

**TECNOLÓGICO NACIONAL DE MÉXICO
CAMPUS LOS MOCHIS**

**TRABAJO DEL PROGRAMA DE AÑO SABATICO
EN SU SEGUNDA ETAPA;
del 20 de Julio de 2025 al 19 de Enero de 2026
QUE CONSISTE EN LA ELABORACIÓN DE APUNTES EN LA
MODALIDAD:**

**B.1 Elaboración de apuntes / B.1.2 Elaboración de apuntes de
asignatura con título:**

“Estadística Inferencial II / GEG-0908 IGEM-2009-201”

Presentado por:

MC JOSÉ SANTOS ROJO LÓPEZ

Profesor adscrito al Departamento de Ciencias Básicas

Los Mochis, Sinaloa a 19 de Enero de 2026

INDICE-----	2
--------------------	----------

INTRODUCCIÓN -----	4
---------------------------	----------

Programa de Estadística Inferencial II para IGEM-2009-201

1.- Regresión lineal simple y correlación

1.1 Modelo de regresión simple -----	5
1.2 Supuestos -----	5
1.3 Determinación de la ecuación de regresión -----	6
1.4 Medidas de variación -----	7
1.5 Cálculo de los coeficientes de correlación y de determinación -----	8
1.6 Análisis residual -----	9
1.7 Inferencias acerca de la pendiente -----	10
1.8 Aplicaciones -----	11

2. Regresión lineal múltiple y correlación

2.1 Modelo de regresión múltiple.	
Estimación de la ecuación de regresión múltiple -----	13
2.2 Matriz de varianza-covarianza -----	14
2.3 Pruebas de hipótesis para los coeficientes de regresión -----	15
2.4 Correlación lineal múltiple -----	16
2.5 Aplicaciones -----	17

3. Análisis de serie de tiempo

3.1 Componentes de una serie de tiempo -----	19
3.2 Método de mínimos cuadrados -----	21
3.3 Métodos de promedios móviles -----	22
3.4 Métodos de suavización exponencial -----	23
3.5 Tendencias no lineales -----	24
3.6 Variación estacional -----	25
3.7 Aplicaciones -----	29

4. Diseño experimental para un factor

4.1 Introducción, conceptualización, importancia y alcances del diseño	
Experimental en el ámbito empresarial -----	30
4.2 Clasificación de los diseños experimentales -----	32
4.3 Nomenclatura y simbología en el diseño experimental -----	38
4.4 Identificación de los efectos de los diseños experimentales -----	40
4.5 La importancia de la aleatorización de los especímenes de prueba --	41
4.6 Supuestos estadísticos en las pruebas experimentales -----	42
4.7 Prueba de Duncan -----	43
4.8 Aplicaciones industriales -----	45

5. Diseño experimental con bloques al azar y diseños factoriales

5.1 Metodología del diseño experimental de bloques al azar -----	47
5.2 Diseño de experimentos factoriales -----	49
5.3 Diseño factorial 2^k -----	54
5.4 Diseño de cuadros latinos -----	56
5.5 Diseños de cuadros grecolatinos -----	60
5.6 Aplicaciones -----	65

INTRODUCCIÓN:

El modelo educativo vigente en el TecNM es de competencias desde el año 2019 y la realización de apuntes de diversas asignaturas en las competencias previas, considerando los objetivos que además de diseñar estrategias para desarrollar la cátedra de ESTADÍSTICA INFERENCIAL II se basan en los programas que existen en la carrera de Ingeniería de Gestión Empresarial (IGE) que permitirá a los estudiantes de esas carreras adquirir las competencias requeridas para aplicarlas en las materias que se encuentran seriadas y de otras materias donde se abordan temas Estadísticos.

En la elaboración de estos apuntes, además de la Teoría necesaria al abordar los diferentes temas se dará énfasis en la aplicación estadística a una serie de problemas técnicos y reales relacionados con el perfil de la carrera señalada, además en la aplicación y manejo del Software Estadístico de Mini-Tab 19 como una forma alternativa más rápida y eficaz de resolver algunos de los problemas que se presentan en estas áreas.

La educación es uno de los grandes problemas nacionales y se le considera de interés prioritario para el desarrollo del País y en particular en el TecNM es cada vez mayor la necesidad de que sus egresados salgan con la mejor preparación posible para que puedan enfrentar los retos que se les presente en su actividad profesional y que mejor manera de que se desarrollen apuntes dirigido a los Docentes y Alumnos que cursaran las materias señaladas para que de una manera ágil y sencilla puedan entender la Teoría y realizar la práctica necesaria para un aprendizaje más eficiente y eficaz.

Con este aporte de apuntes para la asignatura de Estadística Inferencial II que se imparte en la carrera de Ingeniería en Gestión Empresarial en el Sistema del TecNM en los diferentes Tecnológicos que a su vez ofrecen estas carreras se verá fortalecidos con la actualización y una mejor estrategia para el aprendizaje del conocimiento y su aplicación en áreas prácticas.

1.- Regresión lineal simple y correlación

1.1 Modelo de regresión simple

El modelo de regresión lineal simple para IGE de nivel superior se puede expresar de la siguiente manera:

$$Y = a + b(X)$$

Dónde: Y es la variable dependiente o la variable que se predecirá

X es la variable independiente o variable de predicción

Los coeficientes **a** y **b** en una gráfica representan los parámetros de intercepto y pendiente respectivamente y se estiman a través del análisis de regresión lineal. Este modelo se utiliza para analizar la relación entre la variable que se predecirá (Y) en IGE, para determinar su capacidad predictiva en función de (X).

1.2 Supuestos

En regresión lineal simple, cuando se habla de los supuestos a nivel superior (o supuestos clásicos del modelo), normalmente se hace referencia a los supuestos teóricos del modelo poblacional, no a los diagnósticos empíricos. Son los siguientes:

1. Linealidad del modelo

La relación entre la variable dependiente Y y la variable independiente X es lineal en los parámetros:

$$Y = a + bX$$

2. Exogeneidad (media condicional cero)

El término de error tiene esperanza cero dado X:
Esto implica que X no está correlacionada con el error.

3. Varianza constante del error (homocedasticidad)

La varianza del término de error es constante para todos los valores de X:

4. Independencia de las observaciones

Los errores no están correlacionados entre sí, Este supuesto es clave especialmente en datos de medidas de variación en series de tiempo.

5. No multi-colinealidad perfecta

En regresión simple, X debe tener variación:

(En la práctica, este supuesto es trivial en regresión simple.)

6. Normalidad del error (supuesto adicional para inferencia exacta)

Este supuesto no es necesario para que los estimadores (MCO) Mínimos Cuadrados Ordinarios sean in-sesgados, pero sí para pruebas de hipótesis e intervalos de confianza en muestras pequeñas.

En resumen, estos supuestos garantizan que los estimadores de (MCO) sean in-sesgados, eficientes y que la inferencia estadística sea válida.

1.3 Determinación de la ecuación de regresión

Alternativas para determinar los valores de los coeficientes de regresión **a** y **b** de una Ecuación de Regresión del tipo:

$$y = a + bx$$

1.- Solucionando el sistema de ecuaciones que se genera

2.- Determinando los valores:

$$S_{xx} = \sum x^2 - \frac{1}{n} (\sum x)^2$$

$$S_{xy} = \sum xy - \frac{1}{n} (\sum x)(\sum y)$$

Sustituyendo:

$$b = \frac{S_{xy}}{S_{xx}} \quad a = \frac{\sum y - b(\sum x)}{n}$$

3.- Determinando los valores:

$$a = \frac{(\sum y)(\sum x^2) - (\sum x)(\sum xy)}{n(\sum x^2) - (\sum x)^2} \quad b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2}$$

4.- Usando un software estadístico de computación

1.4 Medidas de variación

En este contexto, las medidas de variación más comunes son las siguientes:

1. **Suma Total de Cuadrados (SST):** Mide la variación total de la variable dependiente (Y) alrededor de su media.
2. **Suma de Cuadrados de la Regresión (SSR):** Mide la variación explicada por el modelo de regresión.
3. **Suma de Cuadrados de los Errores (SSE):** Mide la variación no explicada por el modelo, es decir, los errores residuales.

Estas tres medidas están relacionadas por la siguiente ecuación:

$$SST = SSR + SSE$$

Además, el **Coeficiente de Determinación (R^2)** es una medida importante que indica la proporción de la variación total de Y que es explicada por el modelo de regresión. Un valor de R^2 cercano a 1 indica que el modelo explica una gran parte de la variación de Y, mientras que un valor cercano a 0 indica lo contrario.

1.5 Cálculo de los coeficientes de correlación y de determinación

CORRELACIÓN LINEAL

$$\sum(y - \bar{y})^2 = \sum(\hat{y} - \bar{y})^2 + \sum(y - \hat{y})^2$$

(Suma Total de Cuadrados) = (Suma de Cuadrados de Regresión) + (Suma Residual de Cuadrados)

Suma de Cuadrados de Regresión: Mide la porción de la variación total de las y que existiría si las diferencias en x fueran las únicas causas de las diferencias entre las y

Suma Residual de Cuadrados: Es la suma de las desviaciones cuadradas de los valores de y observados de sus valores correspondientes $\hat{y}$ sobre la recta

PARA REGRESIÓN LINEAL SIMPLE

Coefficiente de Determinación (r^2)

Coefficiente de Correlación (r)

$$a) \quad r^2 = \frac{\sum(\hat{y} - \bar{y})^2}{\sum(y - \bar{y})^2}$$

$$r = \sqrt{\frac{\sum(\hat{y} - \bar{y})^2}{\sum(y - \bar{y})^2}}$$

$$b) \quad r^2 = \frac{bS_{xy}}{S_{yy}}$$

$$r = \sqrt{\frac{bS_{xy}}{S_{yy}}}$$

$$c) \quad r^2 = \frac{s_{xy}^2}{s_{xx}s_{yy}}$$

$$r = \sqrt{\frac{s_{xy}^2}{s_{xx}s_{yy}}} = \frac{s_{xy}}{\sqrt{s_{xx}s_{yy}}}$$

1.6 Análisis residual

El **análisis residual** en la regresión lineal simple es una herramienta fundamental para evaluar la validez y calidad de un modelo de regresión. Se centra en el estudio de los **residuos**, que son las diferencias entre los valores observados Y_i y los valores predichos $\hat{Y}_i$ por el modelo: $e_i = Y_i - \hat{Y}_i$

Objetivos del análisis residual (nivel superior)

1. Verificar supuestos del modelo:

Linealidad: Los residuos no deben mostrar patrones sistemáticos (deberían distribuirse aleatoriamente alrededor de cero).

Homocedasticidad: La varianza de los residuos debe ser constante (sin "forma de embudo" en gráficos).

Normalidad: Los residuos deberían seguir aproximadamente una distribución normal (se verifica con histogramas o test como Shapiro-Wilk).

Independencia: Los residuos no deben estar correlacionados (importante en series temporales; se usa el test de Durbin-Watson).

2. Identificar valores atípicos:

Residuos extremadamente grandes (en valor absoluto) pueden indicar observaciones influyentes que distorsionan el modelo.

3. Detectar puntos influyentes:

Usando medidas como la **distancia de Cook**, que identifican observaciones que afectan desproporcionadamente los coeficientes del modelo.

Herramientas gráficas y técnicas

- **Gráfico de residuos vs. predichos:**

Si hay patrones (curvas, dispersión no uniforme), sugiere no linealidad o heterocedasticidad.

- **Gráfico Q-Q (Cuantil-Cuantil):**

Evalúa normalidad: si los puntos se alinean con la recta teórica, los residuos son normales.

- **Gráfico de residuos vs. variables independientes:**

Ayuda a detectar si faltan términos no lineales en el modelo.

Ejemplo de interpretación

Si en el gráfico de residuos vs. pre-dichos aparece una "forma de U", indica que el modelo lineal no captura una relación no lineal subyacente, sugiriendo la necesidad de transformar variables o añadir términos cuadráticos.

Conclusión

El análisis residual es crítico para asegurar que el modelo cumple con los supuestos de la regresión lineal y para mejorar su precisión. Si falla, pueden requerirse transformaciones (logarítmicas, polinómicas) o modelos alternativos.

1.7 Inferencias acerca de la pendiente

En una ecuación de regresión lineal simple de la forma: $Y = a + bX + \epsilon$ se pueden hacer varias inferencias sobre la recta de regresión a un nivel superior, especialmente desde una perspectiva estadística y de modelado predictivo. Aquí algunas de las más relevantes:

1. Significancia del Coeficiente de Pendiente β_1

Hipótesis nula H_0 : $\beta_1 = 0$ (no hay relación lineal entre (X) e (Y)).

Hipótesis alternativa H_1 : $\beta_1 > 0$ (existe una relación lineal).

Se usa una **prueba t** para determinar si β_1 es estadísticamente significativo.

Si el **p-valor** es menor que el nivel de significancia (ej. 0.05), se rechaza H_0 , indicando que la pendiente es significativa.

2. Bondad de Ajuste R^2

El **coeficiente de determinación R^2** mide la proporción de la variabilidad de Y explicada por X.

Un R^2 cercano a 1 indica un buen ajuste, mientras que uno cercano a 0 sugiere que el modelo no explica bien la variabilidad.

3. Intervalos de Confianza para los Coeficientes

Se pueden calcular intervalos de confianza (ej. 95%) para β_0 y β_1 .

Si el intervalo de β_1 no incluye el 0, se confirma su significancia estadística.

4. Supuestos del Modelo

Linealidad: La relación entre X e Y debe ser lineal.

Homocedasticidad: La varianza de los residuos debe ser constante.

Normalidad de los residuos: Los errores ϵ deben distribuirse normalmente (importante para inferencia).

Independencia: Las observaciones deben ser independientes (no auto-correlacionadas).

5. Predicción y Error

La recta permite predecir (Y) dado (X), pero con un **intervalo de predicción** (más amplio que el de confianza).

El **error estándar de la estimación** mide la precisión de las predicciones.

6. Sensibilidad

Los valores atípicos pueden distorsionar la pendiente β_1 y el intercepto β_0 .

Técnicas como **regresión robusta** o análisis de residuos ayudan a detectarlos.

Conclusión

En un nivel superior, la recta de regresión no solo describe una relación lineal, sino que también permite hacer inferencias sobre la fuerza, significancia y validez del modelo, así como evaluar su capacidad predictiva y cumplimiento de supuestos estadísticos.

1.8 Aplicaciones

La **regresión lineal simple** es una herramienta estadística fundamental con diversas aplicaciones en el nivel superior (educación universitaria, investigación y campos profesionales), algunas de las más relevantes:

1. Economía y Finanzas

Predicción de tendencias: Analizar la relación entre variables como inflación y tasas de interés.

Evaluación de riesgos: Estimar cómo factores como el PIB afectan el rendimiento de inversiones.

2. Ciencias Sociales

Investigación en psicología y sociología: Estudiar relaciones como horas de estudio vs. rendimiento académico.

Políticas públicas: Analizar el impacto de programas sociales en indicadores como empleo o pobreza.

3. Ingeniería y Ciencias Naturales

Modelado de procesos: Relacionar variables como temperatura y resistencia de materiales.

Optimización: Mejorar procesos industriales (ej.: producción vs. costos).

4. Salud y Medicina

Epidemiología: Analizar cómo factores como dieta influyen en enfermedades crónicas.

Farmacología: Estudiar la relación entre dosis de medicamentos y efectividad.

5. Marketing y Negocios

Análisis de mercado: Predecir ventas en función de gastos en publicidad.

Satisfacción del cliente: Relacionar calidad de servicio con lealtad del cliente.

6. Educación

Evaluación académica: Medir cómo horas de estudio afectan calificaciones.

Toma de decisiones: Diseñar estrategias basadas en datos para mejorar resultados educativos.

Ventajas en el nivel superior

Sencillez: Fácil de interpretar y aplicar incluso con conocimientos básicos de estadística.

Base para modelos avanzados: Sirve como introducción a técnicas más complejas (regresión múltiple)

2. Regresión lineal múltiple y correlación

2.1 Modelo de regresión múltiple.

Estimación de la ecuación de regresión múltiple

Forma del Modelo: La ecuación de regresión lineal múltiple es:

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k + \epsilon$$

Dónde:

$Y \rightarrow$ es la variable dependiente (la que queremos predecir).

$k \rightarrow$ Número de variables independientes

$X_1, X_2, \dots, X_k \rightarrow$ son las variables independientes (predictoras).

$b_0 \rightarrow$ es el término constante (intercepto).

$b_1, b_2, \dots, b_k \rightarrow$ son los coeficientes de regresión parciales y representan el cambio esperado en (Y) por un cambio unitario en la correspondiente variable independiente, manteniendo constantes las demás variables.

$\epsilon \rightarrow$ es el término de error (residual), que captura la variabilidad en (Y) no explicada por las variables independientes (diferencia entre el valor real y el predicho).

Supuestos:

Para que el modelo sea válido, se deben cumplir ciertos supuestos:

Linealidad: La relación entre las variables independientes y la dependiente es lineal.

Independencia de errores: Los residuos (errores) son independientes entre sí.

Homocedasticidad: La varianza de los errores es constante a lo largo de todos los valores de las variables independientes.

Normalidad de errores: Los errores se distribuyen normalmente (importante para inferencia).

No multicolinealidad: Las variables independientes no están altamente correlacionadas entre sí. La alta correlación entre predictores puede distorsionar los coeficientes y hacer inestable el modelo.

Propósito:

Predicción: Predecir valores de la variable dependiente basándose en nuevas observaciones de las variables independientes.

Inferencia: Comprender la relación entre las variables. Por ejemplo, cuál de las variables independientes tiene un mayor impacto en la variable dependiente (mientras se controlan las demás).

Estimación de los Coeficientes:

El método más común es el de Mínimos Cuadrados. Este método busca minimizar la suma de los cuadrados de las diferencias entre los valores observados ($X_1, X_2, \dots, X_k$) y los valores predichos por el modelo (Y).

Evaluación del Modelo:

Coefficiente de Determinación (R^2): Mide la proporción de la variabilidad total de (Y) que es explicada por el modelo. R^2 ajustado es una versión modificada que penaliza la adición de variables innecesarias.

Pruebas de hipótesis: Pruebas t para verificar la significancia individual de cada coeficiente y prueba F para la significancia global del modelo.

2.2 Matriz de varianza-covarianza

En el contexto de la regresión lineal múltiple, la matriz de varianza-covarianza de los coeficientes estimados (a menudo denotada como Σ o $\text{Var}\hat{\beta}$) es una matriz que contiene las varianzas de los coeficientes estimados en su diagonal y las covarianzas entre los coeficientes estimados en las posiciones fuera de la diagonal.

¿Cómo se calcula?

La matriz de varianza-covarianza de los coeficientes estimados se calcula como:

$$\text{Var}\hat{\beta} = \sigma^2 (\text{Mtx}(X)^T \text{Mtx}(X))^{-1}$$

Dónde:

σ^2 es la varianza del error (o residuos) en el modelo.

$\text{Mtx}(X)$ es la matriz de diseño que contiene las variables independientes (predictores).

$((\text{Mtx}(X)^T \text{Mtx}(X))^{-1})$ es la inversa de la matriz producto cruzado de $\text{Mtx}(X)$.

Interpretación:

Los elementos de la diagonal principal de esta matriz representan las **varianzas** de los coeficientes estimados $\beta_0, \beta_1, \dots, \beta_n$.

Los elementos fuera de la diagonal representan las **covarianzas** entre los coeficientes estimados.

Ejemplo:

Si tienes un modelo con dos predictores X_1 y X_2 , la matriz de varianza-covarianza podría verse así:

$$\widehat{\text{Var}}\boldsymbol{\beta} = \begin{bmatrix} \text{Var}\beta_0 & \text{Cov}\beta_0, \beta_1 & \text{Cov}\beta_0, \beta_2 \\ \text{Cov}\beta_1, \beta_0 & \text{Var}\beta_1 & \text{Cov}\beta_1, \beta_2 \\ \text{Cov}\beta_2, \beta_0 & \text{Cov}\beta_2, \beta_1 & \text{Var}\beta_2 \end{bmatrix}$$

Importancia:

Esta matriz es crucial para realizar inferencias sobre los coeficientes, para calcular intervalos de confianza o realizar pruebas de hipótesis.

Por su dificultad matemática para resolver la matriz varianza-covarianza es recomendable usar un software matemático como Mat-Lab ó un estadístico como Mini-Tab 19.

2.3 Pruebas de hipótesis para los coeficientes de regresión

Prueba de Hipótesis para Coeficientes

1) Plantear las Hipótesis:

$$H_0 : \beta_k = \beta_{k_0}$$

$$H_1 : \beta_k \neq \beta_{k_0}$$

2) Valores Críticos:

$$t_{CR(gl, \alpha/2)} \rightarrow \text{Valor de la dist. "t de Student" con } gl = n - k - 1$$

3) Valor a Comparar:

$$t_{CM} = \frac{b_k - \beta_{k_0}}{S_k}$$

4) Decisión: Si $-t_{CR} \leq t_{COMP} \leq t_{CR} \rightarrow$ Se acepta H_0

Si **NO** ----- entonces ----- $\rightarrow$ Se rechaza H_0
Se acepta H_1

2.4 Correlación lineal múltiple

CORRELACIÓN LINEAL

$$\sum(y - \bar{y})^2 = \sum(\hat{y} - \bar{y})^2 + \sum(y - \hat{y})^2$$

(Suma Total de Cuadrados) = (Suma de Cuadrados de Regresión) + (Suma Residual de Cuadrados)

Suma de Cuadrados de Regresión: Mide la porción de la variación total de las **y** que existiría si las diferencias en **x** fueran las únicas causas de las diferencias entre las **y**

Suma Residual de Cuadrados: Es la suma de las desviaciones cuadradas de los valores de **y** observados de sus valores correspondientes $\hat{y}$ sobre la recta

PARA REGRESIÓN LINEAL MÚLTIPLE

$$\text{a) } r^2 = 1 - \frac{\sum(y - \hat{y})^2}{\sum(y - \bar{y})^2}$$

$$r = \sqrt{1 - \frac{\sum(y - \hat{y})^2}{\sum(y - \bar{y})^2}}$$

2.5 Aplicaciones

La regresión lineal múltiple es una herramienta estadística poderosa con aplicaciones amplias en el nivel superior (educación universitaria, investigación y campos profesionales), algunas de las aplicaciones más relevante

1. Economía y Finanzas

Predicción de indicadores económicos: Analizar cómo múltiples factores (inflación, desempleo, PIB) afectan el crecimiento económico.

Evaluación de riesgos: Estimar el impacto de varias variables (tasas de interés, volatilidad del mercado) en el rendimiento de inversiones.

2. Ciencias Sociales

Investigación en psicología y sociología: Estudiar cómo múltiples factores (educación, ingresos, género) influyen en comportamientos o actitudes.

Políticas públicas: Evaluar el efecto combinado de programas sociales, educación y acceso a servicios en indicadores como pobreza o salud.

3. Ingeniería y Ciencias Naturales

Modelado de procesos: Relacionar múltiples variables (temperatura, presión, tiempo) con resultados en procesos industriales o químicos.

Optimización: Mejorar sistemas complejos (ej.: producción, eficiencia energética) considerando varios factores simultáneamente.

4. Salud y Medicina

Epidemiología: Analizar cómo múltiples factores (dieta, ejercicio, genética) influyen en enfermedades crónicas.

Farmacología: Estudiar el efecto combinado de dosis, frecuencia y características del paciente en la efectividad de medicamentos.

5. Marketing y Negocios

Análisis de mercado: Predecir ventas en función de múltiples factores (publicidad, precio, competencia).

Satisfacción del cliente: Relacionar calidad de servicio, precio y experiencia del cliente con la lealtad hacia una marca.

6. Educación

Evaluación académica: Medir cómo múltiples factores (horas de estudio, asistencia, recursos) afectan el rendimiento estudiantil.

Toma de decisiones: Diseñar estrategias basadas en datos para mejorar resultados educativos considerando varios aspectos simultáneamente.

Ventajas en el nivel superior

Flexibilidad: Permite analizar relaciones complejas entre múltiples variables.

Inferencia estadística: Facilita la realización de pruebas de hipótesis y la construcción de intervalos de confianza para los coeficientes.

Base para modelos avanzados: Sirve como introducción a técnicas más complejas (regresión logística, machine learning).

3. Análisis de serie de tiempo

3.1 Componentes de una serie de tiempo


Las series de tiempo en estadística inferencial, desde una perspectiva de Ingeniería en Gestión Empresarial, son conjuntos de datos recolectados secuencialmente en el tiempo donde el orden temporal es fundamental para su análisis. Su objetivo principal es modelar y predecir el comportamiento futuro de una variable basándose en sus patrones históricos, son conjuntos de datos recolectados secuencialmente a lo largo de intervalos temporales específicos (como horas, días, meses o años). Estos datos representan observaciones de una variable medida en distintos momentos, lo que permite analizar patrones, tendencias o comportamientos a través del tiempo. En resumen, las series de tiempo en estadística inferencial permiten extraer información temporal para tomar decisiones basadas en datos esencial en economía, meteorología, ingeniería y otras áreas.

Modelo clásico de series de tiempo

Clasificación de Series de Tiempo Las características de una serie de tiempo pueden estar definida por cuatros tiempos principales, llamados a menudo componentes de una serie de tiempo.


Análisis de fluctuaciones

Variaciones Cíclicas (C): se refiere a las oscilaciones de larga duración alrededor de la recta o curva de tendencia; estos ciclos, como se llaman a veces, pueden ser o no periódicos, es decir, puede seguir o no exactamente caminos análogos después de intervalos de tiempo iguales. El ejemplo más común de fluctuación cíclica es el ciclo de negocios. A través del tiempo, hay años en que el ciclo de negocios llega a un pico por encima de la línea de tendencia. En otros tiempos, la actividad de los negocios parece caer, llegando a un punto bajo la línea de tendencia. El tiempo que transcurre entre picos o puntos bajos es de al menos 1 año y puede llegar a durar hasta 15 o 20 años. (Automóviles, celulares)




Análisis de tendencia.

Variaciones de Tendencias, seculares o de larga duración (T): se refiere a la dirección general a la que el gráfico de una serie de tiempo parece dirigirse en un intervalo grande de tiempo, esta variación se indica por una curva de tendencia que aparece a trazos. El valor de la variable tiende a aumentar o disminuir en un periodo muy largo. El incremento estable en los costos de vida registrados en el Índice de Precios al Consumidor (IPC) es un ejemplo de tendencia secular.



Análisis de variaciones cíclicas

Variaciones Cíclicas (C): se refiere a las oscilaciones de larga duración alrededor de la recta o curva de tendencia; estos ciclos, como se llaman a veces, pueden ser o no periódicos, es decir, puede seguir o no exactamente caminos análogos después de intervalos de tiempo iguales. El ejemplo más común de fluctuación cíclica es el ciclo de negocios. A través del tiempo, hay años en que el ciclo de negocios llega a un pico por encima de la línea de tendencia. En otros tiempos, la actividad de los negocios parece caer, llegando a un punto bajo la línea de tendencia. El tiempo que transcurre entre picos o puntos bajos es de al menos 1 año y puede llegar a durar hasta 15 o 20 años. (Automóviles, celulares)



Medición de variaciones estacionales e irregulares.

Variaciones Irregulares (I): son movimientos esporádicos de las series de tiempo debido a sucesos ocasionales, tales como inundaciones, huelgas, elecciones, etc. Aunque normalmente se supone que tales sucesos producen variaciones que solamente duran un corto intervalo de tiempo. El valor de una variable no se puede predecir, es decir, cambia de forma aleatoria. Ejemplo: Conflictos mundiales, como el conflicto petrolero en el Medio Oriente en 1973, otro ejemplo es la situación en Irán en 1979-1981, la caída de la OPEP en 1986 y el conflicto en Irak en 1990 afectaron los precios de la gasolina en Estados Unidos son ejemplos de variación irregular.



3.2 Método de mínimos cuadrados

ANÁLISIS DE TENDENCIAS

En la tabla 1 se presentan los datos de ventas para un periodo de 11 años de una compañía que empezó a operar en el año 2020.

Tabla No. 1

Año	Año Codificado (X)	Ventas en Miles de Millones (Y)	XY	X ²
2015	0	0.20	0.0	0
2016	1	0.40	0.4	1
2017	2	0.50	1.0	4
2018	3	0.90	2.7	9
2019	4	1.10	4.4	16
2020	5	1.50	7.5	25
2021	6	1.30	7.8	36
2022	7	1.10	7.7	49
2023	8	1.70	13.6	64
2024	9	1.90	17.1	81
2025	10	2.30	23	100
Totales n = 11	$\sum X = 55$	$\sum Y = 12.9$	$\sum XY = 85.2$	$\sum X^2 = 385$

Determine la Ecuación de Tendencia Lineal para los datos usando el método de mínimos cuadrados, codificando el año 2015 como 0, y llevando todos los valores a dos cifras decimales.

Ec. de Tendencia: $Y_T = b_0 + b_1X$

$$\bar{X} = \frac{\sum X}{n} = \frac{55}{11} = 5 \quad \bar{Y} = \frac{\sum Y}{n} = \frac{12.9}{11} = 1.17$$

$$b_1 = \frac{\sum XY - n\bar{X}\bar{Y}}{\sum X^2 - n\bar{X}^2} = \frac{85.2 - (11 \times 5 \times 1.17)}{385 - (11 \times 5^2)} = 0.19$$

$$b_0 = \bar{Y} - b_1\bar{X} = 1.17 - (0.19 \times 5) = 0.22$$

$$Y_T = 0.22 + 0.19X$$

4

3.3 Métodos de promedios móviles

Un *promedio móvil* es el promedio de los n valores de datos más recientes de una serie de tiempo, este procedimiento puede representarse como:

$$PM = \frac{\sum(n \text{ valores más recientes})}{n}$$

A medida que se dispone del nuevo valor de un dato de una serie de tiempo, la nueva observación se reemplaza a la antigua en la serie de n valores como base para determinar el nuevo promedio, lo que explica el motivo de que se le llame *promedio móvil*

Remitiéndonos a los datos de serie de tiempo anuales de la Tabla 1. Comience con 2019 y determine los promedios móviles de 3 años que se habrían usado para pronosticar las ventas (en millones) de los años subsecuentes para cada grupo de tres años.

Tabla No. 2

Año (t)	Ventas en millones (Y_t)	Pronóstico ($\hat{Y}_t$)
2019	\$ 1.1	
2020	1.5	
2021	1.3	
2022	1.1	$(1.1+1.5+1.3)/3 =$ \$ 1.3

2023	1.7	1.3
2024	1.9	1.4
2025	2.3	1.6
2026		2.0

El promedio móvil puede servir para pronosticar los valores de datos del siguiente periodo de la serie de tiempo, pero no los datos de periodos más distantes a futuro. Es por lo tanto un método adecuado de pronóstico cuando en los datos no está presente la influencia de una tendencia, cíclica o estacional, situación por demás improbable. Así, este procedimiento sirve sencillamente para promediar el componente irregular de los datos más recientes de una serie de tiempo.

3.4 Métodos de suavización exponencial

SUAVIZACIÓN EXPONENCIAL COMO MÉTODO DE PRONÓSTICO

El procedimiento simplificado para la suavización exponencial requiere de un pronóstico “semilla” inicial y se puede determinar mediante la siguiente fórmula:

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha (Y_t - \hat{Y}_t)$$

Dónde: $\hat{Y}_{t+1} \rightarrow$ Pronóstico para el siguiente periodo

$\hat{Y}_t \rightarrow$ Pronóstico para el periodo más reciente

$\alpha \rightarrow$ Constante de suavización ($0 \leq \alpha \leq 1$)

$Y_t \rightarrow$ Valor real para el periodo más reciente

Con referencia a los datos anuales de la serie de tiempo de la Tabla 1, y utilizando el nivel real de ventas del año 2019 (1.1 millones de pesos) como el pronóstico “semilla” de 2020, determine el pronóstico de las ventas anuales, utilizando el método de la suavización exponencial simple y redondeando el pronóstico a una cifra decimal, usando una constante de suavización de $\alpha = 0.20$ y después otra de $\alpha = 0.80$, comparando los dos conjuntos de pronósticos.

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha (Y_t - \hat{Y}_t)$$

$$\hat{Y}_{2020} = \hat{Y}_{2019} + \alpha (Y_{2019} - \hat{Y}_{2019})$$

$$= 1.1 + 0.20(0.4) = 1.1 + 0.08 = 1.18 \cong 1.2$$

PRONÓSTICO: AÑO POR AÑO, CON EL MÉTODO DE SUAVIZACIÓN EXPONENCIAL SIMPLE

TABLA 3

Año (t)	Ventas en millones (Y_t) \$	$\alpha = 0.20$		$\alpha = 0.80$	
		Pronóstico ($\hat{Y}_t$) \$	Error del pronóstico ($Y_t - \hat{Y}_t$)	Pronóstico ($\hat{Y}_t$)	Error del pronóstico ($Y_t - \hat{Y}_t$)
2020	1.5	1.1	0.4	1.1	0.4
2021	1.3	1.2	0.1	1.4	-0.1
2022	1.1	1.2	-0.1	1.3	-0.2
2023	1.7	1.2	0.5	1.1	0.6
2024	1.9	1.3	0.6	1.6	0.3
2025	2.3	1.4	0.9	1.8	0.5
2026		1.6		2.2	

3.5 Tendencias no lineales

Algunas de las tendencias no lineales en series de tiempo en el nivel superior incluyen ciclos, caos y patrones fractales.

Ciclos: son fluctuaciones regulares en una serie de tiempo que se repiten en intervalos predecibles. Estos ciclos pueden ser de corto, mediano o largo plazo y pueden influir en el comportamiento de la serie de tiempo de manera significativa.

Caos: el caos se refiere al comportamiento impredecible y altamente sensible a las condiciones iniciales en una serie de tiempo. En el nivel superior, el caos puede manifestarse como cambios bruscos y desordenados en la tendencia de la serie de tiempo, lo que dificulta su predicción a largo plazo.

Patrones fractales: los patrones fractales son estructuras complejas y auto-similares que se repiten a diferentes escalas en una serie de tiempo. Estos patrones pueden surgir en el nivel superior como regularidades no lineales que se mantienen constantes a lo largo del tiempo, creando formas geométricas irregulares y repetitivas.

3.6 Variación estacional

MEDICIONES DE VARIACIONES ESTACIONALES

ANÁLISIS DE TENDENCIAS

En la tabla 1 se presentan los datos de ventas para un periodo de 11 años de una compañía que empezó a operar en el año 2015.

Tabla 1:

Año	Año Codificado (X)	Ventas en Miles de Millones (Y)
2015	0	0.20
2016	1	0.40
2017	2	0.50
2018	3	0.90
2019	4	1.10
2020	5	1.50
2021	6	1.30
2022	7	1.10
2023	8	1.70
2024	9	1.90
2025	10	2.30
Totales		

n = 11

La Tabla 4 muestra los datos trimestrales de ventas para la Empresa cuyos datos anuales se dan en la Tabla 1

Tabla 4:

Trimestre	Ventas trimestrales, en millones de pesos					
	2020	2021	2022	2023	2024	2025
I	500	450	350	550	550	750
II	350	350	200	350	400	500
III	250	200	150	250	350	400
IV	400	300	400	550	600	650

Determine los índices estacionales mediante el método del cociente a promedio móvil

TABLA 5: HOJA DE TRABAJO para determinar los cocientes de promedios móviles para los datos trimestrales de ventas

Año	Trimestre	Ventas	Total móvil de 4 trimestres	Total móvil centrado de 4 trimestres	Promedio móvil centrado de 4 trimestres	Cociente del promedio móvil (%)
2020	I	500				
	II	350				
	III	250	>1500	>2950	>368.75	>67.8
	IV	400	>1450	>2900	>362.50	>110.3
2021	I	450	>1450	>2850	>356.25	>126.3
	II	350	>1400	>2700	>337.50	>103.7
	III	200	>1300	>2500	>312.50	>64.0
	IV	300	>1200	>2250	>281.25	>106.7
2022	I	350	>1050	>2050	>256.25	>136.6
	II	200	>1000	>2100	>362.50	>76.2
	III	150	>1100	>2400	>300.00	>50.0
	IV	400	>1300	>2750	>343.75	>116.4
2023	I	550	>1450	>3000	>375.00	>146.7
	II	350	>1550	>3250	>406.25	>86.2
	III	250	>1700	>3400	>425.00	>58.8
	IV	550	>1700	>3450	>431.25	>127.5
2024	I	550	>1750	>3600	>450.00	>122.2
	II	400	>1850	>3750	>468.75	>85.3
	III	350	>1900	>4000	>500.00	>70.0
	IV	600	>2100	>4300	>537.50	>116.6
2025	I	750	>2200	>4450	>556.25	>134.8
	II	500	>2250	>4550	>568.75	>87.9
	III	400	>2300			
	IV	650				

TABLA 6: CÁLCULO DE LOS ÍNDICES ESTACIONALES PARA LOS DATOS TRIMESTRALES

Trimestre	2020	2021	2022	2023	2024	2025	Media modificada	Índice estacional (Media x 1.0116)
I		126.3	136.6	146.7	122.2	134.8	132.6	134.1
II		103.7	76.2	86.2	85.3	87.9	86.5	87.5
III	67.8	64.0	50.0	58.8	70.0		63.5	64.2
IV	110.3	106.7	116.4	127.5	111.6		112.8	114.1
							Σ 395.4	Σ 399.9

$$\text{Factor de Ajuste Mensual FAM} = \frac{1200}{\text{Suma de Medias Mensuales}}$$

$$\text{Factor de Ajuste Trimestral FAT} = \frac{400}{\text{Suma de Medias Trimestrales}} \quad \text{Ejem: FAT} = \frac{400}{395.4} = 1.0116$$

APLICACIÓN DE AJUSTES ESTACIONALES

VALORES AJUSTADOS ESTACIONALES PARA LOS DATOS TRIMESTRALES (en millones de pesos)

Con referencia a los índices estacionales que se determinaron en la Tabla 6

a) Calcule el valor ajustado estacionalmente para cada trimestre, redondeando los valores a millares de pesos

TABLA 7:

Trimestre	2020	2021	2022	2023	2024	2025
I	373	336	261	410	410	559
II	400	400	229	400	451	571
III	389	312	234	389	545	623
IV	351	263	351	482	576	570

b) Compare los resultados de los trimestres tercero y cuarto de 2025, con base en:

b-1) El nivel reportado de las ventas reales $\left\{ \begin{array}{l} \text{El III trim. del 2025 las ventas fueron de \$ 400 000 000} \\ \text{(Tabla 4)} \end{array} \right.$
 $\left\{ \begin{array}{l} \text{El IV trim. del 2025 las ventas fueron de \$ 650 000 000} \end{array} \right.$

b-2) Los valores con ajuste estacional $\left\{ \begin{array}{l} \text{El III trim. Del 2025 las ventas fueron de \$ 623 000 000.00} \\ \text{(Tabla 6)} \end{array} \right.$
 $\left\{ \begin{array}{l} \text{El IV trim. Del 2025 las ventas fueron de \$ 570 000 000.00} \end{array} \right.$

Aunque se aprecia un aumento en las ventas reales del III al IV trim. y al comparar los valores ajustados estacionales se puede ver que el aumento no fue tan grande como se esperaba mas bien hubo una reducción en las ventas del orden del 8.5 %

Tendencias y estacionales

PRONÓSTICOS CON BASE EN FACTORES ESTACIONALES Y DE TENDENCIA

a) Modificación de la Ecuación de Tendencias con fechas anuales para obtener valores proyectados mensuales

$$Y_T = \frac{b_0}{12} + \left(\frac{b_1}{12}\right)\left(\frac{X}{12}\right) = \frac{b_0}{12} + \frac{b_1}{144}X$$

b) Modificación de la Ecuación de Tendencias con fechas anuales para obtener valores proyectados trimestrales

$$Y_T = \frac{b_0}{4} + \left(\frac{b_1}{4}\right)\left(\frac{X}{4}\right) = \frac{b_0}{4} + \frac{b_1}{16}X$$

c) Modificación de la Ecuación de Tendencias para que el punto base se encuentre a la mitad del primer mes (15 de Enero)

$$Y_T = \frac{b_0}{12} + \frac{b_1}{144}X - (5.5)\left(\frac{b_1}{144}\right)$$

d) Modificación de la Ecuación de Tendencias para que el punto base se encuentre a la mitad del primer trimestre (15 de Feb.)

$$Y_T = \frac{b_0}{4} + \frac{b_1}{16}X - (1.5)\left(\frac{b_1}{16}\right)$$

Simplifique la Ecuación de Tendencias que se elaboró, para que quede expresada en términos de Trimestres y no de Años y que el punto base quede a la mitad del primer trimestre

$$Y_T = \frac{b_0}{4} + \frac{b_1}{16}X - (1.5)\left(\frac{b_1}{16}\right) = \frac{0.22}{4} + \frac{0.19}{16}X - (1.5)\left(\frac{0.19}{16}\right) = \underline{0.055-0.0178+0.0119X}$$

$$Y_T = 0.0372 + 0.0119X$$

Ajuste la ecuación anterior, para que los valores de la tendencia queden en millones de pesos y no en miles de millones de pesos

$$Y_T = 37.2 + 11.9X$$

Pronostique el nivel de ventas trimestrales para cada uno de los trim. de 2026, con base a la Ecuación que se determinó en el inciso anterior y con los índices estacionales calculados en la tabla 7

$$\text{Trimestre I del 2021} \rightarrow 37.2 + 11.9(44) [134.1/100] = \$ 752.03 \text{ millones de pesos}$$

$$\text{Trimestre II del 2021} \rightarrow 37.2 + 11.9(45) [87.5/100] = \$ 501.1 \text{ millones de pesos}$$

$$\text{Trimestre III del 2021} \rightarrow 37.2 + 11.9(46) [64.2/100] = \$ 375.3 \text{ millones de pesos}$$

$$\text{Trimestre IV del 2021} \rightarrow 37.2 + 11.9(47) [114.1/100] = \$ 680.6 \text{ millones de pesos}$$

3.7 Aplicaciones

Las series de tiempo son herramientas importantes en la Ingeniería de Gestión Empresarial, ya que permiten analizar y predecir el comportamiento de variables relevantes para la toma de decisiones en una organización. Algunas aplicaciones de las series de tiempo en este campo incluyen:

Pronóstico de ventas: Las series de tiempo se utilizan para predecir las ventas futuras de un producto o servicio, lo que permite a las empresas planificar su producción, inventario y estrategias de marketing de manera más efectiva.

Análisis de la demanda: A través de la modelización de series de tiempo, las empresas pueden analizar la demanda de sus productos o servicios a lo largo del tiempo, identificando patrones estacionales, tendencias y comportamientos cíclicos.

Gestión de inventario: Las series de tiempo pueden ayudar a optimizar la gestión de inventario al predecir la demanda futura y ajustar los niveles de stock en consecuencia, evitando excesos o faltantes.

Pronóstico de costos y presupuestos: Las series de tiempo también se utilizan para prever los costos de producción, materiales y otros gastos operativos, lo que simplifica la planificación financiera y la fijación de presupuestos.

Análisis de tendencias económicas: Las series de tiempo permiten a las empresas monitorear y analizar indicadores económicos relevantes, como el crecimiento del PIB, la tasa de desempleo o los precios de las materias primas, para anticipar posibles impactos en los negocios.

En resumen, las series de tiempo son una valiosa herramienta en la ingeniería de gestión empresarial para analizar el pasado, comprender el presente y predecir el futuro, facilitando la toma de decisiones informadas y estratégicas en las organizaciones.

2

4. Diseño experimental para un factor

4.1 Introducción, conceptualización, importancia y alcances del diseño Experimental en el ámbito empresarial

BREVE HISTORIA DEL DISEÑO DE EXPERIMENTOS

George EP Box lideró los avances en el diseño de experimentos. Box, quien trabajó ocho años como estadístico en la industria química en Inglaterra, formuló la metodología de superficie de respuestas, que incluye nuevas familias de diseños y estrategias para la experimentación secuencial. Entre 1950 y 1980, el diseño de experimentos se consolidó como una herramienta común, pero principalmente en el ámbito de la investigación y desarrollo. Sin embargo, su aplicación en plantas de producción no se generalizó hasta la década de 1970 debido a limitaciones en recursos computacionales y la falta de conocimientos estadísticos entre ingenieros y especialistas en fabricación.

La década de 1980 marcó un avance significativo en la comprensión y aplicación del diseño de experimentos, impulsado por los logros en calidad de la industria japonesa. El movimiento de calidad, liderado por expertos como Deming e Ishikawa, fomentó el uso de la estadística, donde el diseño de experimentos mostró su eficacia tanto en la resolución de problemas como en la mejora del diseño de productos y procesos. Entre los reportes destacados en Japón, se encuentra el trabajo de Genichi Taguchi, cuyas ideas sobre diseño robusto dejaron una huella importante en la academia occidental. Como respuesta a la mejora de calidad y procesos, las industrias comenzaron a capacitar a sus ingenieros en el uso del diseño de experimentos, una tendencia que se mantiene vigente. En los últimos veinte años, muchas universidades han incluido el diseño de experimentos como una materia fundamental en la mayoría de las carreras de Ingeniería.

EL DISEÑO DE EXPERIMENTOS ACTUALMENTE

En el campo de la industria es frecuente hacer experimentos o pruebas con la intención de resolver un problema o comprobar una idea (conjetura o hipótesis); por ejemplo, hacer algunos cambios en los materiales, métodos o condiciones de operación de un proceso, probar varias temperaturas en una máquina hasta encontrar la que da el mejor resultado o crear un nuevo material con la intención de lograr mejoras o eliminar algún problema. Sin embargo, es común que estas pruebas o experimentos se hagan sobre la marcha, con base en el ensayo y error, apelando a la experiencia y a la intuición, en lugar de seguir un plan experimental adecuado que garantice una buena respuesta a las interrogantes planteadas. Algo similar ocurre con el análisis de los datos experimentales, donde más que hacer un análisis riguroso de la información obtenida y tomar en cuenta la variación, se realiza un análisis informal, "intuitivo". Es tal el poder de la experimentación que, en ocasiones, se logran mejoras a pesar de que el experimento se hizo con base en el ensayo y error. Sin embargo, en situaciones de cierta complejidad no es suficiente aplicar este tipo de experimentación, por lo que es mejor proceder siempre en una forma eficaz que garantice la obtención de las respuestas a las interrogantes planteadas en un lapso corto de tiempo y utilizando pocos recursos. En general, cuando se requiere mejorar un proceso, existen dos maneras básicas de obtener la información necesaria para ello, una es observar o monitorear vía herramientas estadísticas, hasta obtener señales útiles que permitan mejorarlo; se dice que esta es una estrategia pasiva. La otra manera consiste en experimentar, es decir, hacer cambios estratégicos y deliberados al proceso para provocar dichas señales útiles. Al analizar los resultados del experimento se obtienen las pautas a seguir, que muchas veces se concretan en mejoras sustanciales del proceso. En este sentido, experimentar es mejor que sentarse a esperar a que el proceso nos indique por sí mismo cómo mejorarlo.

5

8

El diseño estadístico de experimentos es precisamente la forma más eficaz de hacer pruebas. El diseño de experimentos consiste en determinar cuáles pruebas se deben realizar y de qué manera, para obtener datos que, al ser analizados estadísticamente, proporcionen evidencias objetivas que permitan responder las interrogantes planteadas, y de esa manera clarificar los aspectos inciertos de un proceso, resolver un problema o lograr mejoras

2

El concepto de experimento y unidad experimental es fundamental en el diseño y análisis de investigaciones científicas y técnicas. Un experimento, como bien mencionas, implica realizar un cambio en las condiciones de un proceso con el fin de observar y medir los efectos que ese cambio tiene en el rendimiento o en alguna propiedad del producto final. Esto se realiza con el objetivo de obtener un conocimiento más profundo del sistema, lo que eventualmente puede llevar a mejoras en el proceso.

En el contexto de la química, por ejemplo, variando parámetros como temperatura y presión, se pueden obtener datos sobre cómo esas variaciones afectan el rendimiento del proceso. Estos datos son cruciales para optimizar las condiciones del proceso y mejorar la calidad y eficiencia del producto.

3

La unidad experimental, por otro lado, es vital para asegurar que los resultados del experimento sean confiables y representativos. Al definir la unidad experimental, se debe considerar qué tan representativo es el dato que se va a obtener en relación con el proceso completo. Un ejemplo sería, si se quiere estudiar una producción de piezas, analizar solo una pieza podría no ofrecer un resultado confiable. En este caso, es mucho más efectivo analizar un lote de piezas que se han producido bajo las mismas condiciones experimentales. Esto permite obtener una visión más amplia y precisa de la calidad de la producción y la tasa de defectos.

La definición adecuada de las unidades experimentales y el diseño del experimento son cruciales para llevar a cabo una analítica sólida que entregue resultados significativos y aplicables en la práctica. Estos componentes son esenciales para el control de calidad, la mejora continua en la innovación de los diversos campos de la industria.


2

4.2 Clasificación de los diseños experimentales



DISEÑOS EXPERIMENTALES Y SU CLASIFICACIÓN

FUNDAMENTOS Y TIPOS ESENCIALES PARA INVESTIGACIÓN EFECTIVA



IMPORTANCIA DE LOS DISEÑOS EXPERIMENTALES

Herramienta fundamental en investigación

Los diseños experimentales permiten estudiar diversos problemas reales con rigor científico para obtener resultados válidos y confiables.

Selección adecuada del diseño

La elección correcta del diseño experimental garantiza precisión, eficiencia y correcta interpretación de los efectos estudiados.

Adaptabilidad y flexibilidad

Los diseños experimentales son herramientas flexibles que se adaptan a necesidades, recursos y objetivos para conclusiones relevantes.

FACTORES QUE INFLUYEN EN LA SELECCIÓN DEL DISEÑO

Objetivo del Experimento

El objetivo guía el tipo de diseño requerido para comparar tratamientos o evaluar factores específicos.

Número de Factores

La cantidad de factores afecta la complejidad y la necesidad de diseños más sofisticados.

Niveles por Factor

El número de niveles determina si el diseño será simple o factorial y la profundidad del análisis.

Restricciones Prácticas

El costo, tiempo y precisión condicionan el alcance y selección del diseño experimental.



CLASIFICACIÓN DE LOS DISEÑOS EXPERIMENTALES



CRITERIOS GENERALES DE CLASIFICACIÓN

Clasificación según objetivo

Los diseños experimentales se clasifican según el objetivo para responder a necesidades específicas de estudio.

Criterios de subclasificación

Número de factores, niveles, efectos y restricciones son criterios que permiten subclasificar los diseños experimentales.

Cinco grupos principales

Diseños para comparar tratamientos, estudiar factores, optimizar procesos, robustez y optimización de mezclas.

Importancia metodológica

Cada categoría ofrece un marco metodológico para obtener respuestas confiables y útiles para la toma de decisiones.



TIPOS DE DISEÑOS SEGÚN SU OBJETIVO



DISEÑOS PARA COMPARAR TRATAMIENTOS

Objetivo del Diseño

El diseño experimental busca comparar dos o más tratamientos para detectar diferencias significativas en sus efectos.

Aplicaciones Comunes

Estos diseños se usan en ensayos clínicos, estudios de laboratorio y pruebas de productos para evaluar desempeño relativo.

Control de Variabilidad


Diseños bien estructurados controlan la variabilidad para asegurar que las diferencias se deban a tratamientos y no a factores externos.

Tipos de Diseños

Diseños completamente al azar, bloques completos al azar y diseños cruzados son ejemplos típicos de esta categoría.



DISEÑOS PARA ESTUDIAR MÚLTIPLES FACTORES



Estudio de múltiples factores

Los diseños factoriales permiten evaluar simultáneamente varios factores y sus efectos en procesos y respuestas.

Interacciones entre factores

Estos diseños facilitan el análisis de interacciones complejas entre variables que no actúan de forma aislada.

Diseños completos y fraccionados

El uso de diseños factoriales completos o fraccionados ayuda a optimizar recursos sin perder información valiosa.

Aplicaciones prácticas


Este enfoque es ampliamente aplicado en industrias, ingeniería, agricultura y ciencias sociales por su eficacia.

DISEÑOS PARA ENCONTRAR EL PUNTO ÓPTIMO DE OPERACIÓN



Objetivo de los diseños óptimos

Estos diseños buscan identificar condiciones para maximizar o minimizar una respuesta específica en un proceso.




Metodología de superficie de respuesta

La superficie de respuesta modela la relación entre factores y respuesta para hallar valores óptimos en experimentos.



Aplicaciones industriales y laboratorio

Estos diseños son cruciales en procesos industriales y ajustes de laboratorio para mejorar eficiencia y calidad.



DISEÑOS ROBUSTOS FRENTA A FACTORES NO CONTROLABLES

Estabilidad y Consistencia

Los diseños robustos mejoran la estabilidad y consistencia ante las variaciones no controlables en procesos y productos.

Minimización de Sensibilidad

El sistema busca reducir la sensibilidad a perturbaciones externas para garantizar calidad estable.

Diseños Taguchi

Los diseños Taguchi son un método reconocido para lograr robustez y alta calidad en manufactura e ingeniería.



DISEÑOS PARA OPTIMIZACIÓN DE MEZCLAS

Proporciones constantes

Los diseños de mezcla manejan proporciones de componentes que suman un total constante en el experimento.

Aplicaciones industriales


Son esenciales en alimentos, farmacéutica y química para optimizar la mezcla de ingredientes y mejorar productos.

Modelado y optimización

Permiten identificar combinaciones óptimas y modelar el aporte de cada componente a la respuesta final.

Link: [disenos experimentales.pptx](#)


CLASIFICACIÓN DE LOS DISEÑOS EXPERIMENTALES



4.3 Nomenclatura y simbología en el diseño experimental

VARIABLES, FACTORES Y NIVELES

En todo proceso intervienen distintos tipos de variables o factores como los que se muestran en la siguiente figura, donde también se plantean algunas interrogantes al planificar un experimento.



¿Cuáles características de calidad se van a medir?

¿Cuáles factores controlables deben incluirse en el experimento?

¿Qué niveles debe utilizar cada factor?

¿Cuál diseño experimental es el adecuado?

1

Variable(s) de respuesta: A través de esta(s) variable(s) se conoce el efecto o los resultados de cada prueba experimental, por lo que pueden ser características de la calidad de un producto y/o variables que miden el desempeño de un proceso. El objetivo de muchos estudios experimentales, es encontrar la forma de mejorar la(s) variable(s) de respuesta. Por lo general, estas variables se representan con la letra Y.

Factores controlables: Son variables de proceso o características de los materiales experimentales que se pueden fijar en un nivel dado. Algunos de éstos son los que usualmente se controlan durante la operación normal del proceso y se distinguen porque, para cada uno de ellos, existe la manera o el mecanismo para cambiar o manipular su nivel de operación. Esto último es lo que hace posible que se pueda experimentar con ellos. Por ejemplo, si en el proceso se usa agua a 60 °C entonces debe existir un mecanismo que permita fijar la temperatura del agua dentro de ese rango de operación. Algunos factores o características que generalmente se controlan son: **temperatura, tiempo de residencia, cantidad de cierto reactivo, tipo de reactivo, método de operación, velocidad, presión**, etc. A los factores controlables también se les llama: *variable de entrada, condiciones de proceso, variable de diseño, parámetro del proceso, las X de un proceso* o simplemente *factores*.

Factores NO controlables o de ruido: Son variables o características de materiales y métodos que no se pueden controlar durante el experimento o la operación normal del proceso. Por ejemplo, algunos factores que suelen ser no controlables son las variables ambientales (luz, humedad, temperatura, partículas, ruido, etc.), el ánimo de los operadores, la calidad del material que se recibe del proveedor (interno o externo). Un factor que ahora es *no controlable* puede convertirse en *controlable* cuando se cuenta con el mecanismo o la tecnología para ello.

Factores estudiados: Son las variables que se investigan en el experimento, para observar cómo afectan o influyen en la variable(s) de respuesta(s). Los factores estudiados pueden ser controlables o no controlables, a estos últimos quizá fue posible y de interés controlarlos durante el experimento. Para que un factor pueda ser estudiado es necesario que durante el experimento se haya probado en, al menos, dos niveles o condiciones. En principio, cualquier factor, sea controlable o no, puede tener alguna influencia en la variable de respuesta que se refleja en su media o en su variabilidad. Para fines de un diseño de experimentos deben seleccionarse los factores que se considera, por conocimiento del objeto de estudio, que pueden tener efecto sobre la respuesta de interés. Obviamente, si se decide o interesa estudiar el efecto de un factor no controlable, parte de la problemática a superar durante el diseño es ver la manera en que se controlará durante el experimento tal factor.

Niveles y tratamientos: A los diferentes valores que se asignan a cada factor estudiado en un diseño experimental se les llaman *niveles*. Una combinación de niveles de todos los factores estudiados, se llaman *tratamiento o punto de diseño*. Por ejemplo, si en un experimento se estudia la influencia de la velocidad y la temperatura, y se decide probar cada una en dos niveles, entonces cada combinación de niveles (velocidad, temperatura) es un tratamiento. De acuerdo con estas definiciones, en el caso de experimentar con un solo factor, cada nivel es un tratamiento.

3

2

4.4 Identificación de los efectos de los diseños experimentales

En Ingeniería de Gestión Empresarial, los diseños experimentales son una herramienta fundamental para identificar y analizar los efectos de diferentes variables en procesos o sistemas existentes. Aquí hay algunos pasos clave para identificar estos efectos:

1. **Definición del problema:** Antes de realizar un experimento, es esencial tener claro el objetivo. Definir lo que se quiere medir o establecer una hipótesis específica puede guiar el diseño.
2. **Selección de variables:** Identificar las variables independientes (factores que se manipulan) y dependientes (resultados que se miden). Las variables deben ser relevantes para el problema que se está investigando.
3. **Diseño del experimento:** Elegir un diseño adecuado (por ejemplo, completamente aleatorizado, bloqueado, fraccionado, etc.) que permita evaluar los efectos de las variables de manera precisa. Este diseño también debe considerar cómo controlar otras variables que puedan influir en los resultados.
4. **Aleatorización:** La aleatorización ayuda a eliminar sesgos y proporciona una base sólida para la inferencia estadística. Al asignar tratamientos de manera aleatoria, se asegura que otros factores no influyan en los resultados.
5. **Recolección de datos:** Realizar el experimento y recolectar datos con métodos sistemáticos. Es importante asegurarse de que los datos sean precisos y representativos.
6. **Análisis de datos:** Utilizar métodos estadísticos apropiados para analizar los datos recolectados. Los análisis pueden incluir ANOVA, regresión, entre otros, para determinar la significancia de los efectos y cómo se relacionan las variables.
7. **Interpretación de resultados:** Evaluar los resultados obtenidos y compararlos con las hipótesis iniciales. Es importante considerar la magnitud y la dirección de los efectos observados.
8. **Conclusiones y recomendaciones:** Basándose en los resultados, formular conclusiones que serán útiles para la toma de decisiones en la gestión empresarial. Esto también puede llevar a la implementación de mejoras o cambios en el proceso.
9. **Validación:** Si es posible, realizar más experimentos o estudios de validación para confirmar que los resultados obtenidos son consistentes y replicables.

2

2 Siguiendo estos pasos, es posible identificar y entender mejor los efectos en distintos escenarios dentro de la Ingeniería de Gestión Empresarial, lo que permite que las decisiones sean más informadas y sustentadas en datos.

2 4.5 La importancia de la aleatorización de los especímenes de prueba

La aleatorización de los especímenes de prueba es un aspecto crucial en el diseño de experimentos, especialmente en el ámbito de la Ingeniería de Gestión Empresarial. Su importancia se puede resumir en varios puntos clave:

1. **Reducción de sesgos:** La aleatorización ayuda a eliminar o disminuir los sesgos que pueden influir en los resultados del experimento. Al asignar aleatoriamente los sujetos a diferentes grupos, se minimizan las diferencias sistemáticas que podrían afectar las conclusiones.
2. **Generalización de resultados:** Permite que los resultados obtenidos a partir de una muestra sean más representativos de la población total. Esto es esencial para poder aplicar los hallazgos a un contexto más amplio en la toma de decisiones empresariales.
3. **Aumento de la validez interna:** La aleatorización mejora la validez interna del experimento al asegurar que las variables independientes y dependientes se evalúan de manera justa, sin efectos de confusión que podrían distorsionar la interpretación de los resultados.
4. **Facilitación del análisis estadístico:** Muchos métodos estadísticos asumen que los datos han sido recogidos de forma aleatoria. La aleatorización permite utilizar un rango más amplio de técnicas analíticas, aumentando la robustez de las conclusiones.
5. **Mejor manejo de la variabilidad:** Al asignar aleatoriamente a los individuos o elementos de prueba, se distribuye equitativamente la variabilidad entre los tratamientos, lo que permite una comparación más efectiva entre las condiciones de prueba.
6. **Mayor credibilidad:** Los experimentos bien diseñados con aleatorización son considerados más creíbles en la comunidad científica y empresarial, lo que puede aumentar la confianza en las decisiones que se adopten basándose en esos resultados.

2 En resumen, la aleatorización en el diseño de experimentos no solo mejora la calidad y confiabilidad de los datos obtenidos, sino que también permite a las organizaciones tomar decisiones más informadas y basadas en evidencia. Esto resulta fundamental en la gestión empresarial, donde las decisiones impactan significativamente en el rendimiento y la estrategia de la empresa.

2

4.6 Supuestos estadísticos en las pruebas experimentales

En el diseño de experimentos dentro de la Ingeniería de Gestión Empresarial, se consideran varios supuestos estadísticos fundamentales para asegurar la validez de los resultados. Estos son:

1. **Independencia:** Las observaciones deben ser independientes entre sí. Esto significa que el resultado de un experimento no debe influir en el de otro.
2. **Normalidad:** Se asume que los errores o residuales del modelo siguen una distribución normal. Esto es especialmente importante para realizar inferencias estadísticas válidas.
3. **Homoscedasticidad:** La varianza de los errores debe ser constante a lo largo de todos los niveles de las variables independientes. Si la varianza no es constante, podría afectar la validez de las pruebas de hipótesis.
4. **Linealidad:** En muchos modelos, se asume que la relación entre las variables independientes y dependientes es lineal. Esto permite el uso de modelos lineales en el análisis.
5. **Adición de efectos:** Se considera que los efectos de los factores son aditivos, lo que significa que el efecto combinado de dos o más factores es la suma de sus efectos individuales.
6. **Aleatorización:** Los tratamientos deben asignarse aleatoriamente a las unidades experimentales para evitar sesgos y asegurar que las comparaciones sean válidas.

Estos supuestos son esenciales para el análisis y la interpretación de los resultados en los experimentos, y su verificación es crucial para asegurar conclusiones válidas y confiables.

2 4.7 Prueba de Duncan

La prueba de Duncan, formalmente conocida como **prueba de rango múltiple de Duncan**, constituye un procedimiento estadístico fundamental en el análisis posterior tras la ejecución de un análisis de varianza (ANOVA) en contextos experimentales rigurosos, especialmente en el ámbito de la **Ingeniería de Gestión Empresarial**. Su relevancia radica no solo en su capacidad técnica para identificar diferencias significativas entre tratamientos, sino en su adaptabilidad a entornos industriales y organizacionales donde la toma de decisiones debe basarse en evidencia empírica robusta y jerárquicamente estructurada. A diferencia de pruebas más conservadoras como la de Tukey o la de Scheffé, la prueba de Duncan adopta un enfoque *secuencial y jerárquico*, lo que la hace particularmente adecuada para evaluar estrategias operativas, procesos logísticos, políticas de mantenimiento o modelos de liderazgo cuyos efectos no son uniformes ni lineales, sino que exhiben umbrales de impacto diferenciados.

3 El fundamento matemático de la prueba se asienta en la **distribución del rango estudentizado**, una distribución de probabilidad que permite comparar simultáneamente múltiples medias ajustando el umbral de significación según el número de comparaciones involucradas. En lugar de aplicar un único valor crítico para todas las comparaciones como ocurre con la prueba de Tukey, Duncan utiliza un *rango crítico variable* que aumenta progresivamente conforme se amplía el número de medias incluidas en una comparación específica. Este mecanismo implica que dos medias serán consideradas estadísticamente distintas si su diferencia supera un umbral que depende tanto del error estándar estimado como del número de pasos entre ellas en un ordenamiento ascendente o descendente. Esta característica la convierte en una herramienta menos conservadora, pero también más sensible a los errores de tipo I, tal como se ha documentado en estudios recientes que advierten sobre su elevada tasa de falsos positivos en comparación con alternativas como el test de Bonferroni o el de Dunnett. No obstante, este menor conservadurismo es estratégicamente valioso en gestión empresarial, donde identificar incluso pequeñas mejoras marginales en eficiencia operativa, reducción de costes o aumento de satisfacción del cliente puede tener un impacto acumulativo sustancial.

En la práctica de la Ingeniería de Gestión Empresarial, la prueba de Duncan se integra dentro de marcos metodológicos más amplios de diseño experimental, como los diseños factoriales o los diseños en bloques aleatorizados. Por ejemplo, en la investigación sobre *mantenimiento*

inteligente, donde se evalúan múltiples configuraciones tecnológicas (sensores IoT, algoritmos predictivos, protocolos de intervención) bajo distintos escenarios de carga productiva, un ANOVA factorial revela si existe un efecto global significativo; sin embargo, es la prueba de Duncan la que permite discernir, con precisión jerárquica, qué combinación específica de tecnología y protocolo genera los menores tiempos de inactividad no planificada, y cuál representa una mejora marginal respecto a la siguiente mejor opción. Asimismo, en estudios sobre liderazgo transformacional y ambi-dextreza de la cadena de suministro, donde se comparan múltiples niveles de intensidad de liderazgo (bajo, medio, alto) en su influencia sobre la capacidad de aprendizaje organizacional, Duncan facilita la agrupación de tratamientos homogéneos, identificando umbrales críticos a partir de los cuales el impacto del liderazgo se vuelve estadísticamente distinto.

Es crucial destacar que la validez de la prueba de Duncan depende estrictamente del cumplimiento de los supuestos clásicos del ANOVA: normalidad de los residuos, homogeneidad de varianzas y independencia de las observaciones. En entornos empresariales reales, donde los datos pueden presentar heterocedasticidad o distribuciones asimétricas (por ejemplo, tiempos de ciclo de producción con colas largas), su aplicación directa requiere verificación previa mediante pruebas como Shapiro-Wilk o Levene, y, en caso de violación, la consideración de alternativas robustas como el test de Games-Howell o el uso de transformaciones estabilizadoras de la varianza. Además, su interpretación debe ir acompañada de medidas de tamaño del efecto (como el cuadrado parcial) y análisis de poder estadístico, ya que la mera significación no garantiza relevancia práctica en la toma de decisiones gerenciales. En resumen, la prueba de Duncan no es un mero artefacto estadístico, sino un instrumento de *razonamiento inferencial jerárquico* que, cuando se aplica con rigor metodológico y contextualizado, permite a los ingenieros de gestión traducir complejidad experimental en conocimiento accionable para la optimización de sistemas organizacionales.

4.8 Aplicaciones industriales

El diseño de experimentos (DOE, por sus siglas en inglés) constituye una columna vertebral metodológica en la Ingeniería de Gestión Empresarial, actuando como puente riguroso entre la toma de decisiones estratégicas y la evidencia empírica cuantificable. Su aplicación industrial no se limita a la mejora táctica de procesos aislados, sino que se extiende a la transformación sistémica de la gestión operativa, la innovación de productos, la optimización de cadenas de suministro y la consolidación de culturas organizacionales orientadas a la calidad y la eficiencia. La literatura científica de alto impacto confirma que el DOE es un catalizador fundamental para la excelencia operacional en entornos industriales complejos y altamente competitivos.

Una de las aplicaciones más documentadas y de mayor retorno es la **optimización de procesos productivos y logísticos**, donde el DOE permite identificar interacciones críticas que el método tradicional de variar un factor a la vez pasa por alto sistemáticamente. Este enfoque integrado, basado en principios experimentales, logró reducciones significativas en los tiempos de ciclo, demostrando que el DOE no es solo una herramienta estadística, sino un marco de pensamiento sistémico para la gestión de operaciones complejas.

En el ámbito de la **mejora de la calidad y la robustez de los procesos**, el DOE es el motor implícito del marco *Quality by Design* (QbD), especialmente en sectores regulados como el farmacéutico. El objetivo no es simplemente alcanzar una media objetivo, sino garantizar que el proceso sea insensible a las variaciones inevitables de los factores de control (robustez). Un producto de alta calidad es aquel que no solo logra su rendimiento medio deseado, sino que exhibe una variabilidad mínima ante las fluctuaciones ambientales y de fabricación, en un mercado de competencia feroz, el DOE es una herramienta indispensable para mejorar tanto los resultados de los procesos industriales como los propios procesos, especialmente cuando los recursos experimentales son limitados, lo que implica una gestión eficiente del conocimiento dentro de la organización.

La **gestión de mantenimiento inteligente** representa otra frontera emergente donde el DOE aporta valor estratégico, en una agenda de investigación empíricamente fundamentada para este campo, destacando que la transición hacia entornos industriales digitalizados exige métodos rigurosos para evaluar

el impacto real de las nuevas tecnologías de mantenimiento predictivo y prescriptivo. Aquí, el DOE permite diseñar experimentos controlados para aislar el efecto de una nueva solución o de análisis de datos sobre indicadores clave de desempeño como la disponibilidad de la planta o el costo total de propiedad, evitando conclusiones erróneas derivadas de correlaciones espurias. Este enfoque es coherente con la visión regenerativa de la sostenibilidad, que propone un salto cualitativo desde una visión mecanicista hacia una de sistemas vivos, donde la gestión empresarial debe ser capaz de diseñar intervenciones que no solo minimicen daños, sino que generen valor positivo neto.

En el contexto de la **innovación de productos y desarrollo de nuevos materiales**, el DOE se integra con técnicas avanzadas de modelado y simulación, el diseño estadístico de experimentos para la mejora de la calidad en PYMEs ilustra cómo esta metodología puede democratizarse, permitiendo a organizaciones de menor escala acceder a herramientas de clase mundial. En el extremo opuesto del espectro se presenta un marco de evaluación de fiabilidad para sistemas estructurales de ingeniería que combina modelos sustitutos, teoría matricial y estrategias adversariales generativas, una arquitectura cuyo diseño experimental subyacente requiere una planificación rigurosa para garantizar la validez de las predicciones multi-objetivo.

Finalmente, la **gestión de la cadena de suministro y la planificación de la producción** también se beneficia profundamente del DOE. La planificación de ventas y operaciones en la industria de tableros de virutas orientadas desarrolla modelos de programación lineal entera mixta para evaluar el impacto antes de su implementación, un enfoque que es esencialmente experimental en su naturaleza: se diseña un "experimento" computacional para simular diferentes escenarios de integración funcional y demanda determinista. Esta práctica refleja la evolución del DOE desde el laboratorio físico hacia el "laboratorio digital", donde los diseños de experimentos se aplican a modelos de simulación para explorar el espacio de diseño con un costo marginal cercano a cero, pero con una rigurosidad metodológica idéntica. La síntesis de estos hallazgos revela que el DOE en la Ingeniería de Gestión Empresarial no es una técnica aislada, sino un paradigma de gestión basado en la evidencia, que permite a las organizaciones navegar la

complejidad con precisión, tomar decisiones con fundamento científico y construir ventajas competitivas sostenibles.

5. Diseño experimental con bloques al azar y diseños factoriales

5.1 Metodología del diseño experimental de bloques al azar

El diseño experimental de bloques al azar es una estrategia estadística fundamental para controlar la variabilidad sistemática conocida en experimentos científicos, permitiendo una estimación más precisa y potente de los efectos de los tratamientos.

Su metodología se basa en tres pilares interconectados:

- 1).- **identificación del factor de bloqueo,**
- 2).- **asignación aleatoria dentro de bloques homogéneos**
- 3).- **análisis estadístico específico que particione la varianza.**

Esta estructura no es meramente técnica, sino una filosofía de control experimental que transforma el ruido estructurado como gradientes espaciales, diferencias entre lotes o heterogeneidad entre sujetos en información útil, en lugar de dejarlo como error irreducible.

La metodología comienza con la identificación rigurosa de una fuente conocida de variabilidad que afecta significativamente la variable respuesta, pero que no es objeto de estudio. En agricultura, esto puede ser un gradiente de salinidad en un humedal costero, en biología molecular, puede ser el efecto de lote en secuenciación de ARN, en ensayos clínicos, puede ser la variabilidad entre centros hospitalarios. Una vez identificada, esta fuente se convierte en el *factor de bloqueo*, y las unidades experimentales se agrupan en *bloques* donde las condiciones sean lo más homogéneas posible. Por ejemplo, en un estudio sobre ganancia de peso en ganado bovino en pasturas mixtas, los bloques podrían definirse por zonas geográficas específicas con características edáficas similares. Cada bloque debe contener, al menos, una unidad experimental para cada tratamiento que se desea comparar; cuando esto se cumple, se denomina Diseño en Bloques Completos al Azar (DBCA), que es la forma más común y robusta.

Dentro de cada bloque, la asignación de los tratamientos a las unidades experimentales se realiza mediante *aleatorización restringida*. Esto significa que, a diferencia de un diseño completamente aleatorizado (DCA), no se asigna cualquier tratamiento a cualquier unidad, sino que se permuta aleatoriamente el conjunto

completo de tratamientos dentro del bloque. Este paso es crítico, garantiza que cualquier comparación entre tratamientos se realice en condiciones comparables, es decir, "manzana con manzana". Si un tratamiento se aplica en un bloque con suelo fértil y otro en uno con suelo pobre, la diferencia observada podría deberse al suelo, no al tratamiento.

Al forzar la comparación dentro del mismo bloque, el efecto del bloque por ejemplo, la fertilidad del suelo se cancela matemáticamente al restar las medias, dejando únicamente la variación aleatoria pura. Esta es la esencia del mecanismo de aumento de potencia estadística, el DBCA elimina la varianza entre bloques del término de error, reduciendo drásticamente la varianza del estimador del efecto del tratamiento. La ganancia de eficiencia relativa se cuantifica mediante el coeficiente de correlación intra-clase, y puede alcanzar valores superiores a 2.7, lo que equivale a obtener la misma precisión estadística con menos de la mitad de las unidades experimentales.

2

En síntesis, la metodología del diseño experimental de bloques al azar es una herramienta de alta sofisticación que eleva la calidad causal de la evidencia empírica. No es un mero procedimiento de análisis, sino un acto de diseño intencional que reconoce la heterogeneidad inherente del mundo natural y la convierte en una ventaja estratégica. Al imponer orden sobre el caos estructurado, permite a los investigadores escuchar con claridad el "susurro" del efecto del tratamiento, incluso en medio del "rugido" de la variabilidad ambiental, técnica o biológica.

5.2 Diseño de experimentos factoriales

Diseño de Experimentos Factoriales: Conceptos Clave y Aplicaciones

En el **Diseño de Experimentos (DOE)**, los **experimentos factoriales** son una herramienta fundamental para estudiar el efecto de **múltiples factores** (variables independientes) y sus **interacciones** sobre una **variable de respuesta**. A continuación, se explica su estructura, ventajas y aplicaciones en el nivel superior.

Diseño Factorial: Un diseño factorial es un arreglo experimental en el que se estudian **todos los posibles niveles** de dos o más factores en todas sus combinaciones. Por ejemplo:

Factores: Variables independientes (ej: temperatura, presión, concentración).

Niveles: Valores que toma cada factor (ej: temperatura baja/alta).

Tratamientos: Combinaciones de niveles (ej: baja temperatura + alta presión).

Ejemplo básico:

2 factores (A y B), cada uno con **2 niveles (bajo/alto)** → $2^2 = 4$ tratamientos.

3 factores (A, B, C), cada uno con **2 niveles** → $2^3 = 8$ tratamientos.

Factorial completo:

Evalúa **todas las combinaciones posibles** de niveles.

Ejemplo: **2^3 factorial** (3 factores con 2 niveles cada uno → 8 tratamientos).

Ventaja: Permite analizar efectos principales e interacciones.

Desventaja: Requiere más recursos cuando hay muchos factores.

Ventajas del Diseño Factorial

Eficiencia: Analiza múltiples factores en un solo experimento.

Interacciones: Detecta si el efecto de un factor depende de otro.

Optimización: Identifica las mejores combinaciones de factores para maximizar/minimizar la respuesta.

Diseño en bloques completos al azar.

Propósito del DBCA

- Controlar variables extrañas (fuentes de variabilidad conocidas): Por ejemplo, diferencias entre turnos, máquinas, operadores, lotes de materia prima, etc.
- Aislar el efecto del factor de interés: Al eliminar la influencia de la variable de bloque, se obtiene una estimación más precisa del efecto de los tratamientos.

Estructura del Experimento

Bloques: Grupos homogéneos de unidades experimentales que comparten una característica común (ejem. misma máquina, mismo operario, mismo día).

Tratamientos: Niveles del factor bajo estudio (ejem. tres métodos de trabajo, dos tipos de material).

Cada bloque contiene todos los tratamientos, y estos se asignan aleatoriamente dentro de cada bloque.

Ejemplo:

Bloque	Turno	Tratamiento A	Tratamiento B	Tratamiento C
	Mañana	15 unidades	18 unidades	12 unidades
	Tarde	14 unidades	17 unidades	10 unidades
	Noche	13 unidades	16 unidades	11 unidades

Ventajas del DBCA

- Reducción del error experimental: Al eliminar la variabilidad entre bloques, se aumenta la precisión.
- Flexibilidad: Permite estudiar tanto el efecto de los tratamientos como el de los bloques.
- Eficiencia: Es más potente que un diseño completamente aleatorizado (DCA) cuando hay heterogeneidad en las unidades experimentales.

Aplicaciones en Ingeniería de Gestión Empresarial

- Optimización de procesos: Comparar métodos de producción en diferentes máquinas (bloques).
- Control de calidad: Evaluar proveedores (tratamientos) considerando lotes de materia prima (bloques).
- Estudios de ergonomía: Probar diseños de herramientas (tratamientos) con distintos operarios (bloques).

Supuestos Críticos:

Aditividad: El efecto de tratamientos y bloques es aditivo (no hay interacción).

Homocedasticidad: Varianza constante del error.

Normalidad: Los errores siguen una distribución normal.

El DBCA es esencial para experimentos donde se debe controlar una fuente de variabilidad conocida (bloques), garantizando que las comparaciones entre tratamientos sean válidas y precisas. Es una herramienta clave en la optimización de procesos industriales, calidad, logística y gestión operativa.

TABLA DE VALORES PARA EL DISEÑO DE BLOQUES COMPLETOS ALEATORIOS (DBCA)

BLOQUES	TRATAMIENTOS				Sumas
	1	2	3	k	$\sum X_{i.}$
1	X_{11}	X_{12}	$X_{13} \dots\dots$	X_{1k}	$X_{1.}$
2	X_{21}	X_{22}	$X_{23} \dots\dots$	X_{2k}	$X_{2.}$
3	X_{31}	X_{32}	$X_{33} \dots\dots$	X_{3k}	$X_{3.}$
.	.	.	.	$\dots\dots$	.
.	.	.	.	$\dots\dots$	.
b	X_{b1}	X_{b2}	$X_{b3} \dots\dots$	X_{bk}	$X_{b.}$
Sumas $\sum X_{.j}$	$X_{.1}$	$X_{.2}$	$X_{.3} \dots\dots X_{.k}$		$X_{..} =$
Medias $\bar{X}_{.j}$	$\bar{X}_{.1}$	$\bar{X}_{.2}$	$\bar{X}_{.3} \dots \bar{X}_{.k}$		$N =$

Donde:

$i \rightarrow 1, 2, 3, \dots, b$ No. de Bloques $j \rightarrow 1, 2, 3, \dots, k$ No. de Tratamientos

Cálculos previos:

$$1) \left(\frac{X_{..}^2}{N} \right) \quad 2) \sum_{i=1}^b \left(\frac{X_{i.}^2}{k} \right) \quad 3) \sum_{j=1}^k \left(\frac{X_{.j}^2}{b} \right) \quad 4) \sum_{j=1}^k \sum_{i=1}^b (X_{ij}^2)$$

$$SC_B = (2 - 1) \quad SC_T = (3 - 1) \quad SC_{Total} = (4 - 1) \quad SC_E = [SC_{Total} - SC_T - SC_B]$$

FORMULARIO DE LA TABLA DE ANOVA PARA DBCA

Fuente de Variabilidad	gl	SC	CM	$F_0 = F_{\text{calculada}}$	$F_{CR} = F_{\text{teórica}}$
Bloques (B)	$gl_B = (b - 1)$	$SC_B =$	xxxxxxxxxx	$F_0 = \frac{CM_T}{CM_E}$	$F_{CR} = F_{(\alpha, gl_T, gl_E)}$
Tratamientos (T)	$gl_T = (k - 1)$	$SC_T =$	$CM_T = \frac{SC_T}{gl_T}$	Decisión: Si $F_0 < F_{CR}$ Se acepta H_0 Si $F_0 > F_{CR}$ { Se rechaza H_0 Se acepta H_1	
Error (E)	$gl_E = (k - 1)(b - 1)$	$SC_E =$	$CM_E = \frac{SC_E}{gl_E}$		
Total (Total)	$gl_{\text{Total}} = (N - 1)$	$SC_{\text{Total}} =$	xxxxxxxxxx		

FORMATO de Tabla de ANOVA para DBCA

Fuente de Variabilidad	Grados de libertad	Suma de Cuadrados	Cuadrado Medio	$F_0 = F_{\text{calculada}}$	$F_{CR} = F_{\text{teórica}}$
Bloque (B)	$gl_B =$	$SC_B =$	xxxxxxxxxx	$F_0 =$	$F_{CR} =$
Tratamientos (T)	$gl_T =$	$SC_T =$	$CM_T =$	Decisión:	
Error (E)	$gl_E =$	$SC_E =$	$CM_E =$		
Total (Total)	$gl_{\text{Total}} =$	$SC_{\text{Total}} =$	xxxxxxxxxx		

5.3 Diseño factorial 2^k

Los **diseños factoriales 2^k** son una herramienta esencial en el **Diseño de Experimentos (DOE)** y tienen aplicaciones prácticas en **Ingeniería en Gestión Empresarial**. Estos diseños permiten estudiar el efecto de **k factores**, cada uno con **dos niveles** (por ejemplo, bajo/alto), en una **variable de respuesta**. A continuación, se explica cómo funcionan y sus aplicaciones en este campo:

Diseño Factorial 2^k

Un diseño 2^k es un arreglo experimental que evalúa **todos los posibles niveles** de **k factores** en todas sus combinaciones. Cada factor tiene **dos niveles**, lo que resulta en **2^k tratamientos**.

Ejemplo:

2 factores (k=2): $2^2 = 4$ tratamientos.

3 factores (k=3): $2^3 = 8$ tratamientos.

4 factores (k=4): $2^4 = 16$ tratamientos.

Estructura de un Diseño 2^k

Cada tratamiento es una combinación única de niveles de los factores. Por ejemplo, en un diseño 2^3 :

Tratamiento	Factor A	Factor B	Factor C
1	Bajo	Bajo	Bajo
2	Alto	Bajo	Bajo
3	Bajo	Alto	Bajo
4	Alto	Alto	Bajo
5	Bajo	Bajo	Alto
6	Alto	Bajo	Alto
7	Bajo	Alto	Alto
8	Alto	Alto	Alto

Aplicaciones en Ingeniería en Gestión Empresarial

a) Optimización de Procesos

Mejora de la eficiencia: Estudiar cómo factores como *tiempo de producción, capacitación del personal y tecnología* afectan la productividad.

Reducción de costos: Evaluar el impacto de *proveedores, métodos de control de calidad y flujo de trabajo* en los costos operativos.

Ejemplo:

Un diseño 2^3 podría analizar:

Factor A: Tipo de maquinaria (nuevo vs. antiguo).

Factor B: Horario de trabajo (turno diurno vs. nocturno).

Factor C: Nivel de capacitación (básico vs. avanzado).

Objetivo: Maximizar la producción minimizando los costos.

b) Gestión de la Cadena de Suministro

Optimización de inventarios: Evaluar cómo *niveles de stock, frecuencia de pedidos y proveedores* afectan los costos de almacenamiento.

Logística y transporte: Analizar el impacto de *rutas de entrega, métodos de embalaje y tiempos de carga* en la eficiencia logística.

5.4 Diseño de cuadros latinos

El diseño de cuadros latinos (DCL) es una técnica de diseño de experimentos (DOE) utilizada en Ingeniería de Gestión Empresarial para controlar la variabilidad y mejorar la eficiencia en experimentos donde intervienen tres factores, cada uno con el mismo número de niveles, y donde se busca minimizar el efecto de variables de ruido.

Características principales:

Estructura del Cuadrado Latino:

Es una matriz cuadrada ($n \times n$) donde cada letra (o símbolo) aparece una sola vez en cada fila y columna.

Ventajas:

- ✓ Eficiencia: Reduce el número de ensayos en comparación con un diseño factorial completo.
- ✓ Control de variables extrañas: Permite eliminar el efecto de dos fuentes de variación.
- ✓ Balanceo: Cada nivel del factor principal aparece una vez en cada fila y columna.

El diseño de cuadros latinos es útil en Ingeniería en Gestión Empresarial para experimentos donde se requiere eficiencia y control de variables externas, como en control de calidad, logística o mejora de procesos.

CONCEPTOS BÁSICOS DE CUADROS LATINOS

- 1.- Diseño Completamente al Azar (DCA) -----> Controla **un** factor de interés (Tratamiento)
- 2.- Diseño de Bloques Completos al Azar (DBCA)-> [Controla **un** factor de interés (Tratamiento)
Controla **un** factor de bloqueo (Bloque)
- 3.- Diseño de Cuadros Latinos (DCL) -----> [Controla **un** factor de interés (Tratamiento)
Controla **dos** factores de bloqueo (Bloques I y II)
- 4.- Diseño de Cuadros Grecolatinos (DCGL) -> [Controla **un** factor de interés (Tratamiento)
Controla **tres** factores de bloqueo (Bloques I, II y III)

CUADROS LATINOS

Un **cuadro latino** es un arreglo de letras latinas (A, B, C, D.....X, Y, Z) en forma de cuadro

Regla fundamental; Cada letra debe aparecer solo una vez en cada renglón y en cada columna.

Dado un **cuadro latino**; cualquier intercambio de columnas o de renglones, también es un **cuadro latino**

Cuadro Latino Estándar: Es aquel en el que en la PRIMERA COLUMNA y en el PRIMER RENGLOON aparecen las letras latinas en orden alfabético

ESTRATEGIA DE SELECCIÓN Y ALEATORIZACIÓN RECOMENDABLE EN LA PRÁCTICA

- 1.- Se construye el cuadro latino estándar más sencillo.
- 2.- Se aleatoriza el orden de los renglones (ó las columnas) y después se aleatoriza el orden de las columnas (ó renglones).
- 3.- Por último; los tratamientos a comparar, se asignan en forma aleatoria a las letras latinas.

Ejemplos de Cuadro Latino Estándar de 4x4:

A	B	C	D
B	C	D	A
C	D	A	B
D	A	B	C

A	B	C	D
B	A	D	C
C	D	B	A
D	C	A	B

A	B	C	D
B	A	D	C
C	D	A	B
D	C	B	A

A	B	C	D
B	D	A	C
C	A	D	B
D	C	B	A

Completar los siguientes Cuadros Latino Estándar de 5x5:

A	B	C	D	E
B				
C				
D				
E				

A	B	C	D	E
B				
C				
D				
E				

A	B	C	D	E
B				
C				
D				
E				

A	B	C	D	E
B				
C				
D				
E				

A	B	C	D	E
B				
C				
D				
E				

TABLA DE VALORES PARA EL DISEÑO DE CUADROS LATINOS (DCL) ($m \times m$)

		Bloque II (Columnas)					SUMAS
		1	2	3		k	$X_{i..}$
Bloque I (Renglones)	1	$A = X_{111}$	$B = X_{122}$	$C = X_{133}$		$F = X_{1k6}$	
	2	$B = X_{212}$	$C = X_{223}$	$D = X_{234}$		$A = X_{2k1}$	
	3	$C = X_{313}$	$D = X_{324}$	$E = X_{335}$		$B = X_{3k2}$	
	.	.	.	.		.	.
	.	.	.	.		.	.
	.	.	.	.		.	.
	k	$F = X_{k16}$	$A = X_{k21}$	$B = X_{k32}$		$H = X_{kkh}$	
SUMAS	X_{-j-}						$X_{...}$
SUMAS	$X_{..k}$	A	B	C		Z	
Medias	$\bar{X}_{..k}$						

Donde: A=1, B=2, C=3, D=4, E=5, F=6, - - - - - , Z=26 Para la posición del tratamiento

$m \rightarrow$ No. de renglones, columnas y tratamientos (letras latinas)

$X_{ij(k)} \rightarrow$ Es la observación en la posición ij del cuadro para el tratamiento k

$X_{i..} \rightarrow$ Suma de las observaciones en el i -ésimo renglón

$X_{-j-} \rightarrow$ Suma de las observaciones en la j -ésima columna

$X_{..k} \rightarrow$ Suma de las observaciones los valores de las posiciones de letras latinas para el tratamiento (k)

$X_{...} \rightarrow$ Suma de todas las observaciones m

CALCULOS PREVIOS:

$$1) \left(\frac{X_{...}^2}{m^2} \right) \quad 2) \sum_{i=1}^m \left(\frac{X_{i..}^2}{m} \right) \quad 3) \sum_{j=1}^m \left(\frac{X_{.j.}^2}{m} \right)$$

$$4) \sum_{k=1}^m \left(\frac{X_{..k}^2}{m} \right) \quad 5) \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m (X_{ij(k)}^2)$$

CALCULOS: $SC_A = (2-1)$ $SC_B = (3-1)$ $SC_T = (4-1)$ $SC_{Total} = (5-1)$ $SC_E = [SC_{Total} - SC_A - SC_B - SC_T]$

FORMULARIO DE LA TABLA DE ANOVA PARA EL DISEÑO DE CUADRO LATINO (DCL) (m x m)

Fuente de Variabilidad	Grados de Libertad (gl)	Suma de Cuadrados (SC)	Cuadrado Medio (CM)	F _{calculada} (F ₀)	F _{teórica} (F _{CR})
Renglón (A)	gl _A = m-1	SC _A =	xxxxxxxxxxxxx	$F_0 = \frac{CM_T}{CM_E}$	$F_{CR}=F_{(\alpha,gl_T,gl_E)}$
Columnas (B)	gl _B = m-1	SC _B =	xxxxxxxxxxx		
Tratamientos(T)	gl _T = m-1	SC _T =	$CM_T = SC_T / gl_T$		
Error (E)	gl _E = (m-1)(m-2)	SC _E =	$CM_E = SC_E / gl_E$	Decisión: Si F ₀ < F _{CR} Se acepta Ho	
Total (Total)	gl _{Total} = m ² -1	SC _{Total} =	xxxxxxxxxxx		
				Si F ₀ > F _{CR} { Se rechaza Ho Se acepta H ₁	

FORMATO de tabla de ANOVA para el DISEÑO DE CUADRO LATINO (DCL) (m x m)

Fuente de Variabilidad	Grados de Libertad (gl)	Suma de Cuadrados (SC)	Cuadrado Medio (CM)	F _{calculada} (F ₀)	F _{teórica} (F _{CR})
Renglón (A)	gl _A =	SC _A =	x x x x x x	F ₀ =	F _{CR} =
Columnas (B)	gl _B =	SC _B =	x x x x x x		
Tratamientos (T)	gl _T =	SC _T =	CM _T =		
Error (E)	gl _E =	SC _E =	CM _E =	Decisión:	
Total (Total)	gl _{Total} =	SC _{Total} =	xxxxxxxxxx		

5.5 Diseños de cuadros grecolatinos

El diseño de cuadros grecolatinos es un método utilizado en el diseño de experimentos (DoE) para controlar y analizar variabilidad en sistemas donde intervienen múltiples factores. Es especialmente útil en Ingeniería en Gestión Empresarial para optimizar procesos, reducir costos y mejorar la calidad en contextos con restricciones experimentales.

Definición y Características

Es una extensión del diseño de cuadros latinos, que controla dos fuentes de variabilidad (filas y columnas). El cuadro grecolatino controla tres fuentes de variabilidad mediante la superposición de dos cuadros latinos ortogonales (uno con letras latinas y otro con letras griegas). Cada combinación de fila, columna, letra latina y letra griega aparece exactamente una vez, garantizando equilibrio.

Estructura Básica

Un cuadro grecolatino de orden (n X n) asigna:

Filas y columnas: Representan dos factores de bloqueo (ejemplo: máquinas y turnos).

Letras latinas: Un tercer factor (ejemplo: operadores).

Letras griegas: Un cuarto factor (ejemplo: método de trabajo).

Ejemplo (4x4):

	F1	F2	F3	F4
C1	A α	B γ	C δ	D β
C2	B β	A δ	D γ	C α
C3	C γ	D α	A β	B δ
C4	D δ	C β	B α	A γ

Aplicaciones en Ingeniería en Gestión Empresarial

Optimización de procesos: Evaluar múltiples variables (ejemplo: velocidad, temperatura, material) en líneas de producción.

Control de calidad: Reducir variabilidad introducida por operadores, máquinas o lotes de materia prima.

Logística: Diseñar rutas de transporte considerando vehículos, conductores y horarios.

Experimentación con recursos limitados: Minimizar el número de pruebas manteniendo validez estadística.

Ventajas

Eficiencia: Analiza 4 factores con (n^2) pruebas [vs. (n^k) en diseños factoriales completos].

Reducción de ruido: Controla tres fuentes de variabilidad no relacionadas con el tratamiento.

Versatilidad: Útil en entornos industriales con restricciones de tiempo/costo

Limitaciones

- a) Requiere que todos los factores tengan el mismo número de niveles.
- b) No permite estudiar interacciones entre factores (supone aditividad).
- c) La interpretación puede ser compleja sin herramientas estadísticas como ANOVA.

El diseño grecolatino es una herramienta poderosa para Ingenieros en Gestión Empresarial que necesitan experimentar en entornos con múltiples variables de confusión, permitiendo decisiones basadas en datos con recursos limitados.

EL ALFABETO LATINO:

A, B, C, D, E, F, G, H, I, J, K, L, M,
N, O, P, Q, R, S, T, U, V, W, X, Y, Z

El Alfabeto Griego:

Alfa	α	Nu	ν
Beta	β	Xi	ξ
Gamma	γ	Ómicron	$\omicron$
Delta	δ	Pi	π
Épsilon	ϵ	Ro	ρ
Zeta	ζ	Sigma	σ
Eta	η	Tau	τ
Teta	θ	Ypsilon	υ
Iota	ι	Fi	ϕ
Kappa	κ	Ji	χ
Lamda	λ	Psi	ψ
Mu	μ	Omega	ω

TABLA DE VALORES PARA EL DISEÑO DE CUADROS GRECOLATINOS (DCGL) de $(m \times m)$

		Bloque II (Columnas)					SUMAS
		1	2	3		k	$X_{j \dots}$
Bloque I (Renglones)	1	$\alpha A = X_{1111}$	$\beta B = X_{1222}$	$\gamma C = X_{1333}$		$\zeta F = X_{1k66}$	
	2	$\beta B = X_{2122}$	$\gamma C = X_{2233}$	$\delta D = X_{2344}$		$\alpha A = X_{2k11}$	
	3	$\gamma C = X_{3133}$	$\delta D = X_{3244}$	$\epsilon E = X_{3355}$		$\beta B = X_{3k22}$	
	.	.	.	.		.	.
	.	.	.	.		.	.
	.	.	.	.		.	.
	k	$\zeta F = X_{k16}$	$\alpha A = X_{k21}$	$\beta B = X_{k32}$		$\theta H = X_{kk\theta h}$	
SUMAS	$X_{.j \dots}$						X....
SUMAS	$X_{\dots l}$	α	β	γ		ω	
SUMAS	$X_{\dots k}$	A	B	C		Z	
Medias	$\bar{X}_{\dots k}$						

Dónde: A=1, B=2, C=3, D=4, E=5, F=6, -----, Z=26 Para la posición del tratamiento

$\alpha=1, \beta=2, \gamma=3, \delta=4, \epsilon=5, \zeta=6, \dots, \omega=24$ Para la posición del bloque III

m → No. de renglones, columnas, letras griegas y tratamientos (letras latinas)

$X_{ij(l)(k)}$ → Es la observación en la posición ij del cuadro para el bloque (l) y el tratamiento (k)

$X_{i \dots}$ → Suma de las observaciones en el i -ésimo renglón

$X_{.j \dots}$ → Suma de las observaciones en la j -ésima columna

$X_{\dots l}$ → Suma de las observaciones de los valores de las posiciones de letras griegas

$X_{\dots k}$ → Suma de las observaciones de los valores de las posiciones de letras latinas para el tratamiento k

$X_{\dots}$ → Suma de todas las observaciones m

CALCULOS PREVIOS:

$$1) \left(\frac{X_{...}^2}{m^2} \right) \quad 2) \sum_{i=1}^m \left(\frac{X_{i...}^2}{m} \right) \quad 3) \sum_{j=1}^m \left(\frac{X_{.j..}^2}{m} \right) \quad 4) \sum_{l=1}^m \left(\frac{X_{...l}^2}{m} \right)$$

$$5) \sum_{k=1}^m \left(\frac{X_{...k}^2}{m} \right) \quad 6) \sum_{i=1}^m \sum_{j=1}^m \sum_{l=1}^m \sum_{k=1}^m (X_{ij(l)(k)}^2)$$

CALCULOS: $SC_A = (2-1)$ $SC_B = (3-1)$ $SC_C = (4-1)$ $SC_T = (5-1)$ $SC_{Total} = (6-1)$

$$SC_E = [SC_{Total} - SC_A - SC_B - SC_C - SC_T]$$

FORMULARIO DE LA TABLA DE ANOVA PARA EL DISEÑO DE CUADRO GRECOLATINO (DCGL) de (m x m)

Fuente de Variabilidad	Grados de Libertad (gl)	Suma de Cuadrados (SC)	Cuadrado Medio (CM)	F _{calculada} (F ₀)	F _{teórica} (F _{CR})
Renglón (A)	gl _A = (m-1)	SC _A =	x x x x x x	$F_0 = \frac{CM_T}{CM_E}$	$F_{CR}=F_{(\alpha, gl_T, gl_E)}$
Columnas (B)	gl _B = (m-1)	SC _B =	x x x x x x		
Bloque GL (C)	gl _C = (m-1)	SC _C =	x x x x x x		
Tratamientos (T)	gl _T = (m-1)	SC _T =	CM_T $= SC_T / gl_T$		
Error (E)	gl _E = (m-1)(m-3)	SC _E =	CM_E $= SC_E / gl_E$	Decisión: Si F ₀ < F _{CR} Se acepta Ho	
Total (Total)	gl _{Total} = (m ² -1)	SC _{Total} =	x x x x x x	Si F ₀ > F _{CR} { Se rechaza Ho Se acepta H ₁	

FORMATO: Tabla de ANOVA para el DISEÑO DE CUADRO GRECOLATINO (DCGL) de (m x m)

Fuente de Variabilidad	Grados de Libertad (gl)	Suma de Cuadrados (SC)	Cuadrado Medio (CM)	F _{calculada} (F ₀)	F _{teórica} (F _{CR})
Renglón (A)	gl _A =	SC _A =	x x x x x x	F ₀ =	F _{CR} =
Columnas (B)	gl _B =	SC _B =	x x x x x x		
Bloque GL (C)	gl _C =	SC _C =	x x x x x x		
Tratamientos (T)	gl _T =	SC _T =	CM _T =		
Error (E)	gl _E =	SC _E =	CM _E =	Decisión:	
Total (Total)	gl _{Total} =	SC _{Total} =	x x x x x x		

5.6 Aplicaciones

Los **diseños factoriales** en el **Diseño de Experimentos (DOE)** tienen aplicaciones clave en **Ingeniería de Gestión Empresarial**, ya que permiten optimizar procesos, reducir costos y mejorar la toma de decisiones basada en datos. A continuación, te detallo sus principales aplicaciones en este campo:

1. Optimización de Procesos Empresariales

Mejora de la productividad: Analizar cómo factores como *tiempo de producción, capacitación del personal y tecnología* afectan la eficiencia operativa.

Reducción de desperdicios: Evaluar el impacto de variables como *métodos de control de calidad, proveedores y flujo de trabajo* en la minimización de defectos.

Ejemplo:

Un diseño factorial 2^3 podría estudiar:

Factor A: Tipo de maquinaria (nuevo vs. antiguo).

Factor B: Horario de trabajo (turno diurno vs. nocturno).

Factor C: Nivel de capacitación (básico vs. avanzado).

Objetivo: Determinar la combinación óptima para maximizar la producción.

2. Gestión de la Cadena de Suministro

Optimización de inventarios: Evaluar cómo *niveles de stock, frecuencia de pedidos y proveedores* afectan los costos de almacenamiento y la satisfacción del cliente.

Logística y transporte: Analizar el impacto de *rutas de entrega, métodos de embalaje y tiempos de carga* en la eficiencia logística.

Ejemplo:

Un diseño factorial fraccionado 2^4 podría probar:

Factor A: Tamaño del lote (pequeño vs. grande).

Factor B: Frecuencia de reabastecimiento (semanal vs. diaria).

Factor C: Tipo de transporte (terrestre vs. aéreo).

Factor D: Almacén centralizado vs. descentralizado.

Objetivo: Minimizar costos logísticos sin afectar el tiempo de entrega.

3. Marketing y Experiencia del Cliente

Diseño de productos/servicios: Probar combinaciones de *precio, características del producto y empaque* para maximizar ventas.

Estrategias de publicidad: Evaluar el impacto de *canales de marketing* (redes sociales, email, TV), *frecuencia de anuncios y mensajes clave* en la conversión de clientes.

Ejemplo:

Un diseño factorial 2^2 con puntos centrales podría analizar:

Factor A: Precio (alto vs. bajo).

Factor B: Tipo de promoción (descuento vs. regalo).

Objetivo: Identificar la estrategia que maximice el retorno de inversión (ROI).

4. Gestión de Calidad y Six Sigma

Reducción de defectos: Estudiar cómo variables como *velocidad de producción, materiales y métodos de inspección* afectan la calidad.

Mejora continua: Implementar diseños factoriales para priorizar acciones de mejora en procesos administrativos y operativos.