

Una introducción al modelamiento multinivel en psicología de la salud usando R

An Introduction to Multilevel Modeling in Health Psychology Using R

Jorge Schleef Bustamante

Universidad Santo Tomás, Temuco, Chile

Manuel S. Ortiz

Universidad de La Frontera, Temuco, Chile

Resumen

El uso de técnicas estadísticas convencionales, como el análisis de la varianza (ANOVA) o regresión de mínimos cuadrados ordinarios, puede llevar a conclusiones erróneas y resultados sesgados cuando existen datos anidados, como pacientes en hospitales o adultos en vecindarios. El modelamiento multinivel permite abordar esta complejidad examinando relaciones entre variables en distintos niveles de una estructura de datos jerárquica. El presente artículo describe los conceptos básicos del análisis multinivel a través de aplicaciones en psicología de la salud usando el programa R. Se ilustran diferentes modelos de regresión multinivel usando datos simulados. Los materiales están disponibles en línea. Los resultados de los análisis representan los efectos predictivos entre grupos e intra grupo de la disponibilidad de áreas para ejercicio en el vecindario y de la intención conductual sobre la actividad física en adultos de distintos vecindarios. La implementación de modelos multinivel puede aportar a la comprensión del cambio conductual y estrategias de intervención para la prevención de enfermedades crónicas.

Palabras clave: Psicología de la salud, conductas de salud, actividad física, análisis multinivel, regresión multinivel.

Jorge Schleef Bustamante, Escuela de Psicología, Facultad de Ciencias Sociales y Comunicaciones, Universidad Santo Tomás, Chile. Manuel S. Ortiz, Departamento de Psicología, Facultad de Educación, Ciencias Sociales y Humanidades, Universidad de La Frontera, Temuco, Chile; Laboratorio de Estrés y Salud, Doctorado en Psicología, Universidad de La Frontera, Temuco, Chile.

La correspondencia en relación con este artículo se dirige a: Dr. Jorge Schleef, Escuela de Psicología, Facultad de Ciencias Sociales y Comunicaciones, Universidad Santo Tomás, Manuel Rodríguez 060, Temuco, Chile. Correo electrónico: jschleef@santotomas.cl



Abstract

The use of conventional statistical techniques, such as analysis of variance (ANOVA) or ordinary least squares regression, can lead to erroneous conclusions and biased results when there is nested data, such as patients in hospitals or adults in neighborhoods. Multilevel modeling allows this complexity to be addressed by examining relationships between variables at different levels of a hierarchical data structure. This article describes the basic concepts of multilevel analysis through applications in health psychology using the program R. Different multilevel regression models are illustrated using simulated data. The materials are available online. The results of the analysis represent the predictive between-group and within-group effects of neighborhood exercise area availability and behavioral intention on physical activity in adults sampled from different neighborhoods. The implementation of multilevel models can contribute to the understanding of behavior change and intervention strategies for the prevention of chronic diseases.

Keywords: Health Psychology; Health behavior; Physical activity; Multilevel analysis; Multilevel regression.

En psicología de la salud, es relevante determinar la influencia de factores contextuales y psicológicos en desenlaces de salud física y conductas de salud, como el uso de cigarrillo, dieta y actividad física ([Kajosaari & Laatikainen, 2020](#); [Kim et al., 2020](#); [Lin et al., 2022](#)). Para estudiar estas relaciones, se recolectan datos en distintos niveles de análisis, los cuales abarcan, típicamente, un nivel inferior donde las unidades son individuos (por ejemplo, pacientes de enfermedades crónicas) y un nivel superior en el que las unidades son grupos o contextos a los que pertenecen los individuos (por ejemplo, hospitalares).

Este agrupamiento establece una estructura jerárquica en los datos que, generalmente, conlleva la violación del supuesto de independencia de las observaciones, inherente a las técnicas estadísticas convencionales de nivel único, como ANOVA o regresión de mínimos cuadrados ordinarios ([Heck & Thomas, 2020](#)). Cuando existen datos anidados, el uso de estas técnicas puede introducir sesgo en los errores estándar, haciendo más pequeñas sus estimaciones, lo que incrementa el riesgo de error tipo I ([Finch et al., 2019](#)). Asimismo, puede llevar a cometer falacia ecológica, esto es “tomar una relación entre variables establecida en un nivel y transferirla a un nivel diferente sin comprobar su validez para ese nivel” ([Snijders & Bosker, 2012](#), p. 70). En estricto rigor, no es lo mismo afirmar que (a) la adherencia al tratamiento sea menor en usuarios que desconfían del profesional de la salud que les atiende, en comparación con que (b) las tasas de adherencia sean más bajas en hospitales donde existe mayor desconfianza hacia los profesionales.

El análisis multinivel es una metodología que compensa las limitaciones descritas al establecer asociaciones estadísticas entre múltiples variables que pertenecen a diferentes niveles de un conjunto de datos agrupados ([Hox et al., 2018](#)). Asimismo, integrar la perspectiva multinivel puede beneficiar la investigación sobre diversos fenómenos relevantes en psicología de la salud, como el vínculo médico-paciente, determinantes comunitarios de la actividad física, o la incidencia de aspectos familiares en el riesgo cardiovascular.

Sin embargo, el aprendizaje de modelamiento multinivel puede ser una tarea desafiante para profesionales en psicología de la salud en Latinoamérica. Una razón es que buena parte de la literatura introductoria en el área se halla en idioma inglés y utiliza terminología estadística que suele variar de una

MODELAMIENTO MULTINIVEL USANDO R

fuente a otra. De la misma forma, los recursos disponibles en la literatura en español son más escasos y no se enfocan en salud ([Murillo, 2008](#); [Oliver et al., 2000](#)) o incluyen ilustraciones de análisis con programas estadísticos de pago ([Aparicio & Morera, 2006](#); [Pardo et al., 2007](#)).

El presente artículo metodológico tiene por objetivo introducir los conceptos básicos del análisis multinivel por medio de aplicaciones en psicología de la salud. Se ilustrarán modelos de regresión multinivel lineales, también referidos como modelos lineales jerárquicos o modelos lineales de efectos mixtos, según la taxonomía de Luke ([2020](#)). Para ello, se utilizará la librería *lme4* ([Bates et al., 2015](#)) del programa R, un programa de acceso abierto y facilita la reproducción de los análisis estadísticos realizados. La notación empleada sigue el estilo de O'Connell et al. ([2022](#)). A pesar del carácter didáctico de esta guía, se asumen conocimientos elementales de regresión lineal y lenguaje R. Para adquirir una base conceptual más exhaustiva acerca del modelamiento multinivel, se pueden consultar los textos de Raudenbush y Bryk ([2002](#)), Snijders y Bosker ([2012](#)) y Hox et al. ([2018](#)).

Transitando a un modelo multinivel

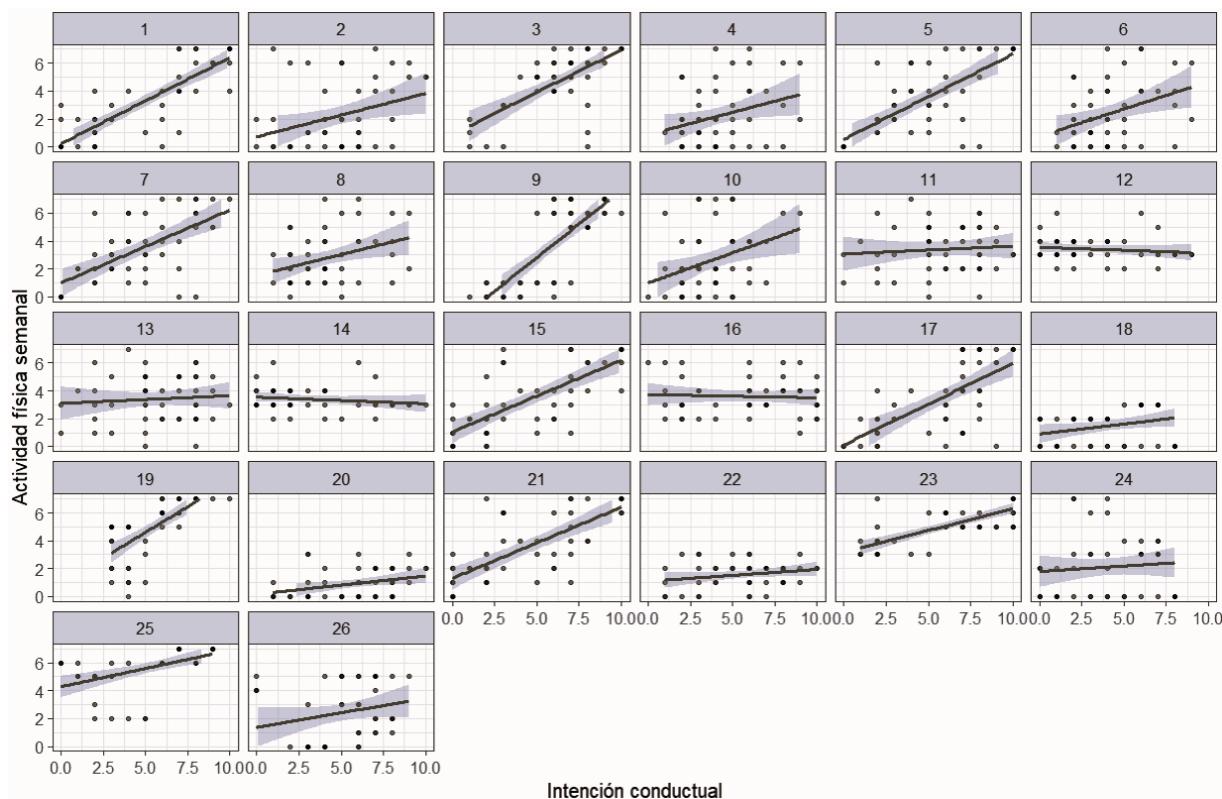
A lo largo de este artículo se analizan datos simulados de un estudio sobre actividad física en el cual se muestrearon 50 personas adultas de 26 vecindarios diferentes seleccionados aleatoriamente dentro de un país ($n = 1300$). El diseño de este estudio ficticio es no experimental transversal. Se midieron tres variables: la frecuencia de actividad física semanal (0 = ningún día, 7 = todos los días); la intención conductual para la actividad física, en una escala de 0 a 10 puntos (altos puntajes indican mayor intención); y si los vecindarios disponían de áreas para realizar actividad física (0 = no, 1 = sí). En estos datos, los individuos son las unidades del nivel inferior (nivel 1 o individual) y los vecindarios las del nivel superior (nivel 2 o grupal). Dentro de esta estructura, las variables predictoras se clasifican según su nivel de análisis.

Por un lado, los puntajes de actividad física e intención conductual son variables de nivel 1, ya que pueden mostrar variaciones de una persona a otra. De este modo, la intención conductual podría explicar diferencias de la actividad física entre los individuos. Al respecto, la Figura 1 muestra la asociación de la intención conductual con la actividad física dentro de cada vecindario. Por otro lado, la disponibilidad de áreas para realizar actividad física es una variable de nivel 2, debido a que es constante para los individuos dentro del mismo vecindario y solo puede variar de un vecindario a otro. Así, la disponibilidad de estas áreas podría explicar diferencias de la actividad física que ocurren entre los vecindarios.

Las asociaciones de la actividad física con la intención conductual de los individuos y la disponibilidad de espacios para actividad física en el vecindario se analizarán con modelos de regresión multinivel lineales, los cuales permiten evaluar la relación entre una variable dependiente cuantitativa medida en el nivel inferior, y variables predictoras cuantitativas o categóricas que pueden encontrarse en múltiples niveles ([Hox et al., 2018](#)). Se usará esta metodología con el propósito de responder las siguientes preguntas de investigación: (a) ¿Es mayor la actividad física en individuos con altos niveles de intención conductual?, (b) ¿Se realiza más actividad física en vecindarios que disponen de áreas para el ejercicio físico?, y (c) ¿Cambia la asociación entre la intención conductual y la actividad física de los individuos según la disponibilidad de áreas para el ejercicio en el vecindario?

Figura 1

Relación entre la intención conductual y la frecuencia de actividad física semanal a través de los vecindarios



Los datos y el script de R para correr los análisis se encuentran disponibles en línea, en un repositorio GitHub (<https://github.com/proyectoMMN/Tutorial>). El archivo de datos se encuentra en formato .sav (SPSS). Para que el objeto *datosMLM* contenga la base de datos para los análisis, esta puede importarse a R usando la función `read_sav()` del paquete `haven` de la siguiente forma:

```
library(haven)  
  
datosMLM <- read_sav("datosMLM.sav")
```

Modelo Nulo

Típicamente, el primer paso en un análisis de regresión multinivel es estimar un modelo nulo sin predictores para la variable dependiente, también referido como ANOVA de una vía de efectos aleatorios (Luke, 2020). Para los datos de actividad física, el modelo nulo es:

MODELAMIENTO MULTINIVEL USANDO R

(Ec. 1)

$$\text{Nivel 1: } AF_{ij} = \beta_{0j} + e_{ij}$$

$$\text{Nivel 2: } \beta_{0j} = \gamma_{00} + u_{0j}$$

En el nivel 1, AF_{ij} es la actividad física del individuo i en el vecindario j ; β_{0j} es un parámetro de intercepto que señala el promedio de actividad física en el vecindario j . El subíndice j vinculado al intercepto introduce una diferencia clave frente al modelo de regresión lineal de nivel único, donde el intercepto se considera un efecto fijo constante para todos los individuos en la muestra (Heck & Thomas, 2020). En un modelo multinivel se permite que el intercepto adopte valores únicos a través de los grupos (Hancock et al., 2019) y, así, que cada vecindario tenga un promedio estimado de actividad física diferente. En otras palabras, el intercepto ahora tiene una parte aleatoria: es susceptible a cambiar de un grupo a otro sin estar limitado a un rango predefinido o conocido de antemano.

Por otro lado, e_{ij} es el término de error del nivel individual y representa la distancia del puntaje particular del individuo i en la variable dependiente con respecto al promedio de su grupo (Geiser, 2013). En regresión multinivel, es común asumir que los errores e_{ij} tienen distribución normal y varianza homogénea entre las unidades de nivel 2 (Bell & Schoeneberger, 2022). La varianza de e_{ij} (σ_e^2) captura las diferencias en actividad física entre individuos que pertenecen al mismo vecindario, es decir, variabilidad intra grupo o del nivel individual (Geiser, 2013).

En el nivel 2, los coeficientes γ son efectos fijos que aplican del mismo modo a través de todos los grupos; γ_{00} es el efecto fijo del intercepto y corresponde al gran promedio de actividad física a través de todos los vecindarios (Finch et al., 2019); u_{0j} son efectos aleatorios vinculados a los interceptos, los cuales representan la diferencia entre el promedio de actividad física del vecindario j y el gran promedio de actividad física γ_{00} (Bell & Schoeneberger, 2022). Se estima la varianza de u_{0j} (τ_{00}), que indica la cantidad de variabilidad en los interceptos de los vecindarios, es decir, varianza entre grupos o de nivel 2 (Heck & Thomas, 2020). En regresión multinivel, se asume que las desviaciones u_{0j} tienen distribución normal y son independientes de los errores del nivel individual e_{ij} (Raudenbush & Bryk, 2002).

La función *lmer()* de la librería *lme4* permite estimar una variedad de modelos de regresión multinivel en R. Los códigos para correr e imprimir los resultados del modelo nulo son:

```
M.nulo <- lmer(Actividad_Fisica ~ 1 + (1 | IDvecindario), data = datosMLM, REML = TRUE)

summary(M.nulo)
```

La parte *Actividad_Fisica ~ 1 + (1 | IDvecindario)* contiene la especificación del modelo nulo. A la izquierda del operador ~ se encuentra la variable dependiente (*Actividad_Fisica*). Luego, se especifican los efectos fijos a la derecha del operador ~ antes del siguiente paréntesis, de manera que *Actividad_Fisica ~ 1* representa el efecto fijo del intercepto. Dentro del paréntesis, los efectos aleatorios se definen

a la izquierda del |, donde el 1 denota que solo se estima el efecto aleatorio del intercepto. A la derecha del | se posiciona la variable de agrupación (*IDvecindario*), señalando que el intercepto aleatorio varía en función del vecindario. El argumento data contiene el archivo de datos y REML = TRUE solicita la estimación de máxima verosimilitud restringida, recomendada cuando el número de grupos es menor a 30 (Bell & Schoeneberger, 2022). Por último, la función *summary()* arroja los resultados del modelo.

Las estimaciones de varianza del nivel individual y grupal fueron $\sigma_e^2 = 3.944$ y $\tau_{00} = 1.232$, respectivamente. Se puede usar esta información para calcular el Coeficiente de Correlación Intra clase (CCI), que cuantifica el grado de dependencia en las observaciones (Luke, 2020). El CCI se calcula como la razón de la varianza entre grupos contra la varianza total ($CCI = \tau_{00} / (\sigma_e^2 + \tau_{00})$), y corresponde a la proporción de variación en el desenlace que ocurre entre los grupos (Peugh, 2010). Un CCI pequeño puede introducir sesgo en pruebas estadísticas convencionales (Cohen et al., 2003). En R, el CCI se puede obtener con la función *icc()* del paquete performance sobre el objeto del modelo:

`icc(M.nulo)`

El CCI en el modelo nulo es .238, indicando que 23.8% de la variabilidad en la actividad física es atribuible a diferencias entre vecindarios. Este resultado respalda la implementación de modelos multínivel para comprender las variaciones intra grupo y entre grupos de la actividad física través de los vecindarios.

Modelo de Interceptos Aleatorios

Para examinar las relaciones de la actividad física con la intención conductual en el nivel individual y la disponibilidad de áreas para hacer actividad física en el nivel grupal, se implementará un modelo de interceptos aleatorios (Ec. 2 [Luke, 2020]). Por razones que se aclararán más adelante, se emplea la intención conductual centrada en el promedio del grupo (*IntenciónCPG*). El centrado en el promedio del grupo implica restar a los puntajes individuales de una variable el promedio del grupo (Peugh, 2010).

(Ec. 2)

$$\text{Nivel 1: } AF_{ij} = \beta_{0j} + \beta_1 IntenciónCPG_{ij} + e_{ij}$$

$$\text{Nivel 2: } \beta_{0j} = \gamma_{00} + \gamma_{01} Areas_j + u_{0j}$$

$$\beta_1 = \gamma 1_0$$

En el nivel 1, AF_{ij} e $IntenciónCPG_{ij}$ se refieren a la actividad física e intención conductual centrada en el promedio grupal del individuo i en el vecindario j , respectivamente; β_{0j} es el intercepto de cada vecindario y corresponde ahora al valor esperado de actividad física dentro del vecindario j cuando el predictor de nivel individual $IntenciónCPG_{ij}$ es 0 (Bell & Schoeneberger, 2022); β_1 es la pendiente de la relación entre la intención conductual y la actividad física; finalmente, e_{ij} es el error del individuo i en

MODELAMIENTO MULTINIVEL USANDO R

el vecindario j . En este modelo, la varianza de e_{ij} (σ_e^2) denota variabilidad residual del nivel individual luego de controlar por $IntenciónCPG_{ij}$ (Raudenbush & Bryk, 2002).

En el nivel 2 hay dos ecuaciones separadas para los interceptos y pendientes de nivel 1. $Areas_j$ es el nivel del predictor de nivel 2 de disponibilidad de áreas para ejercicio en el vecindario j ; γ_{00} es el efecto fijo del intercepto, que indica el promedio esperado de actividad física a través de todos los vecindarios cuando $IntenciónCPG_{ij}$ y $Areas_j$ están en 0 (Bell & Schoeneberger, 2022). Por otro lado, γ_{01} es la pendiente del efecto fijo de $Areas_j$, que expresa la cantidad de cambio esperado en γ_{00} por el incremento de un punto en $Areas_j$. El efecto γ_{01} necesariamente es fijo debido a que no hay unidades de orden superior en la estructura de datos a través de las cuales pueda variar.

Es importante notar que el efecto de $Areas_j$, al ser un predictor de nivel 2, opera sobre los promedios de actividad física a nivel de los grupos y no sobre los puntajes individuales (LoPilato & Vandenberg, 2015). Por otro lado, u_{0j} son los efectos aleatorios de los interceptos en el nivel grupal y señalan la desviación residual del intercepto del vecindario j en torno al efecto fijo del intercepto γ_{00} (Bell & Schoeneberger, 2022). Se estima la varianza de u_{0j} (τ_{00}), que ahora es la varianza residual de los interceptos en el nivel de los vecindarios luego de controlar por $IntenciónCPG_{ij}$ y $Areas_j$ (Hox et al., 2018).

La ecuación del nivel 2 para β_1 solo tiene un efecto fijo γ_{10} , el cual denota la pendiente general del predictor de nivel individual $IntenciónCPG_{ij}$ a través de todos los vecindarios j . A diferencia del efecto fijo del intercepto (γ_{00}), γ_{10} no tiene un término de error asociado, reflejando que en este modelo el efecto de $IntenciónCPG_{ij}$ se mantiene constante en los diferentes vecindarios (Geiser, 2013).

Antes de correr el modelo, se crea la variable de intención conductual centrada en el promedio grupal ($IntenciónCPG_{ij}$) utilizando la función *center()* de la librería *misty* en R:

```
datosMLM$Intencion_ConductualCPG <- center(datosMLM$Intencion_Conductual, type = "CWC",
                                               cluster = datosMLM$IDvecindario)
```

Así, la sintaxis para el modelo de interceptos aleatorios es:

```
M.interaleatorio <- lmer(Actividad_Fisica ~ Intencion_ConductualCPG + Disp_Area + (1 |
                                         IDvecindario), data = datosMLM, REML = TRUE)
```

El único cambio en relación con el comando del modelo anterior es que se agregan los efectos fijos de *Intencion_ConductualCPG* y *Disp_Area*. *lmer()* no entrega valores p , pero esto se puede compensar con el paquete *lmerTest*. Esta librería complementa a *lmer()*, de manera que se incluyen valores p para los efectos fijos al imprimir los resultados de un modelo con *summary()*. Por defecto, estos valores p se basan en pruebas estadísticas que utilizan la aproximación de Satterhwaite para obtener los grados de libertad (Kuznetsova et al., 2017). Sin embargo, cuando el número de grupos es pequeño ($n < 30$), como en este ejemplo, se recomienda el método de Kenward-Roger para computar los grados de libertad

([Bell & Schoeneberger, 2022](#)). Los valores p correspondientes a este método se pueden determinar con el código:

```
summary(M. interaleatorio, ddf = "Kenward-Roger")
```

Los resultados de este modelo muestran que, en personas con niveles promedio de intención conductual relativos a su grupo y de vecindarios sin espacios para hacer ejercicio, la media estimada de actividad física fue de 2.4 veces por semana ($\gamma_{00} = 2.405$, $EE = .227$, $p < .001$). Individuos con altos niveles de intención conductual mostraron mayores niveles de actividad física ($\gamma_{10} = .335$, $EE = .018$, $p < .001$). En vecindarios que disponen de áreas para realizar ejercicio, el promedio de actividad física fue significativamente más alto por 1.6 puntos ($\gamma_{01} = 1.603$, $EE = .321$, $p < .001$).

Modelo de Coeficientes Aleatorios

El modelo de interceptos aleatorios previo especificó el efecto de la intención conductual como un efecto completamente fijo y constante a través de todos los vecindarios j . No obstante, al igual que con los interceptos, en los modelos multinivel se puede dejar que la pendiente de un predictor de nivel individual varíe aleatoriamente de un grupo a otro, lo que podría ser útil para evaluar el grado en que la dirección y magnitud de la asociación entre la intención conductual y la actividad física es diferente según el vecindario. De acuerdo con Luke ([2020](#)), el tipo de modelo multinivel que toma en cuenta variaciones en los interceptos y pendientes a través de las unidades de nivel superior se denomina modelo de coeficientes aleatorios:

(Ec. 3)

$$\text{Nivel 1: } AF_{ij} = \beta_{0j} + \beta_{1j} \text{IntenciónCPG}_{ij} + e_{ij}$$

$$\text{Nivel 2: } \beta_{0j} = \gamma_{00} + \gamma_{01} Areas_j + u_{0j}$$

$$\beta_{1j} = \gamma_{10} + u_{1j}$$

El hecho de que la pendiente de nivel inferior β_1 pueda ser distinta de un grupo a otro se explica agregándole un subíndice j en la ecuación de nivel 1. En este modelo se incluye u_{1j} en la ecuación de las pendientes (β_{1j}) en el nivel 2, diferenciándolo del modelo de interceptos aleatorios anterior; u_{1j} corresponde al componente aleatorio de la pendiente de IntenciónCPG_{ij} . Este señala la desviación de la pendiente para la relación entre IntenciónCPG_{ij} y actividad física del vecindario j con respecto a γ_{10} ([Finch et al., 2019](#)).

Se estima la varianza de u_{1j} (τ_{11}), la cual indica la cantidad de variación en el efecto predictivo de IntenciónCPG_{ij} sobre la actividad física a través de los vecindarios ([Raudenbush & Bryk, 2002](#)). Si τ_{11} es no nula, se debe considerar que existe variabilidad en torno a γ_{10} , de modo que este término pasa a representar únicamente la pendiente promedio de la asociación entre IntenciónCPG_{ij} y la actividad física

MODELAMIENTO MULTINIVEL USANDO R

a lo largo de todos los vecindarios (Hox et al., 2018). Típicamente, también se estima la covarianza de los interceptos y pendientes de nivel 1 (τ_{01}), lo que además es recomendado (Snijders & Bosker, 2012). Se asume que u_{0j} y u_{1j} tienen distribución normal multivariada y son independientes de e_{ij} (Hox et al., 2018).

Utilizando como base el código del modelo de interceptos aleatorios, la sintaxis de *lmer()* para el modelo de coeficientes aleatorios solo requiere especificar la pendiente aleatoria de *Intencion_ConductualCPG* a la izquierda del | dentro del paréntesis donde se definen los efectos aleatorios:

```
M.coefaleatorios <- lmer(Actividad_Fisica ~ Intencion_ConductualCPG + Disp_Area + (1 +
  Intencion_ConductualCPG | IDvecindario), data = datosMLM, REML = TRUE)
```

La varianza estimada de la pendiente de intención conductual a través de los vecindarios fue $\tau_{11} = .062$. Nótese que *lmer()* tampoco entrega una prueba de significancia estadística de esta varianza. El enfoque clásico es implementar un test de razón de probabilidad (*Likelihood Ratio Test*, LRT) para evaluar la necesidad de mantener un efecto aleatorio en el modelo (Snijders & Bosker, 2012). El LRT evalúa el cambio en los estadísticos de desviación de dos modelos anidados, donde valores de desviación bajos indican un mejor ajuste del modelo a los datos (Hox et al., 2018).

Dos modelos están anidados cuando uno está compuesto por un grupo de parámetros de otro más general (Maruyama, 1998). La diferencia en las desviaciones de dos modelos anidados tiene una distribución de chi-cuadrado, donde los grados de libertad son iguales a la diferencia de la cantidad de parámetros en cada modelo (Heck & Thomas, 2020). Así, se compara un modelo que incluye la pendiente aleatoria contra otro que no la incorpora.

En R, la función *ranova()* del paquete *lmerTest* entrega una tabla de LRT para los efectos aleatorios, evaluando si el ajuste del modelo a los datos empeora significativamente al quitar la pendiente aleatoria:

```
ranova(M.coefaleatorios)
```

El resultado del LRT sugiere que el efecto aleatorio de la pendiente de intención conductual es significativo [$\chi^2 (2) = 141.74, p < .001$], indicando que la asociación de la intención conductual y la actividad física de las personas cambia según el vecindario. Los coeficientes de los efectos fijos de la intención conductual ($\gamma_{10} = .331, EE = .052, p < .001$) y disponibilidad de áreas para hacer ejercicio ($\gamma_{01} = 1.768, EE = .331, p < .001$) se mantuvieron similares a los obtenidos con el modelo de intercepto aleatorio.

Modelo de Interceptos y Pendientes como Desenlace

Una característica del modelo de coeficientes aleatorios es que estima la variación en las pendientes de nivel 1 sin buscar predecirla. Sin embargo, desde un punto de vista teórico, es relevante identificar aspectos contextuales de los vecindarios que podrían explicar diferencias en la asociación de la intención conductual con la actividad física de los individuos. Al respecto, la presencia de áreas para hacer ejercicio en el vecindario podría facilitar que la intención se traduzca en la práctica de actividad física,

mientras que la ausencia de estos espacios podría dificultar la realización de ejercicio en individuos con la intención de hacerlo (Rhodes & Dickau, 2013).

Esto se puede expresar formalmente con la hipótesis de que el efecto predictivo positivo de la intención conductual sobre la actividad física será más fuerte en individuos de vecindarios con áreas habilitadas para realizar esta conducta. En modelamiento multinivel, esta hipótesis abarca lo que se conoce como interacción de nivel cruzado, esto es, el modo en que características de las unidades de nivel superior modifican relaciones entre variables de un nivel inferior (Nezlek, 2008). Para probar esta clase de hipótesis, se recomienda usar centrado en el promedio del grupo en los predictores de nivel individual, justificando la creación de $IntenciónCPG_{ij}$ (Hox et al., 2018). El tipo de modelo de regresión multinivel que permite probar interacciones de nivel cruzado es referido como modelo de interceptos y pendientes como desenlace (Luke, 2020):

(Ec. 4)

$$\text{Nivel 1: } AF_{ij} = \beta_{0j} + \beta_{1j} IntenciónCPG_{ij} + e_{ij}$$

$$\text{Nivel 2: } \beta_{0j} = \gamma_{00} + \gamma_{01} Areas_j + u_{0j}$$

$$\beta_{1j} = \gamma_{10} + \gamma_{11} Areas_j + u_{1j}$$

La principal diferencia de este modelo con el de coeficientes aleatorios previo es que se agrega el efecto fijo γ_{11} en la ecuación para las pendientes en el nivel 2; γ_{11} es el efecto del predictor de nivel grupal ($Areas_j$) sobre las pendientes de la relación entre $IntenciónCPG_{ij}$ y la actividad física a través de los vecindarios (Bell & Schoeneberger, 2022). En consecuencia, la varianza de u_{1j} (τ_{11}) es ahora la variabilidad residual de las pendientes aleatorias de nivel 1. Este modelo se puede representar con un diagrama, siguiendo el estilo de Heck y Thomas (2020), tal y como muestra la Figura 2, o una ecuación que combina el nivel 1 y 2:

(Ec. 5)

$$AF_{ij} = \gamma_{00} + \gamma_{10} IntenciónCPG_{ij} + \gamma_{01} Areas_j + \gamma_{11} IntenciónCPG_{ij} Areas_j + u_{0j} + u_{1j} IntenciónCPG_{ij} + e_{ij}$$

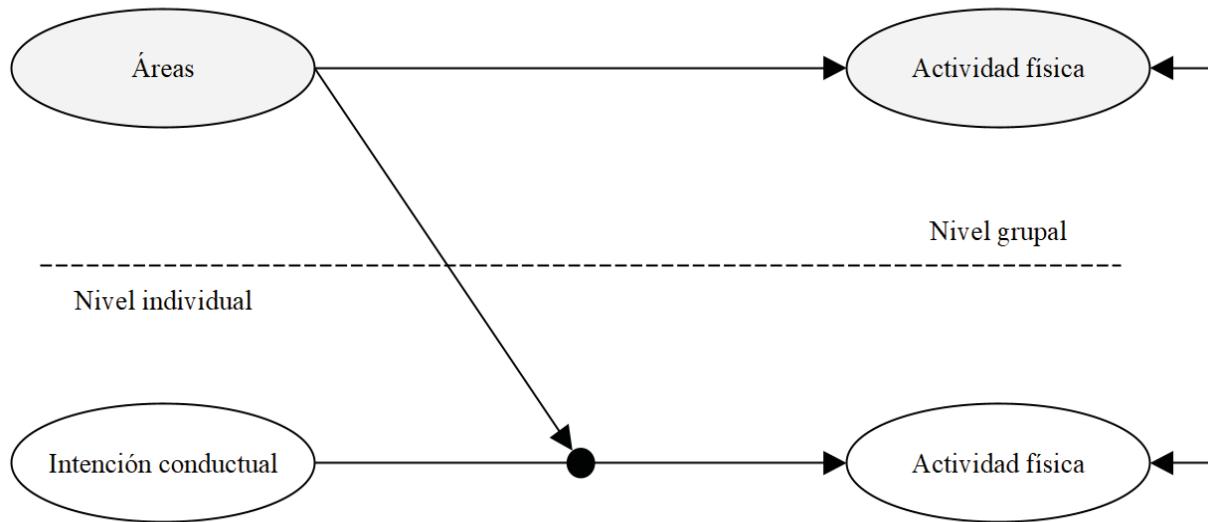
En *lmer()*, las interacciones entre predictores se pueden incorporar usando los nombres de las variables involucradas en la interacción separadas por dos puntos (:). De este modo, la sintaxis del modelo de interceptos y pendientes como desenlace es:

```
M.internivelcruzado <- lmer(Actividad_Fisica ~ Intencion_ConductualCPG + Disp_Area + Intencion_ConductualCPG:Disp_Area + (1 + Intencion_ConductualCPG | IDvecindario), data = datosMLM,
                           REML = TRUE)
```

Al interpretar los resultados de este modelo, se debe tomar en cuenta que, en un modelo de regresión, incluir una interacción cambia el significado de los efectos principales de las variables predictoras que

MODELAMIENTO MULTINIVEL USANDO R

Figura 2
Representación visual del modelo de interceptos y pendientes como desenlace analizado



la componen. Estos se convierten en efectos principales simples, los cuales corresponden al “efecto del predictor específicamente cuando su predictor interactuante es 0” (Hoffman, 2014, p. 43). Esto explica el notorio cambio en la pendiente fija de $IntenciónCPG_{ij}$ en el modelo de interceptos y pendientes como desenlace versus el modelo de coeficientes aleatorios.

El efecto predictivo de la intención conductual sobre la actividad física en individuos de vecindarios que no disponen de áreas para realizar actividad física ($Areas_j = 0$) fue positivo y significativo ($\gamma_{10} = .168$, $EE = .059$, $p = .009$). Por otra parte, la media de actividad física en individuos con niveles promedio de intención conductual relativos a su grupo ($IntenciónCPG_{ij} = 0$) fue significativamente más alta en vecindarios que disponen de áreas para hacer ejercicio ($\gamma_{01} = 1.603$, $EE = .321$, $p < .001$). La interacción de nivel cruzado fue estadísticamente significativa ($\gamma_{11} = .317$, $EE = .083$, $p < .001$). La pendiente de la relación entre intención conductual y actividad física en el nivel individual fue .32 puntos más positiva en vecindarios que contaban con áreas para realizar actividad física.

Tamaño del efecto

En regresión multinivel, el cálculo de estadísticos de varianza explicada (o R^2) es más complicado que en regresión lineal de nivel único, ya que la varianza total de la variable dependiente se divide en intra grupo y entre grupos, y los predictores pueden tener efectos fijos o aleatorios, además de estar en diferentes niveles. La librería r2mlm permite abordar esta complejidad utilizando el marco de referencia integrador de Rights y Sterba (2019) para el cálculo de medidas de R^2 en modelos multinivel. La implementación de este paquete requiere que las variables del modelo sean tratadas como numéricas en

R. El siguiente código despliega los coeficientes de R² para la varianza explicada en total, entre grupos e intra grupos por el modelo de coeficientes aleatorios:

```
r2 <- r2mlm(M.coefaleatorios)
```

```
r2$Decompositions
```

En conjunto, los efectos fijo y aleatorio de la intención conductual explicaron 31.9% y 23.5% de la varianza intra grupos y total de la actividad física, respectivamente. Por otra parte, el efecto fijo de la disponibilidad de áreas para ejercicio explicó 55.7% y 14.7% de la varianza entre grupos y total de la actividad física, respectivamente.

Consideraciones adicionales

La implementación de modelos de regresión multinivel requiere de un tamaño muestral suficiente para obtener estimaciones precisas. Hox et al. (2018) sugieren algunas orientaciones generales de tamaño muestral: al menos 30 grupos con al menos 30 individuos por grupo cuando el interés está en los efectos fijos; al menos 50 grupos con al menos 20 individuos por grupo cuando el foco está en interacciones de nivel cruzado; y al menos 100 grupos con al menos 10 individuos por grupo cuando la atención está en los efectos aleatorios. Sin embargo, también es altamente recomendable planear el tamaño muestral utilizando un análisis de potencia estadística a priori, para lo que ya se han desarrollado herramientas y tutoriales con R (Kumle et al., 2021).

Gran parte de los modelos de regresión multinivel lineales son robustos ante la violación de supuestos distribucionales como normalidad y homocedasticidad de los residuos (Schielzeth et al., 2020). No obstante, el incumplimiento de estas condiciones puede manejarse implementando alguna transformación de la variable dependiente (por ejemplo, logarítmica) o cambiando a un modelo distinto, por lo que su chequeo debe ser una práctica regular (Jacqmin-Gadda et al., 2007). A su vez, los resultados de modelos multinivel pueden verse afectados por factores como la presencia de relaciones no lineales, casos atípicos y datos perdidos.

El manejo de estas situaciones es más complejo que en modelos tradicionales de nivel único. Para modelar relaciones no lineales cuando existen datos anidados, una alternativa es implementar modelos generalizados aditivos jerárquicos, los cuales describen la relación entre predictores y desenlaces de interés por medio de funciones suaves con diferentes grados de ondulación (Pedersen et al., 2019). Los casos atípicos pueden estar en diferentes niveles de análisis; para lidiar con ellos, una opción es usar un método de estimación basado en rangos (Finch, 2017). Además, la pérdida de datos en modelos multinivel puede ser remediada a través de métodos de imputación múltiple que toman en cuenta la dependencia de las observaciones (Lüdtke et al., 2017).

Si bien los modelos ilustrados en el presente artículo usaron una variable dependiente cuantitativa y dos niveles de análisis sobre datos transversales, los modelos de regresión multinivel se pueden extender a

MODELAMIENTO MULTINIVEL USANDO R

situaciones donde hay tres o más niveles de análisis, múltiples desenlaces simultáneamente, clasificación cruzada en diferentes unidades de nivel superior, desenlaces categóricos y datos longitudinales (Heck & Thomas, 2020).

Discusión

Los modelos de regresión multinivel son una herramienta versátil que habilita a los investigadores en psicología de la salud y áreas afines para probar relaciones entre variables que podrían existir en diferentes niveles de análisis, evitando los sesgos asociados al uso de técnicas estadísticas convencionales cuando existen datos anidados. De este modo, posibilitan la investigación acerca de la influencia que diversos factores contextuales podrían tener en desenlaces de salud física y comportamientos saludables, informando estrategias de cambio conductual y programas de prevención o manejo de enfermedades altamente prevalentes a nivel mundial.

De igual manera, el modelamiento multinivel puede ser un recurso necesario en la investigación de un variado rango de tópicos importantes dentro de Latinoamérica, como determinantes sociales y conductas de salud, efectos de variables culturales en desenlaces de salud, el rol de características organizacionales en la calidad de vida, entre otros. Además, diversas técnicas analíticas avanzadas empleadas en psicología toman elementos de regresión multinivel, como los modelos de panel cross-lagged con interceptos aleatorios (Mulder & Hamaker, 2021), los modelos de ecuaciones estructurales dinámicos (Asparouhov et al., 2018) y los modelos de clases latentes multinivel (Finch & French, 2014).

Contribución de autores

El autor Jorge Schleef ha contribuido con la concepción y diseño del trabajo, la redacción del manuscrito así como con la probación de su versión final. El autor Manuel S. Ortiz contribuyó con la revisión crítica del manuscrito así como con la aprobación de su versión final.

Conflicto de intereses

Los autores declaran no tener conflicto de interés con los datos, material e información presentada en esta investigación.

Agradecimientos

Este manuscrito fue financiado parcialmente por el Proyecto Fondecyt 1241128, cuyo investigador principal es el Dr. Manuel S. Ortiz.

Referencias

- Aparicio, A., & Morera, M. (2006). La conveniencia del análisis multinivel para la investigación en salud: una aplicación para Costa Rica. *Población y Salud en Mesoamérica*, 4(2). <https://doi.org/10.15517/psm.v4i2.4556>
- Asparouhov, T., Hamaker, E. L., & Muthén, B. (2018). Dynamic Structural Equation Models. *Structural Equation Modeling: A Multidisciplinary Journal*, 25(3), 359-388. <https://doi.org/10.1080/10705511.2017.1406803>

- Bates, D., Maechler, M., Bolker, B., & Walker, S. (2015). Fitting Linear Mixed-Effects Models Using lme4. *Journal of Statistical Software*, 67(1), 1-48. <https://doi.org/10.18637/jss.v067.i01>
- Bell, B., & Schoeneberger, J. (2022). Introduction to Multilevel Models for Organizational Data. En A. O'Connell, D. McCoach, & B. Bell (Eds.), *Multilevel Modeling Methods With Introductory and Advanced Applications* (pp. 13-50). Information Age Publishing.
- Cohen, J., Cohen, P., West, S., & Aiken, L. (2003). *Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences* (3rd ed.). Lawrence Erlbaum Associates.
- Finch, H. (2017). Multilevel modeling in the presence of outliers: A comparison of robust estimation methods. *Psicológica*, 38(1), 57-92.
- Finch, W., Bolin, J., & Kelley, K. (2019). *Multilevel Modeling Using R* (2nd ed.). Taylor & Francis Group.
- Finch, W. H., & French, B. F. (2014). Multilevel Latent Class Analysis: Parametric and Nonparametric Models. *The Journal of Experimental Education*, 82(3), 307-333. <https://doi.org/10.1080/00220973.2013.813361>
- Geiser, C. (2013). *Data Analysis with Mplus*. The Guilford Press.
- Hancock, G., Stapleton, L., & Mueller, R. (2019). *The Reviewer's Guide to Quantitative Methods in the Social Sciences* (2nd ed.). Routledge.
- Heck, R., & Thomas, S. (2020). *An Introduction to Multilevel Modeling Techniques* (4th ed.). Routledge.
- Hoffman, L. (2014). *Longitudinal Analysis Modeling Within-Person Fluctuation and Change* (1st ed.). Routledge.
- Hox, J., Moerbeek, M., & van de Schoot, R. (2018). *Multilevel Analysis Techniques and Applications* (3rd ed.). Routledge.
- Jacqmin-Gadda, H., Sibillot, S., Proust, C., Molina, J.-M., & Thiébaut, R. (2007). Robustness of the linear mixed model to misspecified error distribution. *Computational Statistics & Data Analysis*, 51(10), 5142-5154. <https://doi.org/https://doi.org/10.1016/j.csda.2006.05.021>
- Kajosaari, A., & Laatikainen, T. E. (2020). Adults' leisure-time physical activity and the neighborhood built environment: A contextual perspective. *International Journal of Health Geographics*, 19(1). <https://doi.org/10.1186/s12942-020-00227-z>
- Kim, S. Y., Jang, M., Yoo, S., JeKarl, J., Chung, J. Y., & Cho, S. (2020). School-Based Tobacco Control and Smoking in Adolescents: Evidence from Multilevel Analyses. *International Journal of Environmental Research and Public Health*, 17(10). <https://doi.org/10.3390/ijerph17103422>
- Kumle, L., Võ, M., & Draschkow, D. (2021). Estimating power in (generalized) linear mixed models: An open introduction and tutorial in R. *Behavior Research Methods*, 53, 2528-2543. <https://doi.org/10.3758/s13428-021-01546-0/Published>
- Kuznetsova, A., Brockhoff, P. B., & Christensen, R. H. B. (2017). lmerTest Package: Tests in Linear Mixed Effects Models. *Journal of Statistical Software*, 82(13), 1-26. <https://doi.org/10.18637/jss.v082.i13>
- Lin, Y.-H., Hsu, H.-C., Bai, C.-H., & Wu, W.-C. (2022). Dietary Patterns among Older People and the Associations with Social Environment and Individual Factors in Taiwan: A Multilevel Analysis. *International Journal of Environmental Research and Public Health*, 19(7). <https://doi.org/10.3390/ijerph19073982>
- LoPilato, A. C., & Vandenberg, R. J. (2015). The not-so-direct cross-level direct effect. In C. E. Lance & R. J. Vandenberg (Eds.), *More statistical and methodological myths and urban legends* (pp. 292-310). Routledge/Taylor & Francis Group.

MODELAMIENTO MULTINIVEL USANDO R

- Lüdtke, O., Robitzsch, A., & Grund, S. (2017). Multiple imputation of missing data in multilevel designs: A comparison of different strategies. *Psychological Methods*, 22(1), 141-165. <https://doi.org/10.1037/met0000096>
- Luke, D. (2020). *Multilevel modeling* (2nd ed.). SAGE Publications.
- Maruyama, G. (1998). *Basics of Structural Equation Modeling*. SAGE.
- Mulder, J. D., & Hamaker, E. L. (2021). Three Extensions of the Random Intercept Cross-Lagged Panel Model. *Structural Equation Modeling: A Multidisciplinary Journal*, 28(4), 638-648. <https://doi.org/10.1080/10705112.2020.1784738>
- Murillo, F. (2008). Los modelos multinivel como herramienta para la investigación educativa. *Magis, Revista Internacional de Investigación En Educación*, 1, 45-62.
- Nezlek, J. B. (2008). An Introduction to Multilevel Modeling for Social and Personality Psychology. *Social and Personality Psychology Compass*, 2(2), 842-860. <https://doi.org/10.1111/j.1751-9004.2007.00059.x>
- O'Connell, A., McCoach, D., & Bell, B. (2022). Introduction to Multilevel Modeling Methods: Pedagogy and Context. En A. O'Connell, D. McCoach, & B. Bell (Eds.), *Multilevel Modeling Methods With Introductory and Advanced Applications* (pp. 1-13). Information Age Publishing.
- Oliver, J., Rosel, J., & Jara, P. (2000). Modelos de regresión multinivel: aplicación en psicología escolar. *Psicothema*, 12(3), 487-494.
- Pardo, A., Ruíz, M., & San Martín, R. (2007). Cómo ajustar e interpretar modelos multinivel con SPSS. *Psicothema*, 19(2), 308-321.
- Pedersen, E. J., Miller, D. L., Simpson, G. L., & Ross, N. (2019). Hierarchical generalized additive models in ecology: An introduction with mgcv. *PeerJ*, 7(e6876). <https://doi.org/10.7717/peerj.6876>
- Peugh, J. L. (2010). A practical guide to multilevel modeling. *Journal of School Psychology*, 48(1), 85-112. <https://doi.org/10.1016/j.jsp.2009.09.002>
- Raudenbush, S., & Bryk, A. (2002). *Hierarchical Linear Models: Applications and Data Analysis Methods* (2nd ed.). Sage Publications.
- Rhodes, R. E., & Dickau, L. (2013). Moderators of the intention-behaviour relationship in the physical activity domain: a systematic review. *British Journal of Sports Medicine*, 47(4), 215-225. <https://doi.org/10.1136/bjsports-2011-090411>
- Rights, J., & Sterba, S. (2019). Quantifying Explained Variance in Multilevel Models: An Integrative Framework for Defining R-Squared Measures. *Psychological Methods*, 24(3), 309-338. <https://doi.org/10.1037/met000184.sup>
- Schielzeth, H., Dingemanse, N. J., Nakagawa, S., Westneat, D. F., Allegue, H., Teplitsky, C., Réale, D., Dochtermann, N. A., Garamszegi, L. Z., & Araya-Ajoy, Y. G. (2020). Robustness of linear mixed-effects models to violations of distributional assumptions. *Methods in Ecology and Evolution*, 11(9), 1141-1152. <https://doi.org/10.1111/2041-210X.13434>
- Snijders, T., & Bosker, R. (2012). *Multilevel Analysis: An Introduction to Basic and Advanced Multilevel Modeling* (2nd ed.). SAGE Publications.

Recibido: 04 de junio de 2024

Revisión recibida: 27 de marzo de 2025

Aceptado: 31 de marzo de 2025

J. SCHLEEF Y M. S. ORTIZ

Sobre los autores:

Jorge Schleef Bustamante  es psicólogo, magíster y doctor en Psicología por la Universidad de La Frontera, Temuco, Chile. Sus líneas de intereses abarcan la metodología de la investigación cuantitativa y la psicología de la salud.

Manuel S. Ortiz  es doctor en Psicología de la Salud, forma parte del Departamento de Psicología de la Universidad de La Frontera, Temuco, Chile. Su línea de investigación es sobre los estresores psicológicos y enfermedades crónicas.

Publicado en línea: 30 de diciembre de 2025