segments linéaires (I) et (II) ?

$$Y_i = \alpha_1 + \beta_1 X_i + \beta_2 (X_i - X^*) D_i + u_i$$

où

Y_i = commission de l'individu „i“
X_i = volume de vente de l'individu „i“
X^* = valeur critique pour les ventes (connue a priori)
$D_i = 1$ si $X_i > X^*$
= 0 si $X_i < X^*$

Remarque : X^* pas tjs connu a priori

- Analyse graphique
- „Switching regression models“

- Si $E(u_i) = 0$:

$$E(Y_i | D_i = 0, X_i, X^*) = \alpha_1 + \beta_1 X_i \quad (X_i < X^*)$$

$$E(Y_i | D_i = 1, X_i, X^*) = \alpha_1 - \beta_2 X^* + (\beta_1 + \beta_2) X_i \quad (X_i > X^*)$$

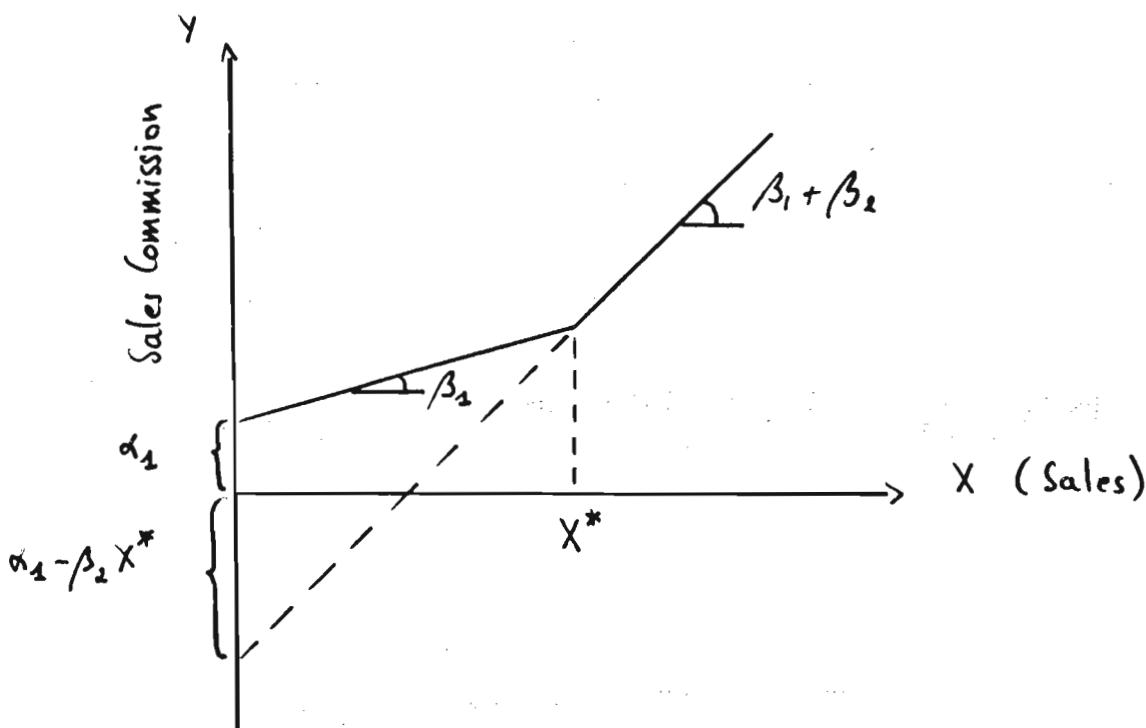


Fig. : Parameters of piecewise linear regression

Exemple : Relation tel coûts totaux & niveau de production

Hyp. : coûts marg. de prod. \neq lorsque prod. > 5500 unités

$$\hat{Y}_i = -145,72 + 0,28 X_i + 0,09 (X_i - X^*) D_i$$

$$t = (-0,82) \quad (6,07) \quad (1,14)$$

où

$$\left\{ \begin{array}{l} Y_i = \text{coûts totaux de l'entreprise } i \text{ (en \$)} \\ X_i = \text{niveau de production de l'entrep. } i \text{ (en unités)} \\ X^* = 5500 \text{ unités} \\ D_i = 1 \text{ si } X_i > X^* \\ = 0 \text{ si } X_i < X^* \end{array} \right.$$

(1 unité = 1 kg)

I) Interprétation des variables dummy de régr. semi-logarithmiques

Coeff. de régr. du modèle sem-log. \rightarrow semi-élasticités

(= mesure variation en % de la variable dép. suite à un changt unitaire de la variable explicative).

Interprétation s'applique uniq. aux variables expl. quant.

Quid si var. expl. qualitative ?

$$\ln Y_i = \beta_1 + \beta_2 D_i + u_i$$

où Y_i = salaire horaire de l'individu i (en \$)

$D_i = 1$ si individu i est une ♀
 $= 0$ sinon

u_i = terme d'erreur

Si $E(u_i) = 0$:

Fction de salaire des ♂ : $E(\ln Y_i | D_i = 0) = \beta_1$

Fction de salaire des ♀ : $E(\ln Y_i | D_i = 1) = \beta_1 + \beta_2$

β_1 = moyenne du log. des salaires horaires de ♂

β_2 = différence tel moyenne du log. des salaires horaire ♂ et ♀

$\exp(\beta_1)$ = salaire horaire „médian“ des ♂

$\exp(\beta_1 + \beta_2)$ = salaire horaire „médian“ des ♀

Ress.: $\exp(\text{moyenne}(\ln)) = \text{médiane}$

$\exp(\ln(\text{moyenne})) = \text{moyenne}$