

14.310x – Data Analysis for Social Scientists

MicroMasters en Statistics and Data Science (SDS) – MITx

BREIT (Brescia Institute of Technology) · Aporta — Grupo Breca

Clase 10

Regresión en la Práctica y Sesgo de Variable Omitida

Ejercicios (5 niveles)

Módulos oficiales del MicroMaster:

M9 – Practical Issues in Running Regressions and Omitted Variable Bias

B.Sc. Cristian Lazo Quispe

✉ clazoq@uni.pe

[in linkedin.com/in/cristian-lazo-quispe](https://www.linkedin.com/in/cristian-lazo-quispe) · github.com/CristianLazoQuispe

Material del *Advanced Program in Data Science & Global Skills*, diseñado y desarrollado por **BREIT (Brescia Institute of Technology)**, iniciativa de **Aporta** —plataforma de innovación e impacto social del **Grupo Breca**— en alianza con el **MIT IDSS** (Institute for Data, Systems, and Society).

Basado en MIT 14.310x (E. Duflo & S. Ellison) y en diversas fuentes abiertas (ver bibliografía al final), bajo licencia CC BY-NC-SA 4.0.

27 de julio de 2026

Niveles de dificultad (*difficulty levels*)

Cada problema está rotulado por color según su nivel, de lo más accesible (Nivel 1) a lo más difícil (Nivel 5). Empieza por donde te sientas cómodo y avanza a tu ritmo; los niveles 4–5 son extensiones para profundizar, no un requisito.

- **Nivel 1 – Fundamentos:** calentamiento muy guiado; para quien parte de casi cero.
- **Nivel 2 – Núcleo:** el nivel objetivo del curso/examen.
- **Nivel 3 – Aplicación:** combina varias ideas en contexto realista.
- **Nivel 4 – Reto:** difícil, integra varios temas.
- **Nivel 5 – Reto+:** muy difícil / fuera del scope típico.

Indicaciones

Resuelve los ejercicios de tu nivel; si terminas, sube al siguiente (ver la leyenda de arriba). Recuerda las ideas clave de la clase. **Sesgo de variable omitida (OVB):** si el modelo verdadero es $Y = \beta_0 + \beta_1 X + \beta_2 W + \varepsilon$ pero omites W , la regresión corta estima

$$\mathbb{E}[\tilde{\beta}_1] = \beta_1 + \beta_2 \delta, \quad \delta = \frac{\widehat{\text{Cov}}(X, W)}{\widehat{\text{Var}}(X)} \quad (\text{pendiente de } W \sim X),$$

y el *signo* del sesgo es el de $\beta_2 \cdot \delta$. **Formas funcionales:** en log-lin el coeficiente es semi-elasticidad (por ciento); en log-log, elasticidad; en un cuadrático $Y = \beta_0 + \beta_1 X + \beta_2 X^2$ el punto de retorno es $X^* = -\beta_1/(2\beta_2)$. **Efectos fijos:** `factor(entidad)` absorbe todo lo constante dentro del grupo (usa la variación *within*). **RDD:** con $D = \mathbf{1}[a \geq a_0]$, el salto en el umbral estima un efecto causal *local*. Evita los *bad controls* (variables que son consecuencia del tratamiento).

1. Problemas

Nivel 1 – Fundamentos (warm-up)

Para quien parte de casi cero: cálculos directos y guiados.

Ejercicio 1.1 (Leer un coeficiente log-lin (en por ciento)). Una regresión del *logaritmo* del salario sobre los años de educación da

$$\widehat{\ln(\text{salario})} = 6.2 + 0.09 \text{ educación}.$$

- (a) Como Y está en logaritmo, ¿el 0.09 se lee en soles o en por ciento?
- (b) Interpreta el 0.09 en una frase.

Ejercicio 1.2 (Signo del sesgo con la regla del producto). El sesgo de variable omitida es $\beta_2 \cdot \delta$, donde β_2 es el efecto de la omitida sobre Y y $\delta = \text{Cov}(X, W) / \text{Var}(X)$ es la relación entre la omitida W y el regresor X .

- (a) Si $\beta_2 > 0$ y $\delta > 0$, ¿el sesgo es hacia arriba o hacia abajo?
- (b) Si $\beta_2 > 0$ y $\delta < 0$, ¿y ahora?

Ejercicio 1.3 (¿Control bueno o *bad control*?). Queremos el efecto de *años de educación* (X) sobre el *salario* (Y). Para cada candidato di si es un buen control (predeterminado) o un *bad control* (consecuencia de X):

- (a) la *región de nacimiento* de la persona;
- (b) la *ocupación* actual (que la educación ayuda a conseguir).

Ejercicio 1.4 (Punto de retorno de un modelo cuadrático). Un perfil de experiencia estima

$$\widehat{\ln(\text{salario})} = \dots + 0.05 \text{exper} - 0.001 \text{exper}^2.$$

El punto de retorno (turning point) es $X^* = -\beta_1 / (2\beta_2)$.

- (a) Calcula X^* .
- (b) ¿El salario sube o baja *después* de ese punto?

Ejercicio 1.5 (Leer una interacción básica). Se estima, con $D = 1$ si es mujer y 0 si es hombre,

$$\widehat{\text{salario}} = 1000 + 150 \text{educación} - 200 D - 40 (\text{educación} \cdot D).$$

- (a) ¿Cuánto sube el salario por un año más de educación para un **hombre**?
- (b) ¿Y para una **mujer**?

Ejercicio 1.6 (Identificar la running variable y el umbral). Un programa otorga una beca a todo estudiante que obtenga **al menos** 14 en un examen de admisión (nota de 0 a 20). Queremos el efecto de la beca sobre el ingreso futuro con un diseño de regresión discontinua (RDD).

- (a) ¿Cuál es la *running variable* y cuál el *umbral* a_0 ?
- (b) Escribe la regla del tratamiento D en términos de la nota a .

Ejercicio 1.7 (¿Qué hace `factor(entidad)`?). En R corremos `lm(y ~ x + factor(escuela))` sobre datos de alumnos de varias escuelas.

- (a) ¿Qué agrega `factor(escuela)` al modelo?
- (b) En una frase, ¿qué “controla” esa parte del modelo?

Nivel 2 – Núcleo (core)

El nivel objetivo del curso/examen; todos deberían llegar aquí.

Ejercicio 1.8 (Aplicar la fórmula del OVB). El modelo verdadero es $Y = \beta_0 + \beta_1 X + \beta_2 W + \varepsilon$ con $\beta_1 = 100$ y $\beta_2 = 300$. La pendiente de W sobre X es $\delta = 0.4$. Corremos la regresión corta (omitiendo W).

- (a) ¿Cuál es el valor esperado de $\tilde{\beta}_1$ (el coeficiente de la corta)?
- (b) ¿Cuánto es el sesgo y en qué dirección?

Ejercicio 1.9 (Elasticidad log-log). Una regresión log-log de la cantidad demandada sobre el precio da

$$\ln(\widehat{\text{cantidad}}) = 8.0 - 1.3 \ln(\text{precio}).$$

- (a) ¿Qué nombre recibe el coeficiente -1.3 ?
- (b) Si el precio sube 10 por ciento, ¿cuánto cambia (aprox.) la cantidad?

Ejercicio 1.10 (Efecto no constante en un modelo cuadrático). Con $\hat{Y} = 20 + 3X - 0.2X^2$ (Y = rendimiento, X = horas de estudio):

- (a) El efecto marginal es $\partial Y / \partial X = 3 - 0.4X$. Calcúlalo en $X = 2$ y en $X = 6$.
- (b) ¿A partir de cuántas horas estudiar de más *empeora* el rendimiento predicho?

Ejercicio 1.11 (El coeficiente se mueve al controlar: ¿por qué?). Regresión del salario sobre la educación. Corta (solo educación): coef = 302. Larga (añadiendo la habilidad, normalmente no observada): coef de educación = 181.

- (a) ¿Cómo se llama el fenómeno que hace que el coeficiente cambie de 302 a 181?
- (b) Sabiendo que gente más hábil estudia más y gana más, explica por qué la corta *sobrestimaba*.

Ejercicio 1.12 (Completar la tabla de signos). Para cada escenario, di la *dirección* del sesgo del coeficiente de X cuando se omite W .

- (a) X = cigarrillos de la madre, Y = peso del bebé; W = pobreza (baja Y : $\beta_2 < 0$; más pobreza $\Rightarrow$ más fumar: $\delta > 0$).
- (b) X = policías en una ciudad, Y = crimen; W = tamaño de la ciudad (sube el crimen: $\beta_2 > 0$; ciudades grandes tienen más policías: $\delta > 0$).

Ejercicio 1.13 (Interacción: efecto para dos grupos). $\hat{Y} = 50 + 8X + 12D + 2(X \cdot D)$, con D una dummy de zona urbana.

- (a) Escribe el efecto marginal de X como función de D .
- (b) ¿Cuánto vale en zona rural ($D = 0$) y urbana ($D = 1$)?

Ejercicio 1.14 (Pooled vs. within: ¿a cuál creer?). Con datos de 6 distritos, la regresión *pooled* de rendimiento sobre gasto da pendiente -0.38 ; al agregar `factor(distrito)` (efectos fijos), la pendiente pasa a $+1.35$.

- (a) ¿Cuál de las dos estima el efecto *dentro* de cada distrito?
- (b) Da una razón por la que la *pooled* sale negativa.

Ejercicio 1.15 (Estimar el salto en un RDD). Beca si el puntaje $a \geq 60$. Se estima, en una ventana alrededor del corte,

$$\hat{Y} = 41 + 9D + 0.5(a - 60), \quad D = \mathbf{1}[a \geq 60].$$

- (a) Predice Y justo por debajo del corte ($a = 60^-$, $D = 0$) y justo por encima ($a = 60^+$, $D = 1$).
- (b) ¿Cuál es el efecto causal local de la beca?

Ejercicio 1.16 (Detectar el *bad control* en un estudio). Un estudio del efecto de un *programa de capacitación* (X) sobre el *salario* (Y) controla por: (i) edad, (ii) educación previa, (iii) *si la persona fue ascendida* después de la capacitación.

- (a) ¿Cuál de los tres es un *bad control*?
- (b) ¿Por qué sesga incluirlo?

Ejercicio 1.17 (Interpretación lin-log). Se estima $\widehat{\text{gasto en salud}} = 200 + 150 \ln(\text{ingreso})$ (gasto en soles).

- (a) Si el ingreso sube 1 por ciento, ¿cuánto sube (aprox.) el gasto en salud?
- (b) ¿Y si el ingreso se *duplica* (sube 100 por ciento)?

Nivel 3 – Aplicación

Combina dos o más ideas en contexto realista; consolida lo aprendido.

Ejercicio 1.18 (Predecir la dirección del sesgo *sin* los datos). Estimamos el efecto del *tamaño de la clase* (X , n.º de alumnos) sobre el *rendimiento* (Y), pero omitimos el *nivel socioeconómico* W del colegio. Se sabe que: colegios con mejor nivel socioeconómico tienen *clases más pequeñas* ($\text{Corr}(X, W) < 0$) y mejor rendimiento ($\beta_2 > 0$).

- (a) ¿Hacia dónde se sesga el coeficiente de X ?

- (b) Si el efecto verdadero de clases más grandes es levemente negativo, ¿la regresión corta podría *exagerar* ese efecto negativo?

Ejercicio 1.19 (Elegir la forma funcional). Un análisis exploratorio (kernel) muestra que el *ingreso* sube con la *edad*, alcanza un máximo cerca de los 50 años y luego baja.

- (a) ¿Basta una regresión lineal $Y = \beta_0 + \beta_1 \text{edad}$? ¿Por qué no?
- (b) Propon una especificación OLS que capture esa forma y di el signo esperado del término nuevo.

Ejercicio 1.20 (Anatomía de la paradoja de Simpson). En cada uno de 3 hospitales, un tratamiento nuevo tiene *mayor* tasa de recuperación que el viejo. Pero juntando todos los datos (pooled), el tratamiento nuevo tiene *menor* tasa de recuperación.

- (a) Explica cómo es posible en términos de una variable omitida (el hospital).
- (b) ¿Qué regresión da la respuesta correcta?

Ejercicio 1.21 (Interpretar τ y su carácter *local*). Un RDD sobre una beca por puntaje ($a_0 = 60$) estima $\hat{\tau} = 9$ con una ventana de ± 15 puntos.

- (a) Interpreta $\hat{\tau} = 9$ con precisión (¿para quiénes vale?).
- (b) ¿Por qué *no* podemos concluir que la beca subiría 9 el resultado de un alumno con 30 puntos?

Ejercicio 1.22 (Decodificar interacción con dummies (estilo DiD)). Con *tratado* y *post* (dummies) y su interacción,

$$\hat{Y} = 10 + 2 \text{tratado} + 3 \text{post} + 5 (\text{tratado} \cdot \text{post}).$$

- (a) Calcula las cuatro medias de celda (control/tratado $\times$ antes/después).
- (b) ¿Cuál de los coeficientes es el efecto del programa (DiD)?

Ejercicio 1.23 (Log y cuadrático juntos). $\ln(\widehat{\text{salario}}) = 6.0 + 0.08 \text{educación} + 0.04 \text{exper} - 0.0008 \text{exper}^2$.

- (a) Interpreta el 0.08 de educación (¿en qué unidades?).
- (b) ¿A cuántos años de experiencia el salario predicho deja de crecer?

Ejercicio 1.24 (Calcular el sesgo desde una tabla de regresiones). Dos modelos sobre los mismos datos:

$$(\text{corta}) \hat{Y} = \dots + 250 X, \quad (\text{larga}) \hat{Y} = \dots + 180 X + 300 W.$$

Además, una regresión auxiliar da $\widehat{W} = \dots + \delta X$.

- (a) Usando $\tilde{\beta}_1 = \beta_1 + \beta_2\delta$, despeja δ .
- (b) Interpreta el signo de δ que obtuviste.

Ejercicio 1.25 (Diseñar la lista de controles). Quieres el efecto causal de *tener internet en casa* (X) sobre el *rendimiento escolar* (Y). Candidatos a control: (i) ingreso del hogar, (ii) educación de los padres, (iii) horas diarias en redes sociales, (iv) región.

- (a) ¿Cuáles incluirías como *buenos* controles?
- (b) ¿Cuál es un *bad control* y por qué?

Nivel 4 – Reto

Difícil: integra varios temas en un mismo problema.

Ejercicio 1.26 (Derivar la fórmula del OVB). Modelo verdadero $Y = \beta_0 + \beta_1 X + \beta_2 W + \varepsilon$ con $\mathbb{E}[\varepsilon | X, W] = 0$. Corremos la regresión corta de Y sobre X y obtenemos $\tilde{\beta}_1 = \widehat{\text{Cov}}(X, Y) / \widehat{\text{Var}}(X)$.

- (a) Sustituye el modelo verdadero en $\text{Cov}(X, Y)$ y simplifica.
- (b) Deduce que $\mathbb{E}[\tilde{\beta}_1] = \beta_1 + \beta_2 \delta$ con $\delta = \text{Cov}(X, W) / \text{Var}(X)$.

Ejercicio 1.27 (Punto de retorno: derivada y segundo orden). Sea $Y = \beta_0 + \beta_1 X + \beta_2 X^2$ con $\beta_2 \neq 0$.

- (a) Deriva respecto de X , iguala a cero y obtén $X^* = -\beta_1 / (2\beta_2)$.
- (b) Usa la segunda derivada para decir cuándo X^* es un *máximo* y cuándo un *mínimo*.

Ejercicio 1.28 (El supuesto de identificación del RDD y una amenaza). En un RDD, el tratamiento es $D = \mathbf{1}[a \geq a_0]$.

- (a) Enuncia el supuesto de identificación (¿qué debe ser *continuo* en a_0 ?).
- (b) Un examen de admisión con corte en 14 permite que el profesor “suba” notas de 13.5 a 14 a sus favoritos. ¿Por qué amenaza esto al RDD? ¿Cómo se detecta?

Ejercicio 1.29 (Efectos fijos eliminan la omitida invariante). Panel con entidades j : $Y_{ij} = \beta X_{ij} + \alpha_j + \varepsilon_{ij}$, donde α_j es un efecto de entidad *no observado* y posiblemente correlacionado con X .

- (a) Escribe el modelo en *desviaciones respecto a la media de la entidad* (resta $\bar{Y}_j, \bar{X}_j$).
- (b) Muestra que α_j desaparece y explica por qué eso elimina el OVB por α_j .

Ejercicio 1.30 (Elasticidad log-log con un cálculo real). Se estima $\ln(\text{cantidad}) = 10 - 0.8 \ln(\text{precio})$. Actualmente el precio es $P = 50$ y la cantidad predicha es $Q = 200$.

- (a) Usando la elasticidad, estima el cambio porcentual en Q si el precio sube a 55 (un +10 por ciento).
- (b) Aproxima el cambio en *unidades* de Q .

Ejercicio 1.31 (Dos omitidas con sesgos de signo opuesto). Estimamos el efecto de la educación (X) sobre el salario, omitiendo *dos* variables: la *habilidad* W_1 (sube el salario, correlación positiva con X) y la *mala salud crónica* W_2 (baja el salario, y las personas con más educación tienden a tener *mejor* salud, i.e. $\text{Corr}(X, W_2) < 0$).

- (a) Da el signo del sesgo que aporta cada omitida.
- (b) ¿Se puede firmar (determinar) el signo del sesgo total? Explica.

Nivel 5 – Reto+

Muy difícil / fuera del scope típico: demostraciones y casos límite.

Ejercicio 1.32 (OVb y el teorema de Frisch–Waugh–Lovell (partialling-out)). El teorema FWL dice que el coeficiente de X en la larga $Y = \beta_0 + \beta_1 X + \beta_2 W + \varepsilon$ se obtiene así: (1) regresa X sobre W y guarda el residuo $\tilde{X}$; (2) regresa Y sobre $\tilde{X}$.

- (a) Interpreta qué es $\tilde{X}$ y por qué “limpiar X de W ” da el efecto *ceteris paribus*.
- (b) Conecta con el OVb: ¿por qué la regresión corta (sobre X sin limpiar) da $\beta_1 + \beta_2 \delta$ en vez de β_1 ?

Ejercicio 1.33 (Sharp vs. fuzzy RDD). En el RDD *nítido* (*sharp*) el tratamiento salta de 0 a 1 exactamente en a_0 . En el *difuso* (*fuzzy*), cruzar el umbral solo *aumenta la probabilidad* de tratarse (no todos cumplen).

- (a) En el sharp, el efecto es (salto en Y). En el fuzzy, ¿por qué hay que *dividir* el salto en Y por algo?
- (b) Escribe el estimador fuzzy como cociente e identifica numerador y denominador.

Ejercicio 1.34 (Bad control formal: condicionar en un *collider*). Sea X (tratamiento) aleatorio, M una variable *posterior* afectada por X y por un factor no observado U que también afecta Y : $M = X + U$, $Y = U + \text{ruido}$ (así X *no* tiene efecto directo sobre Y : el efecto verdadero es 0).

- (a) Sin controlar por M , ¿qué estima la regresión de Y sobre X ?
- (b) Al controlar por M (un post-tratamiento), argumenta por qué aparece una asociación espuria entre X e Y .

Ejercicio 1.35 (OVb en forma matricial (multivariado)). Modelo verdadero $Y = X\beta + W\gamma + \varepsilon$, con X la matriz de regresores incluidos (incluye la constante) y W los omitidos. La regresión corta estima $\tilde{\beta} = (X^\top X)^{-1} X^\top Y$.

- (a) Sustituye el modelo verdadero y muestra que $\mathbb{E}[\tilde{\beta}] = \beta + (X^\top X)^{-1} X^\top W \gamma$.
- (b) Identifica quién juega el papel de “ δ ” del caso simple y da la condición para que *no* haya sesgo.

Prácticas en R — házlas *desde cero*

Estos cuatro ejercicios se resuelven **en R, desde cero**, solo con el enunciado (que ya te dice el archivo de datos, sus columnas y los puntos a encontrar). **Si te trabas**, pide el archivo `pN_*.R` con espacios `----` para completar. El **solucionario** (código + números + interpretación) se entrega al final de la clase (y está en `pN_*_sol.R`).

Ejercicio 1.36 (R desde cero — Sesgo de variable omitida (`ovb.csv`)). Tienes el archivo `ovb.csv` con tres columnas: `salario`, `educacion` y `habilidad`. La *habilidad* casi nunca se observa en datos reales; aquí la incluimos a propósito para poder *ver* el sesgo. **Se pide** (todo en R):

- (a) Corre la regresión *corta* de `salario` sobre `educacion` y anota el coeficiente de `educacion`.
- (b) Corre la *larga* agregando `habilidad`; anota el nuevo coeficiente de `educacion` y el de `habilidad`.
- (c) Calcula δ como la pendiente de regresar `habilidad` sobre `educacion`.
- (d) Verifica que el cambio del coeficiente de `educacion` (corta – larga) es igual a $\beta_2 \cdot \delta$. ¿El sesgo es *hacia arriba* o *hacia abajo*? Interpreta.

Ejercicio 1.37 (R desde cero — Formas funcionales: log y cuadrático (`mincer.csv`)). El archivo `mincer.csv` tiene `salario`, `educacion` y `experiencia`. Queremos un modelo donde el salario entre en *logaritmo* (para leer en por ciento) y la experiencia tenga un término *cuadrático* (para capturar que sube y luego se aplana). **Se pide** (en R):

- (a) Ajusta $\ln(\text{salario})$ sobre `educacion` y `experiencia`, agregando el término cuadrático con `I(experiencia^2)`.
- (b) Interpreta el coeficiente de `educacion` como *semi-elasticidad* (en por ciento).
- (c) Calcula el *punto de retorno* de la experiencia, $-\beta_1/(2\beta_2)$.
- (d) ¿Qué le pasa al salario *después* de ese punto? Justifica con el signo de β_2 .

Ejercicio 1.38 (R desde cero — Efectos fijos y paradoja de Simpson (`panel.csv`)). El archivo `panel.csv` tiene `distrito`, `gasto` (por alumno) y `rendimiento`, para 6 distritos. **Se pide** (en R):

- (a) Corre la regresión *pooled* de `rendimiento` sobre `gasto` y anota la pendiente.

- (b) Agrega `factor(distrito)` (efectos fijos) y anota la nueva pendiente.
- (c) ¿Cambia el *signo*? Explica por qué (¿qué variable omitida hay?) y a cuál de las dos regresiones le creerías.

Ejercicio 1.39 (R desde cero — Regresión discontinua (`rdd.csv`)). El archivo `rdd.csv` tiene `puntaje`, `beca` y `resultado` (ingreso futuro). La beca se otorga si `puntaje` ≥ 60 . Se pide (en R):

- (a) Quédate con una *ventana* alrededor del corte, $|\text{puntaje} - 60| \leq 15$, y crea la running variable *centrada* `x = puntaje - 60`.
- (b) Ajusta `resultado` sobre `beca`, `x` y su interacción `beca:x`.
- (c) El coeficiente de `beca` es el *salto* en el umbral. Interpretalo: ¿para quiénes vale ese efecto?

Fuentes y atribución

Material de repaso **basado en MIT 14.310x – Data Analysis for Social Scientists** (Esther Duflo & Sara Fisher Ellison), MIT OpenCourseWare, licencia **CC BY-NC-SA 4.0** (uso no comercial, con atribución, compartir bajo la misma licencia), y en las fuentes de la bibliografía. Los enunciados se basan en el material del curso y en diversas fuentes abiertas; cuando un problema se adapta de una fuente específica, se cita en el enunciado.

Para esta clase (M9 — Regresión en la práctica y OVB) se usaron, además, como *referencia/inspiración* (sin copiar texto ni código): MIT 14.310x lecciones **L19–L20** (Prof. E. Duflo) y **Homework 9** (datos `fastfood.csv`); y los repositorios abiertos de la comunidad `mynameisjanus/14310xDataAnalysis` (Module 9: OVB, formas funcionales, RDD), `Data-Analysis-Cheat-Sheet-for-Social-Scientists` (Regression Practice: OVB, DiD), `dnackat/data-analysis-for-social-scientists-mitx` (Homework 9: Card & Krueger, RDD) y el *Fall 2020* Module 9 — todos **sin licencia explícita**, usados solo como referencia, no como copia. Textos de apoyo: Wooldridge, *Introductory Econometrics*; Angrist & Pischke, *Mostly Harmless Econometrics* (OVB, efectos fijos, RDD).

Bibliografía.

- Duflo, E. & Ellison, S. F. *14.310x: Data Analysis for Social Scientists*. MIT OpenCourseWare (slides, lecture notes y problem sets). ocw.mit.edu.
- Larsen, R. J. & Marx, M. L. *An Introduction to Mathematical Statistics and Its Applications*, 6.^a ed., Pearson, 2018.
- DeGroot, M. H. & Schervish, M. J. *Probability and Statistics*, 4.^a ed., Pearson, 2012.
- Blitzstein, J. & Hwang, J. *Introduction to Probability* (Harvard Stat 110); W. Chen, *Probability Cheatsheet*.
- Diez, D., Çetinkaya-Rundel, M. & Barr, C. *OpenIntro Statistics*. openintro.org.
- Materiales abiertos de la comunidad del curso en GitHub: `gevorg-hunanyan/probability`; `hanmochen/Probability-Theory-2020`; `mynameisjanus/14310xDataAnalysis`.

creativecommons.org/licenses/by-nc-sa/4.0