

SOCIO 532.2
STATISTIQUES & INFORMATIQUE APPLIQUÉES AUX
SCIENCES SOCIALES

El Hadj Touré, Ph D. Sociologie
Département de psychoéducation,
Université de Sherbrooke

Leçon 3
De l'analyse bivariée.
Régression linéaire approfondie

17:00 1

1

Au programme

<ul style="list-style-type: none"> ■ Régression linéaire simple <ul style="list-style-type: none"> ❖ Quelques éléments de rappel ❖ Régression pour une relation entre deux variables quantitatives: quelques éléments de rappel ❖ Valeurs prédites et diagnostic de régression ❖ Les coefficients de régression standardisés (bêta): justification, calcul et interprétation 	<ul style="list-style-type: none"> ■ Régression linéaire simple avec une VI qualitative <ul style="list-style-type: none"> ❖ Modèle avec une VI dichotomique et parallèle avec l'ANOVA ❖ Modèle avec une VI qualitative non dichotomique et parallèle avec l'ANOVA ❖ Valeurs prédites et diagnostic de régression pour un modèle avec une VI
--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

2

2

Rappel sur les statistiques bivariées

Considérations générales

- Répondent à des questions de recherche du genre:
 - Y a-t-il une relation d'association entre une variable X et une variable Y dans les données de l'échantillon ? Si oui, quelle en est l'intensité, et la direction éventuellement?
 - La relation entre X et Y existe-t-elle dans la population dont provient l'échantillon ?
- Pour ce faire, quelques éléments de pré-analyse:
 - Identifier la VD (Y) et la VI (X)
 - Savoir comment les variables sont mesurées afin de choisir les techniques statistiques appropriées
 - S'assurer que la relation est plausible sociologiquement

17:02 3

3

Rappel sur les statistiques bivariées

Du problème de recherche au choix statistique

- Tester une relation entre deux variables quali
- Tester une relation entre une variable indépendante quali dichotomique et une variable dépendante quanti
- Tester une relation entre une variable indépendante quali non dichotomique et une variable dépendante quanti
- Tester une relation entre deux variables quanti

17.01 4

4 _____

Régression linéaire simple

Rappel

- Strictement parlant, l'analyse de régression linéaire est appropriée lorsque les deux variables sont quantitatives
 - Mesurer la force de la relation (signification réelle) : r, bêta, r-deux
 - Généraliser la relation (signification statistique) : test F
 - Procéder à la prédiction (équation de la droite) : $Y = a + b(X)$
- Le taux de fertilité varie-t-il selon le taux d'urbanisation dans les pays peuplés du monde (Fox, 1999)?
(n=50)

X

Taux d'urbanisation

→

Taux de fertilité


Y

$Y = f(X)$

20%, 81%... 7.3, 1.6...enfants/femme

17.00 5

5 _____



6 _____

Coefficient de régression standardisé (bêta)

Exemple illustratif

- Taux de fertilité selon le taux d'urbanisation (0 à 100)

Modèle		Coefficients non standardisés		Coefficients standardisés		t	Sig.
		B	Erreur standard	Bêta			
1	(Constante)	5,720	,516			11,090	,000
	Taux d'urbanisation	-.041	,009	-.555		-4,626	,000

a. Variable dépendante : Fertilité Taux de fertilité

- Taux de fertilité selon l'IDH (0 à 1)

Modèle		Coefficients non standardisés		Coefficients standardisés		t	Sig.
		B	Erreur standard	Bêta			
1	(Constante)	9,341	,761			12,280	,000
	Indice de développement humain	-8,181	1,048	-.748		-7,808	,000

a. Variable dépendante : Fertilité Taux de fertilité

10

Coefficient de régression standardisé (bêta)

Formule et calcul

- Un coefficient standardisé bêta β se calcule en multipliant le coefficient de régression b par le rapport entre l'écart-type de X et l'écart-type de Y :

$$\beta = b \cdot (s_X / s_Y)$$
 - Calcul bêta de l'effet du taux d'urbanisation
 $\beta = -0,041 \cdot (24,9 / 1,86) = -0,555$
 - Calcul bêta de l'effet de l'indice du développement humain
 $\beta = -8,181 \cdot (0,17 / 1,86) = -0,748$
- Dans une relation bivariée, le coefficient de régression bêta est égal au coefficient de corrélation: $\beta = r$

11

Coefficient de régression standardisé (bêta)

Interprétation statistique

→ Les écarts-types du taux de fertilité, du taux d'urbanisation et de l'IDH sont respectivement de 1,86, 24,9 et 0,17

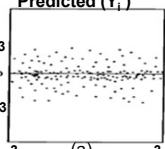
- Le coefficient bêta -0,56 indique que lorsque le taux d'urbanisation augmente d'un écart-type (24,9), le taux de fertilité diminue en moyenne de 0,56 écart-type
 - 0,56 écart-type représente **1,04 enfant/femme** ($0,56 \cdot 1,86$)
- Le coefficient bêta -0,75 indique que lorsque l'IDH augmente d'un écart-type (0,17), le taux de fertilité décroît en moyenne de 0,75 écart-type
 - 0,75 écart-type représente **1,40 enfant/femme** ($0,75 \cdot 1,86$)

12

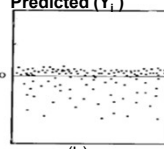
Régression linéaire simple

Vérification des postulats: Diagnostic des résidus

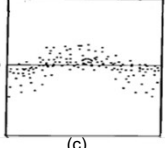
Residuals (errors)



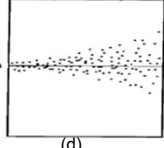
(a)



(b)



(c)



(d)

a) Postulats respectés:

- Normalité (pas de cas déviants)
- Linéarité
- Homogénéité

b) Non normalité

c) Non linéarité

d) Non homogénéité des variances

13

13

Au programme

- Régression linéaire simple
 - ❖ Quelques éléments de rappel
 - ❖ Régression pour une relation entre deux variables quantitatives: quelques éléments de rappel
 - ❖ Valeurs prédites et diagnostic de régression
 - ❖ Les coefficients de régression standardisés (bêta): justification, calcul et interprétation

- Régression linéaire simple avec une VI qualitative
 - ❖ Modèle avec une VI dichotomique et parallèle avec l'ANOVA
 - ❖ Modèle avec une VI qualitative non dichotomique et parallèle avec l'ANOVA
 - ❖ Valeurs prédites et diagnostic de régression pour un modèle avec une VI

14

14

Régression avec VI qualitative

Généralités

- Théoriquement, dans un modèle de régression linéaire simple où la VD est quantitative (ex. taux de fertilité), la VI doit être aussi quantitative (ex. taux d'urbanisation)
- Cependant, en pratique, dans un modèle de régression, on peut y inclure une VI qualitative, après avoir procédé à quelques opérations de recodage ou transformation
 - Pour une VI qualitative dichotomique, elle doit être codée 0/1 pour être interprétée comme une échelle
Région (0.Pauvre, 1.Riche) → Taux de fertilité
 - Pour une VI qualitative non dichotomique (k≥3), elle doit être transformée en variables factices dichotomiques 0/1
Région (0.Pauvre, 1.Emerg., 2.Riche) → Taux de fertilité

15

15

Régression avec VI qualitative non dichotomique

Interprétation statistique des coefficients

- Constante $a=5,57$
 - Lorsque la région est pauvre ($X=0$), le taux de fertilité prédit est de 5,57 enfants/femme
- Coefficient de régression de Région développée $b=-2,88$
 - Si l'on passe d'une région pauvre (0) à une région développée (1), la fertilité diminue de 2,88 enfants/femme
- Coefficient de régression de Région émergente $b=-1,06$
 - Si l'on passe d'une région pauvre (0) à une région émergente (1), la fertilité diminue de 1,06 enfant/femme

17:00 22

22

Régression avec VI qualitative non dichotomique

Prédiction

→ 2 prédictions à l'aide de l'équation : $\hat{Y} = a + b(X)$

- Effet de Région développée ($X=1$)
 - Lorsque la région est développée ($X=1$), le taux de fertilité prédit est de 1,69 enfant/femme
 - $\hat{Y} = 4,57 - 2,88(X)$
 - Fertilité prédite = $4,57 - 2,88(1) = 1,69$ enfant/femme
- Effet de Région émergente ($X=1$)
 - Lorsque la région est émergente ($X=1$), le taux de fertilité prédit est de 3,51 enfants/femme
 - $\hat{Y} = 4,57 - 1,06(X)$
 - Fertilité prédite = $4,57 - 1,06(1) = 3,51$ enfants/femme

17:00 23

23

Régression avec VI qualitative non dichotomique

Scores prédits et résiduels

Echier Edition Affichage Données Transformer Analyse Marketing direr Graphiques Utilitaires Extensions Fenêtre Aide

1: Fertilité 4,40 Y_i \hat{Y}_i $Y_i - \hat{Y}_i$ sur 19

	Pays	Region2	Region1	Fertilité	PRE_2	RES_2
1	Afrique du Sud	Autres	Pays en émergence	4,40	3,51	,89
2	Algérie	Autres	Autres	3,96	4,57	-,61
3	Allemagne	Pays développés	Autres	1,40	1,69	-,29
4	Arabie Saoudite	Autres	Pays en émergence	6,70	3,51	3,19
5	Argentine	Autres	Pays en émergence	2,72	3,51	-,79
6	Australie	Pays développés	Autres	1,83	1,69	,14
7	Bengladesh	Autres	Autres	4,55	4,57	-,02
8	Brésil	Autres	Pays en émergence	2,49	3,51	-,102
9	Canada	Pays développés	Autres	1,84	1,69	,15
10	Chine	Autres	Pays en émergence	1,85	3,51	-,166
11	Colombie	Autres	Autres	2,54	4,57	-,203

24
