

On the Asymptotic Properties of Debiased Machine Learning Estimators

Amilcar Velez
Cornell University

XLIII Encuentro de Economistas del BCRP

Octubre 22, 2025

Introducción

- Parámetro de interés θ_0 satisface

$$E[m(W, \theta_0, \eta_0(X))] = 0$$

- W, X : vectores aleatorios (datos)
- $\eta_0(\cdot)$: función molesta de características
- Estudio estimadores basados en DML (debiased machine learning)
 - DML: metodología para estimar θ_0 cuando $\eta_0(\cdot)$ se estima usando *machine learning*



Motivacion

- DML1 y DML2
 - ambos dividen los datos de manera aleatoria en K bloques para estimar η_0
 - Difieren en como estimar θ_0 usando las estimaciones de η_0
- La teoria asintotica existente (donde K es fijo mientras $n \rightarrow \infty$) predice:
 - $DML1 \sim DML2$
- Simulaciones :
 - $DML2 \geq DML1$

(Q1) Por que deberíamos usar DML2?

(Q2) Como deberíamos elegir K para DML2?

Este paper:

- Estudia las propiedades de DML1 y DML2 bajo una nueva teoria asintotica

Considero secuencias K_n (e.g., $K_n = 5$, $K_n \propto \sqrt{n}$, $K_n = n$)

Bajo esta nueva teoria asintotica explico las diferencias encontradas en simulaciones

Q1: Por que deberiamos usar DML2 ?

- DML2 \succcurlyeq DML1 en términos de bias, ECM, e inferencia
- DML2 es robusto a la elección de K

Q2: Como deberíamos elegir K para DML2? (bajo ciertas condiciones)

- $K = n$ minimiza el bias y ECM asintótico para DML2

Outline

- Setup y notación
- Simulaciones
- Resultados principales
 - Por que y cuando $DML2 \geq DML1$
 - Como seleccionar K para DML2
- Conclusiones

Modelo Econométrico

- El parámetro de interés $\theta \in \mathbb{R}$ satisface :

$$E[m(W, \theta_0, \eta_0(X))] = 0$$

donde

$$m(W, \theta, \eta) = \psi^b(W, \eta) - \psi^a(W, \eta) \theta$$

$$E[\partial_\eta m(W, \theta_0, \eta_0(X)) | X] = 0 \dots \text{(Condición de ortogonalidad de Neyman)}$$

- Ejemplos estudiados en la literatura:
 - Average treatment effect (ATE)
 - Robins et al. (1994): augmented inverse probability weighted (AIPW) estimators
 - Average treatment effect on the treated in difference-in-differences (**ATT-DID**)
 - Sant'Anna and Zhao (2020): double-robust (DR) estimator
 - Local average treatment effect (**LATE**) with covariates
 - Tan (2006), Chernozhukov et al. (2018), Singh and Sun (2024): DR and DML estimator

Problema de estimación

- $E[m(W, \theta_0, \eta_0(X))] = 0$ y $m(W, \theta, \eta) = \psi^b(W, \eta) - \psi^a(W, \eta) \theta$

- Objetivo: estimador $\theta_0 \in \mathbf{R}$ usando una muestra aleatoria $\{W_i : 1 \leq i \leq n\}$

Setup implica

$$\theta_0 = \frac{E[\psi^b(W, \eta_0(X))]}{E[\psi^a(W, \eta_0(X))]}$$

- Un estimador ideal

$$\hat{\theta}_n^* = \frac{\sum_{i=1}^n \psi^b(W_i, \eta_i)}{\sum_{i=1}^n \psi^a(W_i, \eta_i)}$$

donde $\eta_i = \eta_0(X_i)$

$\hat{\theta}_n^*$ *inviabile* \rightarrow estimamos $\hat{\eta}_i$ para η_i (1era-etapa) \rightarrow estimamos θ_0 usando $\hat{\eta}_i$ (2da-etapa)

DML: 1era-etapa usa sample-splitting

1. Dividimos la muestra aleatoriamente en K bloques/celdas de igual tamaño



2. Usamos todos los bloques menos uno para estimar la función molestosa η_0 y predecimos en el bloque restante



3. Repetimos el proceso para todos los bloques(ejemplo K=5)



DML: 2da-etapa

DML1: promedio de estimadores
sample-splitting

$$\hat{\theta}_{n,1}(K) = \frac{1}{K} \sum_{k=1}^K \underbrace{\left(\frac{\sum_{i \in \text{cell } k} \psi^b(W_i, \hat{\eta}_i)}{\sum_{i \in \text{cell } k} \psi^a(W_i, \hat{\eta}_i)} \right)}$$

Estimador $\tilde{\theta}_k$ resuelve
estimacion en cell k

$$\sum_{i \in \text{cell } k} m(W_i, \tilde{\theta}_k, \hat{\eta}_i) = 0$$

DML2: estimador de promedio de
modelos

$$\hat{\theta}_{n,2}(K) = \underbrace{\frac{\sum_{k=1}^K \sum_{i \in \text{cell } k} \psi^b(W_i, \hat{\eta}_i)}{\sum_{k=1}^K \sum_{i \in \text{cell } k} \psi^a(W_i, \hat{\eta}_i)}}$$

Similar al estimador ideal
pero reemplaza η_i por $\hat{\eta}_i$

$$\sum_{k=1}^K \sum_{i \in \text{cell } k} m(W_i, \hat{\theta}_{n,2}(K), \hat{\eta}_i) = 0$$

Comentarios

1. Teoría asintótica existente (donde **K es fijo** mientras $n \rightarrow \infty$):

- Predice **DML1** \sim **DML2**

- $n^{1/2}(\hat{\theta}_{n,j}(K) - \theta_0) \xrightarrow{d} N(0, \sigma^2)$ para $j = 1, 2$

- Chernozhukov et al (2018) propuso intervalos de confianza (IC)

- 95%-IC: $CI_{n,j} = \hat{\theta}_{n,j}(K) \pm 1.96 \hat{\sigma}_{n,j}(K)/\sqrt{n}$ for $j = 1, 2$

- $\hat{\sigma}_{n,j}^2(K)$ estimador para σ^2

2. Simulaciones:


- Sí **DML1** \sim **DML2**

- pero también **DML2** $>$ **DML1**


Outline

- Setup y notación
- Simulaciones
- Resultados principales
 - Por que y cuando $DML2 \geq DML1$
 - Como seleccionar K para DML2
- Conclusiones

$\sqrt{n} |\text{Bias}|$ (sesgo)





Modelo 1: ATT-DID, Sant'Anna & Zhao (2020)



Modelo 2: LATE, Hong and Nekipelov (2010)

Probabilidad de cobertura (en %) de los ICs



Comentarios

1. Simulaciones adicionales muestran:

- $DML1 \sim DML2$:
 - ATE, ATT, ATT-DID, PLM
- $DML2 \succ DML1$
 - LATE, w-ATE, IV-PLM

2. Chernozhukov et al (2018) recomienda en su Remark 3.1 usar DML2

- Stata package **ddml** (Ahrens et al. 2024) & R/python package DoubleML usan DML2

Este trabajo/paper:

- Explicación teórica $DML2 \succeq DML1$
- Condiciones para seleccionar K para DML2

Outline

- Setup y notacion
- Simulaciones
- Resultados principales
 - Por que y cuando $DML2 \geq DML1$
 - Como seleccionar K para DML2
- Conclusiones

Resultado principal para secuencias K_n

Teorema 1 (DML1):

Sea $\{K_n\}_{n \geq 1}$ una secuencia tal que (i) $K_n \leq n$ y (ii) $\lim_{n \rightarrow \infty} \frac{K_n}{\sqrt{n}} = \mathbf{c} \in [0, \infty)$. Asumamos que los supuestos de mi *paper* se cumplen. Entonces,

$$n^{1/2}(\hat{\boldsymbol{\theta}}_{n,1}(K_n) - \boldsymbol{\theta}_0) \xrightarrow{d} N(\boldsymbol{\Lambda} \mathbf{c}, \sigma^2)$$

donde

$$\boldsymbol{\Lambda} = \frac{\text{Cov}[\mathbf{m}(\mathbf{W}_i, \boldsymbol{\theta}_0, \boldsymbol{\eta}_i), -\boldsymbol{\psi}^a(\mathbf{W}_i, \boldsymbol{\eta}_i)]}{E[\boldsymbol{\psi}^a(\mathbf{W}_i, \boldsymbol{\eta}_i)]^2}$$


Teorema 2 (DML2):

Sea $\{K_n\}_{n \geq 1}$ una secuencia tal que $K_n \leq n$. Asumamos que los supuestos de mi *paper* se cumplen. Entonces,


$$n^{1/2}(\hat{\boldsymbol{\theta}}_{n,2}(K_n) - \boldsymbol{\theta}_0) \xrightarrow{d} N(0, \sigma^2)$$

- $\boldsymbol{\Lambda}$ y \mathbf{c} explican $\text{DML2} \geq \text{DML1}$ y cuando $\text{DML2} > \text{DML1}$
- Cálculo de $\boldsymbol{\Lambda}$ solo depende del modelo econométrico; y podemos usar $\mathbf{c} \approx K_n/\sqrt{n}$

$\sqrt{n}|\text{bias}|$ de DML1 es $\approx |\Lambda|c \approx |\Lambda| K/\sqrt{n}$

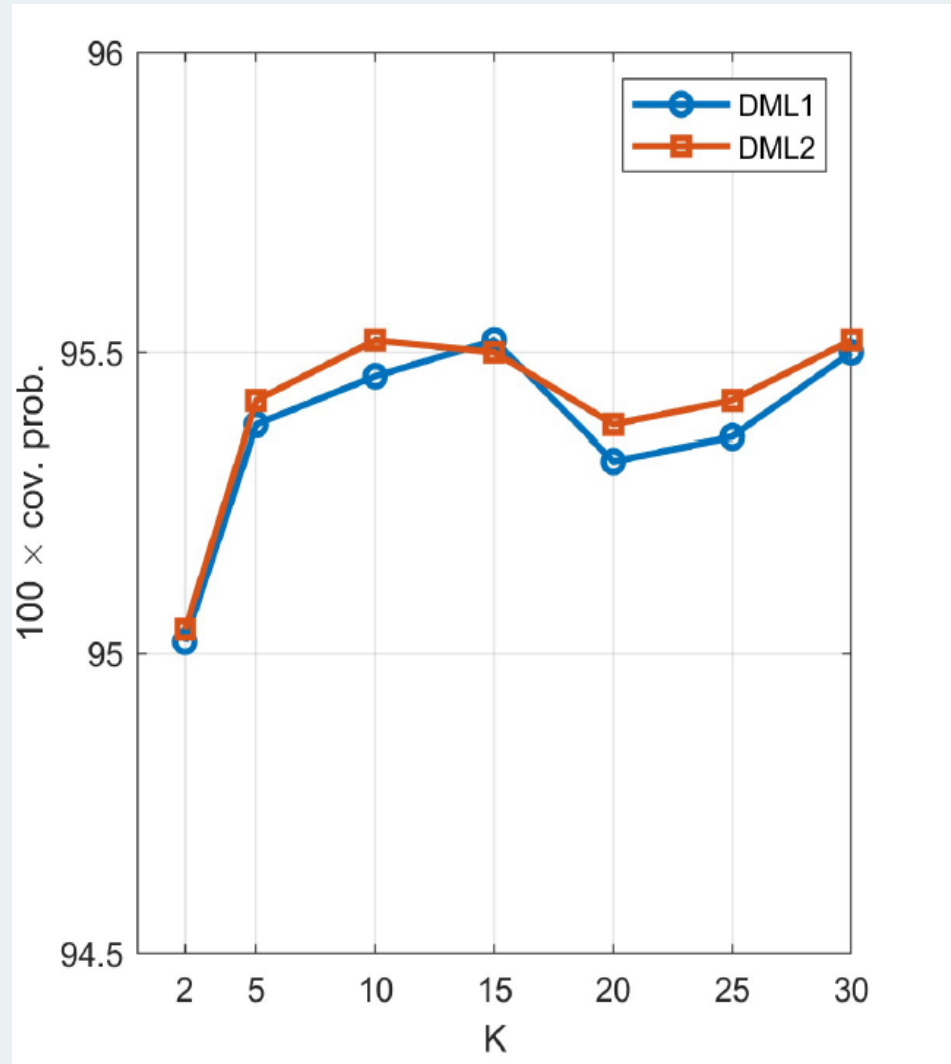


Modelo 1: ATT-DID ($\Lambda = 0$)




Modelo 2: LATE ($\Lambda \neq 0$)

Distribución de DML1 $\approx N(\Lambda K/\sqrt{n}, \sigma^2)$



Modelo 1: ATT-DID ($\Lambda = 0$)



Modelo 2: LATE ($\Lambda \neq 0$)

Observaciones importantes

$$\Lambda = \frac{\text{Cov}[m(W_i, \theta_0, \eta_i), -\psi^a(W_i, \eta_i)]}{E[\psi^a(W_i, \eta_i)]^2}$$

1. Λ es importante para explicar $\text{DML2} \geq \text{DML1}$ en simulaciones (tomando $\mathbf{c} \approx \mathbf{K}_n/\sqrt{n}$)
 - Λ puede ser calculado para distintos modelos econométricos:
 - ATE, ATT, ATT-DID, y PLM tienen $\Lambda = \mathbf{0} \Rightarrow \text{DML2} \sim \text{DML1}$
 - LATE, w-ATE, y IV-PLM tienen $\Lambda \neq \mathbf{0} \Rightarrow \text{DML2} \succ \text{DML1}$
2. Además,
 - DML2 es robusto a la elección de K: $n^{1/2}(\hat{\theta}_{n,2}(\mathbf{K}_n) - \theta_0) \xrightarrow{d} N(0, \sigma^2)$
 - los intervalos de confianza usando DML2 continúan validos

\Rightarrow Inferencia usando DML2 es valida y robusta a la elección de K

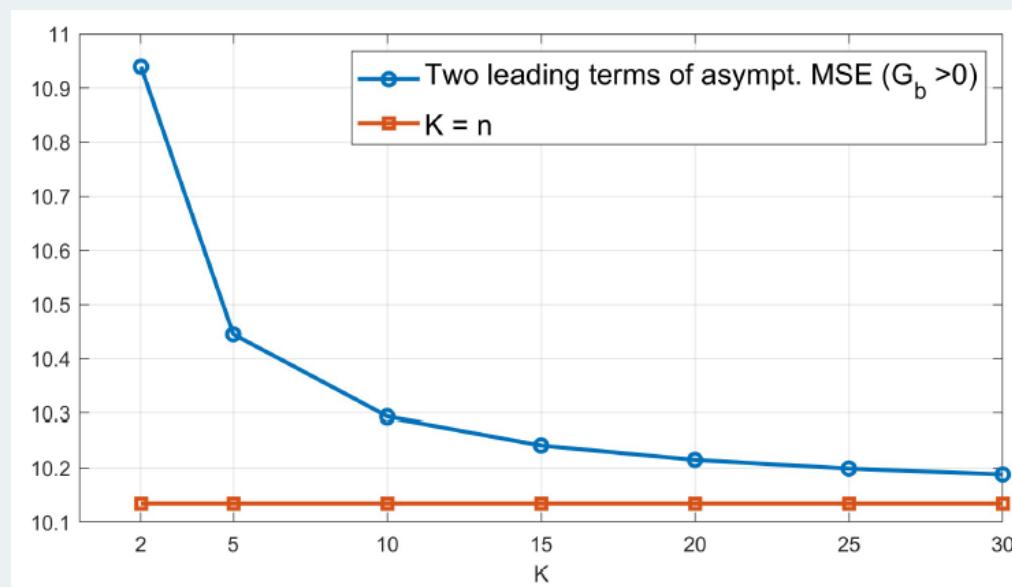
Outline

- Setup y notacion
- Simulaciones
- Resultados principales
 - Por que y cuando $DML2 \geq DML1$
 - Como seleccionar K para DML2
- Conclusiones

Aproximación de 2do-orden

$$E \left[\underbrace{n \left(\hat{\theta}_{n,2}(K_n) - \theta_0 \right)^2}_{n \times \text{ECM}} \right] \approx \underbrace{\sigma^2 + G_b \left(1 + \frac{1}{K_n - 1} \right)^{2\varphi - 1/2}}_{\text{Aproximación de \textbf{segundo orden} del ECM (SO-ECM)}} n^{1/2-2\varphi} + o(n^{1/2-2\varphi})$$

Asumimos $\hat{\eta}$ tiene estructura tal que $\|\hat{\eta} - \eta_0\|_2 = O(n^{-\varphi})$, donde $\varphi \in (\frac{1}{4}, \frac{1}{2})$



\Rightarrow DML2 con $K_n = 10$ mas preciso que DML2 con $K_n = 5$

\Rightarrow DML2 con $K_n = n$ mas preciso que DML2 con cualquier K_n constante

Conclusiones

- Este trabajo estudia DML1 y DML2 bajo una nueva teoría asintótica (secuencias K_n)
- Explica las diferencias encontradas en simulaciones
 - Introduce el parámetro Λ
- Brinda dos razones para elegir DML2 sobre DML1
 - DML2 domina asintóticamente a DML1 en términos de bias, MSE, e inferencia
 - DML2 es robusto a la selección de K
- Bajo ciertas condiciones adicionales, se recomienda seleccionar $K=n$ para DML2

Gracias por su atención!