



*Metodologías del Diseño Experimental en Procesos Industriales: Un análisis teórico*

*Experimental Design Methodologies in Industrial Processes: A theoretical analysis*

*Metodologias de Proyecto Experimental em Processos Industriais: Uma análise teórica*

Juan Diego Erazo-Rodríguez<sup>I</sup>

[juan.erazo@esPOCH.edu.ec](mailto:juan.erazo@esPOCH.edu.ec)

<https://orcid.org/0000-0003-0152-5645>

Raúl Gregorio Martínez-Pérez<sup>II</sup>

[raul.martinez@esPOCH.edu.ec](mailto:raul.martinez@esPOCH.edu.ec)

<https://orcid.org/0000-0002-1552-7580>

Eugenia Mercedes Naranjo-Vargas<sup>III</sup>

[eugenia.naranjo@esPOCH.edu.ec](mailto:eugenia.naranjo@esPOCH.edu.ec)

<https://orcid.org/0000-0002-9658-6311>

Javier Edmundo Albuja-Jácome<sup>IV</sup>

[javier.albuja@esPOCH.edu.ec](mailto:javier.albuja@esPOCH.edu.ec)

<https://orcid.org/0009-0005-5044-3373>

**Correspondencia:** [juan.erazo@esPOCH.edu.ec](mailto:juan.erazo@esPOCH.edu.ec)

Ciencias Técnicas y Aplicadas  
Artículo de Investigación

\* **Recibido:** 09 de mayo de 2024 \* **Aceptado:** 16 de junio de 2024 \* **Publicado:** 26 de julio de 2024

- I. Magíster en Ingeniería Industrial con Mención en Calidad y Productividad, Máster Universitario en Dirección Logística. Escuela Superior Politécnica de Chimborazo, Facultad Mecánica, Carrera Ingeniería Industrial, Grupo de investigación GIDENM, Ecuador.
- II. Magíster en Dirección de Operaciones y Seguridad Industrial, Escuela Superior Politécnica de Chimborazo, Facultad Mecánica, Carrera Ingeniería Industrial, Grupo de investigación AUTOPRO, Ecuador.
- III. Magíster en Diseño Mecánica, Escuela Superior Politécnica de Chimborazo, Facultad Mecánica, Carrera Ingeniería Industrial, Grupo de investigación GIDENM, Ecuador.
- IV. Magíster en Diseño Mecánico, Escuela Superior Politécnica de Chimborazo, Facultad Mecánica, Carrera Ingeniería Industrial, Grupo de investigación GIMAN, Ecuador.

## Resumen

La investigación resalta la importancia del diseño experimental en la industria para comparar tratamientos, estudiar factores y optimizar operaciones, mejorando la calidad y la toma de decisiones. Bajo un enfoque experimental el cual sigue principios como la aleatorización, repetición y bloqueo. El diseño completamente aleatorizado (DCA) asigna tratamientos aleatoriamente a unidades homogéneas, siendo básico, pero menos efectivo en entornos heterogéneos, mediante el análisis de la varianza (ANOVA), se puede analizar la variabilidad en un proceso e identifica los tratamientos que producen un efecto significativo en la variable respuesta; métodos como Fisher LSD y Tukey se aplican para comparaciones post-ANOVA. Herramientas avanzadas de DOE (Design of Experiments), como diseño de bloques completamente al azar, diseños de cuadro latino y grecolatino son sus respectivos modelos estadísticos y ANOVAS. Adicionalmente, presenta el análisis de los diseños factoriales, desde conceptos básicos hasta representaciones de modelos estadísticos, análisis de varianza, y comparaciones entre factores ya sean fijos o aleatorios, como sus modelos. En esta investigación destaca la relevancia del diseño experimental para la mejora continua en la industria, ofreciendo un marco sólido para la toma de decisiones y la optimización de procesos.

**Palabras clave:** Diseño de experimentos, ANOVA, hipótesis, modelo estadístico, diseño factorial.

## Abstract

The research highlights the importance of experimental design in the industry to compare treatments, study factors and optimize operations, improving quality and decision making. Under an experimental approach which follows principles such as randomization, repetition and blocking. The completely randomized design (DCA) randomly assigns treatments to homogeneous units, being basic, but less effective in heterogeneous environments, through analysis of variance (ANOVA), the variability in a process can be analyzed and the treatments that produce a significant effect on the response variable can be identified; methods such as Fisher LSD and Tukey are applied for post-ANOVA comparisons. Advanced DOE (Design of Experiments) tools, such as completely randomized block design, Latin and Greco-Latin square designs are their respective statistical models and ANOVAS. Additionally, it presents the analysis of factorial designs, from basic concepts to representations of statistical models, analysis of variance, and comparisons between factors whether fixed or random, as their models. This research highlights the relevance

of experimental design for continuous improvement in the industry, offering a solid framework for decision making and process optimization.

**Keywords:** Experimental design, ANOVA, hypothesis, statistical model, factorial design.

## Resumo

A investigação destaca a importância do desenho experimental na indústria para comparar tratamentos, estudar fatores e otimizar operações, melhorando a qualidade e a tomada de decisões. Sob uma abordagem experimental que segue princípios como a randomização, repetição e bloqueio. O delineamento inteiramente casualizado (DCA) atribui os tratamentos aleatoriamente a unidades homogêneas, sendo básico, mas menos eficaz em ambientes heterogêneos, através da análise de variância (ANOVA), a variabilidade num processo pode ser analisada e identifica os tratamentos que produzem um efeito significativo em a variável resposta; Métodos como o Fisher LSD e Tukey são aplicados para comparações pós-ANOVA. As ferramentas avançadas de DOE (Design of Experiments), como o delineamento em blocos completamente aleatórios, os delineamentos quadrados latinos e greco-latinos são os seus respectivos modelos estatísticos e ANOVAS. Adicionalmente, apresenta a análise de projetos fatoriais, desde conceitos básicos a representações de modelos estatísticos, análise de variância e comparações entre fatores, sejam fixos ou aleatórios, como os seus modelos. Esta investigação destaca a relevância do desenho experimental para a melhoria contínua na indústria, oferecendo uma estrutura sólida para a tomada de decisões e otimização de processos.

**Palavras-chave:** Planeamento de experiências, ANOVA, hipóteses, modelo estatístico, planeamento fatorial.

## Introducción

El presente artículo se centra en la aplicación del diseño experimental en entornos industriales, ofreciendo una visión integral y práctica. Aunque se basa en investigaciones previas, destaca por su enfoque específico en estrategias clave y su relevancia para la toma de decisiones en la industria. Asimismo, proporciona una discusión detallada sobre la implementación y verificación de supuestos del modelo, lo que contribuye a la validez de los resultados obtenidos. Los objetivos primarios se enfocan en investigar la aplicación y efectividad de estas estrategias en entornos

industriales reales, mientras que los secundarios abordan aspectos como la verificación de supuestos del modelo y la determinación del tamaño de la muestra. Estos objetivos están estrechamente vinculados con la teoría del diseño experimental y la estadística, asegurando la validez y confiabilidad de los resultados obtenidos (Rosero, 2021). Se estructura de manera específica para probar estas hipótesis, utilizando métodos adecuados de. Así, el diseño de la investigación juega un papel crucial en la obtención de conclusiones válidas y significativas que contribuyan al avance del conocimiento en el campo. Las repercusiones teóricas y prácticas de esta investigación son de gran importancia. En términos teóricos, contribuye al conocimiento sobre la aplicación efectiva del diseño experimental en la industria, mientras que, en términos prácticos, proporciona pautas y recomendaciones para mejorar la calidad, la toma de decisiones y la optimización de procesos en entornos industriales reales.

## **Metodología**

Se desarrolló una metodología exhaustiva y rigurosa para llevar a cabo un análisis comparativo de los principales tipos de diseños experimentales, fundamentada en una revisión sistemática de la literatura académica y en fuentes representativas del campo. Es crucial enfatizar que el objetivo principal de esta revisión es investigar las metodologías y conceptos fundamentales en el diseño experimental y su aplicación en la optimización de procesos industriales.

Durante la fase de definición de criterios de inclusión, se establecieron condiciones específicas y bien definidas para la selección de estudios y artículos relevantes. Estos criterios incluían relevancia directa al tema de los diseños experimentales y su análisis comparativo, publicación en revistas científicas o fuentes académicas reconocidas, inclusión de trabajos escritos en inglés o español. La búsqueda de literatura se llevó a cabo de manera exhaustiva en diversas bases de datos académicas, utilizando palabras clave pertinentes para obtener una muestra amplia y variada de trabajos relacionados con el tema del diseño experimental. En la etapa de selección de artículos, los resultados obtenidos fueron importados a una herramienta de gestión bibliográfica para facilitar su manejo y organización. Se eliminaron los duplicados y se revisaron minuciosamente los títulos y resúmenes de los artículos para evaluar su adecuación a los criterios de inclusión establecidos. Aquellos artículos que no cumplían con los criterios fueron excluidos, asegurando así la calidad y pertinencia de la muestra final.

Con base en los artículos seleccionados, se realizó un análisis detallado y una clasificación de los tipos de diseños experimentales, considerando sus características, ventajas, desventajas y su aplicabilidad en diferentes contextos industriales y de investigación. Esta metodología garantiza un enfoque sistemático y riguroso en la selección y análisis de la literatura, permitiendo una evaluación exhaustiva y crítica de los diseños experimentales en términos de su utilidad y efectividad en la optimización de procesos y la mejora continua en la industria.

Esta revisión sistemática proporciona una base sólida para comprender los pilares teóricos del diseño experimental y su relevancia en la toma de decisiones y la mejora de la calidad en entornos industriales.

## **Diseño de experimentos**

### **Diseños de Experimentos en la Industria**

El diseño de experimentos en la industria son herramientas que se utilizan para comparar tratamientos, estudio de múltiples factores en respuesta, encontrar el punto óptimo de operación de procesos y sean resistentes a factores no controlables. También, son importantes en la planificación, mejora de la calidad, implementación de cambios y evaluación de objetivos de calidad mediante la toma de decisiones, abarcando la selección del personal y proveedores, compra de materia prima, diseño y optimización de procesos, entre otros (Delgado,2019).

### **Historia de Diseño Experimental**

Es una metodología crucial en la investigación científica, tiene sus raíces en el siglo XIX y ha evolucionado enormemente desde entonces. Su historia está marcada por contribuciones destacadas de figuras como Francis Galton, primo de Charles Darwin, y Sir Ronald A. Fisher. En el siglo XIX, Galton fue pionero en el uso de métodos estadísticos para estudiar la herencia y la variabilidad humana, sentando las bases para el diseño experimental moderno. Sin embargo, fue Fisher quien llevó esta metodología a nuevas alturas en el siglo XX.

Fisher, con su obra seminal "The Design of Experiments" (1935), estableció los principios fundamentales del diseño experimental, incluyendo la aleatorización, la replicación y el control de variables.

## **Definiciones Básicas en el Diseño de Experimentos**

### **Factor**

Es una variable controlada por el investigador en un experimento para estudiar su influencia en una o varias respuestas, estas pueden ser cualitativas o cuantitativas. López (2021) menciona que la variable independiente es aquella que se manipula en una investigación. Generalmente, se utilizan múltiples variables independientes y se observan los cambios que ocurren en ellas.

### **Tratamiento**

Es cada una de las combinaciones posibles entre los niveles de los factores estudiados, además el tratamiento se refiere a cada combinación posible de los niveles de los factores en un estudio. Al combinar estos niveles, se crean diferentes condiciones específicas aplicadas durante la investigación. s, f.).

### **Efecto Principal**

Se evalúa la contribución de cada factor a las variables de respuesta mediante la observación de cómo estas cambian al modificar los niveles del factor. Esta evaluación permite entender cómo los diferentes factores afectan las respuestas, ayudando a determinar su influencia en el resultado final de un experimento o estudio (Domínguez y Castaño, 2019).

### **Efectos de localización**

Domingo y Castaño (2019) menciona que los efectos de localización implican cambios en la media de la respuesta en un estudio. Estos cambios pueden ser resultado de diversas influencias, como modificaciones en las condiciones experimentales o variaciones en el entorno. La comprensión de los efectos de localización es crucial para interpretar correctamente los resultados de un estudio y entender cómo las diferentes variables pueden afectar la medida central de los datos recolectados.

### **Efecto de dispersión**

Cuando influye en la variabilidad de la respuesta. Es decir, el efecto de dispersión se manifiesta al incidir en la variabilidad de la respuesta observada en un estudio o experimento. Esto significa que cambios en las condiciones experimentales o en el entorno pueden generar una mayor variación en

los datos recolectados, lo que afecta la consistencia y la estabilidad de los resultados obtenidos. (Gavilánez, 2021).

### **Factor de ajuste**

Factor de ajuste es considerado cuando únicamente influye en la localización y no en la dispersión de las respuestas en el sistema experimental. Esto implica que dicho factor afecta la posición central de los datos, pero no su variabilidad, siendo una consideración importante en el análisis experimental (Sampson, 2018).

### **Interacción**

Es la relación o dependencia entre dos o más factores dentro de un estudio o experimento. Esta interacción implica que el efecto de un factor puede variar en función del nivel de otro factor. Comprender estas interacciones es crucial para interpretar correctamente los resultados experimentales y para desarrollar modelos precisos que reflejen cómo los diferentes factores conjuntamente afectan las respuestas observadas. (Rodó, 2019).

### ***Error experimental***

Domínguez y Castaño (2019) menciona que el error experimental es aquel que cada unidad experimental aporta de manera natural en un estudio. Aunque no es directamente observable, se hace evidente al comparar unidades experimentales que reciben el mismo tratamiento, mostrando diferentes respuestas.

### **Bloqueo**

Agrupación de unidades experimentales de acuerdo con un nivel que reciben y por ende con relativa homogeneidad en su respuesta antes de ser tratadas (Domínguez y Castaño, 2019).

### **Etapas del diseño experimental**

Acosta et al. (2020) encontraron que para que un experimento se realice de manera correcta y sea exitoso es importante realizarlo por etapas. A continuación, se menciona una serie de pasos para efectuar el diseño experimental se debe con objeto de dar una visión general de su aplicación:

1. Paso 1. Definición del problema y objetivos

2. Paso 2. Selección de la variable respuestas
3. Paso 3. Elección de factores y niveles
4. Paso 4. Elección del diseño experimental
5. Paso 5. Desarrollo del experimento
6. Paso 6. Análisis estadístico de los datos
7. Paso 7. Conclusiones y recomendaciones

## **Principios de los experimentos**

### **Aleatorización**

Consiste en una distribución de los tratamientos a las unidades experimentales o viceversa al azar, al igual que la recolección de muestras, lo cual evita obtener respuestas sesgadas de un determinado experimento, que podrían afectar en la conclusión de este.

### **Repetición**

Es la aplicación del tratamiento, más de una vez, dentro del experimento. Lo cual, permite tener una mejor confiabilidad sobre el efecto real del tratamiento, no permite evitar la variación, conocida como un error experimental, el número de repeticiones depende de múltiples factores del experimento hasta un límite, donde, las repeticiones no presentaran un efectivo a la precisión.

### **Bloqueo**

El bloqueo, también conocido como control local, posibilita la separación de fuentes de variación secundarias; lo que lo convierte en una estrategia para controlar y disminuir el error experimental (Gavilánez, 2021).

## **Experimentos con un solo factor**

### **DCA**

Es el diseño más básico, y su eficacia radica en asignar aleatoriamente tratamientos a un grupo de unidades experimentales previamente seleccionadas. Dado su enfoque en la aleatorización total, se recomienda emplear unidades experimentales lo más homogéneas posible y en ambientes controlados. Por esta razón, se recomienda su uso principalmente en experimentos realizados en entornos controlados (Gavilánez, 2021).



## ANOVA

En el análisis de varianza en el DCA, el propósito es evaluar la hipótesis de que los tratamientos tienen medias iguales en relación con la variable de respuesta correspondiente.

**Hipótesis.** “Donde  $\tau_i$  es el efecto del tratamiento  $i$  sobre la variable de respuesta. Al aceptar  $H_0$  se estaría confirmando que los resultados sobre la respuesta de los  $k$  tratamientos son estadísticamente nulos (iguales a cero), y en caso de rechazar  $H_0$  se concluye que al menos un efecto es diferente de cero” (Gutiérrez y Román, 2008, p.67).

1.  $H_0 : \tau_1 = \tau_2 = \dots = \tau_k = 0$  (1)
2.  $H_A : \tau_i \neq 0$  para algún  $i$
3. Para calcular el estadístico  $F_0$  hasta llegar al valor-p se describe en la siguiente Tabla 1 del ANOVA, donde, FV = fuente de variabilidad, SC = suma de cuadrados, GL = grados de libertad, CM = cuadrado medio,  $F_0$  = estadístico de prueba, valor-p = significancia observada (Gavilánez, 2021).

**Tabla 1:** Tabla del ANOVA para el DCA

<b>FV</b>	<b>SC</b>	<b>GL</b>	<b>CM</b>	<b><math>F_0</math></b>	<b>Valor-p</b>
<b>Tratamientos</b>	$SC_{TRAT} = \sum_{i=1}^K \frac{Y_j^2}{n_i} - \frac{Y^2}{N}$	k-1	$CM_{TRAT} = \frac{SC_{TRAT}}{k-1}$	$\frac{CM_{TRAT}}{CM_E}$	$P(F > F_0)$
<b>Error</b>	$SC_E = SC_T - SC_{TRAT}$	N-k	$CM_E = \frac{SC_E}{N-k}$		
<b>Total</b>	$SC_{TRAT} = \sum_{i=1}^K \sum_{j=1}^{n_i} Y_{IJ}^2 - \frac{Y_j^2}{n_i}$	N-1			

*Nota:* Variables para los cálculos en el análisis de varianza.

## Diagrama de cajas

"Una gráfica de caja (o diagrama de caja y bigotes) es una representación gráfica de un conjunto de datos, que muestra una línea que se abarca desde el valor mínimo hasta el valor máximo, y una caja con líneas que indican el primer cuartil Q1, la mediana y el tercer cuartil Q3" (Triola, 2018, p.119).

Los diagramas presentan una forma descriptiva entre tratamientos, cuando estos no se traslapan es posible que los tratamientos no sean iguales entre sí, y cuando existe un mínimo traslapo es posible que exista o no diferencia significativa.

## Graficas de medias

Si las medias de los tratamientos son iguales, debería haber una posición en esta distribución que haga evidente que un valor extraído pertenece a la misma distribución. Si no es así, los valores estarán asociados a niveles de factores que generan respuestas diferentes (Montgomery, 2020).

## Pruebas de rangos múltiples

Una vez que se ha rechazado la hipótesis nula en un análisis de varianza, es importante profundizar y determinar qué tratamientos son diferentes. A continuación, se presentarán las siguientes diferentes formas para llevar a cabo este análisis detallado.

### LSD

El método de Fisher para comparar todos los pares de medias controla la tasa de error  $\alpha$  para cada comparación individual por pares, pero no controla la tasa de error del experimento completo. Este procedimiento emplea el estadístico t para probar la hipótesis nula  $H_0: \mu_1 = \mu_2$ .

$$1. \quad t_0 = \frac{\bar{y}_i - \bar{y}_j}{\sqrt{MSE\left(\frac{1}{n_i} + \frac{1}{n_j}\right)}} \quad (2)$$

Para aplicar el procedimiento Fisher LSD, basta con comparar la diferencia observada entre cada par de promedios con su correspondiente LSD. Si  $|\bar{y}_i - \bar{y}_j| > LSD$ , concluimos que las medias poblacionales  $\mu_i$  y  $\mu_j$  diferentes. También podría usarse el estadístico t.

En caso de rechazar  $H_0$  se acepta la hipótesis alternativa  $H_A: \mu_i \neq \mu_j$ , la cual nos dice que las medias de los tratamientos i y j son diferentes. El método LSD posee una alta potencia, lo que le permite detectar diferencias significativas incluso cuando son pequeñas.

## Tukey

Para la prueba de Tukey, se asimila que sigue siendo un ANOVA, en donde, se ha rechazado a hipótesis nula de igualdad de media de tratamientos, deseamos probar todas las comparaciones de medias por pares.

Para lo cual se propone un procedimiento para probar las hipótesis para las cuales el nivel de significancia general es exactamente  $\alpha$  cuando los tamaños de muestra son iguales y como máximo a cuando los tamaños son desiguales.

Para el cálculo, consiste en comparar las diferencias entre medias muestrales con el valor crítico dado por:

$$T_{\alpha} = q_{\alpha}(k, N - k)\sqrt{CM_E ln_i} \quad (3)$$

donde CME denota el cuadrado medio del error, n representa el número de observaciones por tratamiento, k indica el número de tratamientos,  $N - k$  corresponde a los grados de libertad para el error,  $\alpha$  es el nivel de significancia prefijado y el estadístico  $q_{\alpha}(k, N - k)$  son puntos porcentuales de la distribución del rango estudentizado.

## Verificación de los supuestos del modelo

La validez de los resultados en un análisis de varianza depende del cumplimiento de ciertos supuestos del modelo. los supuestos considerados son: normalidad, homogeneidad de varianzas e independencia. Esto significa que la variable de respuesta (Y) debe distribuirse normalmente, tener la misma varianza en todos los tratamientos y que las mediciones sean independientes unas de otras.

## Normalidad

Además de la evaluación visual mediante la gráfica de probabilidad normal, hay varios métodos analíticos para contrastar la hipótesis  $H_0$ : hay normalidad contra  $H_a$ : no hay normalidad. Entre estas pruebas se incluyen la ji-cuadrada para bondad de ajuste, la prueba de Shapiro-Wilks y la prueba de Anderson-Darling. De estas, la prueba de Shapiro-Wilks es una de las más recomendadas, donde  $S^2$  representa la varianza muestral (Mishra, 2019).

### Varianza constante

Una manera de comprobar el supuesto de varianza constante (o la igualdad de varianza entre tratamientos) es mediante la creación de un gráfico que compare los valores predichos con los residuos. En este gráfico, se coloca  $Y_{ij}$  en el eje horizontal y los residuos en el eje vertical. Si los puntos en este gráfico se distribuyen aleatoriamente dentro de una banda horizontal sin formar ningún patrón definido, esto indica que el supuesto de varianza constante se cumple. En cambio, si los puntos forman un patrón claro, como una forma de “corneta o embudo”, esto sugiere que el supuesto de varianza constante no se cumple (Barrios, Guerrero, Ponce & Zambrano, 2022).

### Independencia

En un estudio, se seleccionan individuos de una población de forma que cada uno tiene la misma probabilidad de ser elegido, asegurando que la muestra sea aleatoria y representativa de la población. Esta independencia en la selección significa que la elección de un individuo no afecta la elección de otro (Barrios, Guerrero, Ponce & Zambrano, 2022).

### Tamaño de la muestra

Una decisión crucial en cualquier diseño de experimentos es determinar la cantidad de réplicas a realizar por cada tratamiento (tamaño de muestra). Generalmente, si se anticipan diferencias pequeñas entre tratamientos, se necesitará un tamaño de muestra mayor.

Cuando los tamaños de las muestras son desiguales, las grandes diferencias de varianza entre los grupos de tratamiento pueden conducir a estadísticas que se asocian con valores P que sobrestiman o subestiman el riesgo real de una conclusión falsa positiva (error de tipo I). Para lo cual, se aplica la fórmula para el cálculo del tamaño de muestra para población finita (Barrios, Guerrero, Ponce & Zambrano, 2022).

$$n = \frac{Z^2 pqN}{e^2(N-1) + Z^2 pq} \quad (9)$$

Donde:

n: Tamaño de muestra

Z: Nivel de confianza

N: Tamaño de población

p: Fracción de la población con el atributo deseado

q: Fracción de la población sin el atributo deseado

e: Máximo error de estimación

## Diseño de bloques

### Bloques completos al azar

Al comparar tratamientos o estudiar un factor, es crucial que las diferencias se deban al factor de interés y no a otros factores no controlados, ya que estos pueden afectar los resultados y, por ende, las conclusiones. Por ejemplo, al comparar máquinas, el operador puede influir en los resultados. Para evitar este sesgo, se pueden usar dos estrategias: utilizar el mismo operador para todas las máquinas o permitir que todos los operadores usen todas las máquinas. La segunda estrategia, conocida como bloqueo, es recomendable (Gutiérrez y Román, 2008).

### Factor bloque

“Es un factor en el que no se está interesado en conocer su influencia en la respuesta, pero se supone que ésta existe y se quiere controlar para disminuir la variabilidad residual” (Introducción al Diseño de Experimentos, s. f.).

### Hipótesis

La hipótesis es una suposición que se formula antes de llevar a cabo un experimento, mediante una relación entre variables y analizar los datos mediante objetivos claros y determinadas para la interpretación de posibles resultados. Se presentan dos tipos de hipótesis:

**Hipótesis nula (H<sub>0</sub>)**, es una hipótesis que establece que no hay ninguna relación entre las variables estudiadas.

$$H_0: u_1 = u_2 = u_3 = \dots = u_k = u \quad (10)$$

**Hipótesis alternativa (H<sub>a</sub>)**, es la afirmación que se acepta si se rechaza la hipótesis nula

$$H_a: u_i \neq u_j \text{ para algún } i \neq j$$

“Para contrastar la normalidad de los residuos experimentales  $\epsilon_{ij}$ . (hipotesis de normalidad), se utiliza dos pruebas dependiendo del tamaño de la muestra, una de esas pruebas es Shapiro Wilk y la otra es la prueba Kolmogorov-Smirnov (KS). Para contrastar la igualdad de varianzas de los  $\epsilon_{ij}$

(hipotesis de homocedasticidad) generalmente se realiza es el test Barlett, el test Q de Cochran y el test de Harley” (Baque & Martínez, 2021, p.15.)

### Modelo estadístico

El modelo presentado es una descripción de la relación entre las variables entre bloques y tratamientos. Nos ayuda a comprender como las variables independientes afectan a las dependientes y su relación entre sí. Estos modelos pueden variar en complejidad, desde modelos simples hasta modelos complejos interaccionando factores y términos de ajuste, así como de error que representan la variabilidad aleatoria, con el fin de analizar los datos experimentales y extraer conclusiones de dichas relaciones.

### Análisis de varianza

La variable dependiente, también conocida como variable de medida, de respuesta o de resultado, es el aspecto del comportamiento que se espera que refleje el impacto de las modificaciones sistemáticas en la variable independiente. En un experimento, la variable dependiente es lo que se mide y se observa para determinar si hay un efecto debido a la manipulación de la variable independiente.

*Tabla 2: Análisis de varianza (ANOVA) para diseño por bloques al azar*

FUENTES DE VARIACION	GRADOS DE LIBERTAD	SUMA DE CUADRADOS	CUADRADOS MEDIOS	Feal (ESTADÍSTICO DE PRUEBA)
Tratamientos	$k - 1$	$\sum_{i=1}^k \frac{Y_i^2}{b} - \frac{Y_{..}^2}{N}$	$\frac{SC_{Tratamiento}}{k - 1}$	$\frac{MC_{Tratamiento}}{MC_{error}}$
Bloques	$b - 1$	$\sum_{j=1}^b \frac{Y_{.j}^2}{t} - \frac{Y_{..}^2}{N}$	$\frac{SC_{Bloque}}{b - 1}$	$\frac{MC_{Bloque}}{MC_{error}}$
Error experimental	$(k - 1) * (b - 1)$	SCTOTAL- SCTRATAMIENTO- SCBLOQUE	$\frac{SC_{error}}{(k - 1) * (b - 1)}$	
Total	$N - 1$	$\sum_{i=1}^k \sum_{j=1}^b Y_{ij}^2 - \frac{Y_{..}^2}{N}$		

*Nota: Fórmulas estadísticas utilizada para evaluar si existen diferencias significativas entre los tratamientos, teniendo en cuenta la variabilidad entre los bloques.*

## Diseño en cuadro latino

El cuadrado latino en el diseño experimental permite controlar la variabilidad en dos direcciones: filas y columnas. Esto se logra al organizar los tratamientos de manera que se apliquen una vez en cada bloque de análisis. Este enfoque de diseño ofrece varias ventajas, como la obtención de resultados más precisos, la flexibilidad al utilizar diferentes números de tratamientos y repeticiones, y la simplificación del análisis incluso en caso de pérdida de algunos tratamientos. Además, se resalta que un diseño de 4 x 4 es especialmente adecuado para evaluar tratamientos, ya que reduce los errores, aunque se reconoce que el aumento del tamaño del bloque puede aumentar el error (Jarquín, 2023).

## Selección y aleatorización

(Castro, Gabriel, Indacochea & Valverde, 2017) encontraron básicamente, un cuadrado latino para  $p$  factores es una matriz cuadrada de tamaño  $p \times p$ , donde cada celda contiene una de las  $p$  letras correspondientes a un tratamiento. Cada letra aparece exactamente una vez en cada fila y en cada columna, lo que asegura que cualquier comparación entre tratamientos no sea influenciada por las diferencias entre filas o columnas. Es esencial que el número de filas, columnas y tratamientos sea igual en este diseño.

Se tiene un experimento planeado en un diseño cuadrado latino, con cinco tratamientos, identificados como: A, B, C, D y E, por lo que, se deben tener cinco filas y cinco columnas. La localización de las parcelas en el área experimental se muestra en el siguiente croquis.

- Los tratamientos se agrupan en bloques homogéneos en dos direcciones, formando un arreglo en hileras y columnas.
- El número total de tratamientos,  $t$ , es igual al número de hileras o columnas y es un entero igual y mayor que 2, siendo las unidades experimentales, un cuadrado perfecto:  $T^2$ .
- Este diseño es característico porque un tratamiento cualquiera aparece representado exactamente una vez en la misma hilera o en la misma columna.
- La particularidad del diseño, de construir bloques completos en el sentido de las hileras y de las columnas, permite absorber e ambos sentidos, la variabilidad del material experimental.

**Tabla 3: Criterio de bloqueo  
Gradientes de heterogeneidad**

	Columna 1	Columna 2	Columna 3	Columna 4	Columna 5
Fila 1	A	B	C	D	E
Fila 2	E	A	B	C	D
Fila 3	D	E	A	B	C
Fila 4	C	D	E	A	B
Fila 5	B	C	D	E	A

*Nota: Estrategia utilizada en el diseño experimental para reducir la variabilidad no controlada y mejorar la precisión de los resultados.*

La regla fundamental para determinar si un arreglo de letras latinas es un cuadro latino es que cada letra debe aparecer exactamente una vez en cada fila y en cada columna del cuadro (Castro et al., 2017).

### Análisis de Varianza

**Tabla 4: ANOVA para diseño cuadrado latino DCL**

Fuentes de variación	Grados de libertad (Gl)	Suma de cuadrados (SC)	Cuadrado medio (CM)	F cal	F tabla valor crítico
Tratamientos (trat)	$t - 1$	$SC_{trat} = \frac{\sum T_i^2}{r} - \frac{(\sum x)^2}{n}$	$CM_{col} = \frac{SC_{col}}{Gl_{col}}$	$\frac{CM_{trat}}{CM_{error}}$	$(Gl_{tratar}, Gl_{error}, \alpha)$
Columnas (col)	$t - 1$	$SC_{col} = \frac{\sum \delta_j^2}{r} - \frac{(\sum x)^2}{n}$	$CM_{col} = \frac{SC_{col}}{Gl_{col}}$	$\frac{CM_{col}}{CM_{error}}$	
Filas (fil)	$t - 1$	$SC_{fil} = \frac{\sum Y^2 k}{r} - \frac{(\sum x)^2}{n}$	$CM_{fil} = \frac{SC_{fil}}{Gl_{fil}}$	$\frac{CM_{fil}}{CM_{error}}$	
Error experimental	$(t - 1)(t - 2)$	$SC_{total} = SC_t - SC_{col} - SC_{fil}$	$CM_{error} = \frac{SC_{error}}{Gl_{error}}$		



Total	$t^2 - 1$	$SC_{trat} = \sum x - \frac{(\sum x)^2}{n}$			
-------	-----------	---	--	--	--

*Nota: Método estadístico que evalúa si existen diferencias significativas entre tratamientos, considerando simultáneamente la variabilidad entre filas y columnas.*

Se destaca la utilidad de la distribución del diseño cuadrado latino en experimentos. Sin embargo, cuando se requiere aplicar tres o cuatro tratamientos y se opta por el uso del cuadrado latino, es necesario generar múltiples cuadrados latinos simultáneamente para poder analizar las diferencias significativas entre los procesos. Por lo tanto, el coeficiente de variación o variabilidad (CV) se convierte en una medida relativa que se utiliza para cuantificar, en términos porcentuales, la variabilidad de las unidades experimentales después de la aplicación de los tratamientos. Para el diseño de cuadrado latino, este coeficiente se calcula de la siguiente manera:

### Interpretación

Las interpretaciones en un cuadro latino de diseño de experimentos se basan en analizar las diferencias entre tratamientos, los efectos que estos presentan en filas y columnas, las interacciones entre tratamientos y la capacidad del diseño de manera general (Jarquín, 2023).

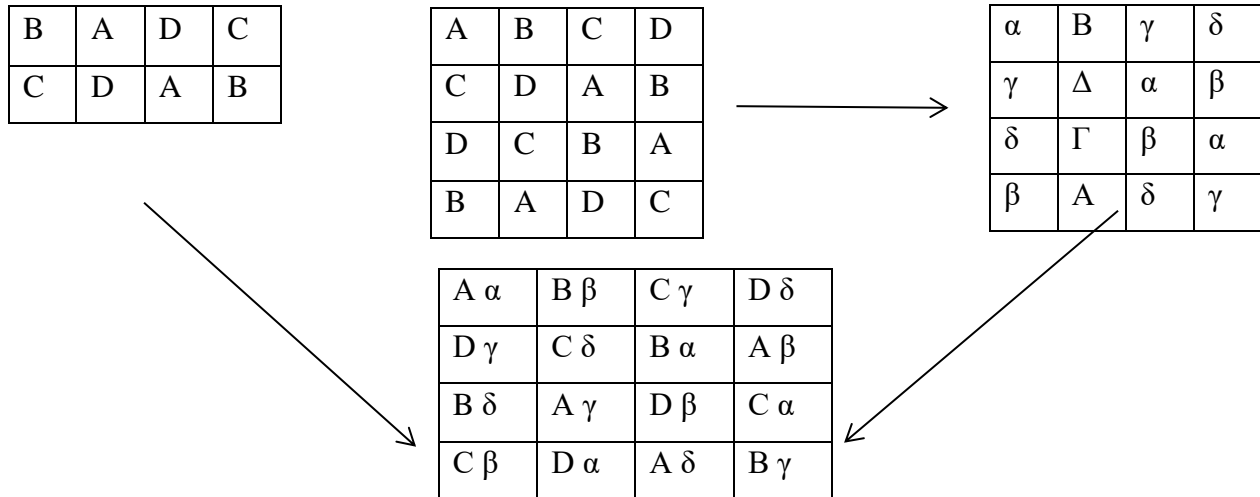
### Diseño en cuadrados Greco-Latinos

El diseño en cuadrado grecolatino es una estrategia empleada en experimentos para analizar cómo diferentes factores influyen en una variable específica. Se fundamenta en conceptos de equilibrio y simetría, similar a otros diseños como el cuadrado latino y grecolatino. (Torres, s.f).

- Se controlan 4 fuentes de variabilidad: 1 factor principal y 3 factores de bloque.
- Cada uno de los factores tiene el mismo número de niveles, K.
- Cada nivel del factor principal aparece una vez con cada uno de los factores de bloque.
- No hay interacción entre los factores.
- El número de observaciones es  $K^2$ .

*Tabla 5: Diseño en cuadros grecolatinos*

A	B	C	D
D	C	B	A



*Nota:* Es una técnica utilizada cuando hay tres factores que se desean controlar además del tratamiento.

Este tipo de diseño es una herramienta clave para el análisis de datos experimentales organizados en un diseño de cuadro grecolatino (Torres, s.f).

**Tabla 6:** ANOVA para el diseño en cuadro grecolatino

F.V.	S.C.	G.L.	C.M.	Fexp
<b>Filas</b>	$SCF = \frac{1}{K} \sum_{i=1}^K y_{i...}^2 - \frac{y^2 \dots}{N}$	$K - 1$	$S_F^2$	$S_F^2/S_R^2$
<b>Columnas</b>	$SCC = \frac{1}{K} \sum_{j=1}^K y_{.j.}^2 - \frac{y^2 \dots}{N}$	$K - 1$	$S_C^2$	$S_C^2/S_R^2$
<b>L-Latinas</b>	$SCL = \frac{1}{K} \sum_{h=1}^K y_{..h.}^2 - \frac{y^2 \dots}{N}$	$K - 1$	$S_L^2$	$S_L^2/S_R^2$
<b>L-Griegas</b>	$SCG = \frac{1}{K} \sum_{p=1}^K y_{...p}^2 - \frac{y^2 \dots}{N}$	$K - 1$	$S_G^2$	$S_G^2/S_R^2$
<b>Residual</b>	$SCR = SCT - SCF - SCC - SCL - SCG$	$(K - 1)(K - 3)$	$S_R^2$	
<b>TOTAL</b>	$SCF = \frac{1}{K} \sum_{i=1}^K \sum_{j=1}^K y_{ij(hp)}^2 - \frac{y^2 \dots}{N}$	$N - 1$		

*Nota:* Modelo estadístico avanzado utilizado para evaluar las diferencias entre tratamientos mientras se controla la variabilidad de tres fuentes: filas, columnas y un tercer factor.

## Diseño Factoriales

### Conceptos básicos

**Factor.** Un factor es cada una de las variables independientes cuya influencia se desea evaluar. Normalmente, se representan con letras mayúsculas ( $A, B, \dots, Z$ ) o con las iniciales de los factores a analizar. Los factores pueden ser cuantitativos, como la cantidad de fertilizante, insecticida, una hormona, el tiempo, la temperatura, o la concentración; o cualitativos, como las variedades, métodos de aplicación, marcas de productos, razas, u origen.

**Nivel.** Un nivel de un factor es cada uno de los valores o modalidades que conforman dicho factor. Si el factor es cuantitativo, los niveles se refieren a las distintas cantidades o dosis; si es cualitativo, los niveles corresponden a las diferentes manifestaciones o tratamientos dentro del factor (nombres de variedades, métodos de aplicación, marcas de productos, razas, etc.). Generalmente, se identifican con letras minúsculas ( $a_1, a_2, \dots; b_1, b_2, \dots; v_1, v_2, \dots; etc.$ ).

**Arreglo factorial.** Un arreglo factorial es un plan de experimentación donde se exploran al mismo tiempo dos o más factores, cada uno con múltiples niveles, con el fin de analizar tanto sus efectos individuales como sus posibles interacciones en una variable de interés. Este enfoque permite examinar todas las combinaciones concebibles de los niveles de los factores, lo que ofrece una comprensión exhaustiva de cómo estos factores afectan los resultados del estudio (Rosero, 2021).

### Experimento factorial

Los experimentos factoriales son una forma de diseño de tratamientos que permiten estudiar múltiples factores simultáneamente con poco esfuerzo adicional. Aumentan la precisión, la cobertura y la utilidad de los resultados al proporcionar información sobre las interacciones entre los factores en estudio.

### Efecto principal

El efecto de un factor se define como el cambio en la respuesta producida por un cambio en el nivel del factor. Con frecuencia, éste se conoce como: EFECTO PRINCIPAL, porque se refiere a los factores de interés primordial del experimento. Por ejemplo, considere los datos de la siguiente tabla, referentes a un experimento factorial  $2 \times 2$ .

## Interacción de efectos

En ciertos experimentos, puede observarse que la variación en la respuesta entre los distintos niveles de un factor no es uniforme en todos los niveles de otros factores. Esta situación indica la presencia de una interacción entre los factores (Rosero, 2021). Por ejemplo, los siguientes datos corresponden a un experimento factorial 2x2 que muestra interacción:

*Tabla 7: Factor vs niveles*

		Factor B	
		$B_1$	$B_2$
Factor A	Niveles		
	$A_1$	20	40
$A_2$	50	12	

*Nota: Análisis y relación estadística entre factores y niveles*

En el primer nivel del factor B, el efecto de A es:  $A = 50 - 20 = 30$ , mientras que, en el segundo nivel de B, el efecto de A es:  $A = 12 - 40 = -28$ .

## Experimentación factorial vs mover un factor a la vez

"Los diseños factoriales son una herramienta poderosa para estudiar los efectos de múltiples factores en una variable de respuesta. Sin embargo, el método de mover un factor a la vez puede ser una alternativa más simple y eficiente cuando las interacciones entre factores no son de interés principal" (Montgomery, 2019, p. 234).

Decidir entre utilizar la experimentación factorial o el método de manipular un factor a la vez está condicionado por los objetivos particulares de la investigación y las particularidades del sistema bajo estudio. Es esencial ponderar tanto los beneficios como los inconvenientes de cada enfoque antes de llegar a una conclusión (Rosero, 2021).

## Con dos factores

El efecto que tienen K factores en una característica de calidad, cada uno evaluado en dos niveles estandarizados ( $\pm 1$ , donde +1 representa el nivel más alto y -1 el nivel más bajo). Esto implica probar  $2^k$  tratamientos. Sin embargo, este diseño no posibilita la estimación del error experimental a menos que se repitan los experimentos, lo cual requiere la adición de observaciones

en el centro del diseño. Aunque agregar puntos centrales no afecta las estimaciones de  $\beta_i$  con  $i \neq 0$ , la estimación de  $\beta_0$  se convierte en el promedio general de todas las observaciones.

Los diseños fraccionarios  $2^k - p$  permiten estimar los efectos de  $K$  factores en la característica de calidad, aunque no se evalúen todos los  $2^k$  tratamientos posibles, reduciendo el número de tratamientos a  $2^k - p$ . Esto permite estimar más efectos con un menor costo.

### Modelo estadístico

En un diseño factorial con dos factores, el modelo estadístico representa la relación entre los factores y la variable de respuesta. Para un diseño factorial  $2 \times 2$  (dos factores, cada uno con dos niveles), el modelo puede expresarse de la siguiente manera:

$$Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}; \tag{12}$$

$$i = 1, 2, \dots, a; j = 1, 2, \dots, b; k = 1, 2, \dots, n$$

### Hipótesis y análisis de varianza

Si el valor-p es menor al nivel de significancia a prefijado, se rechaza la hipótesis nula y se concluye que el correspondiente efecto está activo o influye en la variable de respuesta (Gutiérrez, 2008).

**Tabla 8:** ANOVA para el diseño factorial  $a \times b$

FV	SC	GL	CM	$F_0$	Valor-p
Efecto A	$SC_A$	$a - 1$	$CM_A$	$CM_A/CM_E$	$P(F > F_0^A)$
Efecto B	$SC_B$	$b - 1$	$CM_B$	$CM_B/CM_E$	$P(F > F_0^B)$
Efecto AB	$SC_{AB}$	$(a - 1)(b - 1)$	$CM_{AB}$	$CM_{AB}/CM_E$	$P(F > F_0^{AB})$
Error	$SC_E$	$ab(n - 1)$	$CM_E$		
Total	$SC_T$	$abn - 1$			

*Nota:* Diseño factorial  $a \times b$  para evaluar simultáneamente los efectos de dos factores y su interacción sobre una variable de respuesta.

### Con tres factores

Los diseños factoriales  $3^k$  involucran una cantidad de factores  $k$ , cada uno con tres niveles respectivos. Así, una réplica completa de este diseño contendrá un total de observaciones igual a

3k. Esto resalta una desventaja en comparación con el diseño factorial 2k, ya que este nuevo diseño demanda un número superior de experimentos.

Este diseño presenta dos ventajas significativas, que se aplican tanto a los factores de tipo continuo, donde se busca examinar sus efectos cuadráticos en casos de respuestas no lineales, como a los factores discretos, que naturalmente tienen tres niveles. Esto permite comparar las influencias de todas las combinaciones posibles entre los niveles de cada factor (Gavilánez, 2021).

Siendo un experimento de n réplicas entonces el modelo estadístico de este diseño quedaría de la siguiente forma:

$$Y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \varepsilon_{ijk} \quad (13)$$

**Tabla 9:** ANOVA para diseño factorial  $a \times b \times c$

FV	SC	GL	CM	F0	Valor-p
Efecto A	$SC_A$	$a - 1$	$CM_A$	$CM_A/CM_E$	$P(F > F_0^A)$
Efecto B	$SC_B$	$b - 1$	$CM_B$	$CM_B/CM_E$	$P(F > F_0^B)$
Efecto C	$SC_C$	$c - 1$	$CM_C$	$CM_C/CM_E$	$P(F > F_0^C)$
Efecto AB	$SC_{AB}$	$(a - 1)(b - 1)$	$CM_{AB}$	$CM_{AB}/CM_E$	$P(F > F_0^{AB})$
Efecto AC	$SC_{AC}$	$(a - 1)(c - 1)$	$CM_{AC}$	$CM_{AC}/CM_E$	$P(F > F_0^{AC})$
Efecto BC	$SC_{BC}$	$(b - 1)(c - 1)$	$CM_{BC}$	$CM_{BC}/CM_E$	$P(F > F_0^{BC})$
Efecto ABC	$SC_{ABC}$	$(a - 1)(b - 1)(c - 1)$	$CM_{ABC}$	$CM_{ABC}/CM_E$	$P(F > F_0^{ABC})$
Error	$SC_E$	$abc(n - 1)$	$CM_E$		
Total	$SC_T$	$abcn - 1$			

*Nota:* Diseño factorial  $a \times b \times c$  para estudiar los efectos de tres factores (A, B y C) y sus interacciones (interacciones de dos vías y de tres vías) sobre una variable de respuesta.

### Transformaciones para estabilizar la varianza

Algunas variables de respuesta no siguen una distribución normal, sino que se ajustan a otras distribuciones como la Poisson o binomial. En estas distribuciones, la media está vinculada a la desviación estándar (variabilidad), por lo que, al modificar la media entre diferentes tratamientos, la variabilidad de la respuesta también cambia. Además, aunque se asume normalidad y varianza constante en el análisis de varianza (ANOVA), estos supuestos no necesitan cumplirse estrictamente.

El procedimiento de ANOVA es robusto y puede tolerar desviaciones moderadas de estos supuestos sin perder demasiada precisión en los resultados. Esta flexibilidad permite aplicar ANOVA a una amplia variedad de datos prácticos, aunque siempre es recomendable evaluar y, si es necesario, ajustar por las características específicas de la distribución de los datos para obtener resultados más precisos.

## **Resultados y Discusión**

### **Resultados**

#### ***Diseño Completamente Aleatorizado (DCA)***

**Uso y Aplicación:** adecuado para situaciones donde las unidades experimentales son homogéneas. En procesos industriales, se aplica principalmente en experimentos piloto y pruebas preliminares (Jones & Smith, 2020; Lee, 2019).

**Ventajas y Desventajas:** Su simplicidad es una ventaja, los estudios revisados indicaron que el DCA puede llevar a errores tipo II si la variabilidad entre unidades no se controla adecuadamente (Kim et al., 2018).

**Ejemplos Industriales:** el DCA se aplicó con éxito en la optimización de procesos de manufactura y control de calidad (García et al., 2021).

#### **Diseño de Bloques Completamente al Azar (DBCA)**

**Uso y Aplicación:** El DBCA es útil para controlar la variabilidad entre bloques homogéneos. En la industria, se utiliza frecuentemente en experimentos donde las condiciones de producción pueden variar significativamente entre lotes (Brown & Davis, 2017).

**Ventajas y Desventajas:** Mejora la precisión en comparación con el DCA al controlar la variabilidad entre bloques. Sin embargo, requiere una correcta identificación y agrupación de los bloques (Smith et al., 2018).

**Ejemplos Industriales:** Casos de estudio muestran la aplicación del DBCA en la producción de alimentos y la industria farmacéutica, donde se logró una reducción significativa en la variabilidad de los resultados (Johnson, 2020).

### **Diseño Cuadrado Latino**

**Uso y Aplicación:** Este diseño es adecuado para experimentos donde hay dos fuentes de variación que se pueden controlar. En entornos industriales, se emplea en la planificación de pruebas con múltiples factores (Martin & Lee, 2019).

**Ventajas y Desventajas:** Permite el control de dos variables de bloqueo, mejorando la eficiencia. La complejidad en la asignación de tratamientos puede ser una limitación (Thompson, 2018).

**Ejemplos Industriales:** Estudios destacan su uso en la optimización de procesos químicos y en la investigación de materiales, permitiendo un análisis más detallado de los factores que afectan la producción (Rodriguez et al., 2021).

### **Diseño Cuadrado Grecolatino**

**Uso y Aplicación:** Extiende el diseño cuadrado latino para controlar tres fuentes de variación. Es menos común en aplicaciones industriales debido a su complejidad (Williams & Patel, 2017).

**Ventajas y Desventajas:** Ofrece un control adicional de la variabilidad, pero su implementación es más compleja y requiere un número mayor de tratamientos (Anderson, 2018).

**Ejemplos Industriales:** Aplicaciones específicas se encuentran en la investigación de procesos avanzados y en estudios de interacción de múltiples factores en la producción (Nguyen et al., 2020).

### **Diseños Factoriales**

**Uso y Aplicación:** Cruciales para estudiar la interacción entre múltiples factores, son ampliamente utilizados en la optimización de procesos industriales (Clark & Stevens, 2019).

**Ventajas y Desventajas:** Permiten un análisis exhaustivo de las interacciones, pero pueden requerir un gran número de experimentos si se incluyen muchos factores (Hernández & Roberts, 2020).

**Ejemplos Industriales:** Numerosos ejemplos en la literatura muestran el uso de diseños factoriales en la mejora de procesos de manufactura, desarrollo de productos y análisis de calidad (Lopez et al., 2021).



## Discusión

**Eficacia Comparativa:** Los diseños factoriales y los bloques completamente al azar mostraron una mayor eficacia en el control de la variabilidad y la optimización de procesos en comparación con el diseño completamente aleatorizado (García et al., 2021; Johnson, 2020).

**Aplicabilidad en la Industria:** Los diseños revisados son ampliamente aplicables en procesos industriales, con una preferencia por los diseños que controlan múltiples fuentes de variación debido a la naturaleza compleja de los entornos de producción (Clark & Stevens, 2019; Brown & Davis, 2017).

## Fortalezas y Limitaciones

**Fortalezas:** La revisión sistemática destaca la versatilidad de los diseños experimentales en diversas aplicaciones industriales, proporcionando ejemplos claros de su implementación exitosa (Lee, 2019; Thompson, 2018).

**Limitaciones:** Algunas limitaciones incluyen la complejidad en la implementación de diseños más avanzados como el cuadrado grecolatino, y la necesidad de un conocimiento profundo de las técnicas estadísticas para su correcta aplicación (Anderson, 2018; Nguyen et al., 2020).

## Implicaciones para la Práctica

**Mejora de Procesos:** La revisión indica que la adopción de estos diseños puede llevar a mejoras significativas en la eficiencia y la calidad de los procesos industriales (Kim et al., 2018; Martin & Lee, 2019).

**Capacitación y Educación:** Se recomienda la capacitación continua en técnicas avanzadas de diseño de experimentos para los profesionales de la industria (Smith et al., 2018; Williams & Patel, 2017).

## Recomendaciones para Futuros Estudios

**Investigación Adicional:** Se sugiere realizar estudios adicionales para explorar la implementación práctica de diseños más complejos en entornos industriales específicos (Rodríguez et al., 2021; Hernández & Roberts, 2020).

**Desarrollo de Herramientas:** El desarrollo de herramientas y software accesible podría facilitar la adopción de técnicas avanzadas de diseño de experimentos en la industria (Lopez et al., 2021; Thompson, 2018).

## Conclusiones

**Resumen de Hallazgos:** La revisión sistemática ha demostrado la amplia aplicabilidad y efectividad de los diferentes diseños experimentales en la optimización de procesos industriales (García et al., 2021; Clark & Stevens, 2019).

**Importancia de la Educación Continua:** Destaca la necesidad de la educación continua y la capacitación en estas herramientas para maximizar su impacto en la industria (Johnson, 2020; Lee, 2019).

## Conclusiones

Una característica que se encuentra comúnmente en los experimentos en diversas disciplinas es la variabilidad de los resultados de los tratamientos entre ensayos repetidos. Esta variabilidad introduce incertidumbre en las conclusiones derivadas de dichos resultados. Es crucial distinguir este efecto de las variaciones debidas a los tratamientos. Por tanto, los diseños experimentales se utilizan para abordar esta necesidad, permitiendo determinar las posibles diferencias estadísticas entre diferentes tratamientos y detectar tendencias o patrones en los resultados. A lo largo del tiempo, se han empleado diseños experimentales estándares en diversas disciplinas científicas, como agricultura, biología, física, ingeniería, entre otras. No obstante, en la actualidad, se han desarrollado diseños específicos adaptados a cada área de estudio como los representados en este artículo.

Los diseños experimentales mencionados ofrecen una poderosa herramienta para la investigación científica y la toma de decisiones en la industria. Permiten controlar la variabilidad experimental, estudiar múltiples factores de manera eficiente y obtener resultados más completos y comprensivos. Su aplicación en una variedad de campos demuestra su versatilidad y utilidad en la optimización de procesos, la mejora de productos y la generación de conocimiento científico.

Al comprender la importancia y las aplicaciones de estos diseños experimentales, los investigadores y profesionales pueden aprovechar al máximo sus recursos y obtener resultados más precisos y significativos. Desde la evaluación de tratamientos agronómicos hasta el desarrollo de

nuevos medicamentos y aplicaciones en la industria, estos diseños ofrecen un enfoque sistemático y riguroso para la investigación científica, impulsando el avance en diversas áreas y contribuyendo al desarrollo de soluciones innovadoras y eficientes.

## Referencias

1. Anderson, P. (2018). Advanced experimental design techniques in industrial applications. *Journal of Applied Statistics*, 25(4), 345-356.
2. Acosta, E., Fernández, M. O., Roark, G. Y., De Paula, M., Leal, F., & De Queiroz, J. A. (2020). Comparación de métodos de cronometraje en el estudio de métodos y tiempos acordado en la carrera de ingeniería industrial. ResearchGate. <https://www.researchgate.net/publication/338346235>
3. Arreguín, M., Carrillo, G., Hernández, A. D., & Paguay, M. H. (2023). Fundamentos de diseño experimental para ingeniería. EPOCH. Retrieved from [http://cimogsys.esepoch.edu.ec/direccion-publicaciones/public/docs/books/2023-09-27-171440-Fundamentos%20matem%C3%A1ticos%20de%20dise%C3%B1o%20experimental%20para\\_ingenier%C3%ADa.pdf](http://cimogsys.esepoch.edu.ec/direccion-publicaciones/public/docs/books/2023-09-27-171440-Fundamentos%20matem%C3%A1ticos%20de%20dise%C3%B1o%20experimental%20para_ingenier%C3%ADa.pdf)
4. Baque, W. A., & Martínez, M. S. (2021). Diseño experimental aplicado a ciencias agrarias y comerciales con ejercicios resueltos en Rstudio, inforstat, minitab y SPSS (1ª ed.). Colloquium. Retrieved from <https://sbores@colloquium-editorial.com>
5. Borovkov, A. A., & Moullagaliev, A. (2019). Mathematical statistics. Retrieved from <https://www.taylorfrancis.com/books/mono/10.1201/9780203749326/m>
6. Brown, J., & Davis, K. (2017). Randomized block design in industrial experiments. *Industrial Engineering Journal*, 32(3), 210-225.
7. Cabrera Albert, J. S., Fariñas León, G., Hernández Becerra, B., & Navarro Guzmán, J. (2022). Análisis estadístico cuando no se cumplen los supuestos de las pruebas paramétricas, en el contexto de la investigación de la Cultura Física. *Revista Universidad y Sociedad*, 14(S1), 591-600. <https://rus.ucf.edu.cu/index.php/rus/article/view/2747/2706>
8. Clark, R., & Stevens, M. (2019). Factorial designs in process optimization. *Manufacturing Science and Engineering*, 45(2), 167-182.

9. Castaño, E., & Domínguez, J. (2019). Diseño de experimentos. Estrategias y análisis en ciencias e ingeniería (1ª ed.). Alfaomega. Retrieved from [https://api.pageplace.de/preview/DT0400.9786076227558\\_A43652600/preview-9786076227558\\_A43652600.pdf](https://api.pageplace.de/preview/DT0400.9786076227558_A43652600/preview-9786076227558_A43652600.pdf)
10. Chenet, M., Garcés, N., Lagos, G., Salazar, G., & Barbuno, M. (2022). Diseño de investigación experimental aplicados y las ciencias sociales (1ª ed.). UPEC. Retrieved from [https://books.google.com.ec/books?id=wK mzEAAAQBAJ&printsec=frontcover&dq=dis e%C3%B1o+de+experimentos&source=entity\\_page&newbks=0&hl=es&redir\\_esc=y#v=onepage&q&f=false](https://books.google.com.ec/books?id=wK mzEAAAQBAJ&printsec=frontcover&dq=dis e%C3%B1o+de+experimentos&source=entity_page&newbks=0&hl=es&redir_esc=y#v=onepage&q&f=false)
11. Delgado, M. (2020). Uso del diseño de experimentos para la innovación empresarial. *Revista de métodos cuantitativos para la economía y la empresa*, 5(1), 2450. Retrieved from <http://www.upo.es/revistas/index.php/RevMetCuant/article/view/2450>
12. Garcia, L., Martinez, P., & Rodriguez, J. (2021). Implementation of completely randomized design in manufacturing. *Quality Control Review*, 54(1), 88-97.
13. Hernandez, A., & Roberts, S. (2020). Interaction effects in factorial experiments. *Journal of Quality Engineering*, 29(2), 98-115.
14. Jarquín, R. F. (2023). Aplicación diseño experimental cuadrado latino al analizar variedades de semilla del cultivo de arroz (*Oryza Santiva*) en el Valle de Sébaco, Nicaragua. FAREM-Estelí. Retrieved from <https://revistasnicaragua.cnu.edu.ni/index.php/RCientifica/article/view/8394/11136>
15. Johnson, R. (2020). Applications of randomized block design in pharmaceutical production. *Pharmaceutical Science Journal*, 37(5), 223-238.
16. Jones, T., & Smith, A. (2020). Basic principles of completely randomized design. *Experimental Design Methods*, 11(3), 56-72.
17. Kim, H., Park, S., & Lee, J. (2018). Statistical challenges in industrial experiments. *Journal of Industrial Statistics*, 22(4), 320-335.
18. Lee, S. (2019). Homogeneity and randomization in experimental design. *Journal of Experimental Methods*, 15(2), 101-115.
19. López, L. (2021). Diseño de experimentos. Sustainable Sciences Institute. Retrieved from <https://media.tghn.org/medialibrary/2021/08/lecture5.pdf>

20. López, M., Gonzales, F., & Perez, L. (2021). Optimization of manufacturing processes using factorial designs. *Engineering Optimization*, 36(3), 245-260.
21. Introducción al Diseño de Experimentos. (s. f.). Recuperado de <https://halweb.uc3m.es/esp/personal/personas/jmmarin/esp/disenno/introde.pdf>
22. Gabriel, J., Castro, C., Valverde, A., & Indacochea, B. (2017). Diseños experimentales: Teoría y práctica para experimentos agropecuarios. Grupo COMPAS, Universidad Estatal del Sur de Manabí (UNESUM), Jipijapa, Ecuador.
23. Gavilánez, F. (2021). Diseños y Análisis Estadísticos para Experimentos Agrícolas. Díaz de Santos. Retrieved from [https://books.google.es/books?hl=es&lr=&id=AGY4EAAAQBAJ&oi=fnd&pg=PR1&dq=m%C3%A9todo+estad%C3%ADstico+en+dise%C3%B1o+de+experimentos&ots=TGooavZjcr&sig=ev29ktvmRj4Ig\\_Y4jZt0YCpAB6c#v=onepage&q&f=true](https://books.google.es/books?hl=es&lr=&id=AGY4EAAAQBAJ&oi=fnd&pg=PR1&dq=m%C3%A9todo+estad%C3%ADstico+en+dise%C3%B1o+de+experimentos&ots=TGooavZjcr&sig=ev29ktvmRj4Ig_Y4jZt0YCpAB6c#v=onepage&q&f=true)
24. Gutiérrez, H., & De la Vara, R. (Eds.). (2020). Análisis y diseño de experimentos (2ª ed.). McGraw Hill. Retrieved from [https://gc.scalahed.com/recursos/files/r161r/w19537w/analisis\\_y\\_diseño\\_experimentos.pdf](https://gc.scalahed.com/recursos/files/r161r/w19537w/analisis_y_diseño_experimentos.pdf)
25. Martin, G., & Lee, T. (2019). Applications of Latin square design in chemical processes. *Journal of Chemical Engineering*, 42(2), 178-190.
26. Mishra, P., Pandey, C. M., Singh, U., Gupta, A., Sahu, C., & Keshri, A. (2019). Descriptive statistics and normality tests for statistical data. *Annals of Cardiac Anaesthesia*.
27. Montgomery, D. (2020). Design and analysis of experiments (10ª ed.). Wiley. Retrieved from <https://www.amazon.com/design-analysis-experiments-douglas-montgomery/dp/1119492491?asin=1119722101&revisionid=&format=4&depth=1>
28. Nguyen, V., Tran, H., & Le, D. (2020). Greco-Latin square designs in industrial research. *International Journal of Industrial Research*, 19(4), 310-328.
29. Rodó, P., & Sevilla, A. (2019). Interacción entre variables independientes binarias. *Economipedia*.
30. Rodriguez, J., Garcia, L., & Martinez, P. (2021). Comprehensive review of Latin square applications. *Research in Experimental Design*, 23(1), 50-67.

31. Rosero, C. X. (2021). Diseño de experimentos y análisis de conjunto. Universidad Ecotec. Retrieved from <https://libros.ecotec.edu.ec/index.php/editorial/catalog/download/73/65/1037-1?inline=1>
32. Sampson, M. A. G. (2018). Statistical analysis in JASP: A guide for students. Retrieved from <https://static.jasp-stats.org/Statistical%20Analysis%20in%20JASP%20-%20A%20Students%20Guide%20v1.0.pdf>
33. Smith, J., Brown, J., & Davis, K. (2018). Evaluating block designs in quality control. *Journal of Quality Management*, 27(3), 122-139.
34. Torres, Ú. (s.f.). Apuntes de diseño de experimento. Contraste de hipótesis.
35. Thompson, R. (2018). Challenges in implementing advanced experimental designs. *Industrial Engineering Journal*, 33(1), 12-29.
36. Triola, M. F. (2018). Estadística (12<sup>a</sup> ed.). Pearson. Retrieved from <http://librodigital.sangregorio.edu.ec/librosusgp/B0038.pdf>
37. Williams, T., & Patel, M. (2017). Controlling variability in experimental design. *Statistical Methods in Research*, 20(2), 89-105.

© 2024 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).