

Análisis de covarianza para el control retrospectivo del sesgo en investigación agrícola: aplicación con R

Jorge Claudio Vargas-Rojas

Meilyn González-Calero

Marileny Piña-Duarte

DOI 10.15517/n6pcpy68

¿Cómo citar este artículo?

Vargas Rojas, C., González Calero, M. y Piña Duarte, M. (2025). Análisis de covarianza en investigación agrícola: aplicación con R. *Revista InterSedes* 26(54). 10.15517/n6pcpy68



Análisis de covarianza para el control retrospectivo del sesgo en investigación agrícola: aplicación con R

Analysis of covariance for retrospective bias control in agricultural research: an application using R

Jorge Vargas-Rojas

*Sede Regional de Guanacaste, Universidad de Costa Rica
Liberia, Costa Rica*

jorgeclaudio.vargas@ucr.ac.cr

 <https://orcid.org/0000-0002-1139-2148>

Meilyn González-Calero

*Sede Regional de Guanacaste, Universidad de Costa Rica
Liberia, Costa Rica*

meilyn.gonzalez@ucr.ac.cr

 <https://orcid.org/0009-0000-5469-8289>

Marileny Piña-Duarte

*Sede Regional de Guanacaste, Universidad de Costa Rica
Liberia, Costa Rica*

marileny.pina@ucr.ac.cr

 <https://orcid.org/0009-0006-2694-4597>

Resumen

Este trabajo se desarrolló en el marco del curso Diseño de Experimentos II, de la carrera de Agronomía de la Universidad de Costa Rica, en 2023, con el objetivo de explicar el uso del análisis de covarianza (ANCOVA) como método de análisis de datos con el lenguaje de programación R. Se utilizó una base de datos que describe, bajo un diseño de bloques completos al azar (DBCA), un experimento en el que se midió el número de plantas por unidad experimental para controlar su posible efecto sobre el rendimiento de seis variedades de maíz. Se ajustaron cuatro modelos: el modelo_rl, para evaluar la viabilidad; el modelo_hp, para evaluar la homogeneidad de las pendientes; y dos modelos adicionales, el modelo_scov, sin efecto de la covariable y el modelo_cov, con la covariable. Para la evaluación de estos últimos dos modelos, se utilizaron los criterios de información penalizada (criterio de información de Akaike [AIC],

Abstract

This work was developed within the framework of the Experimental Design II course in the Agronomy program at the University of Costa Rica in 2023, aiming to explain the analysis of covariance (ANCOVA) as a data analysis method using the R programming language. A database describing an experiment under a completely randomized block design (CRBD) was employed, where the number of plants per experimental unit was measured to control its potential effect on the yield of six corn varieties. Four models were fitted: the model_rl to assess viability, the model_hp to assess the homogeneity of slopes, and two additional models, the model_scov without the covariate effect, and the model_cov with the covariate. For the evaluation of these last two models, penalized information criteria [Akaike information criterion (AIC), Bayesian information criterion (BIC)] and hypothesis testing based on the likelihood ratio test

criterio de información Bayesiano [BIC]) y la prueba de hipótesis basada en el cociente de verosimilitud (LRT). El modelo_cov tuvo mejor ajuste que el modelo_scov, pues la inclusión de la covariable disminuyó el error residual, lo que produjo mayor precisión en las estimaciones y permitió una comparación objetiva de las medias. EL ANCOVA es una estrategia para considerar fuentes de variación secundarias difíciles de controlar pero que, por su naturaleza cuantitativa, son medibles.

Palabras clave: *modelos estadísticos, análisis de datos, bioestadística, análisis de varianza, análisis estadístico.*

(LRT) were utilized. The model_cov exhibited a better fit than the model_scov; the inclusion of the covariate reduced residual error, resulting in greater precision in estimates and enabling an unbiased comparison of means. ANCOVA is a strategy to consider secondary sources of variation that are difficult to control but, due to their quantitative nature, are measurable.

Keywords: *statistical models, data analysis, biostatistics, analysis of variance, statistical analysis.*

Fecha de recepción: 23/1/2024 * Fecha de aceptación: 7/1/2026

Introducción¹

En el marco de un experimento agrícola típico, se aplican tratamientos a un conjunto de unidades experimentales con el propósito de evaluar su efecto sobre una o más variables de respuesta (Gómez, 1972; Montgomery, 2020). Sin embargo, la estimación de los efectos de los tratamientos y la diferencia de sus medias es de naturaleza probabilística y están vinculadas no solo a la expresión de un tratamiento en particular, sino también a otros factores ajenos a este, que se denominan, en conjunto, error experimental (Barrientos García, 1981). En términos generales, el error experimental se puede definir como la variabilidad en la variable de respuesta atribuible a factores desconocidos. Si estos factores no se controlan, pueden afectar la validez de la inferencia estadística realizada (Balzarini et al., 2015; Stroup et al., 2018).

Sería deseable que las unidades experimentales fueran completamente homogéneas, de manera que cualquier posible diferencia no nula en la variable respuesta que surgiera después de aplicarles algún tratamiento, pueda ser atribuible exclusivamente a este. No obstante, disponer de un conjunto de unidades experimentales totalmente homogéneas resulta imposible, particularmente cuando se realizan ensayos en un campo agrícola (Stroup, 2002). Por lo tanto, para obtener resultados confiables que reflejen de manera precisa los efectos de los tratamientos, se deben emplear técnicas adecuadas de diseño y análisis de experimentos que permitan reducir el error experimental (Vargas Rojas y Navarro Flores, 2019). Para lograr dicho cometido, es fundamental identificar las posibles fuentes de variación, que se pueden clasificar en tres escenarios (Gavilán Luna, 2021; Navarro Flores y Vargas Rojas, 2015)

El primer escenario se presenta cuando existen fuentes de variación de naturaleza desconocida y no controlable en el experimento. En este caso, se debe optar por una aleatorización irrestricta para distribuir las fuentes de variación en todas las unidades experimentales, debido a que no se identifican las fuentes secundarias (Barraza et al., 2019).

El segundo escenario surge cuando las fuentes de variación son conocidas y controlables. En esta situación, es necesario aplicar el principio de bloqueo para controlar las fuentes de variación no deseadas. Esto se logra mediante un esquema de aleatorización restringida, con el objetivo de mejorar la precisión en las comparaciones entre tratamientos (Montgomery, 2020). El principio básico del bloqueo en este esquema es empleado en experimentos de campo para mitigar los efectos adversos de la heterogeneidad del suelo (van Es et al., 2007). La efectividad depende de la identificación de la fuente de variación antes de llevar a cabo el ensayo, ya que, sin esta identificación, no es posible intervenir.

¹ Este proyecto formó parte del curso Diseño de Experimentos II (AF-0213) de la carrera de Agronomía de la Sede Regional de Guanacaste de la Universidad de Costa Rica.

El tercer escenario se presenta cuando existen fuentes de variación conocidas, no controlables, pero que se pueden cuantificar. En algunos casos, estas fuentes de variación pueden identificarse antes de iniciar el experimento; por ejemplo, el número de plantas que hay en cada unidad experimental, una cosecha anterior del mismo ensayo, la cantidad de arvenses presentes en cada unidad experimental al inicio del ensayo, entre otros. Asimismo, la fuente de variación puede definirse después de iniciar el experimento, ejemplos de esta naturaleza podrían ser ataques de plagas o enfermedades localizados en algunas de las unidades experimentales (Gomez y Gomez, 1984).

Las fuentes de variación descritas en el tercer escenario no son sistemáticas, así que no se pueden aislar mediante técnicas de bloqueo. No obstante, es posible incluir estas fuentes de variación en el modelo estadístico como una covariable, cuantificada en cada una de las unidades experimentales. Este enfoque corresponde a un análisis de covarianza (ANCOVA): una técnica que combina el análisis de varianza (ANDEVA) y el análisis de regresión. Su objetivo principal es ajustar las medias de la variable de interés, al incluir la variabilidad causada por una covariable, lo que permite realizar una comparación de los tratamientos a través del análisis de varianza sin el sesgo ocasionado por la covariable (Montgomery, 2020; Stroup et al., 2018).

Para llevar a cabo un ANCOVA es indispensable que la covariable cumpla con los supuestos de viabilidad y pertinencia. Por un lado, la viabilidad se refiere a la existencia de una relación funcional entre la variable respuesta y la covariable para cada tratamiento (Correa Londoño, 2013; Pérez-Rodríguez et al., 2014). Generalmente, por razones de simplicidad, se espera que la relación funcional sea la de una regresión lineal simple. Sin embargo, otros modelos de regresión más complejos se pueden utilizar (Littell et al., 2006). Por otro lado, la pertinencia se refiere a que la covariable y el efecto de los tratamientos deben ser independientes entre sí (Peter, 2020). La forma más sólida de garantizar esta independencia es utilizar covariables cuya manifestación ocurra antes de aplicar los tratamientos. Cuando la covariable se identifica después de aplicarlos, se debe evaluar con precaución si es pertinente, ya que si resulta no serlo, la regresión podría eliminar parte del efecto de los tratamientos (Correa Londoño, 2013).

Además del cumplimiento de la pertinencia y la viabilidad, es deseable que las pendientes de las regresiones entre la variable respuesta de cada tratamiento y la covariable sean homogéneas; es decir, que tengan la misma pendiente. Esta condición asegura que las comparaciones entre las medias ajustadas de los tratamientos puedan realizarse en cualquier valor de la covariable sin afectar la magnitud de las diferencias (Littell et al., 2006). Para determinar si las pendientes de regresión de los tratamientos no difieren de forma estadística, es necesario evaluar la interacción entre la covariable y los tratamientos (Shieh, 2017).

En la investigación agrícola, el ANCOVA es una alternativa útil para controlar fuentes de variación que no se pueden manejar efectivamente con el diseño del experimento. Esto es especialmente relevante

ante sucesos inesperados en los ensayos, ya que esta área está expuesta a diversos factores externos no controlables que pueden afectar la homogeneidad de las unidades experimentales. A pesar de su potencial, este es un método estadístico que rara vez se explora en profundidad en este tipo de investigación, y los materiales disponibles brindan poca cobertura sobre su uso en esta área (Yang y Juskiw, 2011). En este contexto, el objetivo de este trabajo fue explicar el uso del ANCOVA como método de análisis de datos provenientes de investigación agrícola con el lenguaje de programación R (RCore Team, 2023).

Materiales y métodos

Este trabajo se desarrolló en el marco del curso Diseño de Experimentos II de la carrera de Agronomía en la Sede Regional de Guanacaste de la Universidad de Costa Rica, durante el año 2023. Para explicar y discutir el uso del ANCOVA, se utilizó la Tabla 18.4.2 del libro de Snedecor y Cochran (1998, p. 383). Dicha base de datos describe un experimento bajo un diseño de bloques completos al azar (DBCA), cuyo objetivo fue comparar el rendimiento de seis variedades de maíz, expresado originalmente en libras por unidad experimental; para efectos de este trabajo, los rendimientos se transformaron a kilogramos de mazorca por unidad experimental. Los datos se almacenaron en un *data frame* con el nombre “datos” y se encuentran disponibles en el Apéndice A.

Las seis variedades de maíz evaluadas constituyeron los tratamientos del experimento. No obstante, las unidades experimentales, debido a defectos en la sembradora, presentaron un número variable de plantas (NP). Ante esta situación, el investigador decidió estimar el número de plantas por unidad experimental y utilizar esta variable como covariable en el análisis.

Todos los procedimientos se realizaron con el programa estadístico R, versión 4.2.2 (R Core Team, 2023). El ajuste de los modelos se efectuó mediante el paquete nlme, versión 3.1-160 (Pinheiro et al., 2023). Se proporciona el código utilizado (Apéndice B) con el fin de que el análisis pueda ser reproducido por cualquier lector de este trabajo.

Evaluación de viabilidad: para evaluar si el modelo de regresión lineal simple describe adecuadamente la relación funcional entre la covariable y cada variedad, se ajustó un modelo denominado modelo_rl, el cual se especifica en la Ecuación 1.

ECUACIÓN 1

$$y_{ij} = \alpha_i + (\alpha_i \times \beta_i x_{ij}) + b_j + e_{ij}$$

Donde y_{ij} es el j -ésimo rendimiento del i -ésimo tratamiento; α_i es el i -ésimo efecto del factor tratamiento; β_i es la pendiente del i -ésimo tratamiento; x_{ij} es la medición hecha de la covariable correspondiente a y_{ij} ; y b_j es el efecto aleatorio del j -ésimo bloque.

Así, el modelo de la Ecuación 1 incluyó como efectos fijos el término de variedad y el término covariable $\times$ variedad, sin incluir el término principal de la covariable, lo que permitió estimar la pendiente de cada tratamiento y evaluar si un modelo de regresión lineal simple describe la relación entre los datos de cada uno de estos y la covariable. El bloque se incluyó como efecto aleatorio. Para esta prueba se utilizó un nivel de significancia del 5 %. El código utilizado se presenta a continuación:

```
modelo_rl<-lme(Rendimiento~Variedad+Variedad:NP,  
              random=list(Bloque=pdIdent(~1)),  
              method="REML",  
              data=datos)  
  
anova(modelo_rl, type = "marginal")
```

La función `anova`, con el argumento `type = "marginal"`, aplicada sobre el objeto que almacenó los resultados del modelo, evaluó mediante el estadístico F tipo III la significancia de los efectos fijos del modelo. En el caso del efecto fijo correspondiente a la pendiente de cada tratamiento (`Variedad:NP`), que constituye el término de interés, se contrastó la hipótesis nula de que todas las pendientes son iguales a cero frente a la hipótesis alternativa de que al menos una es distinta de cero.

Evaluación de pertinencia: dado que la covariable no se midió antes de la aplicación de los tratamientos, fue necesario recurrir a una discusión conceptual para respaldar esta suposición y, de esta manera, asegurar la independencia entre los tratamientos y la covariable. En este contexto, se asumió que todas las variedades utilizadas en el experimento no presentaban la capacidad de macollamiento, es decir, producían solo un tallo y una mazorca. Por lo tanto, la falta de uniformidad en el número de tallos por unidad experimental se atribuyó a un posible defecto en el proceso de siembra y, en consecuencia, se consideró que el uso de la covariable era pertinente.

Evaluación de la homogeneidad de pendientes: para esta etapa, primero se realizó un gráfico de dispersión con la relación entre la variable respuesta y la covariable para cada tratamiento, en el que, de manera empírica, se visualizó si las líneas formadas son —aproximadamente— paralelas. Se usó el paquete `ggplot2` versión 3.4.0 (Wickham, 2016), el código utilizado fue el siguiente:

```
ggplot(datos, aes(x = NP, y = Rendimiento, color = Variedad)) +  
  geom_point() +  
  geom_smooth(method = "lm", se = FALSE)+  
  labs(title = "",  
        x = "Número de tallos",  
        y = expression("Producción"~(lb~UE^-1))) +  
  scale_y_continuous(limits = c(0, 270),  
                     breaks = seq(0, 270, by = 30)) +  
  theme_bw()
```

Además, se ajustó un modelo (modelo_hp) donde se incluyeron el término de tratamiento, la covariable y la interacción entre covariable $\times$ tratamiento como efectos fijos, y el bloque fue incluido como efecto aleatorio.

ECUACIÓN 2

$$y_{ij} = \alpha_4 + (\alpha_i - \alpha_4) + \beta_4 x_{ij} + (\beta_i - \beta_4) + b_j + e_{ij}$$

Donde y_{ij} es el j -ésimo rendimiento del i -ésimo tratamiento; α_i es el i -ésimo efecto del factor tratamiento; β_i es la pendiente del i -ésimo tratamiento; x_{ij} es la medición hecha de la covariable correspondiente a y_{ij} ; b_j es el efecto aleatorio del j -ésimo bloque, que se supone que tiene distribución normal con media cero y varianza (σ_b^2) constante entre bloques; e_{ij} : es el error aleatorio de cada observación ij , se supone que tiene distribución normal e independiente con esperanza 0 y varianza $\sigma^2 \forall i, j \neq i', j'$. Además, se supone que b_j y e_{ij} son variables aleatorias independientes.

En el modelo de la Ecuación 2, las pendientes son reexpresadas como $\beta_i = \beta_4 + (\beta_i - \beta_4)$. De esta manera, el término covariable $\times$ tratamiento (interacción) evaluó la hipótesis de igualdad de pendientes (más detalles se pueden encontrar en [Littell et al. \[2006\]](#)). Para esta prueba se usó un nivel de significancia de 5%. A continuación, se presenta el código para ajustar el modelo_hp:

```
modelo_hp <- lme(Rendimiento ~ 1 + Variedad + NP + Variedad:NP,  
  random = list(Bloque = pdIdent(~1)),  
  method = "REML",  
  data = datos)  
  
anova(modelo_hp, type = "marginal")
```

Al igual que en el código correspondiente al modelo especificado en la Ecuación 2, la función `anova`, con el argumento `type = "marginal"`, evaluó (F tipo III) la significancia de los efectos fijos del modelo. En este caso, el término de interés fue el correspondiente a la interacción (Variedad:NP), que contrastó la hipótesis nula de que todas las pendientes son iguales a cero frente a la hipótesis alternativa de que al menos una es distinta de cero.

Ajuste de modelo y comparación: el modelo del ANCOVA que se utilizó se presenta en la Ecuación 3.

ECUACIÓN 3

$$y_{ij} = \alpha_i + \beta x_{ij} + b_j + e_{ij}$$

Donde y_{ij} es el j -ésimo rendimiento del i -ésimo tratamiento; α_i es el i -ésimo efecto del factor tratamiento; β es la pendiente común para todos los tratamientos; x_{ij} es la medición hecha de la covariable correspondiente a y_{ij} ; b_j es el efecto aleatorio del j -ésimo bloque, que se supone que tiene distribución normal con media cero y varianza (σ_b^2) constante entre bloques; e_{ij} : es el error aleatorio de cada observación ij , se supone que tiene distribución normal e independiente con esperanza 0 y varianza $\sigma^2 \forall i, j \neq i', j'$. Además, se supone que b_j y e_{ij} son variables aleatorias independientes.

Se ajustó el modelo de covarianza para los datos del experimento descrito; de acá en adelante, se utilizó el `modelo_cov`:

```
modelo_cov <- lme(Rendimiento~1+Variedad+NP,
  random=list(Bloque=pdIdent(~1)),
  method="ML",
  data=datos)

anova(modelo_cov, type = "marginal")
```

También se ajustó otro modelo sin la covariable, llamado `modelo_scov`, que se especifica en la Ecuación 4.

ECUACIÓN 4

$$y_{ij} = \alpha_i + b_j + e_{ij}$$

Donde y_{ij} es el j -ésimo rendimiento del i -ésimo tratamiento; α_i es el i -ésimo efecto del factor tratamiento; b_j es el efecto aleatorio del j -ésimo bloque, que se supone que tiene distribución normal con media cero y varianza (σ_b^2) constante entre bloques; e_{ij} : es el error aleatorio de cada observación ij , se

supone que tiene distribución normal e independiente con esperanza 0 y varianza $\sigma^2 \forall i, j \neq i', j'$. Además, se supone que b_j y e_{ij} son variables aleatorias independientes.

El modelo de la Ecuación 4 correspondió a uno de análisis de varianza para un diseño de bloques completos al azar. El código utilizado se presenta a continuación:

```
modelo_scov <- lme(Rendimiento~1+Variedad,  
  random=list(Bloque=pdIdent(~1)),  
  method="ML",  
  data=datos)  
  
anova(modelo_scov, type = "marginal")
```

Tanto en la Ecuación 3 como en la Ecuación 4 la función anova se usó para contrastar las hipótesis correspondientes a los efectos fijos. Además, ambas se compararon para visualizar el efecto de incluir la covariable dentro del modelo.

Dado que modelo_cov y modelo_scov varían únicamente en el efecto fijo de la covariable, en primera instancia, ambos se ajustaron con el método de máxima verosimilitud (ML, por sus siglas en inglés) y la comparación se llevó a cabo mediante el criterio de información penalizada de Akaike (AIC) y el criterio de información penalizada de Schwarz (BIC). Ambos criterios se basan en el logaritmo de la función de verosimilitud con una penalización según el número de parámetros estimados en el modelo de estructura de covarianza. En los dos criterios, valores menores indican un mejor ajuste del modelo (Gómez et al., 2019; West et al., 2014). El análisis se implementó mediante el siguiente código en R:

```
AIC(modelo_cov, modelo_scov)  
BIC(modelo_cov, modelo_scov)
```

Asimismo, como el modelo sin covariable (modelo_scov) se puede considerar como un caso en específico (modelo reducido) de un más completo (modelo_cov), se realizó una prueba cociente de verosimilitud (LRT, por sus siglas en inglés). En esta prueba la hipótesis nula indica que el modelo reducido es el de mejor ajuste, mientras que la hipótesis alternativa indica que el modelo completo es el que mejor ajusta a los datos (Oddi et al., 2020). Seguidamente, se detalla el código empleado:

```
anova(modelo_cov, modelo_scov)
```

Por último, para efectos prácticos, ambos modelos se ajustaron con máxima verosimilitud restringida (REML, por sus siglas en inglés), se estimaron las medias ajustadas para un valor promedio de la covariable y se realizó la prueba de comparaciones múltiples de Tukey (se programó en R), con la finalidad de visualizar los cambios en el error estándar de las medias y en las comparaciones entre los modelos. Se usó un nivel de significancia del 5%.

Resultados

Viabilidad


El valor p del término Variedad:NP para el modelo modelo_rl fue de 0,0008 ($F = 11,91$), lo que indicó que las pendientes de cada tratamiento no son cero. En consecuencia, es plausible usar un modelo de regresión lineal para explicar la relación funcional entre la covariable y la variable respuesta en cada uno de los tratamientos.

Homogeneidad de pendientes

En términos generales, se puede observar que existe una relación lineal directa entre la covariable y la variable respuesta (Figura 1). Es decir, a medida que aumentó el número de tallos por unidad experimental, también aumentó la producción. Además, a partir de la Figura 1, se puede apreciar que las rectas de regresión de cada una de las variedades tienen pendientes similares. Aunque no son rectas completamente paralelas, no se observan indicios que sugieran la necesidad de considerar un modelo con pendientes distintas. El valor p del término de la interacción covariable $\times$ tratamiento del modelo_hp fue de 0,63 ($F = 0,71$). Este resultado indicó que el modelo de rectas homogéneas es adecuado.

FIGURA I

Gráfico de dispersión entre número de tallos (covariable) y producción (variable respuesta) para cada variedad



Comparación de modelos

En el Cuadro 1, se presentan el AIC, el BIC, la prueba de cociente de verosimilitud y su respectivo valor p de ambos modelos.

CUADRO I

Criterio de información de Akaike (AIC), criterio bayesiano (BIC) y prueba de cociente de verosimilitud (LRT) para los modelos ajustados

Modelo		AIC	BIC	LRT	Valor p
modelo_cov	1	188,90	198,33		
modelo_scov	2	156,66	167,27	34,24	<0,0001

El modelo que incluye la covariable (modelo_cov) fue el que presentó mejor AIC y BIC, lo que indica que fue el modelo de mejor ajuste. Asimismo, el p valor para la prueba de cociente de verosimilitud fue menor a 0,05

Ajuste de medias y comparaciones múltiples

Las medias ajustadas para un valor promedio de la covariable, el error estándar y la clasificación de las medias según la prueba de Tukey para cada uno de los tratamientos se presentan en el Cuadro 2. De este, se desprenden tres aspectos importantes: el primero es que el error estándar de las medias es menor en el modelo que incluye la covariable; el segundo es que las medias ajustadas no son las mismas para los modelos; y el tercero, que se deriva de los dos anteriores, es que la separación de medias es distinta para cada modelo.

CUADRO 2

Medias ajustadas, errores estándar y clasificación de la separación de medias para cada tratamiento

Variedad	modelo_cov			modelo_scov		
	Medias	Error estándar	Clasificación	Medias	Error estándar	Clasificación
D	99,69	2,60	a	105,60	4,44	a
F	96,96	2,53	a	97,55	4,44	ab
C	87,63	2,53	b	88,23	4,44	bc
A	86,80	2,66	b	78,53	4,44	c
B	86,54	2,56	b	82,70	4,44	c
E	86,17	2,58	b	91,20	4,44	bc

Discusión

En primera instancia, es relevante recalcar que, además de los supuestos del ANCOVA mencionados en este trabajo, el modelo también debe cumplir con los supuestos de todo modelo lineal: independencia

de errores, normalidad de errores y homogeneidad de las varianzas de los errores, por lo que estos deben ser evaluados con las técnicas correspondientes (Kahan et al., 2016; Huitema, 2020).

En cuanto a la pertinencia, cuando la covariable no se cuantifica antes de aplicar los tratamientos, como en el ejemplo que se presentó en este trabajo, se debe valorar si su expresión es o no influenciada por el efecto de los tratamientos (variedades de maíz, en este caso). Por ejemplo, si se realiza un experimento para evaluar materiales de maíz con capacidad de macollamiento, una de las variables de interés podría ser, precisamente, la capacidad de macollamiento, expresada como el número de tallos por unidad de área. En este contexto, sería inapropiado incluir el número de tallos como covariable, ya que esto eliminaría parte del efecto relacionado con la capacidad de macollamiento de las diferentes variedades de maíz para la comparación de las medias entre variedades (Egbewale et al., 2014; Shieh, 2017).

El objetivo del ANCOVA es comparar las medias de cada tratamiento para un valor específico de la covariable. En este caso, se utilizó un valor promedio de la covariable debido a su mayor eficiencia en la comparación. Al cumplirse el supuesto de homogeneidad de pendientes (las rectas de regresión entre la covariable y la variable de respuesta de todos los tratamientos son paralelas), es posible realizar la comparación para cualquier otro valor de la covariable sin afectar las conclusiones (Shieh, 2017; Huitema, 2020). Por el contrario, si la homogeneidad de las pendientes de regresión no se cumple, puede que el efecto de la covariable sobre la variable respuesta varíe entre los diferentes grupos de tratamientos (Johnson, 2016; Pérez-Rodríguez et al., 2014). En este caso, sería necesario llevar a cabo comparaciones de las medias ajustadas de los tratamientos en al menos tres valores de la covariable, como por ejemplo los percentiles 5, 50 y 95 (Littell et al., 2006).

El potencial del ANCOVA radica en su capacidad para modelar la variabilidad no explicada por los tratamientos y que no puede ser aislada mediante el diseño del experimento. Esto se logra al incorporar observaciones numéricas adicionales que explican parte de la variación presente. En este trabajo fue el número de tallos por unidad experimental, pero también otros factores como área foliar afectada, la incidencia de una enfermedad o las condiciones climáticas pueden introducir variabilidad adicional e incluirse como covariables en el análisis, para reducir la influencia de estas fuentes de error y lograr una comparación más precisa entre los tratamientos de interés (Correa Londoño, 2013; Johnson, 2016).

La eficacia de ANCOVA como método de control del error experimental en comparación con el ANDEVA se puede observar en la disminución del error estándar de las medias del modelo ajustado con la covariable en comparación con el modelo ajustado sin la covariable (Cuadro 1). Asimismo, se pueden observar los cambios en los valores de las medias al ajustar con la covariable, y las variaciones en la comparación múltiple de medias; lo que conduce a mayor precisión en las conclusiones sobre los tratamientos y a

la reducción del sesgo en las comparaciones. En caso de no contar con estos datos, esa variación se incluiría en el error experimental, lo que lleva a estimaciones menos precisas (Montgomery, 2020).

En este trabajo, se tuvieron dos opciones para comparar las medias de los tratamientos: una fue realizar la comparación de las medias ajustadas en el valor promedio de la covariable, la otra fue contrastar cada media sin tener en cuenta la covariable. En este proceso, la diferencia mínima significativa de Fisher no separa el tratamiento F de los tratamientos E y C, ya que estos dos tratamientos no necesariamente tenían un mayor rendimiento, sino que el azar hizo que la sembradora depositara mayor cantidad de semilla. En este sentido, el ANCOVA realiza una comparación insesgada en la que evalúa todos los tratamientos para un nivel común de la covariable. Asimismo, la comparación que realiza la hace más precisa, ya que existe una disminución del cuadrado medio del error (Huitema, 2020).

Según Yang y Juskiw (2011), la técnica de ANCOVA presenta una alta aplicabilidad en la investigación agrícola. No solo destaca como un método eficaz para controlar fuentes de variación impredecibles mediante diseños experimentales de bloqueo convencionales, sino que, debido al mejor ajuste de los datos y mayor precisión que puede brindar, también es pertinente que los investigadores agrícolas la conozcan para que puedan considerarla cuando se les presenten situaciones como las explicadas en este trabajo. También se debe tener presente que el uso de técnicas de bloqueo y ANCOVA no son mutuamente excluyentes: se pueden usar en conjunto para mejor control del error experimental (Huitema, 2020; Peter, 2020).

Conclusiones

La inclusión de la covariable en el modelo permitió una comparación de medias insesgada, además de disminuir el error estándar de las medias.

La inclusión de covariables en la modelación es una estrategia útil y versátil para considerar fuentes de variación secundarias que son difíciles de controlar pero que, por su naturaleza cuantitativa, también son fáciles de medir.

Referencias bibliográficas

- Balzarini, M., Di Rienzo, J., Tablada, M., Gonzalez, L., Bruno, C., Córdoba, M., Robledo, W. y Casanoves, F. (2015). *Estadística y biometría: ilustraciones del uso de InfoStat en problemas de agronomía* (2ª ed.). Editorial Brujas.
- Barraza, F., Arancibia, M., Madrid, E. y Papuzinski, C. (2019). General concepts in biostatistics and clinical epidemiology: random error and systematic error. *Medwave*, 19(7), Article e7687. [ht-](#)

[tps://doi.org/10.5867/medwave.2019.07.7687](https://doi.org/10.5867/medwave.2019.07.7687)

- Barrientos García, M. (1981). *Evaluación de 4 métodos para la determinación de tamaño y forma óptimos de parcela para experimentación agrícola* [Tesis de licenciatura, Universidad de San Carlos de Guatemala]. Repositorio Centroamericano SIIDCA-CSUCA. <https://catalogosiidca.csuca.org/Record/USAC.91383>
- Correa Londoño, G. (2013). El análisis de covarianza como mecanismo de control de factores de confusión. *Revista Facultad Nacional de Agronomía-Medellín*, 66(1), 6981-6985. <https://revistas.unal.edu.co/index.php/refame/article/view/39539>
- Egbewale, B. E., Lewis, M. y Sim, J. (2014). Bias, precision and statistical power of analysis of covariance in the analysis of randomized trials with baseline imbalance: a simulation study. *BMC Medical Research Methodology*, 14(49). <https://doi.org/10.1186/1471-2288-14-49>
- Gavilánez Luna, F. (2021). *Diseños y análisis estadísticos para experimentos agrícolas*. Ediciones Diaz de Santos S.A.
- Gomez, K. y Gomez, A. (1984). *Statistical Procedures for Agricultural Research* (2ª ed.). Wiley.
- Gómez, K. A. (1972). *Techniques for field experiments with rice*. Rice Research Institute.
- Gómez, S., Torres, V., García, Y., Herrera, M., Medina, Y. y Rodríguez, R. (2019). Procedimiento estadístico para el análisis de experimentos con medidas repetidas en el tiempo en la esfera agropecuaria. *Cuban Journal of Agricultural Science*, 53(4), 353-360. http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2079-34802019000400353&lng=es&ctlng=es.
- Huitema, B. E. (2020). *Analysis of covariance (ANCOVA)*. Oxford Bibliographies <https://doi.org/10.1093/obo/9780199828340-0256>
- Johnson, T. R. (2016). Violation of the homogeneity of regression slopes assumption in ANCOVA for two-group pre-post designs: tutorial on a modified Johnson-Neyman procedure. *The Quantitative Methods for Psychology*, 12(3), 253-263. <https://doi.org/10.20982/tqmp.12.3.p253>
- Kahan, B. C., Rushton, H., Morris, T. P. y Daniel, R. M. (2016). A comparison of methods to adjust for continuous covariates in the analysis of randomized trials. *BMC Medical Research Methodology*, 16(42). <https://doi.org/10.1186/s12874-016-0141-3>
- Littell, R., Milliken, G., Stroup, W., Wolfinger, R. y Schabenberger, O. (2006). *SAS for Mixed Models* (2ªed.). SAS Institute Inc.
- Montgomery, D. C. (2020). *Design and analysis of experiments* (10ª ed.). John Wiley & Sons.

- Navarro Flores, J. R. y Vargas Rojas, J. C. (2015). Eficiencia relativa del diseño de bloques completos al azar para ensayos de arroz en Bagaces, Guanacaste, Costa Rica. *InterSedes*, 16(32), 61-70. https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S2215-24582015000200061
- Pérez-Rodríguez, M., Palacios-Cruz, L., Moreno, J., Rivas-Ruiz, R. y Talavera, J. O. (2014). Investigación clínica XIX del juicio clínico al análisis de covarianza. *Revista Médica del Instituto Mexicano del Seguro Social*, 52(1), 70-75. <https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=47612>
- Peter, C. (2020). *Analysis of Covariance*. The International Encyclopedia of Communication Research Methods. <https://doi.org/10.1002/9781118901731.iecrm0005>
- Pinheiro, J., Bates, D., DebRoy, S., Sarkar, D. y R Core Team. (2023). *nlme: Linear and Nonlinear Mixed Effects Models*. <https://CRAN.R-project.org/package=nlme>
- RCore Team. (2023). R: A language and environment for statistical computing. R Foundation for Statistical Computing. <http://www.r-project.org>.
- Shieh, G. (2017). On tests of treatment-covariate interactions: An illustration of appropriate power and sample size calculations. *PLOS ONE*, 12(5), Article e0177682. <https://doi.org/10.1371/journal.pone.0177682>
- Snedecor, G. y Cochran, W. (1998). *Statistical methods* (8ª ed.). Iowa State University Press.
- Stroup, W. W. (2002). Power analysis based on spatial effects mixed models: A tool for comparing design and analysis strategies in the presence of spatial variability. *Journal of Agricultural, Biological, and Environmental Statistics*, 7(4), 491-511. <https://doi.org/10.1198/108571102780>
- Stroup, W. W., Milliken, G. A., Claassen, E. A. y Wolfinger, R. D. (2018). *SAS for mixed models: introduction and basic applications*. SAS Institute Inc.
- van Es, H. M., Gomes, C., Sellmann, M. y van Es, C. L. (2007). Spatially-Balanced Complete Block designs for field experiments. *Geoderma*, 140(4), 346-352. [www.doi.org/10.1016/j.geoderma.2007.04.017](https://doi.org/10.1016/j.geoderma.2007.04.017)
- Vargas Rojas, J. C. y Navarro Flores, J. R. (2019). Tamaño y forma de unidad experimental para ensayos de rendimiento de arroz (*Oryza sativa*), en Guanacaste, Costa Rica. *UNED Research Journal*, 11(3), 355-360. <https://doi.org/10.22458/urj.v11i3.2653>
- West, B. T., Welch, K. B. y Galecki, A. T. (2014). *Linear mixed models. A Practical Guide Using Statistical Software* (2ª ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/b17198>

- Wickham, H. (2016). *Ggplot2: Elegant graphics for data analysis* (2ª ed.). Springer International Publishing.
- Yang, R.C. y Juskiw, P. (2011). Analysis of covariance in agronomy and crop research. *Canadian Journal of Plant Science*, 91, 621-641. <https://doi.org/10.4141/cjps2010-032>

APÉNDICE A

Datos utilizados en el análisis de covarianza

Variedad	Bloque	Rendimiento	Rend	NP
A	1	202,0	91,7	28,0
A	2	165,0	74,9	22,0
A	3	191,0	86,7	27,0
A	4	134,0	60,8	19,0
B	1	145,0	65,8	23,0
B	2	201,0	91,2	26,0
B	3	203,0	92,1	28,0
B	4	180,0	81,7	24,0
C	1	188,0	85,3	27,0
C	2	185,0	83,9	24,0
C	3	185,0	83,9	27,0
C	4	220,0	99,8	28,0
D	1	201,0	91,2	24,0
D	2	231,0	104,8	28,0
D	3	238,0	108,0	30,0
D	4	261,0	118,4	30,0
E	1	202,0	91,7	30,0
E	2	178,0	80,8	26,0
E	3	198,0	89,8	26,0
E	4	226,0	102,5	29,0
F	1	228,0	103,4	30,0
F	2	221,0	100,3	25,0
F	3	207,0	93,9	27,0
F	4	204,0	92,6	24,0

Nota.

1. Rendimiento: en libras por unidad experimental.

2. Rend: en kilos por unidad experimental.