

Cómo interpretar regresiones logísticas binarias con Odds Ratio Marginales y Promedios de Efectos Marginales: una guía aplicada con Stata

Matías-Salvador Ballesteros^a <https://orcid.org/0000-0003-1321-2777>

Universidad de Buenos Aires. Argentina

^a Instituto de Investigaciones Gino Germani (IIGG). Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET). Correo electrónico: mballesteros@sociales.uba.ar

Artículo original. Recibido: 12/12/2025. Revisado: 22/04/2026. Aceptado: 11/05/2026. Publicación avanzada: 10/06/2025. Publicado: 01/07/2026

Resumen

INTRODUCCIÓN. Desde hace más de una década, distintos autores advierten sobre los problemas de comparabilidad cuando se informan Odds Ratio Condicionales en las regresiones logísticas. En este contexto, los Promedios de los Efectos Marginales (PEM) han ganado protagonismo como alternativa basada en probabilidades. Más recientemente, los Odds Ratios Marginales (ORM) se proponen como una medida relativa comparable entre modelos y poblaciones. Este trabajo tiene por objetivo presentar, comparar y ejemplificar el uso conjunto de ambas medidas.

MÉTODO. Se utiliza un ejemplo empírico con una variable dependiente dicotómica y se estiman modelos de regresiones logísticas binarias. A partir de ellos, se calculan los PEM y ORM con Stata, mostrando los pasos para su obtención y cómo interpretarlos.

RESULTADOS. La utilización de PEM y ORM puede conducir a interpretaciones diferentes, en particular cuando se quiere comparar poblaciones con diferentes distribuciones de la variable dependiente.

DISCUSIÓN. Se concluye que PEM y ORM no son medidas sustitutas, sino complementarias, y que en ocasiones su uso conjunto puede permitir una interpretación más correcta de los resultados en investigaciones aplicadas.

Palabras clave

regresión logística binaria, análisis de regresión, análisis multivariante, modelo estadístico, promedio de efectos marginales, odds ratios marginales

Referencia recomendada

Ballesteros, M. S. (2026). Cómo interpretar regresiones logísticas binarias con Odds Ratio Marginales y Promedios de Efectos Marginales: una guía aplicada con Stata. *REIRE Revista d'Innovació i Recerca en Educació*, 19(2), 1-13. <https://doi.org/10.1344/reire.52597>

© 2026 El autor. Este artículo es de acceso abierto sujeto a la licencia Reconocimiento 4.0 Internacional de Creative Commons, la cual permite utilizar, distribuir y reproducir por cualquier medio sin restricciones siempre que se cite adecuadamente la obra original. Para ver una copia de esta licencia, visite

<https://creativecommons.org/licenses/by/4.0/>



UNIVERSITAT DE
BARCELONA

Títol (català)

Com interpretar regressions logístiques binàries amb Odds Ratios Marginals i Mitjanes d'Efectes Marginals: una guia aplicada amb Stata

Resum

INTRODUCCIÓ. Des de fa més d'una dècada, diversos autors adverteixen sobre els problemes de comparabilitat quan s'informen Odds Ratios Condicionals en les regressions logístiques. En aquest context, les Mitjanes dels Efectes Marginals (MEM) han guanyat protagonisme com a alternativa basada en probabilitats. Més recentment, els Odds Ratios Marginals (ORM) s'han proposat com una mesura relativa comparable entre models i poblacions. Aquest treball té com a objectiu presentar, comparar i exemplificar l'ús conjunt d'aquestes dues mesures.

MÈTODE. Es fa servir un exemple empíric amb una variable dependent dicotòmica i s'estimen models de regressió logística binària. A partir d'aquests models, es calculen els PEM i els ORM amb Stata, mostrant els passos per obtenir-los i la manera d'interpretar-los.

RESULTATS. L'ús de MEM i ORM pot conduir a interpretacions diferents, especialment quan es comparen poblacions amb distribucions diferents de la variable dependent.

DISCUSSIÓ. Es conclou que les MEM i els ORM no són mesures substitutives sinó complementàries, i que en algunes ocasions fer-les servir conjuntament pot permetre una interpretació més correcta dels resultats en investigacions aplicades.

Paraules clau

regressió logística, anàlisi de regressió, anàlisi multivariada, model estadístic, mitjana d'efectes marginals, odds ratios marginals

Title (English)

How to Interpret Binary Logistic Regressions Using Marginal Odds Ratios and Average Marginal Effects: An Applied Guide with Stata

Abstract

INTRODUCTION. For more than a decade, several authors have highlighted comparability problems when reporting Conditional Odds Ratios in logistic regressions. In this context, Average Marginal Effects (AMEs) have gained prominence as a probability-based alternative. More recently, Marginal Odds Ratios (MORs) have been proposed as a relative measure that is comparable across models and populations. This article aims to present, compare, and illustrate the joint use of these two measures.

METHOD. An empirical example with a dichotomous dependent variable is used, and binary logistic regression models are estimated. Based on these models, AMEs and MORs are computed using Stata. The steps needed to obtain them, and how to interpret them, are detailed.

RESULTS. The use of AMEs and MORs can lead to different interpretations, particularly when comparing populations with different distributions of the dependent variable.

DISCUSSION. It is concluded that AMEs and MORs are not substitute measures but complementary ones, and that in some cases their combined use can enable a more accurate interpretation of results in applied research.

Keywords

binary logistic regression, regression analysis, multivariate analysis, statistical model, average marginal effects, marginal odds ratios

1. Introducción

En la investigación empírica en ciencias sociales es habitual el uso de regresiones logísticas binarias para modelar variables dependientes dicotómicas. Tradicionalmente, la interpretación de estos modelos se apoya en los Odds Ratio Condicionales (ORC) (Karlson y Jann, 2023). Sin embargo, desde hace más de una década, distintos autores han advertido sobre las limitaciones de esta medida para la comparación entre modelos, grupos o poblaciones (Breen et al., 2018; Mize et al., 2019; Mood, 2010). Estas prácticas interpretativas son habituales en investigaciones aplicadas en ámbitos como la educación, la salud o las políticas públicas, donde la comparación entre grupos y contextos es central.

Como respuesta a estas limitaciones, se han propuesto alternativas basadas en efectos marginales poblacionales, entre las que destacan el Promedio de los Efectos Marginales (PEM, *Average Marginal Effects* [AME] en inglés) (Ballesteros, 2018; Mize, 2019; Mize et al., 2019; Mood, 2010, entre otros) y, más recientemente, los Odds Ratios Marginales (ORM, *Marginal Odds Ratios* [MOR] en inglés) (Jann y Karlson, 2023; Karlson y Jann, 2023).

El objetivo de este trabajo es presentar y comparar distintas estrategias de interpretación de regresiones logísticas binarias, centrándose en las limitaciones de los ORC y en el uso de los PEM y los ORM. Asimismo, se discuten las diferencias entre estas medidas y las situaciones en las que resulta más adecuado utilizar cada una de ellas.

Como complemento aplicado, se describen los comandos de Stata empleados para su estimación¹. Para facilitar la comprensión, se utiliza un ejemplo empírico basado en datos secundarios sobre la realización de Actividad Física en el Tiempo Libre (AFTL) durante la última semana, provenientes de una encuesta de Argentina y otra de España.

1.1. Problemas de Odds Ratio Condicionales (ORC) en regresión logística binaria

Un motivo de la gran popularidad de las regresiones logísticas binarias es que permiten presentar los resultados en términos de Odds Ratio (OR). Siguiendo la clasificación reciente de Karlson y Jann (2023), denominaremos a esta medida ORC para diferenciarla de los ORM que presentaremos más adelante. En modelos logísticos, los coeficientes estimados y sus ORC están afectados por un problema conocido metodológicamente como no colapsabilidad ("*noncollapsibility*"), reescalamiento ("*rescaling*") o heterogeneidad no observada ("*unobserved heterogeneity*"). Este fenómeno puede entenderse comparando con la regresión lineal, donde el coeficiente de una variable solo cambia si añadimos al modelo otra variable que esté correlacionada con ella. En cambio, en la regresión logística, el coeficiente del ORC puede modificarse cuando se incorporan variables a un modelo, aunque no estén relacionadas con las variables independientes utilizadas previamente (Breen et al., 2018; Karlson y Jann, 2023; Mood, 2010).

Esto tiene consecuencias prácticas muy importantes, ya que invalida comparaciones que eran consideradas estándar en las ciencias sociales antes de que la literatura metodológica advirtiera sobre este problema (Mood, 2010), pero que aún persisten en buena parte de la investigación empírica. No es posible comparar los ORC entre modelos con distintas variables en una misma muestra; es decir, analizar si cambia el efecto de una variable

¹ Si bien en este artículo se utiliza Stata por ser el software de referencia en la literatura metodológica que fundamenta el trabajo (Jann y Karlson, 2023; Karlson y Jann, 2023; Mize, 2019), cabe señalar que R y Python permiten calcular los PEM mediante paquetes específicos como *marginaleffects* (Arel-Bundock et al., 2024). SPSS, en cambio, no dispone de implementaciones nativas equivalentes para el cálculo directo de estas medidas.

independiente al introducir posibles factores de confusión o mediadores en el modelo. Tampoco se debería comparar coeficientes entre grupos (como hombres y mujeres) dentro de una muestra o muestras de distintos lugares o años. Hacerlo puede llevar a confundir cambios en la escala del modelo con diferencias reales en la magnitud de la asociación o desigualdad estudiada (Breen et al., 2018; Mood, 2010).

1.2. La alternativa de los PEM

Ante los problemas señalados anteriormente sobre los ORC, gran parte de la literatura metodológica (Mize, 2019; Mood, 2010, entre otros) recomienda trabajar con medidas derivadas de los efectos marginales, que permiten expresar los resultados en términos de probabilidades y no tienen los problemas de la heterogeneidad no observada. El PEM expresa el cambio promedio en la probabilidad predicha de que se produzca la categoría de contraste de la variable dependiente, asociado a una variación en una variable independiente, manteniendo constantes las restantes covariables del modelo. A diferencia de los ORC, los PEM informan cambios asociados a variaciones en las variables independientes y se expresan en unidades de probabilidad, lo que facilita su interpretación sustantiva (Mood, 2010).

Estas medidas prácticamente no se ven afectadas por la heterogeneidad no observada que no está correlacionada con las variables independientes del modelo, lo que evita el problema del cambio de escala de los coeficientes y permite comparaciones válidas entre modelos, grupos poblacionales y períodos (Mood, 2010).

1.3. La alternativa de los ORM y la diferencia con los PEM

Como señalamos anteriormente, los PEM tienen la gran ventaja de no verse afectados por la heterogeneidad no observada o la no colapsabilidad. Además, distintos autores señalan como una ventaja que se presente en términos de probabilidades en lugar de OR, debido a que es más intuitiva su interpretación (Mize, 2019; Mood, 2010). Sin embargo, Karlson y Jann (2023) destacan que, para muchas temáticas de interés y enfoques de estudio dentro de las ciencias sociales, es conveniente trabajar con OR. Ello se debe a que esta medida no es sensible a la distribución marginal de los valores de la variable dependiente, a diferencia de los PEM. Mientras que los PEM muestran cambios absolutos en las probabilidades, los OR representan una medida relativa de efecto.

Debido a que los PEM dependen de la distribución de la variable dependiente, esto puede generar dificultades en comparar el efecto de las variables entre dos poblaciones con diferentes distribuciones de las variables dependientes. Como señalan Jann y Karlson (2023), mientras más desigual es la distribución de la variable dependiente, menor tiende a ser el efecto del PEM y mayor va a ser la diferencia con el ORM. El ejemplo que trabajamos en este artículo puede ser ilustrativo en este sentido, ya que las variables dependientes tienen una distribución muy distinta en Argentina (26,3 % realiza AFTL) y en España (49,3 % realiza AFTL).

Karlson y Jann (2023) señalan que los ORM permiten mantener la interpretación relativa del OR, pero sin los problemas de heterogeneidad no observada. Es decir, los ORM funcionan de forma similar a los PEM en términos de que ambos son efectos marginales poblacionales y no se ven afectados por la heterogeneidad no observada, pero con la ventaja de informar una medida relativa (OR del promedio poblacional) que facilita la comparación entre modelos, grupos o poblaciones.

2. Método

Para ejemplificar cómo interpretar los PEM y los ORM de una regresión logística binaria y cómo solicitar su estimación con Stata, utilizamos datos provenientes de dos encuestas basadas en muestras probabilísticas multietápicas y estratificadas, con ponderadores calibrados para asegurar representatividad a nivel nacional. La primera es la Encuesta Nacional de Nutrición y Salud (ENNyS) del 2018/19 de Argentina, que se realizó mediante un diseño polietápico en cuatro fases de selección aleatoria con estratificación por región (Ministerio de Salud, 2022). La segunda es la Encuesta de Salud de España (ESdE) de 2023, que utilizó un muestreo trietápico con estratificación de secciones censales (Instituto Nacional de Estadística y Ministerio de Sanidad, 2025). Para el presente trabajo se consideraron únicamente las personas de 18 años y más, resultando en 7.467 casos en la ENNyS y 20.639 en la ESdE. Luego de excluir los casos con datos faltantes en alguna de las variables utilizadas, la muestra analítica quedó conformada por 7.290 casos en la ENNyS y 18.384 en la ESdE. La utilización de dos encuestas nacionales con contextos sociales distintos y niveles de prevalencia muy diferentes en la variable dependiente permite ilustrar de manera empírica las diferencias en la interpretación de medidas absolutas como los PEM y relativas como los ORM.

Con el objetivo de asegurar comparabilidad entre encuestas y relevancia sustantiva del indicador, recortamos la población a quienes tienen 18 años y más. A partir de una pregunta conceptualmente equivalente en ambas encuestas y para realizar la regresión logística binaria, construimos una variable dependiente dicotómica: Realizó AFTL. Las categorías son no realizó (0, categoría de referencia para la regresión) y realizó (1, categoría de contraste). Además, utilizamos cinco variables independientes que se encontraban presentes o que pudimos construir de manera equivalente para las dos encuestas, lo que garantiza un nivel básico de comparabilidad entre ambos contextos: sexo, grupo etario, nivel de ingreso por unidad consumidora del hogar², nivel educativo y presencia de menores de 14 años en el hogar. Para facilitar la comprensión de la sintaxis que describimos más adelante, en la Tabla 1 se presenta el nombre de cada variable (la etiqueta de Stata), el código del nombre que se utilizó en Stata (nombre de Stata), el nombre de cada categoría, el código de cada categoría y el rol de la categoría en la regresión (contraste o referencia).

Para llevar a cabo el análisis, excluimos todos los casos que tenían al menos un valor perdido en una de las variables, para así trabajar con casos completos en todas las variables del modelo. Este procedimiento se adoptó debido a la baja proporción de valores perdidos en las variables analizadas y a la ausencia de diferencias sustantivas en los patrones de no respuesta entre ambas encuestas. Todas las estimaciones se realizaron utilizando los ponderadores muestrales provistos por cada encuesta, con el objetivo de que los resultados fueran representativos de la población adulta de cada país. En la sintaxis más abajo, el factor de ponderación fue incluido mediante la variable PONDERA.

Como desarrollaremos más adelante, las conclusiones que se obtienen de los ORM y de los PEM pueden ser disímiles cuando se realizan comparaciones entre poblaciones con distribuciones muy diferentes en sus variables dependientes. El caso analizado resulta ilustrativo en este sentido, ya que en Argentina el 26,3 % de la población realizó AFTL, mientras que ese porcentaje se eleva al 49,3 % en España. Lo anterior genera un escenario adecuado para observar cómo las medidas absolutas y relativas pueden conducir a interpretaciones diferentes.

² Se trabajó con el ingreso per cápita por unidad consumidora del hogar. Los dos primeros quintiles fueron agrupados en la categoría bajo, el 3.^{er} y 4.^o quintil en la categoría medio y el 5.^o quintil en la categoría alto.

Tabla 1

Descripción de las variables independientes utilizadas en la regresión logística

Nombre de variable (etiqueta)	Nombre de variable en Stata	Categoría	Códigos	Rol en regresión
Sexo	SEXO	Varón	1	Contraste
		Mujer	2	Referencia
Grupo etario del encuestado	GRUPOETARIO	18 a 34	1	Referencia
		35 a 49	2	Contraste
		50 a 64	3	Contraste
		65 y más	4	Contraste
Nivel de ingreso por unidad consumidora del hogar	INGRESO	Bajo	1	Contraste
		Medio	2	Contraste
		Alto	3	Referencia
Nivel educativo	NIVED	Primario	1	Contraste
		Secundario	2	Contraste
		Superior	3	Referencia
Menores de hasta 14 años en el hogar	MENORES	Sin menores	0	Referencia
		Con menores	1	Contraste

2.1. Sintaxis en Stata explicada


2.1.1. Sintaxis para PEM

Para realizar la Tabla 2 que se presenta más adelante con la estimación del PEM de una regresión logística, la sintaxis se debe correr tanto para la encuesta de Argentina como para la de España. En el ejemplo lo presentamos solo para la encuesta de Argentina.

1. En el archivo “do file” se debe solicitar una regresión logística binaria como base de la estimación de PEM.

Figura 1

“Do file” de Stata para realizar una regresión logística binaria



El comando “logit” solicita la regresión logística. La primera variable que se incluye es la dependiente (AF en el ejemplo) y luego todas las independientes incluidas en el modelo (SEXO, GRUPOETARIO, INGRESO3, NIVED y MENORES).

Para algunas variables independientes utilizamos “i.” que indica que la variable es categórica. En otras utilizamos “ib.” con un número. En este caso, también se indica que es una variable categórica, pero con el número se indica cuál categoría se toma como referencia. Por ejemplo, con *ib3.NIVED* estamos indicando que tome como referencia la tercera categoría (nivel superior). Si dejamos solo *i.* toma como referencia la primera categoría de la variable.

Para finalizar, estamos ponderando los resultados por la variable PONDERA, lo cual se realiza a partir de la función *pweight*.

2. Luego se solicita la estimación de PEM

Figura 2

“Do file” de Stata para solicitar el PEM

```

1 logit AF ib2.SEXO i.GRUPOETARIO ib3.INGRESO3 ib3.NIVED i.MENORES [pweight=PONDERA], or
2
3 margins, dydx (SEXO GRUPOETARIO INGRESO3 NIVED MENORES)
4

```

Se utiliza el comando *margins, dydx* para solicitar el PEM. En el paréntesis se incluyen todas las variables independientes utilizadas en el modelo sobre las que queremos obtener los valores del PEM.

El resultado que nos arroja el Stata para la encuesta de Argentina es el que se muestra en la Figura 3.

Figura 3

Tabla que muestra Stata luego de solicitar los PEM de la regresión logística

	Delta-method				[95% conf. interval]	
	dy/dx	std. err.	z	P> z		
SEXO						
Hombre	.1391584	.0148733	9.36	0.000	.1100074	.1683095
GRUPOETARIO						
25 a 34	-.0739986	.0247899	-2.99	0.003	-.1225859	-.0254114
35 a 49	-.085631	.0249383	-3.43	0.001	-.1345092	-.0367528
50 a 64	-.1895158	.0251863	-7.52	0.000	-.2388801	-.1401515
65 y mas	-.2469167	.0261798	-9.43	0.000	-.2982281	-.1956053
INGRESO3						
Bajo	-.1172394	.0218376	-5.37	0.000	-.1600404	-.0744384
Medio	-.0636836	.0203658	-3.13	0.002	-.1035999	-.0237674
NIVED						
1	-.1993614	.0267498	-7.45	0.000	-.2517901	-.1469328
2	-.0905073	.0246707	-3.67	0.000	-.1388609	-.0421536
MENORES						
Con menores	-.0705698	.0160258	-4.40	0.000	-.1019799	-.0391598


Debajo del “ dy/dx ” informa el valor del PEM. Por ejemplo, “0,1391584”, que en la Tabla 2 lo redondeamos a 0,139. Debajo de $P > z$ muestra la significancia y en 95 % *conf. interval*, muestra el intervalo de confianza al 95 % del PEM.

2.1.2. Sintaxis para ORM

1. Repetir el paso 1 y solicitar la regresión logística binaria.
2. Reemplazar el pedido de estimación de PEM por ORM con el comando *lnmor*.

Figura 4

“Do file” de Stata para solicitar los ORM



```

1  logit AF ib2.SEXO i.GRUPOETARIO2 ib3.INGRESO3 ib3.NIVED i.MENORES [pweight=PONDERA], or
2
3  lnmor ib2.SEXO i.GRUPOETARIO2 ib3.INGRESO3 ib3.NIVED i.MENORES, or
4

```

A diferencia de la estimación de PEM, aquí nuevamente se deben señalar las variables que son categóricas y qué categoría tomar como referencia. Además, luego de la última variable se debe incorporar “, or” para que informe los valores en ORM. Los ORM se estiman mediante el comando *lnmor*, desarrollado por Karlson y Jann (2023).

Si no se tiene instalado, instalar con *ssc install lnmor*. El resultado que muestra STATA para la encuesta de Argentina es el que aparece en la figura 5.

Figura 5

Tabla que arroja Stata luego de solicitar los ORM de la regresión logística

AF	Odds Ratio	Robust std. err.	t	P> t	[95% conf. interval]	
SEXO						
Hombre	2.049468	.1588848	9.26	0.000	1.76052	2.385841
GRUPOETARIO2						
35 a 49	.8271354	.0771368	-2.04	0.042	.6889414	.9930495
50 a 64	.4574893	.0537932	-6.65	0.000	.3633098	.5760827
65 y mas	.294895	.0468275	-7.69	0.000	.2160127	.402583
INGRESO3						
Bajo	.5545581	.0623524	-5.24	0.000	.444862	.6913037
Medio	.7420422	.0720009	-3.07	0.002	.6135107	.8975013
NIVED						
1	.3490747	.0496896	-7.39	0.000	.2640781	.4614283
2	.6837237	.0749261	-3.47	0.001	.5515512	.8475696
MENORES						
Con menores	.6721968	.0554116	-4.82	0.000	.5718962	.7900885

Debajo del “*Odds Ratio*” informa el valor del ORM. Por ejemplo, “2.04968”, que en la Tabla 3 lo redondeamos a 2,05.

Debajo de $P > z$ muestra la significancia y en 95 % *conf. interval*, muestra el intervalo de confianza al 95 % del ORM.

3. Resultados

3.1. Lectura e interpretación de los PEM

En la Tabla 2 se presenta un modelo de regresión logística binaria en el que se muestran las probabilidades de realizar AFTL en Argentina y en España. En la misma se observan las probabilidades de cada categoría de contraste de las variables independientes con relación a las de una categoría de referencia. La lectura se puede realizar en puntos porcentuales (no en porcentajes) para facilitar la transmisión del resultado.

A continuación, incorporamos la lectura de algunas de las variables de la Tabla 2 a modo de mostrar un ejemplo de cómo se puede realizar. Recordemos que se está observando el efecto neto de cada variable, es decir, una vez controlado el efecto de las restantes. Un coeficiente de 0,139 para los hombres en Argentina (referencia mujer) indica que, en promedio, la probabilidad de realizar actividad física es 13,9 puntos porcentuales mayor para los hombres que para las mujeres. En España, esa diferencia de probabilidades es de 4,9 puntos porcentuales. Si bien el solapamiento de intervalos no constituye un test estadístico formal de diferencia, en la Tabla 2 está incorporado el intervalo de confianza al 95 % para ambas encuestas. En este caso, los intervalos no se solapan (10,9-16,8 vs 3,1-6,7), lo cual sugiere diferencias significativas.

Cabe destacar que el resultado negativo indica menos probabilidades. Así, por ejemplo, se observa que, tanto en Argentina como en España, las personas con estudios primarios o secundarios tienen menos probabilidades de realizar AFTL que quienes tienen estudios superiores. Si nos centramos en quienes tienen nivel primario, observamos que es 19,6 puntos porcentuales menor en Argentina, mientras que en España esa diferencia es de 29,4 puntos porcentuales. Nuevamente, los intervalos no se solapan, lo cual sugiere diferencias significativas entre países. Por otro lado, la Tabla 2 nos indica la significación estadística de las diferencias para cada país. En este caso, todas las variables tienen efectos estadísticamente significativos, rechazando la hipótesis nula con un nivel de significación del 1 % ($p < 0,01$).

Como conclusión de la Tabla 2, podemos afirmar que, tanto en Argentina como en España, aumentan las probabilidades de realizar AFTL entre los hombres, mientras que disminuyen entre quienes no pertenecen a hogares de altos ingresos, no tienen título universitario, tienen menores en el hogar y no pertenecen al grupo etario más joven. Como veremos más adelante, esto coincide con los resultados que se obtienen trabajando con ORM. A su vez, nos permite señalar que las desigualdades de género son mayores en Argentina, mientras que el efecto del nivel educativo es mayor en España. Para el resto de las variables el efecto es similar. Como veremos a continuación, las conclusiones que obtenemos con ORM no son exactamente las mismas.

Tabla 2

Regresión logística binaria con PEM de realizar AFTL durante la última semana¹ en población de 18 años y más de Argentina en el 2018/19 y de España en el 2023

	Argentina			España		
	PEM	IC (95 %)		PEM	IC (95 %)	
Sexo (Ref.: mujer)	0,139**	0,109	0,168	0,049**	0,031	0,067
Grupo etario del encuestado (Ref.:18 a 34)	-	-	-	-	-	-
35 a 49	-0,041**	-0,080	-0,002	-0,106**	-0,134	-0,079
50 a 64	-0,147**	-0,187	-0,107	-0,168**	-0,194	-0,141
65 y mas	-0,205**	-0,247	-0,163	-0,260**	-0,289	-0,231
Nivel de ingreso por unidad consumidora del hogar (Ref.: alto)	-	-	-	-	-	-
Bajo	-0,115**	-0,158	-0,071	-0,176**	-0,202	-0,151
Medio	-0,062**	-0,102	-0,022	-0,076**	-0,100	-0,052
Nivel educativo (Ref: Superior completo)	-	-	-	-	-	-
Primario	-0,195**	-0,247	-0,143	-0,294**	-0,325	-0,264
Secundario	-0,082**	-0,130	-0,034	-0,190**	-0,211	-0,169
Menores de hasta 14 años en el hogar (Ref.: sin)	-0,077**	-0,109	-0,046	-0,038**	-0,062	-0,014

Nota. ** $p < 0,01$, * $p < 0,05$. ¹ No realiza AFTL = 0, Realiza AFTL = 1. Fuente: elaboración propia en base a ENNyS 2018/19 y ESdE 2023.

3.2. Lectura e interpretación de los ORM

En la Tabla 3 podemos observar los ORM. Cabe recordar que estos coeficientes no indican cambios directos en la probabilidad (como los PEM), sino cambios en los OR, que comparan la probabilidad de que ocurra un evento entre dos grupos. Cuando el valor es mayor a 1, implica mayores Odds y la interpretación es directa. Cuando es menor a 1 implica menores Odds y una estrategia habitual para facilitar la interpretación es expresar el inverso del ORM (dividir a 1 por el valor del ORM).

Una vez controlado el efecto del resto de las variables, el ORM de realizar AFTL para los hombres en comparación con las mujeres es de 2,05 en Argentina. Esto significa que los odds de realizar actividad física de los hombres son aproximadamente el doble (o un 105 % mayores) que los de las mujeres. En España, la brecha es menor: el ORM es de 1,22, indicando que los odds de los hombres son un 22 % mayores que los de las mujeres.

Si nos centramos en el nivel educativo, vemos que tener solo estudios primarios reduce fuertemente las odds de realizar AFTL en comparación con tener estudios superiores. En Argentina, las personas con nivel educativo hasta primario tienen 2,86 veces menos odds ($1/0,35 = 2,86$) que los que tienen nivel superior, mientras que en España son 3,37 veces menos odds ($1/0,30 = 3,37$). Si bien en España el efecto es mayor, observemos que los intervalos de confianza se superponen (0,26-0,46 y 0,26-0,34), lo cual sugiere, aunque no prueba formalmente, que las diferencias no son estadísticamente significativas.

Tabla 3

Regresión logística binaria con ORM de realizar AFTL durante la última semana¹ en población de 18 años y más de Argentina en el 2018/19 y de España en el 2023

	Argentina			España		
	OR	IC (95%)		OR	IC (95%)	
Sexo (Ref.:mujer)	2,05**	1,76	2,39	1,22**	1,13	1,31
Grupo etario del encuestado (Ref.:18 a 34)						
35 a 49	0,83*	0,69	0,99	0,65**	0,58	0,73
50 a 64	0,46**	0,36	0,58	0,51**	0,45	0,57
65 y mas	0,29**	0,22	0,40	0,35**	0,30	0,39
Nivel de ingreso por unidad consumidora del hogar (Ref.: alto)						
Bajo	0,55**	0,44	0,69	0,49**	0,44	0,55
Medio	0,74**	0,61	0,90	0,73**	0,66	0,81
Nivel educativo (Ref: Superior completo)						
Primario	0,35**	0,26	0,46	0,30**	0,26	0,34
Secundario	0,68**	0,55	0,85	0,46**	0,42	0,50
Menores de hasta 14 años en el hogar (Ref.: sin)	0,67**	0,57	0,79	0,86**	0,78	0,95

Nota. ** p < 0,01, *p < 0,05. ¹ No realiza AFTL = 0, Realiza AFTL = 1. Fuente: elaboración propia en base a ENNyS 2018/19 y ESdE 2023.

Al comparar los resultados de la regresión logística binaria con ORM (Tabla 3) con los de PEM (Tabla 2) en términos de significancia, los resultados son iguales cuando miramos a un solo país. En ambos países y con ambas medidas, tienen mayores probabilidades/odds de realizar AFTL los hombres, los jóvenes, las personas con estudios superiores y quienes viven en hogares sin menores y de altos ingresos. La diferencia está en que en un caso se informa la diferencia absoluta y en el otro la relativa.

En cambio, cuando comparamos entre países, vemos que las conclusiones no son exactamente las mismas. Con los ORM, los intervalos de confianza de la diferencia entre quienes tienen estudios primarios con quienes tienen estudios superiores de España y Argentina se solapan (sucede lo mismo con estudio secundario). En cambio, vimos en la Tabla 2 que con PEM las diferencias son mayores en España y los intervalos no se solapan. Al usar PEM, el efecto parece mayor en España simplemente porque hay más personas que realizan AFTL en general. Al usar ORM, se corrige esa diferencia de base y se observa que la desigualdad relativa es similar. Por otro lado, al igual que con PEM, se observa que las desigualdades de género son mayores en Argentina y que para el resto de las variables el efecto es similar.

3.3. Síntesis comparativa entre ORC, PEM y ORM

En la Tabla 4 presentamos un resumen de las principales características desarrolladas en el documento sobre los ORC, los PEM y los ORM³. Como se observa, la principal diferencia entre las ORC y los ORM es que la primera está afectada por la heterogeneidad no observada por lo que no permite comparación entre modelos, grupos y

³ La comparación empírica entre ORC, PEM y ORM excede el alcance de este artículo; para un análisis detallado se remite a Karlson y Jann (2023) y Mood (2010).

muestras. La principal diferencia entre los PEM y los ORM es que la primera es una medida de desigualdad absoluta y que por lo tanto puede haber limitaciones cuando se realizan comparaciones entre grupos si la variable dependiente tiene una distribución muy diferente. En cambio, los ORM es una medida relativa, que no se ve afectada por la distribución de la variable dependiente. Por otro lado, la interpretación directa de los PEM como probabilidades en puntos porcentuales facilita la comunicación de resultados.

Tabla 4

Principales características de las ORC, PEM y ORM.

Medida	Escala	Afectada por la heterogeneidad no observada	Afectado por distribución de variable dependiente	Comparable entre modelos y muestras
ORC	Relativa	Sí	No	No
PEM	Absoluta	No	Sí	Sí
ORM	Relativa	No	No	Sí

4. Discusión

En este trabajo resumimos los argumentos de por qué no se deben utilizar los ORC como en ocasiones se continúan empleando en estudios dentro de las ciencias sociales. Además, presentamos dos medidas alternativas (PEM y ORM), cuya elaboración en Stata y su interpretación es relativamente sencillas y accesibles en investigaciones aplicadas.

Ahora bien, ¿qué medida es más conveniente utilizar, PEM o ORM? En gran medida, la elección dependerá del tipo de pregunta de investigación y si el foco está puesto en la desigualdad absoluta o en la desigualdad relativa. El PEM responde a la pregunta de cuánto cambia la probabilidad absoluta de que ocurra el evento de interés al pasar de una categoría de la variable independiente a otra. Además, tiene la ventaja de ofrecer una interpretación directa en puntos porcentuales, que es de muy fácil comunicación para el público general. En cambio, el ORM responde a la pregunta de cómo cambian las desigualdades relativas o las *odds* de que ocurra el evento de interés entre las categorías de la variable independiente. Esta medida es particularmente conveniente si el objetivo es comparar desigualdades entre poblaciones con diferentes distribuciones de la variable dependiente (como en el ejemplo de la AFTL entre Argentina y España). Esto se debe a que los ORM no son sensibles a la distribución marginal de la variable dependiente, mientras que los PEM sí lo son. Destacamos que PEM y ORM no son medidas sustitutas sino complementarias. En algunos casos, la incorporación de ambas medidas nos puede permitir una mejor comprensión del fenómeno social en estudio.

Financiamiento del trabajo

El análisis se realizó en el marco de los proyectos PIP CONICET Código 11220220100111 y UBACyT Código 20020220100032, ambos radicados en el Instituto de Investigaciones Gino Germani de la Universidad de Buenos Aires. El artículo, además, fue elaborado en el contexto del proyecto INCASI2, que ha recibido financiación del programa de investigación e innovación Horizonte Europa de la Unión Europea en virtud del acuerdo de subvención Marie Skłodowska-Curie n.º 101130456 (<https://incasi.uab.es>). Sin embargo, las opiniones y puntos

de vista expresados son únicamente los de los autores y no reflejan necesariamente los de la Unión Europea o la Agencia Ejecutiva Europea de Investigación. Ni la Unión Europea ni la autoridad que concede la subvención pueden considerarse responsables de ellos.

Agradecimientos

Agradezco a Juan Manuel García González y a Ildelfonso Marqués Perales, quienes me realizaron sugerencias sobre una versión preliminar del manuscrito. También a los evaluadores del artículo por sus aportes realizados.

Referencias

- Arel-Bundock, V., Greifer, N., & Heiss, A. (2024). How to interpret statistical models using marginal effects for R and Python. *Journal of Statistical Software*, 111(9), 1-32. <https://doi.org/10.18637/jss.v111.i09>
- Ballesteros, M. S. (2018). *Promedio de los efectos marginales e interacciones en las regresiones logísticas binarias*. INCASI Working Paper Series, 3. Recuperado de <https://ddd.uab.cat/record/189811>
- Breen, R., Karlson, K. B., & Holm, A. (2018). Interpreting and understanding logits, probits, and other nonlinear probability models. *Annual Review of Sociology*, 44(1), 39-54. <https://doi.org/10.1146/annurev-soc-073117-041429>
- Jann, B., & Karlson, K. B. (2023). Estimation of marginal odds ratios. *University of Bern Social Sciences Working Papers*, 44. Recuperado de <https://boris-portal.unibe.ch/server/api/core/bitstreams/ffb56244-05ff-40b8-84cd-adc9c8f73470/content>
- Karlson, K. B., & Jann, B. (2023). Marginal odds ratios: What they are, how to compute them, and why sociologists might want to use them. *Sociological Science*, 10, 332-347. <https://doi.org/10.15195/v10.a10>
- Instituto Nacional de Estadística y Ministerio de Sanidad (2025). *Encuesta de Salud de España 2023. Metodología*. Recuperado de https://www.sanidad.gob.es/estadEstudios/estadisticas/encuestaSaludEspana/ESdE2023/ESdE23_Metodologia.pdf
- Mize, T. D. (2019). Best practices for estimating, interpreting, and presenting nonlinear interaction effects. *Sociological Science*, 6, 81-117. <https://doi.org/10.15195/v6.a4>
- Mize, T. D., Doan, L., & Long, J. S. (2019). A general framework for comparing predictions and marginal effects across models. *Sociological Methodology*, 49(1), 152-189. <https://doi.org/10.1177/0081175019852763>
- Ministerio de Salud (2022). *Encuesta Nacional de Nutrición y Salud. Segundo Informe de Indicadores Priorizado*. Ministerio de Salud, Buenos Aires. Recuperado de <https://iah.ms.gov.ar/doc/902.pdf>
- Mood, C. (2010). Logistic regression: Why we cannot do what we think we can do, and what we can do about it. *European Sociological Review*, 26(1), 67-82. <https://doi.org/10.1093/esr/jcp006>