

Exercise 1: Answer the following questions. When using math formula, make sure you define the variables used. (10 pts)

- a. (1.5 pts) Explain what is the difference between one-sided and two-sided compliance problems. Give an example of each case.
- b. (1.5 pts) What is a randomized controlled experiment. Give an example.
- c. (2 pts) Define the propensity score? What is it used for?
- d. (2 pts) Specify which treatment effect we can identify in a fuzzy regression discontinuity design and give its expression.
- e. (1.5 pts) Explain what is the difference between matching with replacement and matching without replacement. Which one delivers the most efficient estimate?
- f. (1.5 pts) Explain what is the difference between parametric and non-parametric estimation.

Exercise 2: (10 pts)

We want to investigate whether higher education causes higher wages. We use a dataset in which for n individuals we observe their wage rate (in logarithms, y), whether they have been to college ($c = 1$ if they have been, 0 if not), age and gender ($s = 1$ are males).

We regress the logarithm of the wage rate, y_i , on the college variable c_i and we get for the coefficient of education, an estimate of 0.048 with a standard error (s.e.) of 0.0030. This estimate is denoted $\hat{\beta}_1$. We call x the other variables age and gender. We also linearly regress the logarithm of the wage rate, y_i , on the college variable c_i AND variables x_i and we get for the coefficient of education, an estimate of 0.068 with a standard error (s.e.) of 0.0034. This estimate is denoted $\hat{\beta}_2$.

Question 1: (2 pts) Define precisely what the treatment is, what the potential outcomes are and what the average treatment effect on the treated (ATT) is. Explain with words or with formula.

Question 2: (2 pts) Describe the linear regression that would lead to estimates of the ATT in the population when the potential outcomes are given by:

$$y(d) = \alpha(d) + \beta(d)c + x\gamma(d) + \varepsilon(d)$$

when x consists of age and gender.

Question 3: (1 pt) Under what condition, $\hat{\beta}_1$ is a consistent estimate of ATT.

Question 4: (1 pt) Under what conditions, $\hat{\beta}_2$ is a consistent estimate of ATT.

Question 5: (1 pt) Explain what the common support assumption means in this context.

Question 6: (3 pts) Compare the estimated ATT obtained using Question 2 to $\hat{\beta}_1$ and $\hat{\beta}_2$ in terms of their statistical properties. You might need to formulate some additional conditions.

Exercice 1: Répondez aux questions suivantes. Si vous utilisez des formules mathématiques, veillez à bien définir les variables utilisées. (10 pts)

- a. (1.5 pts) Expliquer la différence entre les problèmes de one-sided et two-sided compliance. Donner un exemple pour chacun.
- b. (1.5 pts) Qu'est-ce qu'une expérience aléatoire contrôlée? Donner un exemple.
- c. (2 pts) Définissez le score de propensité (propensity score)? À quoi sert-il?
- d. (2 pts) Spécifiez quel effet de traitement on peut identifier dans un fuzzy regression discontinuity design et donner son expression mathématique.
- e. (1.5 pts) Expliquer la différence entre matching avec remise et matching sans remise (with/without replacement). Lequel donne l'estimateur le plus efficace?
- f. (1.5 pts) Expliquer la différence entre estimation paramétrique et estimation non-paramétrique..

Exercice 2: (10 pts)

On cherche à savoir si un niveau d'étude élevé implique un salaire élevé. On utilise des données sur n individus pour qui on observe le salaire (en logarithme, y), s'ils sont allés à l'université ($c = 1$ s'ils y sont allés, 0 sinon), l'âge et le sexe ($s = 1$ pour les hommes).

On régresse le logarithme du salaire, y_i sur la variable université (college) c_i et on obtient un estimateur de 0.048 pour cette variable avec un écart-type (s.e.) de 0.0030. On appelle cet estimateur $\hat{\beta}_1$. Soient x les autres variables âge et sexe. On régresse le logarithme du salaire, y_i sur la variable université c_i ET les autres variables x_i et on obtient comme estimateur du coefficient de la variable d'éducation 0.068 avec un écart-type (s.e.) de 0.0034. On appelle cet estimateur $\hat{\beta}_2$.

Question 1: (2 pts) Définir précisément quel est le traitement, quels sont les outcomes potentiels et qu'est-ce-que que l'effet de traitement sur les traités (ATT). Expliquer avec des mots ou des formules mathématiques.

Question 2: (2 pts) Décrire la régression linéaire qui donnerait un estimateur de l'ATT quand les outcomes potentiels sont donnés par:

$$y(d) = \alpha(d) + \beta(d)c + x\gamma(d) + \varepsilon(d)$$

où x représente l'âge et le sexe.

Question 3: (1 pt) Sous quelle condition $\hat{\beta}_1$ est un estimateur convergent de l'ATT.

Question 4: (1 pt) Sous quelles conditions, $\hat{\beta}_2$ est un estimateur convergent de l'ATT.

Question 5: (1 pt) Expliquer ce que l'hypothèse de support commun (common support) signifie dans ce contexte.

Question 6: (3 pts) Comparer l'estimateur d'ATT obtenu à la Question 2 avec $\hat{\beta}_1$ et $\hat{\beta}_2$ et leurs propriétés statistiques. Vous pourriez avoir besoin de formuler des hypothèses supplémentaires.