

To EB or not to EB

Actualizando la metodología de estimación de áreas pequeñas en el Banco Mundial



WORLD BANK GROUP

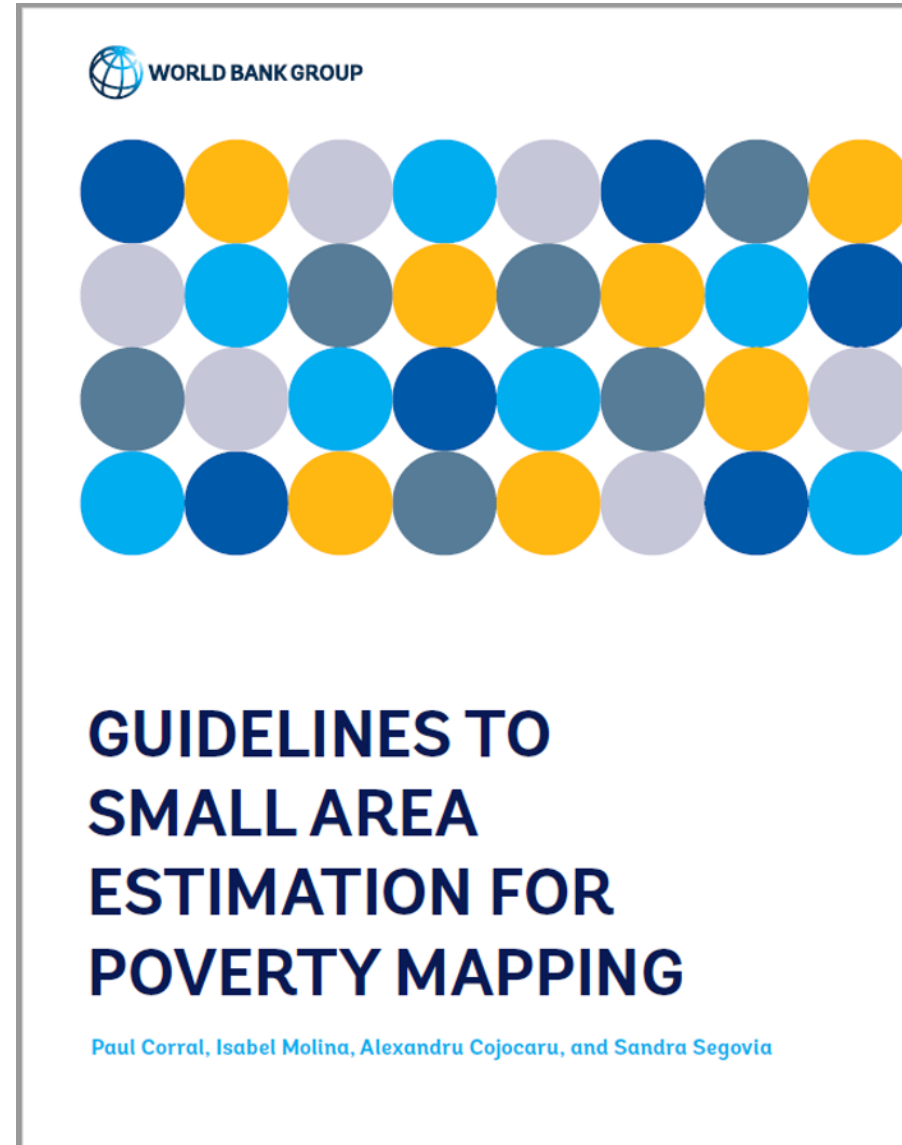
Paul Corral

Based on work done with:

Isabel Molina and

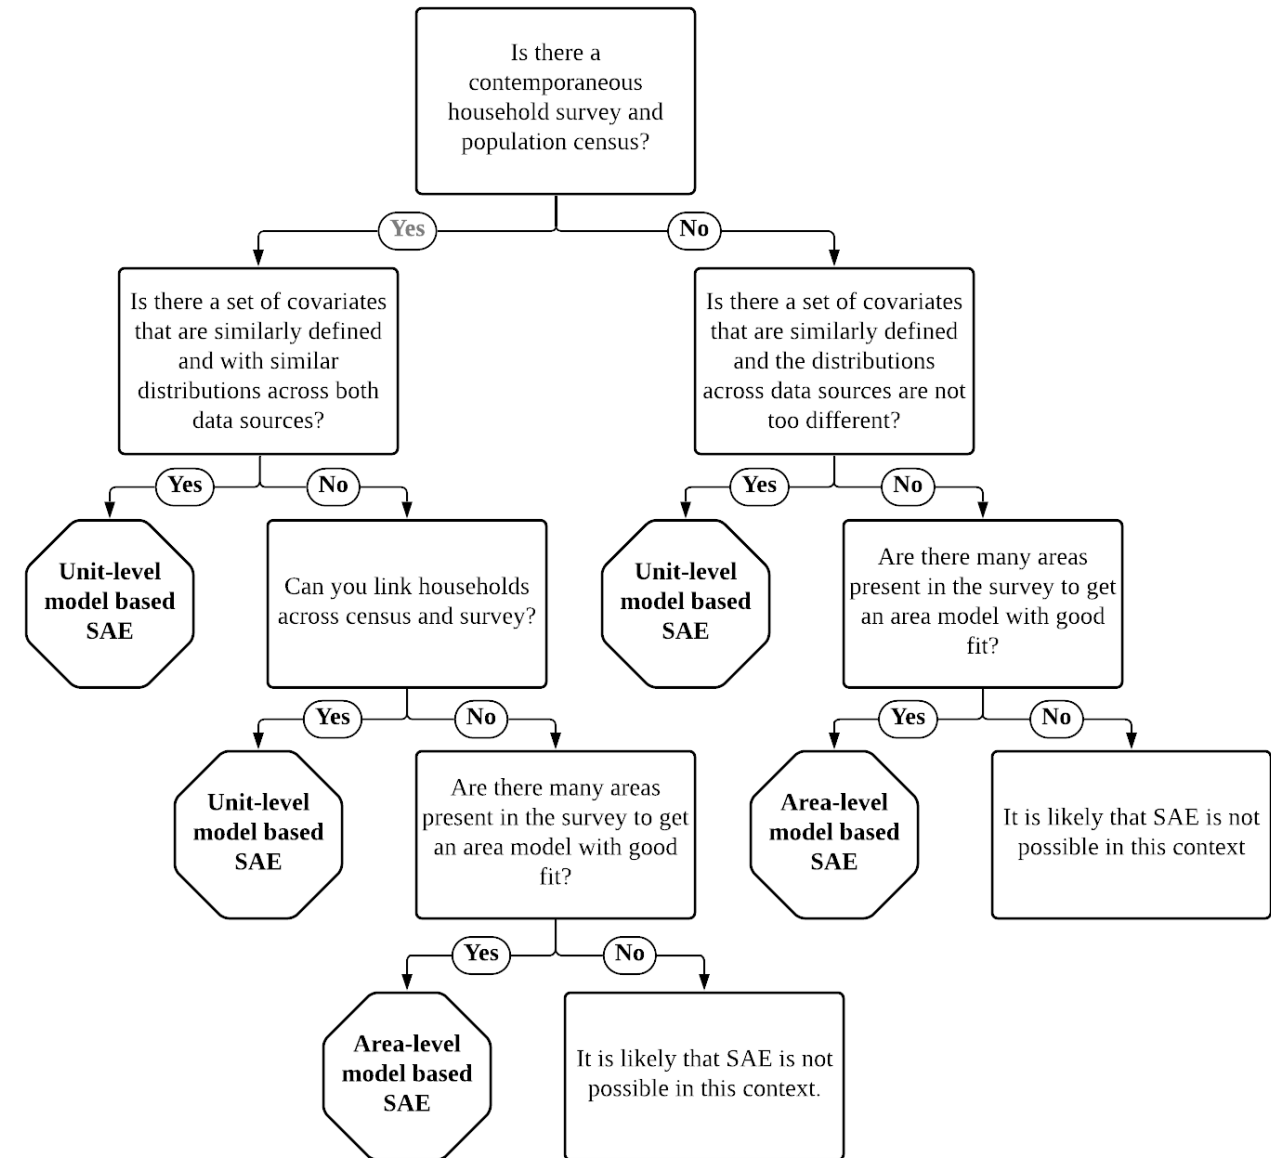
Kristen Himelein, Kevin McGee, Sandra Segovia, Alexandru Cojocaru and Minh Nguyen

Estimación para áreas pequeñas en el Banco Mundial



Las guías presentan un esquema para elegir la metodología apropiada para cada escenario

- Nos enfocamos en el uso de metodologías que han sido evaluadas extensivamente y que se ha demostrado que dan estimadores no sesgados y que mejoran la precisión
- Incluye múltiples ejemplos y códigos para que lectores interesados puedan replicar simulaciones con datos reales y generados



Un poco de historia sobre mapas de pobreza en el BM

- El primer intento serio se realizó por Hentschel, Lanjouw, Lanjouw y Poggi (2000)
 - La distribución de ingreso se simula en los datos del censo basados en parámetros estimados utilizando datos de encuestas a hogares que proporcionan información detallada de ingresos
 - Al simular la distribución completa de ingresos, se pueden obtener indicadores más allá de la pobreza y el ingreso promedio para un área determinada.
- Elbers, Lanjouw y Lanjouw (ELL - 2003) consideran efectos aleatorios de ubicación.
 - Molina y Rao (2010) mejoran el método de ELL e incorporan información a nivel de área de la encuesta para obtener el mejor predictor empírico (Empirical Best o EB en inglés).
 - La estimación EB garantiza que la media de la variable dependiente en cada área sea EBLUP, pero no garantiza lo mismo para la pobreza.
 - También aplican un bootstrap paramétrico alineado con las suposiciones basado en trabajo de González-Manteiga et al. (2008).

El primer intento de implementar EB en el Banco Mundial no fue ideal

- En el 2014 van der Weide propuso una actualización para incorporar la metodología EB a la herramienta oficial del Banco Mundial en ese entonces: PovMap
- El método trataba de unir la metodología EB con el método de estimación de indicadores y ruido que se usaba con ELL
 - El método que usa ELL está inspirado en la literatura de imputación múltiple, donde el objetivo no está alineado con minimizar el ruido de los indicadores
 - Además, debido a particulares del modelo, se usaban muestras Bootstrap para calzar el modelo con cada muestra y con cada muestra se obtenían los indicadores.
 - El estimador del indicador de interés era la media de los indicadores obtenidos con cada muestra y el ruido era medido como la varianza de los indicadores obtenidos con cada muestra
 - El método fue estándar, junto a ELL, en PovMap y luego en el paquete sae de Stata hasta el 2020.

El método supuesto bajo la metodología ELL y EB es el mismo

- El modelo con errores anidados usado para modelos a nivel de unidad viene del trabajo de Battese, Harter y Fuller (1988)

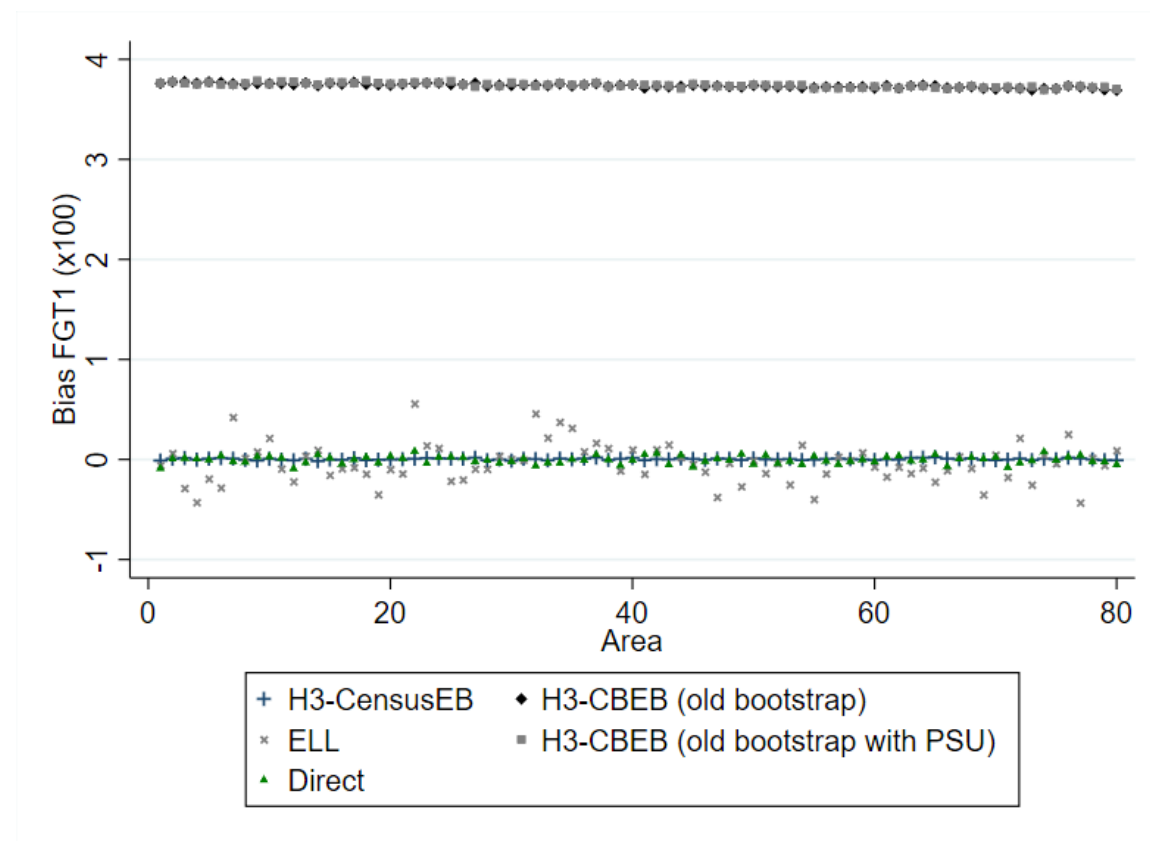

$$y_{ch} = x_{ch}\beta + \eta_c + e_{ch}; \quad h = 1, \dots, N_c; c = 1, \dots, C$$

donde $\eta_c \sim N(0, \sigma_\eta^2)$ y $e_{ch} \sim N(0, \sigma_e^2)$

En el 2019 iniciamos trabajo para implementar el Bootstrap de Gonzales-Manteiga et al. (2008) al paquete sae de Stata

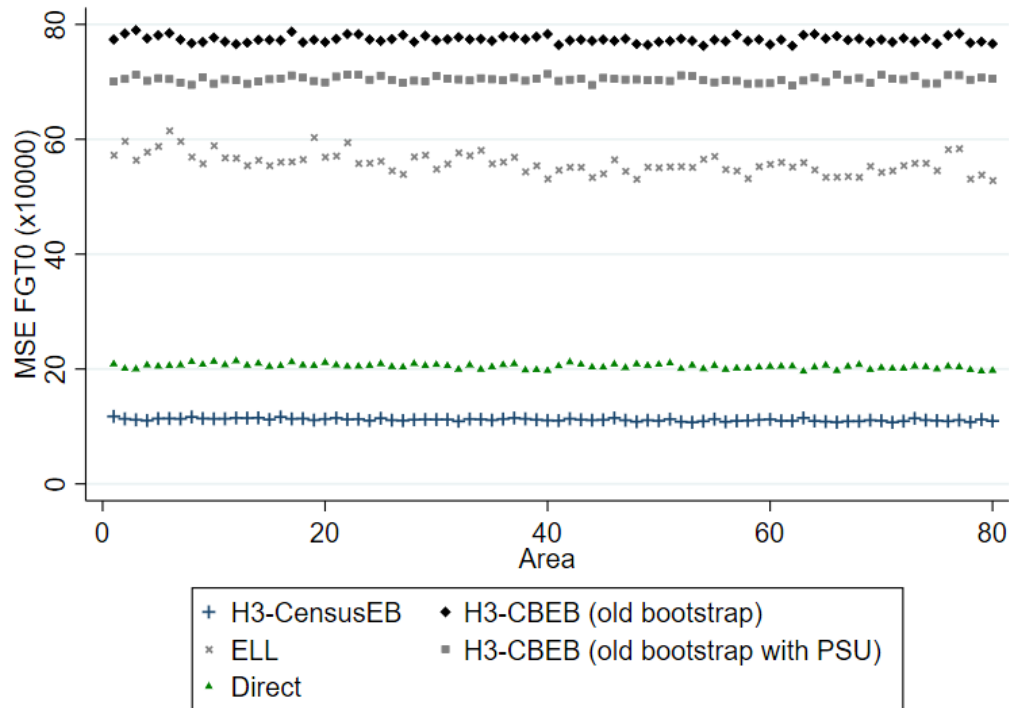
- El trabajo surgió después de contratar a la Prof. Isabel Molina para que revise el trabajo realizado en Moldova
- Prof. Molina nos indico que el ruido del modelo a nivel de unidad daba muy similar al ruido de modelos a nivel de área – algo que no debería ser el caso
- Decidimos replicar las simulaciones que presentaban Molina y Rao (2010)
- Fue inmediatamente claro que había un problema en la metodología EB usada en el Banco Mundial
- A fines del 2019 empezamos a colaborar con Prof. Molina para actualizar la metodología y la herramienta que usa el Banco Mundial

La adaptación EB que usaba el Banco daba estimadores sesgados

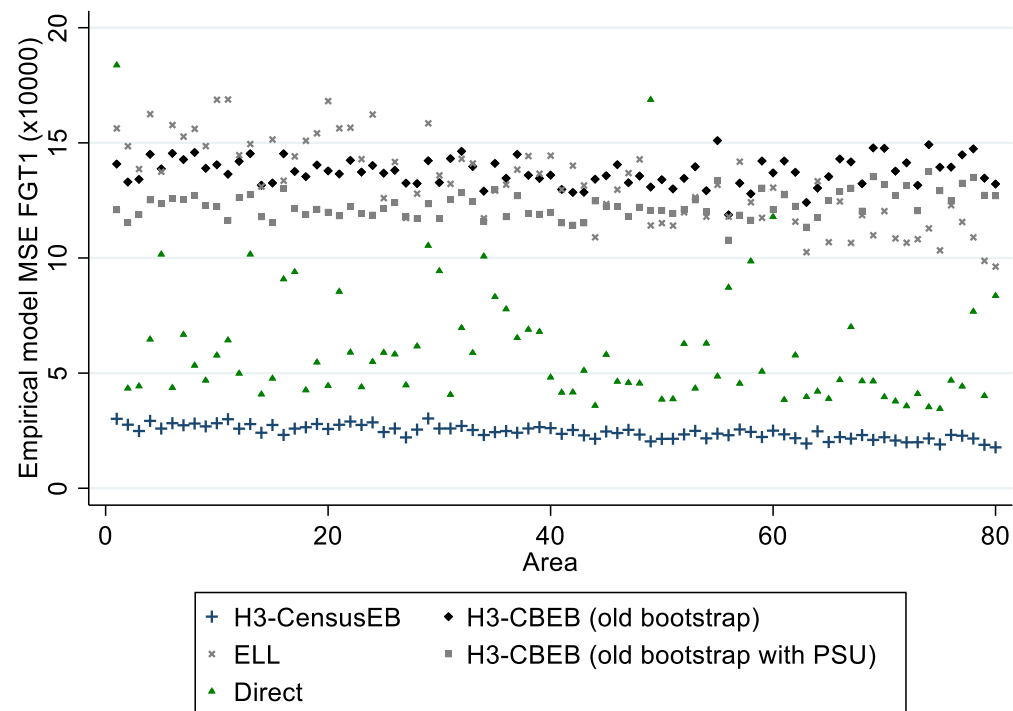


La adaptación EB que usaba el Banco daba estimadores sesgados

Tasa

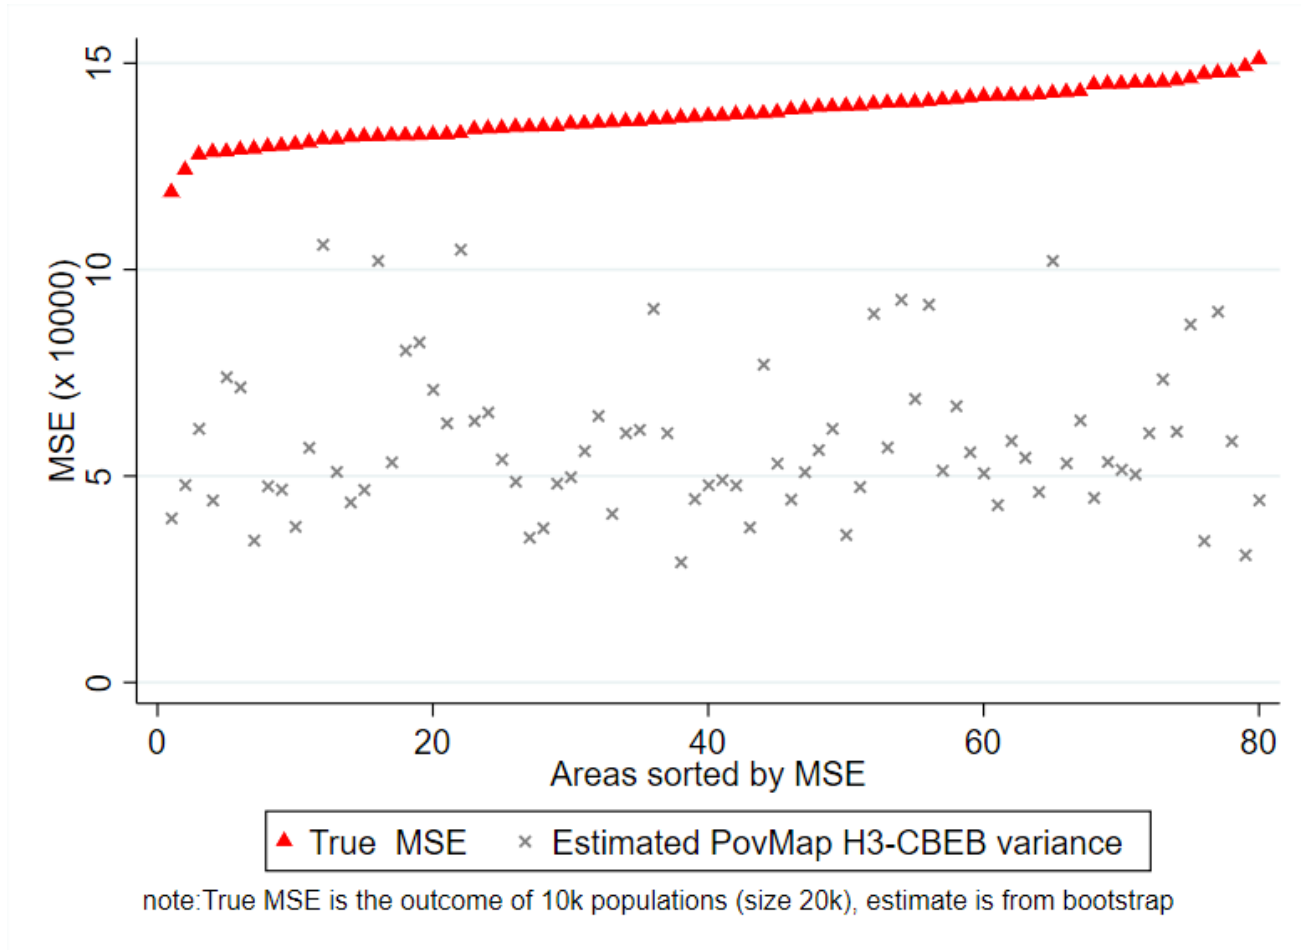


Brecha



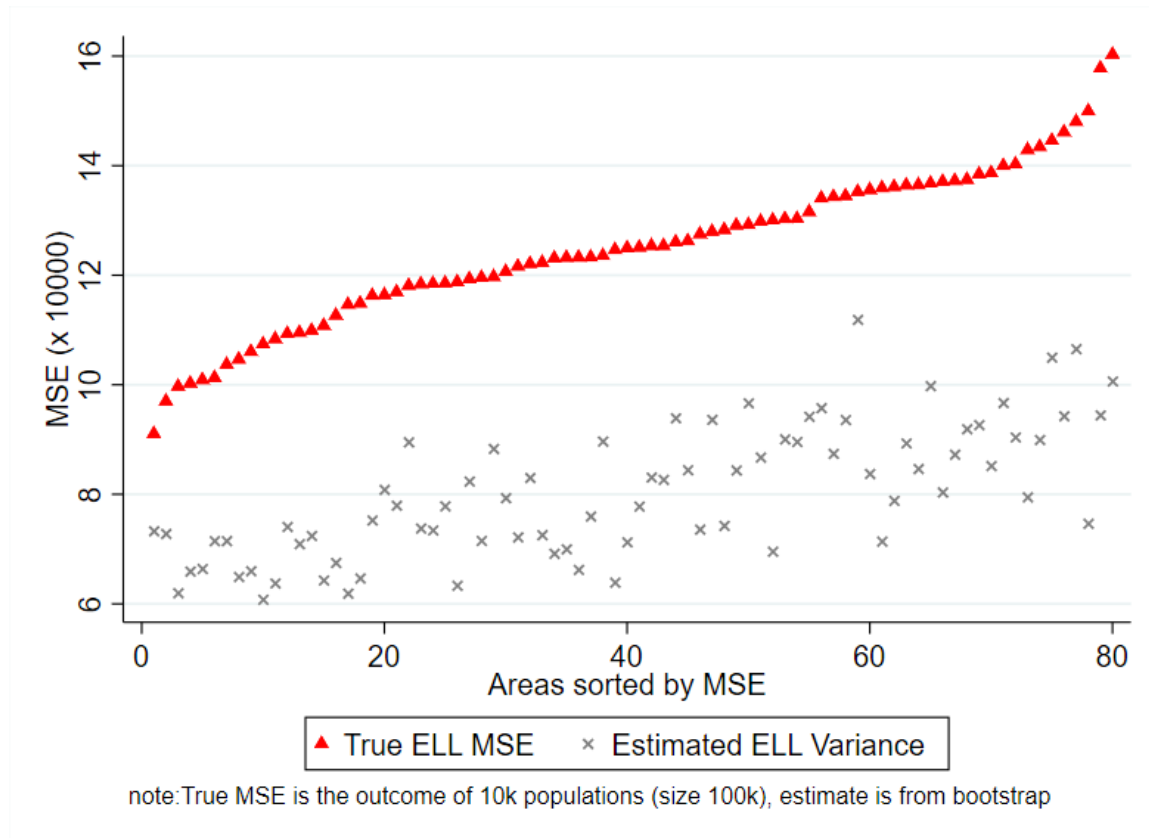
Aquí podemos ver como el intento original de obtener un estimador EB (H3-CBEB) daba estimadores mas ruidosos que ELL para FGT0 y que los directos en estos experimentos

La adaptación EB que usaba el Banco daba estimadores sesgados



Además de rendir estimadores mas ruidosos, el ruido del método estaba infraestimado debido a que intentaba medirlo siguiendo metodologías de imputación múltiple.

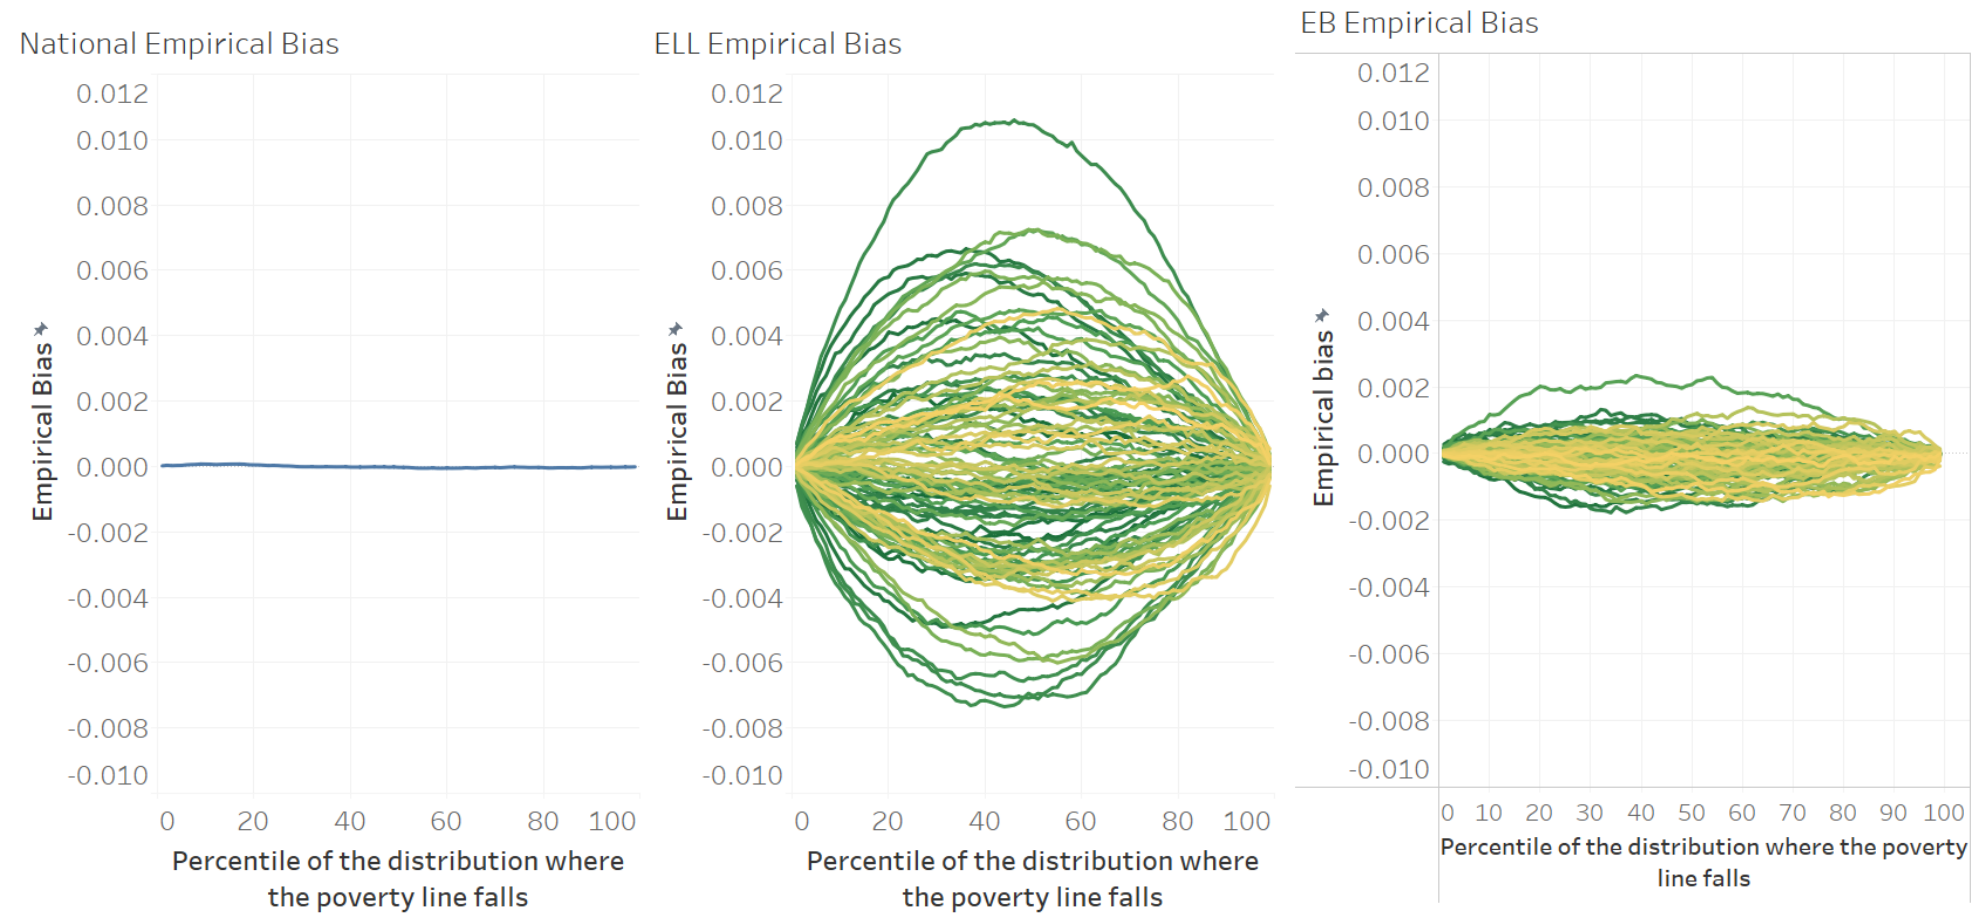
El problema de infraestimación del ruido, también afectaba a ELL



- Es importante notar que ELL y EB suponen el mismo proceso de generación de datos
 - La medición del ruido debería considerar esto
- La metodología usada previamente infraestima el ruido verdadero de la metodología
 - Esto es a pesar de que la metodología previa nos daba estimadores con mayor ruido.

➤ See Corral, Molina, Nguyen (2021) for more details

El método EB es una considerable mejora sobre el tradicional ELL implementado en PovMap – ¿Por que hemos actualizado nuestras herramientas?



EB nos asegura que la predicción de la variable dependiente este alineada a la encuesta.

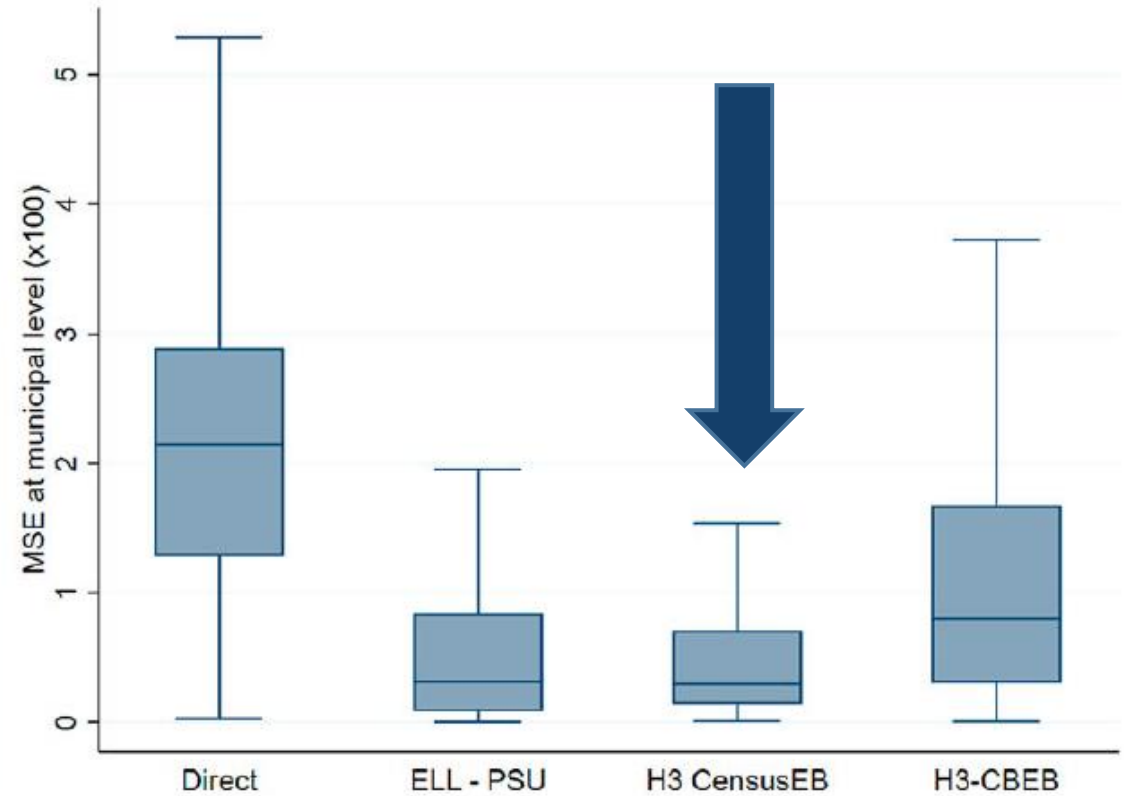
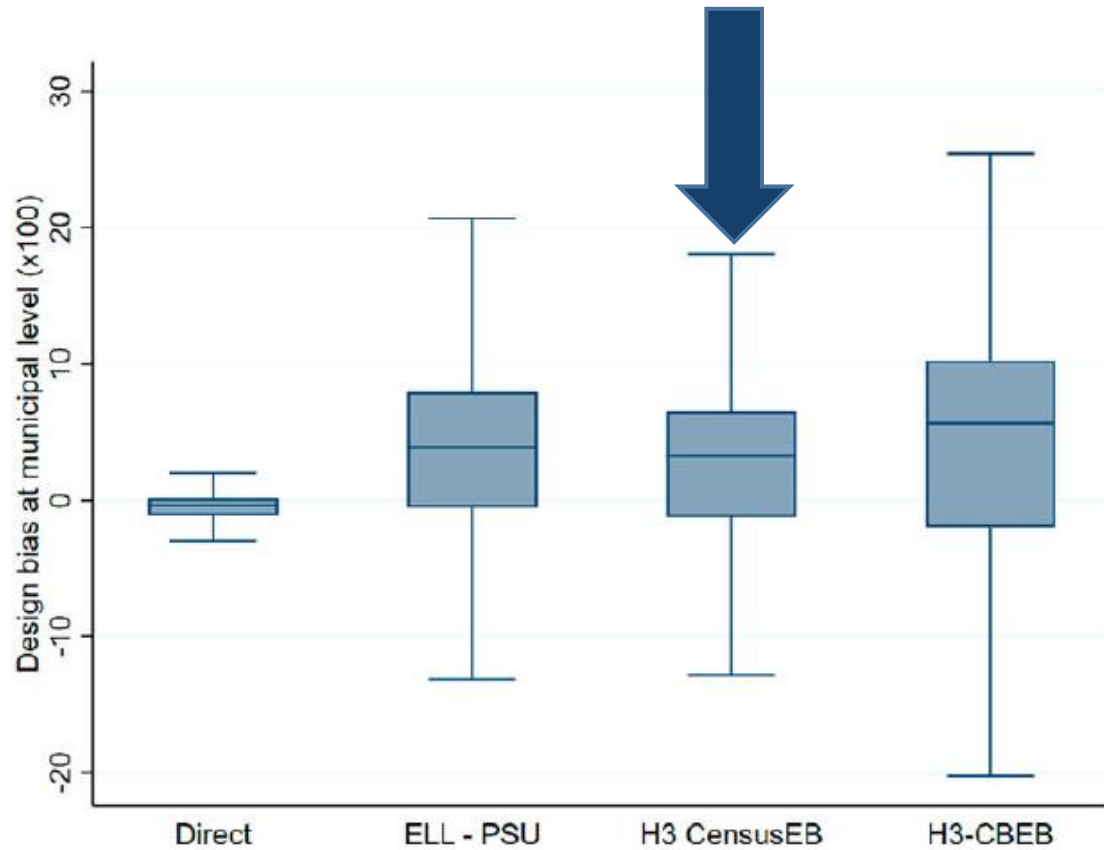
- A nivel nación ELL presenta buenos resultados
- Pero nos interesan los resultados a nivel de área, y aquí es evidente que EB es superior

Resultados de una simulación donde tomamos la línea de pobreza a través de 99 percentiles de ingreso

¿Que tal funciona con datos reales?

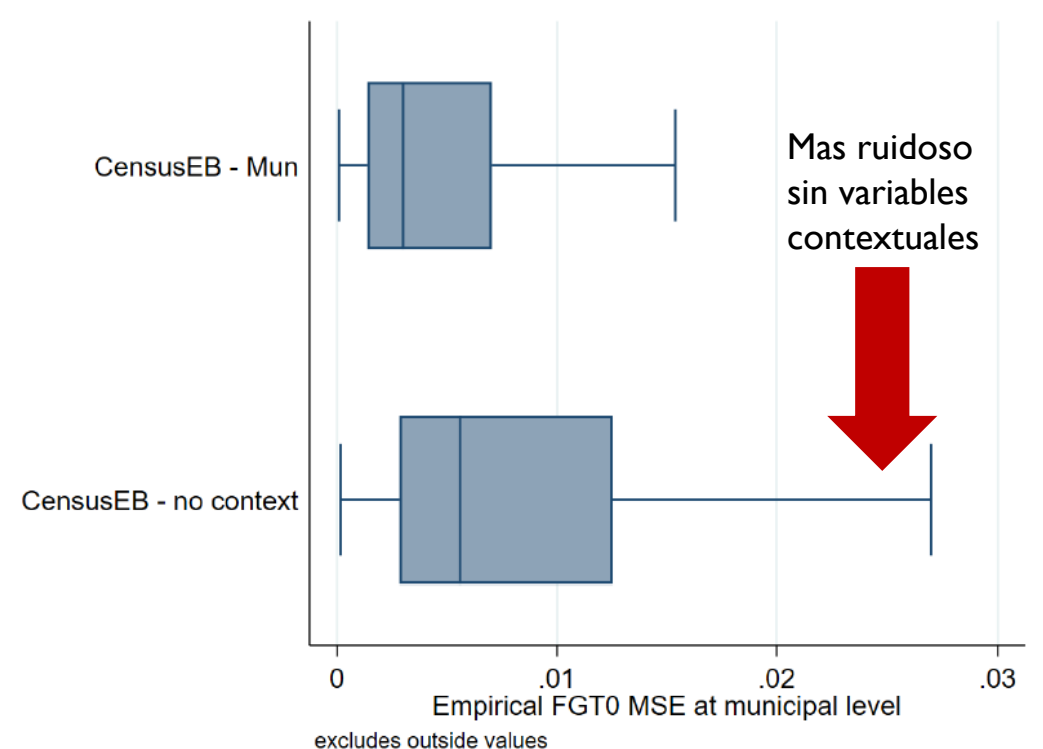
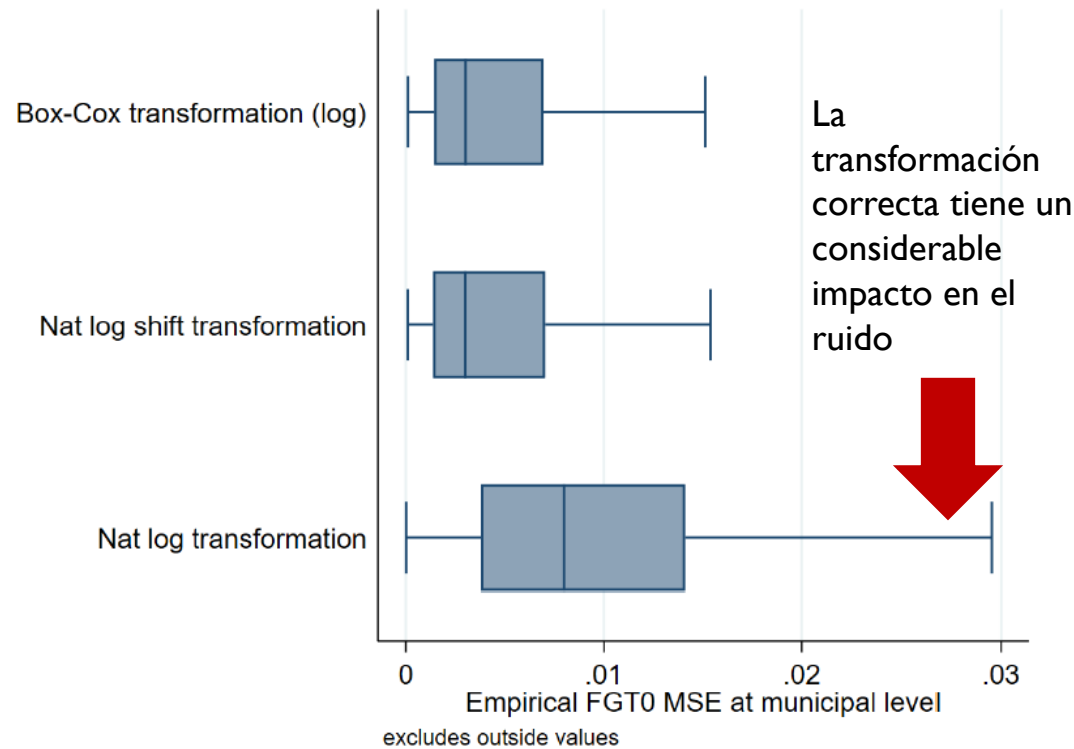
- Aprovechamos la Encuesta Intracensal del 2015 de Mexico
 - Encuesta representativa a nivel municipal
 - Incluye medida de ingreso
 - Tiene una muestra de 5.9 millones de hogares
- Modificamos la encuesta para crear un censo
- Del censo tomamos 500 muestras siguiendo la metodología de muestreo de las encuestas LSMS
- Con cada muestra obtenemos estimados de pobreza a nivel municipal usando diferentes metodologías de SAE

¿Que tal funciona con datos reales?




Corral, Molina, & Nguyen (2021)

Las guías también muestran la importancia de hallar una transformación que aproxime las suposiciones del método y el usar variables contextuales



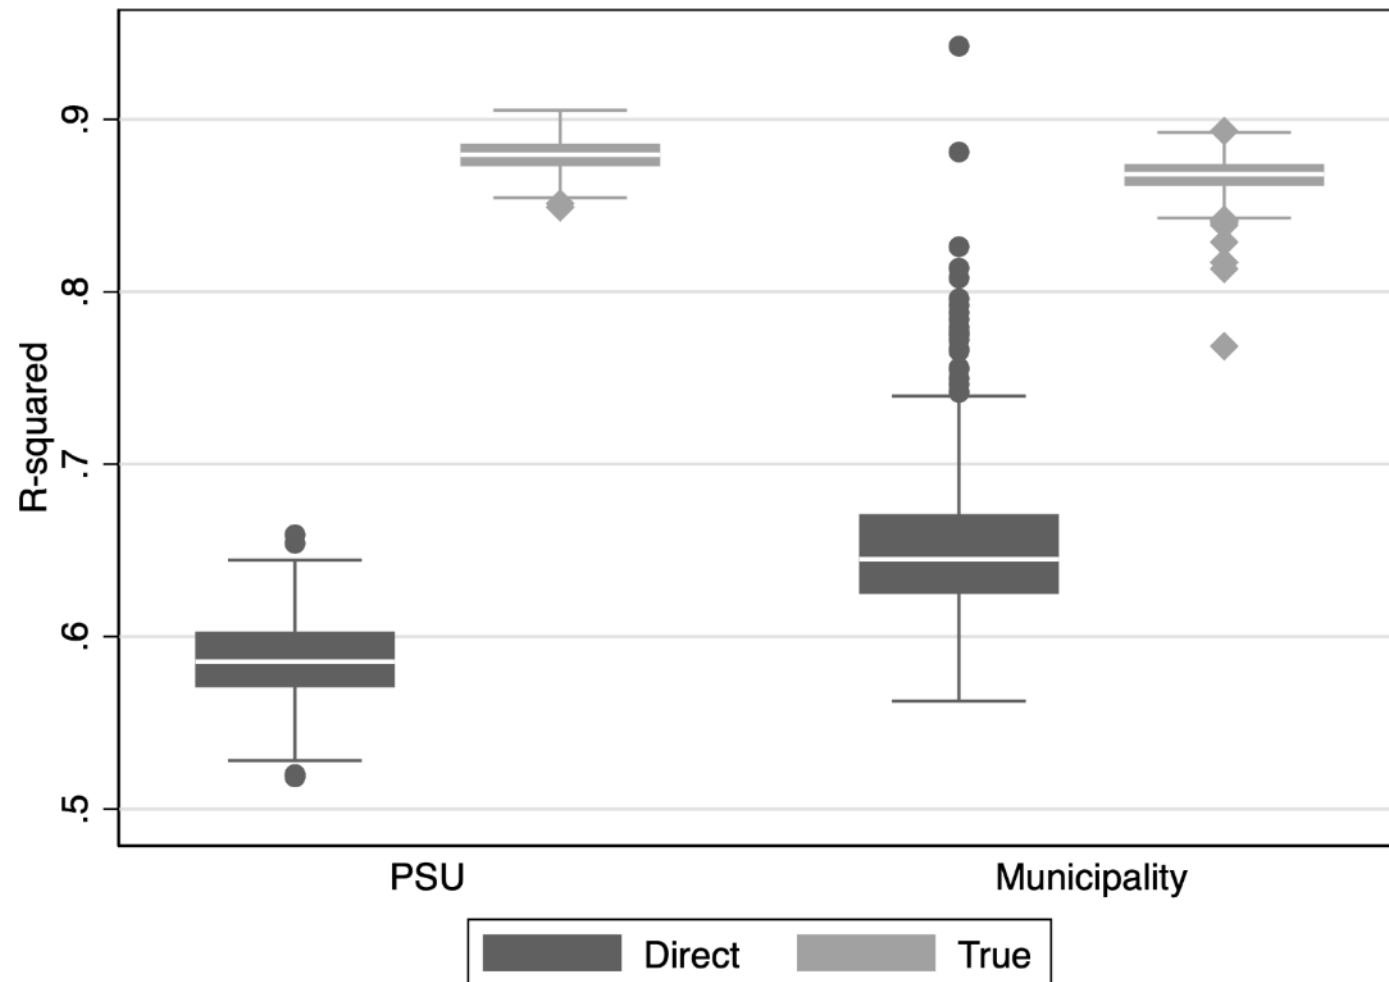
- Guidelines to small area estimation for poverty mapping

Como se comparan estos estimadores con los de “machine learning” (ML)?



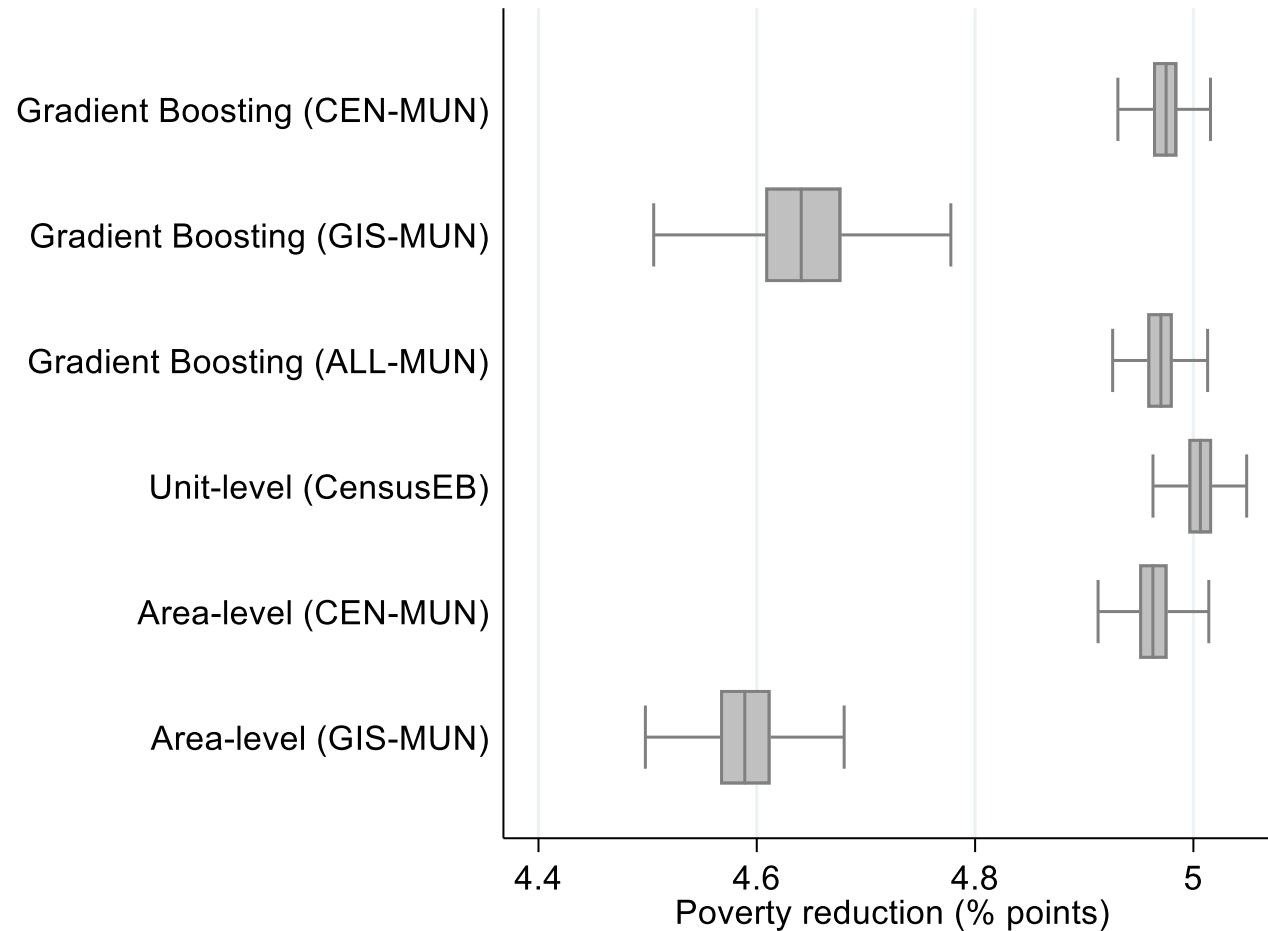
- Los métodos de machine learning también son aplicables cuando no hay un censo contemporáneos
- Los métodos ML son comparables a los tradicionales
- Sin embargo, depende de los datos
- En este escenario, los datos geospaciales públicos no rinden resultados de buena calidad
- Es preferible que los datos geospaciales complementen otros datos

La validación usada para métodos ML no es adecuada



- En la literatura estos métodos suelen validarse midiendo la proporción de la variabilidad de los estimadores directos que es explicada por los estimadores del modelo
- Pero nuestra meta no es el estimador directo que es ruidoso. Nuestra meta es la tasa verdadera,

Los métodos muestran buen resultado en reducción de pobreza al ser usados para informar áreas que deben tener prioridad



- Gracias a que tenemos el censo, tenemos la “verdadera” tasa de pobreza y el “verdadero” ingreso del hogar
- Usando el ranqueo de cada método distribuimos fondos de manera uniforme a todos los hogares dentro de una localidad
 - Vamos de la mas pobre a la siguiente mas pobre hasta que se acaban los recursos
- Basándonos en el ranqueo “verdadero” el mejor resultado es de 5.1 puntos porcentuales de reducción
- Todos los métodos dan un decente ranqueo
- Debemos tener cuidado cuando lo que nos interesa para nuestro programa es la tasa estimada. En ese caso debemos enfocarnos en métodos y estimadores con mínimo sesgo

La practica de pobreza y equidad ha creado el paquete de sae en Stata que reemplaza a PovMap

[sae Stata package](#) :

- Permite modelos:
 - ELL como implementado en Elbers, Lanjouw, y Lanjouw (2003)
 - EB como presentados en Molina y Rao (2010)
 - CensusEB como presentado en Corral, Molina, y Nguyen (2021) – calza el modelo considerando factores de expansión de la encuesta y heteroskedasticidad
 - Two-fold EB como presentado en Marhuenda et al. (2017) – permite EB a dos diferentes niveles geográficos
 - Además incluye lo siguiente:
 - Transformaciones de la variable dependiente
 - Simulaciones Monte Carlo y Bootstrap que acomodan el censo completo
- Guidelines to small area estimation for poverty mapping

Conclusiones

- El método EB actualizado funciona mejor que el método anterior en todos los escenarios probados, con fracciones de muestreo grandes o pequeñas, tamaños de población grandes o pequeños, un poder explicativo de covariables mayor o menor, efectos de ubicación más fuertes o más débiles, incluso en presencia de colas más pesadas que la distribución normal.
- El procedimiento de Bootstrap correspondiente tiene éxito al estimar adecuadamente el verdadero MSE, a diferencia de los procedimientos considerados previamente basados en métodos de MI.
- Las guías recientemente producidas presentan una evaluación a las metodologías más aplicadas dentro del Banco Mundial y afuera
 - Presentan que modelo es aplicable y que precauciones se deben tomar al aplicar un modelo
 - También presentamos códigos para que la gente pueda replicar y aprender siguiendo los códigos
- Mientras avanza la literatura las guías podrán ser actualizadas
- Los métodos nuevos de machine learning presentan mucha promesa, pero aun falta investigar más
 - Sobre todo el como se estima el error de los modelos es un componente esencial que se debe investigar.