


105 Preguntas de estadística para entrevistas de Data Science



Por Antonio Richaud

P1. ¿Cuáles son los temas más importantes en estadística?

Algunos de los temas importantes en estadística son:

- Medida de tendencia central
- Medida de dispersión
- Covarianza y Correlación
- Función de Distribución de Probabilidad
- Estandarización y normalización
- Teorema del límite central
- Población y muestra
- Pruebas de hipótesis

P2. ¿Qué es EDA (Análisis Exploratorio de Datos)?

- EDA implica el proceso de analizar datos visual y estadísticamente para entender sus patrones, distribuciones y relaciones subyacentes.
- El objetivo de EDA es obtener información sobre los datos, identificar posibles problemas y guiar los pasos del procesamiento de datos.

P3. ¿Qué son los datos cuantitativos y cualitativos?

Los datos se pueden categorizar en dos tipos principales: datos cuantitativos y datos cualitativos.

Datos Cuantitativos (numéricos)	Datos Cualitativos (categóricos)
Se basan en números, son contables o medibles.	Se basan en la interpretación, son descriptivos y se relacionan con el lenguaje.
Se analizan utilizando análisis estadístico.	Se analizan agrupando los datos en categorías y temas.
Tipos de datos cuantitativos: Datos discretos y datos continuos.	Tipos de datos cualitativos: Datos nominales y datos ordinales.
Ej: Edad, Altura, Peso, Ingreso, Tamaño del grupo, Puntaje de prueba.	Ej: Género, Estado civil, Lengua materna, Calificaciones, Colores.

P4. ¿Cuál es el significado de KPI en estadística?

KPI significa “Indicador Clave de Desempeño”. Los KPI son métricas o medidas específicas que se utilizan para evaluar y valorar el desempeño de un proceso, sistema u organización.

Se usan en varios campos, incluyendo negocios, finanzas, salud, educación y más. La elección de los KPI depende de los objetivos y metas de la organización o proceso que se está evaluando.

Al monitorear y analizar regularmente los KPI, las organizaciones pueden identificar áreas de mejora, tomar decisiones basadas en datos y medir el progreso hacia sus objetivos estratégicos.

P5. ¿Cuál es la diferencia entre Análisis Univariado, Bivariado y Multivariado?

Análisis Univariado	Análisis Bivariado	Análisis Multivariado
Involucra el examen de una sola variable.	Involucra el examen de la relación entre dos variables.	Involucra el análisis de múltiples variables simultáneamente.
Analiza las distribuciones, estadísticas resumidas y características.	Se enfoca en cómo los cambios en una variable están asociados con cambios en otra variable.	Observamos cómo múltiples variables interactúan e influyen entre sí.
Ej: Histogramas, Diagramas de caja, Media, Mediana, Desviación estándar.	Ej: Diagramas de dispersión, Coeficientes de correlación, Tabulaciones cruzadas.	Ej: Pairplot, Análisis de Componentes Principales (PCA), Análisis Factorial.

P6. ¿Cómo abordarías un conjunto de datos que tiene más del 30% de sus valores faltantes?

Elige un método de imputación apropiado basado en la naturaleza de los datos faltantes:

- **Imputación con Media/Mediana:**

Imputa los valores faltantes con la media o mediana de la variable. Este es un método simple pero puede no ser adecuado para variables con distribuciones no normales.

- **Imputación con Moda:**


Imputa los valores faltantes con la moda (el valor más frecuente) de la variable para datos categóricos.

- **Imputación con K-Vecinos Más Cercanos (KNN):**

Imputa los valores faltantes encontrando los vecinos más cercanos basados en otras variables.

P7. Da un ejemplo donde la mediana es una mejor medida que la media.

- La elección entre usar la mediana o la media como medida de tendencia central depende de la distribución de los datos y las características específicas del conjunto de datos.
- Una situación común donde la mediana es una mejor medida que la media es cuando se trata con datos que tienen valores atípicos extremos o una distribución altamente sesgada.



Ejemplo:

Supongamos que tienes los siguientes ingresos para diez residentes en la ciudad (en miles de dólares): {25,28,30,32,35,38,40,42,45,5000}

Ahora, calculemos tanto la media como la mediana:

a. Media (Promedio):

$$\text{Mediana} = (25 + 28 + 30 + 32 + 35 + 38 + 40 + 42 + 45 + 5000)/10 = 488.7$$

El ingreso promedio (488.7) está fuertemente influenciado por el valor atípico extremo (5000), haciendo que sea mucho mayor que el ingreso típico de los residentes en la ciudad.

b. Mediana:

Para encontrar la mediana, primero ordena los ingresos en orden ascendente:

25,28,30,32,35,38,40,42,45,5000

$$\text{Mediana} = (35 + 38) / 2 = 36.5$$

El ingreso mediano (36.5) es una mejor medida de tendencia central en este escenario porque no se ve afectada por valores extremos.

P8. ¿Cuál es la diferencia entre Estadísticas Descriptivas e Inferenciales?

Las estadísticas descriptivas y las estadísticas inferenciales son dos ramas fundamentales de la estadística que tienen propósitos diferentes en el análisis de datos. Aquí te dejo una descripción general de las diferencias clave entre ellas:

Estadísticas Descriptivas	Estadísticas Inferenciales
Se utilizan para resumir y describir las características principales de un conjunto de datos. Su objetivo es proporcionar una visión clara y concisa de los datos.	Se utilizan para hacer inferencias o sacar conclusiones sobre una población más grande basada en una muestra de datos. Implican generalizar de una muestra a una población.
Generalmente se utilizan en la etapa inicial del análisis de datos para entender el conjunto de datos e identificar patrones, tendencias y características importantes.	Generalmente se utilizan después de la exploración inicial de datos (estadísticas descriptivas) cuando los investigadores quieren hacer predicciones, probar hipótesis o hacer declaraciones sobre una población.
Se aplican generalmente tanto a poblaciones como a muestras. Pueden usarse para resumir datos de una población completa o de una muestra extraída de la población.	Se enfocan en hacer declaraciones o inferencias sobre una población basada en datos de una muestra. Implican estimar parámetros de población y evaluar la incertidumbre asociada con esas estimaciones.
Ejemplos: Las estadísticas descriptivas comunes incluyen medidas de tendencia central (p. ej., media, mediana, moda), medidas de dispersión (p. ej., rango, varianza, desviación estándar), distribuciones de frecuencia, histogramas y tablas resumen.	Ejemplos: Las técnicas estadísticas inferenciales comunes incluyen pruebas de hipótesis, intervalos de confianza, análisis de regresión, análisis de varianza (ANOVA), pruebas de chi-cuadrado y varios formularios de análisis multivariado.

P9. ¿Puedes indicar el método de dispersión de los datos en estadística?

En estadística, las medidas de dispersión, también conocidas como medidas de variabilidad o dispersión, se utilizan para describir cómo los puntos de datos en un conjunto de datos están distribuidos o dispersos. Estas medidas proporcionan información valiosa sobre hasta qué punto los valores de los datos se desvían de la tendencia central (por ejemplo, la media) y cuán variable o homogéneo es el conjunto de datos.

Hablemos de algunos métodos comunes para medir la dispersión:

- **Rango:**

El rango es la medida más simple de dispersión y se calcula como la diferencia entre los valores máximo y mínimo en un conjunto de datos. Proporciona una idea de la extensión de los datos, pero es sensible a los valores atípicos.

- **Varianza:**

La varianza cuantifica la diferencia cuadrada promedio entre cada punto de datos y la media. Se calcula tomando el promedio de las desviaciones cuadradas de la media.

- **Desviación Estándar:**

La desviación estándar es la raíz cuadrada de la varianza. Proporciona una medida de dispersión en las mismas unidades que los datos originales, lo que facilita su interpretación.

P10. ¿Cómo podemos calcular el rango de los datos?

El rango es una medida de la extensión o dispersión de los datos y es simplemente la diferencia entre los valores máximo y mínimo en el conjunto de datos. Representa la amplitud o extensión de los valores desde el más bajo hasta el más alto dentro de tus datos.

$$\text{Rango} = \text{Máximo} - \text{Mínimo}$$

Ejemplo:

Supongamos que tienes un conjunto de datos de calificaciones de exámenes para una clase de estudiantes: Calificaciones: {60, 72, 78, 85, 92, 95}

$$\text{Rango} = \text{Máximo} - \text{Mínimo} = 95 - 60 = 35$$

Entonces, el rango de las calificaciones de los exámenes en este conjunto de datos es 35. Esto significa que las calificaciones varían desde un mínimo de 60 hasta un máximo de 95, cubriendo un rango de 35 puntos. :)

P11. ¿El rango es sensible a los valores atípicos?

Sí, el rango es sensible a los valores atípicos. Dado que depende únicamente de los valores extremos en el conjunto de datos (el máximo y el mínimo), los valores atípicos, que son valores extremos que se encuentran lejos de la tendencia central de los datos, pueden tener un impacto significativo en el rango.

P12. ¿Cuáles son los escenarios en los que se mantienen los valores atípicos en los datos?

Los valores atípicos pueden mantenerse en los datos cuando representan información importante y significativa, eventos inusuales o raros, o ocurrencias poco comunes que son relevantes para el análisis, como la detección de anomalías, la comprensión del comportamiento extremo o el estudio de casos únicos.

P13. ¿Cuál es el significado de la desviación estándar?

- La desviación estándar es una medida estadística que cuantifica la cantidad de variación o dispersión en un conjunto de valores de datos.
- Proporciona información sobre cuán dispersos o agrupados están los puntos de datos alrededor del valor medio (promedio).
- En otras palabras, la desviación estándar nos ayuda a entender hasta qué punto los puntos de datos individuales se desvían de la media.
- La desviación estándar se calcula como la raíz cuadrada de la varianza determinando la desviación de cada punto de datos en relación con la media.

$$\sigma = \sqrt{\frac{\sum_i^N (X_i - \bar{X})^2}{N}}$$

P14. ¿Qué es la corrección de Bessel?


La corrección de Bessel es un ajuste estadístico que se realiza en la fórmula para calcular la varianza muestral y la desviación estándar muestral. Se utiliza para proporcionar una estimación más precisa de la varianza y desviación estándar de la población cuando se trabaja con una muestra de una población más grande.

La idea clave detrás de la corrección de Bessel es que cuando calculas la varianza o desviación estándar utilizando datos muestrales (en lugar de datos de toda la población), tiendes a subestimar la verdadera varianza o desviación estándar de la población. Esta subestimación ocurre porque basas tus cálculos en un subconjunto más pequeño de los datos.

La corrección de Bessel ajusta esta subestimación dividiendo la suma de las diferencias cuadradas de la media entre $(n - 1)$, donde “n” es el tamaño de la muestra. En contraste, cuando se calcula la varianza y la desviación estándar de la población, se divide por “n” (el tamaño real de la población). Al usar $(n - 1)$ en lugar de “n” en la fórmula, la corrección de Bessel incrementa ligeramente la varianza y desviación estándar calculadas, haciéndolas más representativas de la población.

P15. ¿Qué entiendes por una curva dispersa y una curva concentrada?

En el contexto de las distribuciones de datos y la estadística, estos términos describen el grado de variabilidad o dispersión en los datos.



Curva Dispersa (Mayor Dispersión)	Curva Concentrada (Menor Dispersión)
Una curva o distribución dispersa típicamente tiene una mayor extensión o rango de valores. Esto significa que los puntos de datos están más dispersos entre sí.	Una curva o distribución concentrada típicamente tiene una menor extensión o rango de valores. Esto significa que los puntos de datos están más cercanos entre sí.
Se asocia con una desviación estándar más alta y un rango mayor o un rango intercuartílico (IQR) más grande.	Se asocia con una desviación estándar más baja y un rango menor o un rango intercuartílico (IQR) más pequeño.
En representaciones gráficas, a menudo resulta en una distribución más ancha o plana con una mayor extensión de puntos de datos.	En representaciones gráficas, a menudo resulta en una distribución más estrecha y alta con puntos de datos agrupados más cercanos entre sí.
Ejemplo: Un conjunto de datos de niveles de ingresos para una población diversa, donde algunos individuos tienen ingresos muy altos y otros tienen ingresos muy bajos, creando una amplia dispersión.	Ejemplo: Un conjunto de datos de calificaciones de exámenes para un grupo de estudiantes que obtuvieron puntajes muy cercanos entre sí, creando una distribución concentrada.

P16. ¿Puedes calcular el coeficiente de variación?

- El coeficiente de variación (CV) es una medida de variabilidad relativa y se calcula como la relación de la desviación estándar (sigma) a la media (mu) de un conjunto de datos. A menudo se expresa como un porcentaje para hacerlo más interpretable.
- La fórmula para calcular el coeficiente de variación es la siguiente:

$$(CV) = \frac{\sigma}{\mu} \times 100$$

Donde:

- CV = Coeficiente de variación
- σ = Desviación estándar del conjunto de datos
- μ = Media del conjunto de datos

El coeficiente de variación es particularmente útil cuando deseas comparar la variabilidad relativa de dos o más conjuntos de datos con diferentes unidades de medida o medias diferentes. Proporciona una forma estandarizada de expresar la dispersión de los datos en relación con la media, lo que facilita la comparación de conjuntos de datos de diferentes escalas.

Ejemplo:

Puntajes de exámenes: Considera dos clases, Clase A y Clase B, con puntajes de exámenes. Aquí están las estadísticas para ambas clases:

- Clase A: Puntaje promedio = 85, Desviación estándar = 10
- Clase B: Puntaje promedio = 90, Desviación estándar = 8

Ahora, calculemos el coeficiente de variación para ambas clases:

- Para la Clase A: $CV \approx 11.76\%$
- Para la Clase B: $CV \approx 8.89\%$

En este ejemplo, la Clase A tiene un coeficiente de variación más alto (11.76%) en comparación con la Clase B (8.89%). Esto sugiere que los puntajes de los exámenes en la Clase A son más variables en relación con su media en comparación con la Clase B.

P17. ¿Qué significa la imputación de la media para datos faltantes? ¿Por qué es mala?

La imputación de la media es un método para manejar datos faltantes reemplazando los valores faltantes con el valor medio (promedio) de los datos disponibles en la misma columna.

Desventajas de la imputación de la media:

- **Introducción de sesgo:**

La imputación de la media puede introducir sesgo en el conjunto de datos.

- **Pérdida de variabilidad:**

Imputar valores faltantes con la media reduce la variabilidad de los datos porque todos los valores imputados son iguales.

- **Desconsidera los patrones de datos:**

La imputación de la media no toma en cuenta ningún patrón subyacente o relaciones en los datos. Trata todos los valores faltantes como si fueran independientes de otras variables o condiciones, lo cual puede no ser el caso.

- **Impacto en el rendimiento del modelo:**

En el aprendizaje automático, la imputación de la media puede afectar negativamente el rendimiento del modelo, especialmente cuando los valores faltantes están relacionados con la variable objetivo o cuando contienen información importante. Puede llevar a predicciones inexactas y reducir la efectividad del modelo.

- **Imputación de datos categóricos:**

La imputación de la media es principalmente adecuada para datos numéricos. Al tratar con datos categóricos, otros métodos de imputación como la imputación de la moda (reemplazar valores faltantes con la moda, o categoría más común) son más apropiados.

P18. ¿Cuál es el beneficio de usar diagramas de caja (box plots)?

Los diagramas de caja (box plots) son herramientas gráficas valiosas en estadística y análisis de datos que proporcionan varios beneficios para visualizar y resumir las distribuciones de datos.

Te dejo algunos de los beneficios clave de usar diagramas de caja:

- Resumen de la distribución de datos
- Identificación de valores atípicos
- Comparación de múltiples grupos
- Detección de asimetría
- Visualización de cuartiles
- Robustez frente a valores atípicos
- Facilidad de interpretación
- Evaluación de la calidad de los datos


P19. ¿Cuál es el significado de los cinco números de la estadística?

El resumen de los cinco números consta de cinco valores clave que ayudan a describir la tendencia central, la dispersión y la forma de un conjunto de datos. Los cinco valores en el resumen de cinco números son:

1. **Mínimo (Min):** Este es el valor más pequeño en el conjunto de datos, representando el punto de datos más bajo. Te da una idea del límite inferior de los datos.
2. **Primer cuartil (Q1):** El primer cuartil, también conocido como el cuartil inferior, es el valor por debajo del cual se encuentra el 25% de los datos. Marca el percentil 25 del conjunto de datos y representa el límite inferior del 50% medio de los datos.
3. **Mediana (Q2):** La mediana, o el segundo cuartil, es el valor medio del conjunto de datos cuando está ordenado en orden ascendente. Divide los datos en dos mitades iguales, con el 50% de los datos por debajo y el 50% por encima de él. La mediana representa la tendencia central de los datos.
4. **Tercer cuartil (Q3):** El tercer cuartil, también conocido como el cuartil superior, es el valor por debajo del cual se encuentra el 75% de los datos. Marca el percentil 75 del conjunto de datos y representa el límite superior del 50% medio de los datos.
5. **Máximo (Max):** Este es el valor más grande en el conjunto de datos, representando el punto de datos más alto. Te da una idea del límite superior de los datos.

P20. ¿Cuál es la diferencia entre el primer cuartil, el segundo cuartil y el tercer cuartil?

- El primer cuartil (Q1) es el valor por debajo del cual se encuentra el 25% de los datos. Representa el límite inferior del 50% central de los datos.
- El segundo cuartil (Q2), también conocido como la mediana, es el valor medio de los datos cuando están ordenados. Divide los datos en dos mitades iguales, con el 50% por debajo y el 50% por encima.
- El tercer cuartil (Q3) es el valor por debajo del cual se encuentra el 75% de los datos. Representa el límite superior del 50% central de los datos.



Piensa en los cuartiles como una forma de dividir tus datos en cuatro partes iguales, con Q1 marcando el punto del 25%, Q2 (mediana) marcando el punto del 50%, y Q3 marcando el punto del 75%. Estos valores te ayudan a entender dónde se concentra la mayoría de los datos y cómo se dispersan.

P21. ¿Cuál es la diferencia entre porcentaje y percentil?


Porcentaje y percentil son conceptos relacionados en estadística, pero tienen significados distintos.

Porcentaje	Percentil
El porcentaje es una unidad de medida denotada por el símbolo “%”.	El percentil es un concepto estadístico utilizado para describir una posición o ubicación específica dentro de un conjunto de datos.
Representa una proporción o fracción de un todo, dividida por 100. En otras palabras, cuando expresas una cantidad como un porcentaje, la estás dividiendo entre 100.	Representa el valor por debajo del cual se encuentra un porcentaje determinado de los datos. Los percentiles se utilizan para entender la distribución de los datos e identificar cómo se clasifica un punto de datos en comparación con otros.
Por ejemplo, el 25 por ciento (25%) es equivalente a 0.25 o 25/100. Significa 25 de cada 100, o una cuarta parte del total.	Por ejemplo, el percentil 25 (también conocido como el primer cuartil, Q1) es el valor por debajo del cual se encuentran el 25% de los puntos de datos en un conjunto de datos.

P22. ¿Qué es un valor atípico (outlier)?

- Un valor atípico es un punto de datos que se desvía significativamente del resto de los datos en un conjunto.
- En otras palabras, es una observación que está inusualmente distante de otras observaciones en el conjunto de datos.
- Los valores atípicos pueden ser valores excepcionalmente altos (valores atípicos positivos) o valores excepcionalmente bajos (valores atípicos negativos).

P23. ¿Cuál es el impacto de los valores atípicos en un conjunto de datos?



1. Impactos Negativos:

• Influencia en las medidas de tendencia central:

Un solo valor atípico extremo puede influir en la media en su dirección, haciendo que no sea representativa de la mayoría de los datos.

• Impacto en las medidas de dispersión:

La presencia de valores atípicos puede inflar medidas como la desviación estándar y el rango intercuartílico (IQR), haciéndolos más grandes de lo que serían sin valores atípicos.

• Sesgo en las distribuciones de datos:

Los valores atípicos positivos pueden resultar en distribuciones sesgadas a la derecha, mientras que los valores atípicos negativos pueden resultar en distribuciones sesgadas a la izquierda. Esto puede afectar la interpretación de los datos.

- **Estadísticas resumen engañosas:**

Los valores atípicos pueden distorsionar la interpretación de las estadísticas resumen.

- **Impacto en las pruebas de hipótesis:**

Los valores atípicos pueden afectar los resultados de las pruebas de hipótesis. Pueden llevar a conclusiones incorrectas, como detectar diferencias significativas cuando no existen o no detectar diferencias reales cuando los valores atípicos las enmascaran.

2. Impactos Positivos:

- **Detección de anomalías:**

Los valores atípicos pueden señalar la presencia de anomalías o eventos raros en un conjunto de datos. Identificar estas anomalías puede ser valioso en varios campos, incluyendo la detección de fraude, control de calidad y detección de valores atípicos en experimentos científicos.

- **Modelado robusto:**

En algunos casos, los valores atípicos pueden ser observaciones genuinas que son importantes para modelar. Por ejemplo, en el modelado financiero, los movimientos extremos de precios de acciones pueden contener información valiosa para predecir tendencias del mercado.

P24. Menciona métodos para detectar valores atípicos en un conjunto de datos.

Existen varios métodos para detectar valores atípicos en un conjunto de datos, que van desde técnicas gráficas hasta pruebas estadísticas. Aquí hay algunos métodos comúnmente utilizados:

- **Diagramas de caja (Box-and-Whisker Plots):**

Los diagramas de caja proporcionan una representación visual de la distribución de los datos, incluyendo la identificación de posibles valores atípicos. En un diagrama de caja, los valores atípicos se muestran típicamente como puntos de datos individuales más allá de los bigotes del diagrama.

- **Diagramas de dispersión (Scatterplots):**

Los diagramas de dispersión son particularmente útiles para identificar valores atípicos en datos bivariados o multivariados. Los valores atípicos pueden aparecer como puntos de datos que están lejos del grupo principal de puntos en el diagrama de dispersión.

- **Puntuaciones Z (Z-Scores):**

Las puntuaciones Z (puntuaciones estándar) miden cuántas desviaciones estándar se encuentra un punto de datos de la media. Los puntos de datos con puntuaciones Z absolutas altas (típicamente mayores que 2 o 3) a menudo se consideran posibles valores atípicos.

- **Método del rango intercuartílico (IQR):**

El método IQR implica calcular el rango intercuartílico ($IQR = Q3 - Q1$) y luego identificar los valores que caen por debajo de $Q1 - 1.5 * IQR$ o por encima de $Q3 + 1.5 * IQR$ como posibles valores atípicos.

- **Inspección visual:**

A veces, una simple inspección visual de los datos a través de histogramas, diagramas QQ (diagramas cuantil-cuantil) u otras técnicas de visualización puede revelar la presencia de valores atípicos.

Es importante tener en cuenta que la elección del método de detección de valores atípicos debe estar guiada por las características de tus datos y los objetivos específicos de tu análisis.

P25. ¿Cómo puedes manejar los valores atípicos en los conjuntos de datos?

Manejar valores atípicos en conjuntos de datos es un paso importante en el preprocesamiento de datos para asegurar que no influyan indebidamente en los resultados de tu análisis o modelado. El enfoque que elijas para manejar los valores atípicos depende de la naturaleza de los datos, el contexto del análisis y tus objetivos específicos. Aquí hay varios métodos para manejar valores atípicos:

- **Truncamiento o eliminación de datos:**

Un enfoque común es simplemente eliminar los valores atípicos del conjunto de datos. Esto debe hacerse con precaución, especialmente si los valores atípicos representan observaciones válidas e importantes. Eliminar valores atípicos es apropiado cuando es probable que sean el resultado de errores de entrada de datos o errores de medición.

- **Transformación de datos:**

Transformar los datos puede ser una forma útil de mitigar el impacto de los valores atípicos. Las transformaciones comunes incluyen transformaciones logarítmicas, de raíz cuadrada o inversas. Estas transformaciones tienden a comprimir el rango de valores extremos.

- **Windsorización:**

La windsorización implica limitar los valores extremos reemplazándolos con un valor percentil especificado. Por ejemplo, puedes reemplazar los valores por encima del percentil 95 con el valor en el percentil 95.

- **Imputación:**

Para los valores faltantes que no son valores atípicos extremos, puedes imputarlos usando varios métodos, como imputación de la media, imputación de la mediana o técnicas más avanzadas como la imputación mediante regresión.

- **Estadísticas robustas:**

Usar métodos estadísticos robustos que sean menos sensibles a los valores atípicos puede ser un enfoque efectivo. Por ejemplo, reemplazar la media con la mediana y usar el rango intercuartílico (IQR) en lugar de la desviación estándar puede hacer que el análisis estadístico sea más robusto.

- **Enfoques basados en modelos:**

En el modelado predictivo, considera usar algoritmos que sean menos sensibles a los valores atípicos, como métodos de regresión robusta o métodos de ensamblado como los bosques aleatorios, que pueden manejar mejor los valores atípicos que la regresión lineal.

- **Conocimiento del dominio:**

Confía en el conocimiento del dominio para entender el contexto de los valores atípicos. A veces, lo que aparece como un valor atípico puede ser un punto de datos válido e importante. Consulta con expertos en el dominio para determinar la adecuación de manejar valores atípicos.

- **Reporte y transparencia:**

Independientemente del enfoque elegido, es crucial documentar de manera transparente cómo se manejaron los valores atípicos en el análisis para asegurar la reproducibilidad e interpretabilidad de tus resultados.

P26. ¿Cómo calcular el rango y el rango intercuartílico?

Calcular el rango y el rango intercuartílico (IQR) es un proceso sencillo que implica el uso de fórmulas estadísticas básicas. Así es como se calculan ambos:

- **Rango:**

El rango es la medida más simple de dispersión en un conjunto de datos. Es la diferencia entre los valores máximo y mínimo en el conjunto de datos.

$$\text{Rango} = \text{Valor Máximo} - \text{Valor Mínimo}$$


- **Rango intercuartílico (IQR):**

El rango intercuartílico (IQR) es una medida de la dispersión o variabilidad del 50% central de los datos. Se calcula como la diferencia entre el tercer cuartil (Q3) y el primer cuartil (Q1) del conjunto de datos.

$$\text{IQR} = \text{Q3} - \text{Q1}$$

P27. ¿Qué es la regla empírica?

The Empirical Rule



La regla empírica, también conocida como la regla **68-95-99.7** o la regla de los tres sigmas, es una guía estadística utilizada para describir la distribución aproximada de los datos en una distribución normal (en forma de campana). Proporciona información sobre cómo se distribuyen los valores de los datos alrededor de la media (promedio) en un conjunto de datos normalmente distribuido.

La regla empírica establece que:


- Aproximadamente el 68% de los datos se encuentran dentro de una desviación estándar de la media.
- Aproximadamente el 95% de los datos se encuentran dentro de dos desviaciones estándar de la media.
- Aproximadamente el 99.7% de los datos se encuentran dentro de tres desviaciones estándar de la media.

P28. ¿Qué es la asimetría (skewness)?

La asimetría es una medida de la asimetría de una distribución. Una distribución es asimétrica cuando sus lados izquierdo y derecho no son imágenes especulares.

Una distribución puede tener asimetría a la derecha (o positiva), a la izquierda (o negativa) o asimetría cero. Una distribución asimétrica a la derecha es más larga en el lado derecho de su pico, y una distribución asimétrica a la izquierda es más larga en el lado izquierdo de su pico:

- Asimetría a la derecha (positiva)
- Asimetría cero
- Asimetría a la izquierda (negativa)



P29. ¿Cuáles son las diferentes medidas de asimetría?


Existen diferentes medidas de asimetría utilizadas para cuantificar esta propiedad. Las tres medidas más comunes de asimetría son:

- Primer Coeficiente de Asimetría de Pearson (o Asimetría de Momento)
- Coeficiente de Asimetría de Momento Estandarizado de Fisher-Pearson (o Asimetría de Muestra)
- Coeficiente de Asimetría de Bowley (o Asimetría de Cuartil)

P30. ¿Qué es la curtosis?

La curtosis es una medida estadística que cuantifica la “colalidad” o “puntiagudez” de la distribución de probabilidad de una variable aleatoria de valor real. En otras palabras, te dice cómo se distribuyen los datos con respecto a las colas (valores extremos) y el pico central de la distribución.

Clasificaciones de la curtosis basadas en la forma de la distribución de datos:



P31. ¿Dónde se utilizan las distribuciones de cola larga?

Las distribuciones de cola larga se utilizan en varios campos y aplicaciones donde la presencia de eventos raros pero significativos, valores extremos o valores atípicos son de particular interés o importancia. En la hoja que viene te dejo algunas áreas donde las distribuciones de cola larga se utilizan comúnmente:

- **Finanzas y Gestión de Riesgos:**

Las distribuciones de cola larga se utilizan frecuentemente para modelar los rendimientos de activos, la volatilidad del mercado y el riesgo financiero. Son empleadas en la evaluación de riesgos y la gestión de carteras para tener en cuenta eventos extremos como caídas del mercado o grandes ganancias de inversión.

- **Seguros:**

Las compañías de seguros utilizan distribuciones de cola larga para modelar reclamaciones de seguros. Estas distribuciones tienen en cuenta eventos raros pero costosos, como desastres naturales o grandes reclamaciones médicas.

- **Ciencia Ambiental:**


En estudios relacionados con desastres naturales, como huracanes, terremotos e inundaciones, las distribuciones de cola larga se utilizan para estimar la probabilidad de que ocurran eventos extremos.

- **Epidemiología:**

Los epidemiólogos pueden utilizar distribuciones de cola larga para modelar la propagación de enfermedades infecciosas, ya que tienen en cuenta brotes esporádicos o eventos de superpropagación.


P32. ¿Qué es el teorema del límite central?

En teoría de probabilidades, el teorema del límite central (CLT) establece que la distribución de una variable muestral se aproxima a una distribución normal (es decir, una “curva de campana”) a medida que el tamaño de la muestra se hace más grande, es decir, $n \geq 30$, asumiendo que todas las muestras son idénticas en tamaño y sin importar la forma real de la distribución de la población.



P33. ¿Algún ejemplo para demostrar el funcionamiento del teorema del límite central?

Casualmente traigo un ejemplo en la bolsita de mi camisa: una población sigue una distribución de Poisson (imagen izquierda). Si tomamos 10,000 muestras de la población, cada una con un tamaño de muestra de 50, las medias de las muestras siguen una distribución normal, como lo predice el teorema del límite central (imagen derecha).



P34. ¿Qué condiciones generales deben cumplirse para que el teorema del límite central sea válido?

Para que el Teorema del Límite Central (CLT) sea válido, se deben cumplir las siguientes condiciones:

- **Muestreo Aleatorio:**

Los datos deben ser seleccionados aleatoriamente de la población.

- **Independencia:**

Los puntos de datos deben ser independientes entre sí.

- **Tamaño de Muestra Suficiente:**

El tamaño de la muestra generalmente debe ser mayor o igual a 30.

- **Varianza Finita:**

La población debe tener una varianza finita.

- **Distribución Idéntica:**

Idealmente, los datos deben provenir de una población con la misma distribución.

El CLT establece que a medida que aumenta el tamaño de la muestra, las medias muestrales se aproximan a una distribución normal.

P35. ¿Qué significa sesgo de selección?

El sesgo de selección es el sesgo que ocurre durante el muestreo de datos. Este tipo de sesgo ocurre cuando una muestra no es representativa de la población, lo cual se va a analizar en un estudio estadístico.

P36. ¿Cuáles son los tipos de sesgo de selección en estadística?

Existen muchos tipos de sesgo de selección, como se muestra a continuación:

- Selección del observador
- Deserción
- Sesgo protopático
- Intervalos de tiempo
- Sesgo de muestreo

P37. ¿Cuál es la probabilidad de lanzar dos dados justos y obtener una suma de 8?

• Para encontrar la probabilidad de lanzar dos dados justos y obtener una suma de 8, necesitamos determinar cuántos resultados favorables (sumas de 8) hay y luego dividirlo entre el número total de posibles resultados.

• Cada dado tiene 6 caras, numeradas del 1 al 6. Cuando lanzas dos dados, hay $6 \times 6 = 36$ posibles resultados porque cada dado tiene 6 posibles resultados, y son independientes.

• Ahora, calculemos los resultados favorables cuando la suma es 8: (2, 6), (3, 5), (4, 4), (5, 3), (6, 2). Hay 5 resultados favorables.

• Entonces, la probabilidad de obtener una suma de 8 al lanzar dos dados justos es:

Probabilidad = Número de resultados favorables / Número total de resultados posibles = $5/36$
Por lo tanto, la probabilidad es $5/36$. :b

P38. ¿Cuáles son los diferentes tipos de distribución de probabilidad utilizados en Ciencia de Datos?

Las distribuciones de probabilidad son funciones matemáticas que describen la probabilidad de diferentes resultados o eventos en un proceso aleatorio. Hay varios tipos de distribuciones de probabilidad, cada una con sus propias características y aplicaciones.

Hay dos tipos principales de distribuciones de probabilidad: discretas y continuas.

1. **Distribuciones de Probabilidad Discretas:**

En una distribución de probabilidad discreta, la variable aleatoria solo puede tomar valores distintos y separados, a menudo enteros. Ejemplos comunes de distribuciones de probabilidad discretas incluyen:

- Distribución de Bernoulli
- Distribución Binomial
- Distribución de Poisson

2. **Distribuciones de Probabilidad Continuas:**

En una distribución de probabilidad continua, la variable aleatoria puede tomar cualquier valor dentro de un rango especificado. Ejemplos comunes de distribuciones de probabilidad continuas incluyen:

- Distribución Normal (Distribución Gaussiana)
- Distribución Uniforme
- Distribución Log-Normal
- Ley de Potencia
- Distribución de Pareto

P39. ¿Qué entiendes por el término Distribución Normal/Gaussiana/de campana?

Una distribución normal, también conocida como distribución gaussiana o distribución de campana, es un concepto estadístico fundamental en teoría de probabilidad y estadística. Es una distribución de probabilidad continua que se caracteriza por una forma específica de su función de densidad de probabilidad (PDF o sea Probability Density Function), que tiene las siguientes propiedades clave:

- **Simetría:** La distribución normal es simétrica, lo que significa que está centrada alrededor de un solo pico, y los lados izquierdo y derecho son imágenes especulares entre sí. La media, la mediana y la moda de una distribución normal son todas iguales y se ubican en el centro de la distribución.
- **Forma de campana:** La PDF de una distribución normal tiene una forma de campana, con el punto más alto (pico) en la media y valores que disminuyen gradualmente a medida que te alejas del pico.
- **Media y Desviación Estándar:** La distribución normal se caracteriza completamente por dos parámetros: la media (μ) y la desviación estándar (σ). La media representa el centro de la distribución, mientras que la desviación estándar controla la dispersión de los datos. Las desviaciones estándar más grandes resultan en distribuciones más amplias.

• **Regla Empírica:** La distribución normal sigue la regla empírica (también conocida como la regla 68-95-99.7 como ya te había explicado anteriormente), que establece que aproximadamente:

- El 68% de los datos se encuentran dentro de una desviación estándar de la media.

- El 95% de los datos se encuentran dentro de dos desviaciones estándar de la media.

- El 99.7% de los datos se encuentran dentro de tres desviaciones estándar de la media.

• **Continua:** La distribución normal es una distribución de probabilidad continua, lo que significa que puede tomar un número infinito de valores dentro de su rango. No hay huecos ni discontinuidades en la distribución.

Muchos fenómenos naturales, como los pesos, alturas y puntajes de CI, se aproximan a una distribución normal. También es fundamental en la prueba de hipótesis y el modelado estadístico.

P40. ¿Puedes indicar la fórmula para la distribución normal?

Esta fórmula representa la curva en forma de campana de la distribución normal, que es simétrica alrededor de la media (μ) y caracterizada por su media y desviación estándar. Describe la probabilidad de observar un valor específico (x) en un conjunto de datos distribuidos normalmente.


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Donde:

- $f(x)$ es la función de densidad de probabilidad en un valor dado de (x)
- μ es la media de la distribución normal
- σ es la desviación estándar de la distribución normal
- π es la constante matemática pi (3.14159... Ya te la sabes :b)
- e es la base del logaritmo natural (aproximadamente 2.71828)

P41. ¿Cuál es la relación entre la media y la mediana en una distribución normal?

En una distribución normal, la media y la mediana son iguales y coinciden en el centro de la distribución.



P42. ¿Cuáles son algunas de las propiedades de una distribución normal?

Una distribución normal, también conocida como distribución gaussiana o curva de campana, tiene varias propiedades clave:

- **Curva en forma de campana:** La distribución parece una campana simétrica, con un pico en el medio y colas que se afinan gradualmente en ambos lados.
- **Simetría:** Es perfectamente simétrica, lo que significa que si divides la curva por la mitad, un lado es una imagen especular del otro.
- **Pico central:** El punto más alto (pico) de la curva es la media, que también es la mediana de los datos.
- **Media = Mediana = Moda:** La media (promedio), la mediana (valor medio) y la moda (valor más común) están todas en el mismo punto en el medio de la distribución.
- **Colas que se extienden hasta el infinito:** Las colas de la curva se extienden simétricamente en ambas direcciones, pero se acercan cada vez más al eje horizontal a medida que se alejan de la media.
- **Dispersión controlada por la desviación estándar:** El ancho de la curva está determinado por la desviación estándar. Una desviación estándar mayor hace que la curva sea más ancha, y una menor la hace más estrecha.

- **Regla empírica:** Esta regla ayuda a estimar dónde es probable que se encuentren los puntos de datos dentro de la distribución. Se basa en la regla 68-95-99.7, que dice que aproximadamente el 68% de los datos se encuentran dentro de una desviación estándar de la media, el 95% dentro de dos desviaciones estándar y aproximadamente el 99.7% dentro de tres desviaciones estándar.
- **Usada en muchas situaciones de la vida real:** La distribución normal es comúnmente vista en la naturaleza y en sistemas humanos, incluyendo cosas como las medidas de altura, los puntajes de CI y los errores en la fabricación.
- **Fácil para el análisis estadístico:** Debido a sus propiedades bien definidas, la distribución normal se utiliza a menudo en estadística para modelar y hacer predicciones sobre datos.

P43. ¿Cuál es la suposición de normalidad?

La suposición de normalidad en estadísticas es la idea de que los datos o residuos en un análisis estadístico deben seguir una distribución de probabilidad continua, simétrica y en forma de campana llamada distribución normal.

P44. ¿Cómo convertir una distribución normal a una distribución normal estándar?

Convertir una distribución normal a una distribución normal estándar implica un proceso llamado “estandarización” o “normalización”. Este proceso transforma los valores de la distribución normal original en valores equivalentes que siguen una distribución normal estándar con una media de 0 y una desviación estándar de 1.

Aquí están los pasos para convertir una distribución normal a una distribución normal estándar:

1. Determinar la media y la desviación estándar de la distribución normal

original: Identifica la media (μ) y la desviación estándar (σ) de la distribución normal original.

2. Calcular la puntuación Z: La puntuación Z (también conocida como puntuación estándar) mide cuántas desviaciones estándar se encuentra un valor particular de la media en la distribución original.

$$Z = \frac{(X - \mu)}{\sigma}$$

Donde:

- (Z) es la puntuación Z.
- X es el valor de la distribución original que deseas convertir.
- μ es la media de la distribución original.
- σ es la desviación estándar de la distribución original.

3. La puntuación Z resultante representa la distribución normal estándar:

La puntuación Z que calculas en el paso 2 representa el valor equivalente en una distribución normal estándar.

Siguiendo estos pasos, puedes convertir cualquier valor de una distribución normal en un valor correspondiente en la distribución normal estándar. Esta conversión es útil para realizar cálculos basados en la distribución normal estándar y para hacer comparaciones entre datos de diferentes distribuciones normales.

P45. ¿Puedes decirme el rango de los valores en una distribución normal estándar?

En una distribución normal estándar, también conocida como distribución normal o distribución Z, el rango de posibles valores se extiende desde el infinito negativo ($-\infty$) hasta el infinito positivo ($+\infty$).

Sin embargo, es importante notar que, aunque el rango de posibles valores es teóricamente infinito, la gran mayoría de los valores en una distribución normal estándar se concentran dentro de un rango relativamente estrecho alrededor de la media, que es 0. La distribución tiene forma de campana, y a medida que te alejas de la media en cualquier dirección, la densidad de probabilidad de los valores disminuye. Las colas de la distribución se extienden hasta el infinito, pero se vuelven cada vez más pequeñas a medida que te alejas de la media.

Estadísticamente, la mayoría de los valores en una distribución normal estándar caen dentro de unas pocas desviaciones estándar de la media.


Aproximadamente:

- El 68% de los datos se encuentran dentro de una desviación estándar de la media.
- El 95% de los datos se encuentran dentro de dos desviaciones estándar de la media.
- El 99.7% de los datos se encuentran dentro de tres desviaciones estándar de la media.

Esto significa que los valores dentro del rango de aproximadamente -3 a +3 desviaciones estándar de la media cubren la gran mayoría de las observaciones en una distribución normal estándar. Más allá de este rango, la probabilidad de observar un valor se vuelve extremadamente baja.

P46. ¿Qué es el principio de Pareto?

- El Principio de Pareto, también conocido como la regla 80/20 o la Ley de los pocos vitales, es un principio nombrado en honor al economista italiano Vilfredo Pareto.
- Sugiere que, en muchas situaciones, un pequeño porcentaje de causas o entradas es responsable de un gran porcentaje de los resultados o salidas.
- En su forma más simple, el Principio de Pareto establece que aproximadamente el 80% de los efectos provienen del 20% de las causas.




P47. ¿Qué son las distribuciones asimétricas hacia la izquierda y hacia la derecha?

Las distribuciones asimétricas hacia la izquierda y hacia la derecha, también conocidas como distribuciones con sesgo negativo y positivo, son tipos de distribuciones asimétricas en estadística. Describen la forma de la distribución de los puntos de datos en un conjunto de datos.

1. Distribución con sesgo negativo (asimetría hacia la izquierda):

- Las distribuciones con sesgo hacia la izquierda tienen una cola más larga en el lado izquierdo (o negativo) de la distribución.
- El pico de la distribución (moda) suele estar ubicado a la derecha del centro.
- La media (promedio) suele ser menor que la mediana.


- En una distribución con sesgo hacia la izquierda, los datos se concentran en el lado derecho y la cola se extiende hacia la izquierda.



Ejemplo: La distribución de las edades al jubilarse puede tener sesgo hacia la izquierda, ya que la mayoría de las personas se jubilan alrededor de cierta edad, pero muy pocas se jubilan a una edad más joven.

2. Distribución con sesgo positivo (asimetría hacia la derecha):


- Las distribuciones con sesgo hacia la derecha tienen una cola más larga en el lado derecho (o positivo) de la distribución.
- El pico de la distribución (moda) suele estar ubicado a la izquierda del centro.
- La media (promedio) suele ser mayor que la mediana.
- En una distribución con sesgo hacia la derecha, los datos se concentran en el lado izquierdo y la cola se extiende hacia la derecha.



Ejemplo: La distribución de los ingresos en una población puede tener sesgo hacia la derecha, ya que la mayoría de las personas ganan ingresos promedio, pero unos pocos ganan ingresos muy altos.

La asimetría es una medida utilizada para cuantificar el grado de asimetría en una distribución.

- Un valor de asimetría positivo indica asimetría hacia la derecha.
- Un valor de asimetría negativo indica asimetría hacia la izquierda.
- Un valor de asimetría de 0 indica una distribución perfectamente simétrica.



Entender la asimetría de un conjunto de datos es esencial en estadística porque puede afectar la elección de análisis estadísticos y técnicas de modelado apropiadas. Las distribuciones con sesgo hacia la izquierda y hacia la derecha a menudo requieren enfoques diferentes para el análisis y la interpretación.

P48. Si una distribución tiene sesgo hacia la derecha y una mediana de 20, ¿la media será mayor o menor que 20?

Si una distribución tiene sesgo hacia la derecha (sesgo positivo) y tiene una mediana de 20, entonces la media será típicamente mayor que 20:

- La cola de la distribución se extiende hacia la derecha, lo que significa que hay algunos valores relativamente grandes que tiran de la media en esa dirección.
- La mediana, siendo el valor medio, es menos afectada por los valores extremos en la cola, por lo que es típicamente menor que la media en una distribución con sesgo positivo.

P49. Dada una distribución con sesgo hacia la izquierda que tiene una mediana de 60, ¿qué conclusiones podemos sacar sobre la media y la moda de los datos?

En una distribución con sesgo hacia la izquierda (sesgo negativo) con una mediana de 60:

Relación entre media, mediana y moda:

- Dado que la distribución tiene sesgo hacia la izquierda, significa que la cola de la distribución está en el lado izquierdo, y hay algunos valores relativamente pequeños que tiran de la media en esa dirección.
- La mediana, siendo el valor medio, es menos afectada por los valores extremos en la cola. En una distribución con sesgo hacia la izquierda, la mediana es típicamente mayor que la media.
- En una distribución con sesgo hacia la izquierda, la moda es típicamente mayor que la mediana y la media. A menudo está más cerca del pico de la distribución, que está ubicado a la derecha del centro.

En resumen, puedes concluir que en una distribución con sesgo hacia la izquierda con una mediana de 60, la media es probablemente menor que 60 y la moda es probablemente mayor que 60.

P50. Imagina que Juanito participó en un examen. El examen tiene una puntuación media de 160 y una desviación estándar de 15. Si la puntuación Z de Juanito es 1.20, ¿cuál sería su puntuación en el examen?

Para encontrar la puntuación de Juanito en el examen dada su puntuación Z, puedes usar la fórmula para calcular una puntuación a partir de una puntuación Z en una distribución normal:

$$Z = \frac{(X - \mu)}{\sigma} \leftrightarrow Z \times \sigma = X - \mu \leftrightarrow X = (Z \times \sigma) + \mu$$

En este caso:

$Z = 1.20$ (puntuación Z de Juanito), $\sigma = 15$ (desviación estándar), $\mu = 160$ (media)

$$X = (1.20 \times 15) + 160$$


$$X = 18 + 160$$

$$X = 178$$

Por lo tanto, la puntuación de Juanito en el examen sería 178. :)

P51. La curva normal estándar tiene un área total debajo de uno y es simétrica alrededor de cero. ¿Verdadero o falso?

Verdadero. La curva normal estándar, también conocida como la distribución normal estándar o la distribución Z, es un tipo específico de distribución normal con una media (promedio) de 0 y una desviación estándar de 1.




P52. ¿Cuál es el significado de la covarianza?

La covarianza es una medida de la relación entre dos variables aleatorias y hasta qué punto cambian juntas. O, en otras palabras, define los cambios entre las dos variables, de manera que un cambio en una variable es igual a un cambio en otra variable.

La covarianza puede ayudar a entender si dos variables tienden a moverse en la misma dirección (covarianza positiva) o en direcciones opuestas (covarianza negativa).

P53. ¿Puedes decir la diferencia entre curvas unimodales, bimodales y en forma de campana?

Las curvas unimodales, bimodales y en forma de campana son términos utilizados para describir diferentes características de la forma de una distribución de datos:



1. Curva Unimodal:


- **Definición:** Una curva unimodal representa una distribución de datos con un solo pico o moda, lo que significa que hay un único valor alrededor del cual se agrupan más los datos.
- **Forma:** Las distribuciones unimodales son típicamente simétricas o asimétricas, pero solo tienen un pico principal.

Ejemplo: Una distribución normal, donde los datos se distribuyen simétricamente alrededor de la media, es un ejemplo clásico de una curva unimodal. Otras distribuciones unimodales pueden tener sesgo hacia la izquierda (negativo) o hacia la derecha (positivo).

2. Curva Bimodal:

- **Definición:** Una curva bimodal representa una distribución de datos con dos picos o modas, lo que indica que hay dos valores alrededor de los cuales los datos se agrupan más.
- **Forma:** Las distribuciones bimodales tienen dos picos principales separados por un valle o una caída en la distribución.

Ejemplo: La distribución de puntajes de exámenes en un aula con dos grupos distintos de altos y bajos rendimientos puede ser bimodal. De manera similar, una distribución de las temperaturas diarias en un año podría tener dos picos, uno para el verano y otro para el invierno.



3. Curva en forma de campana:

- **Definición:** Una curva en forma de campana representa una distribución de datos que tiene una forma simétrica y suave que se asemeja a una campana.
- **Forma:** Las distribuciones en forma de campana tienen un solo pico (unimodal) y son simétricas, con las colas de la distribución disminuyendo gradualmente a medida que te alejas del pico.

Ejemplo: El ejemplo clásico de una curva en forma de campana es una distribución normal, donde los datos se distribuyen simétricamente alrededor de la media. Sin embargo, otras distribuciones con una apariencia similar en forma de campana también pueden existir.

P54. ¿Una distribución simétrica necesita ser unimodal?

No, una distribución simétrica no necesariamente necesita ser unimodal. Una distribución simétrica simplemente significa que los datos se distribuyen de manera que son simétricos en forma de imagen especular, con valores igualmente probables en ambos lados del punto central de la distribución (usualmente la media o la mediana).

Por lo tanto, mientras que la simetría y la unimodalidad a menudo van juntas, la simetría no requiere inherentemente la unimodalidad, y una distribución simétrica puede tener múltiples modas.

P55. ¿Cuáles son algunos ejemplos de conjuntos de datos con distribuciones no gaussianas?

Muchos conjuntos de datos del mundo real exhiben distribuciones no gaussianas o no normales debido a diversas razones subyacentes. Aquí hay algunos ejemplos de conjuntos de datos con distribuciones no gaussianas:

1. Ingresos: Los datos de ingresos a menudo tienen sesgo hacia la derecha, con la mayoría de las personas ganando ingresos promedio y unas pocas ganando ingresos muy altos. Esto lleva a una distribución que no sigue una forma normal.

2. Rendimientos del mercado de valores: Los rendimientos diarios del mercado de valores pueden tener colas gruesas y agrupamiento de volatilidad, lo que hace que su distribución no sea normal. Los eventos como las caídas del mercado pueden causar desviaciones significativas de la normalidad.

3. Tráfico en sitios web: El número de visitantes a un sitio web en cualquier día a menudo sigue una distribución con una cola larga. Unos pocos días con tráfico extremadamente alto pueden resultar en una distribución sesgada.

4. Edades al jubilarse: La distribución de las edades a las que las personas se jubilan puede tener sesgo hacia la izquierda, ya que la mayoría se jubila alrededor de una cierta edad y muy pocos se jubilan a edades más jóvenes.

5. Número de llegadas de clientes: El número de clientes que llegan a una tienda o centro de servicios sigue una distribución de Poisson, que es discreta y no normal.

6. Puntajes de exámenes: Los puntajes de exámenes, particularmente en entornos educativos, a menudo tienen una distribución con varios picos debido a diversas subpoblaciones de estudiantes, lo que lleva a una distribución multimodal.

7. Tamaños de población de ciudades: La distribución de los tamaños de población de las ciudades en todo el mundo a menudo tiene sesgo hacia la derecha, con unas pocas ciudades muy grandes y la mayoría de las ciudades teniendo poblaciones más pequeñas.

8. Tiempo de espera: La distribución de los tiempos de espera en colas o líneas a menudo tiene sesgo hacia la derecha, con unas pocas personas experimentando tiempos de espera muy largos y la mayoría experimentando tiempos de espera más cortos.

9. Compromiso en redes sociales: El número de “me gusta”, “compartidos” o comentarios en publicaciones de redes sociales puede exhibir una distribución altamente sesgada, con unas pocas publicaciones volviéndose virales y recibiendo una cantidad desproporcionada de interacciones.

10. Altura y peso: Aunque la altura y el peso humanos a menudo siguen distribuciones aproximadamente normales, también pueden verse influenciados por factores como la nutrición y la genética, lo que lleva a desviaciones de la normalidad en algunas poblaciones.

Estos ejemplos muestran que los datos del mundo real pueden tomar diversas formas y características, y no todos los conjuntos de datos siguen el ideal de la distribución gaussiana o normal. Entender la distribución de los datos es esencial para realizar análisis estadísticos precisos y modelado.

P56. ¿Cuál es la fórmula de la distribución binomial?

La distribución binomial es una fórmula utilizada para calcular la probabilidad de un número específico de éxitos (usualmente denotado como “k”) en un número fijo de ensayos independientes de Bernoulli, donde cada ensayo tiene dos posibles resultados: éxito (usualmente denotado como “p”) y fracaso (usualmente denotado como “q”, donde $(q = 1 - p)$).

La función de masa de probabilidad (PMF, Probability Mass Function) de la distribución binomial se da por la fórmula:

$$P(X = k) = \binom{n}{k} * p^k * q^{n-k}$$

Donde:

- $P(X = k)$ es la probabilidad de exactamente k éxitos.
- n es el número total de ensayos.
- k es el número de éxitos para los que quieres encontrar la probabilidad.
- p es la probabilidad de éxito en un solo ensayo.
- q es la probabilidad de fracaso en un solo ensayo ($q = 1 - p$).
- $\binom{n}{k}$ representa el coeficiente binomial, que a menudo se calcula como $\binom{n}{k} = \frac{n!}{k!(n-k)!}$ donde “!” denota el factorial.

P57. ¿Cuáles son los criterios que deben cumplir las distribuciones binomiales?

La distribución binomial es una distribución de probabilidad que modela un tipo específico de experimento aleatorio. Para usar la distribución binomial, se deben cumplir ciertos criterios o supuestos:

- **Número fijo de ensayos (n):** El experimento consiste en un número fijo de ensayos idénticos, denotados como “n”. Cada ensayo puede resultar en uno de dos posibles resultados: éxito o fracaso.
- **Independencia:** El resultado de un ensayo no afecta el resultado de cualquier otro ensayo. En otras palabras, los ensayos son independientes entre sí.
- **Probabilidad constante de éxito (p):** La probabilidad de éxito (a menudo denotada como “p”) permanece constante de ensayo a ensayo. Esto significa que la probabilidad de éxito es la misma para cada ensayo.
- **Resultados binarios:** Cada ensayo tiene solo dos resultados posibles: éxito y fracaso. Estos resultados son mutuamente excluyentes, lo que significa que un ensayo no puede resultar en éxito y fracaso simultáneamente.
- **Ensayos de Bernoulli:** Los ensayos individuales son ensayos de Bernoulli, que son experimentos con dos posibles resultados (éxito y fracaso) que cumplen con los criterios mencionados anteriormente (número fijo de ensayos, independencia, probabilidad constante y resultados binarios).

P58. ¿Cuáles son algunos ejemplos de distribuciones simétricas?

Las distribuciones simétricas se caracterizan por su simetría en forma de espejo, donde los datos son igualmente probables en ambos lados del punto central. Algunos ejemplos de distribuciones simétricas incluyen:

- **Distribución normal (distribución gaussiana):**
 - La distribución simétrica más conocida.
 - Tiene forma de campana y se caracteriza por su media y desviación estándar.
 - Muchos fenómenos naturales y mediciones, como la altura y el peso en una población, se aproximan a una distribución normal.
- **Distribución uniforme:**
 - En una distribución uniforme continua, todos los valores dentro de un intervalo tienen igual probabilidad.
 - En una distribución uniforme discreta, todos los resultados tienen igual probabilidad.
 - Ejemplo: Lanzar un dado de seis caras sigue una distribución uniforme discreta.
- **Distribución logística:**
 - Tiene forma de S, similar a la distribución normal, pero con colas más pesadas.
 - Se utiliza a menudo en la regresión logística y en la modelación de procesos de crecimiento.

P59. Explica brevemente el procedimiento para medir la longitud de todos los tiburones en el mundo. 🐟

1. Define el nivel de confianza (el más común es 95%).
2. Toma una muestra de tiburones del mar (para obtener mejores resultados, asegúrate de que el número de tiburones en la muestra sea mayor a 30).
3. Calcula la longitud media y la desviación estándar de las longitudes.
4. Calcula las estadísticas t.
5. Obtén el intervalo de confianza en el que debería estar la longitud media de todos los tiburones.


P60. ¿Cuáles son los tipos de muestreo en estadística?

En estadística, el muestreo es el proceso de seleccionar un subconjunto de individuos o ítems de una población más grande para hacer inferencias sobre toda la población. Existen varios tipos de métodos de muestreo. Ahí te van algunos de los tipos más comunes de muestreo:

1. Muestreo aleatorio simple:

- Involucra la selección aleatoria de individuos o ítems de la población sin ningún patrón o criterio específico.
- Todos los miembros de la población tienen la misma probabilidad de ser seleccionados.
- Se puede hacer con o sin reemplazo (es decir, el mismo individuo/ítem puede ser seleccionado más de una vez o no).


Simple random sample



2. Muestreo estratificado:

- Divide la población en subgrupos no superpuestos o estratos basados en ciertas características (por ejemplo, edad, género, ubicación).
- Luego se toman muestras aleatorias de cada estrato.
- Asegura que cada subgrupo esté representado en la muestra, lo que lo hace útil cuando hay diferencias significativas entre subgrupos.


Stratified sample



3. Muestreo sistemático:

- Involucra la selección de cada enésimo individuo/ ítem de una lista o secuencia.
- Típicamente, se elige un punto de inicio aleatorio y luego se selecciona cada enésimo individuo/ ítem.
- Útil cuando hay un orden o secuencia natural en la población.


Systematic sample



4. Muestreo por cluster:


- Divide la población en clusters o grupos, a menudo basados en proximidad geográfica u otro criterio.
- Se selecciona una muestra aleatoria de clusters, y todos los individuos/ítems dentro de los clusters seleccionados se incluyen en la muestra.
- Eficiente para poblaciones grandes y geográficamente dispersas.

Cluster sample




5. Muestreo de conveniencia:

- Involucra la selección de individuos o ítems que están fácilmente disponibles y son convenientes para muestrear.
- A menudo se usa en investigaciones exploratorias o preliminares, pero puede introducir sesgo porque puede no ser representativo de toda la población.



6. Muestreo por juicio (muestreo intencional):

- Involucra la selección de individuos/ítems basándose en el juicio y criterios específicos del investigador.
- Útil cuando el investigador quiere enfocarse en un subgrupo o característica particular.
- Puede ser sesgado si no se hace cuidadosamente.



La elección del método de muestreo depende de los objetivos de la investigación, los recursos disponibles y las características de la población que se está estudiando. Cada método tiene sus propias fortalezas y limitaciones, y los investigadores deben considerar estos factores al diseñar y llevar a cabo un estudio.

P61. ¿Por qué es necesario el muestreo?

El muestreo es necesario por varias razones simples y prácticas:

1. **Eficiencia:** El muestreo es más rápido y más rentable que recolectar datos de toda una población, especialmente cuando la población es grande.

2. **Conservación de recursos:** Ahorra tiempo, dinero y recursos, haciendo que la investigación sea más factible y práctica.
3. **Oportunidad:** Permite una recolección y análisis de datos más rápidos, lo cual puede ser crucial en situaciones sensibles al tiempo.
4. **Accesibilidad:** Algunas poblaciones son difíciles de acceder, haciendo que el muestreo sea la única opción práctica.
5. **Precisión:** Cuando se hace correctamente, el muestreo proporciona estimaciones precisas de las características de la población.
6. **Reducción de riesgos:** Reduce el potencial de errores en la recolección y análisis de datos.
7. **Inferencia:** Proporciona una base para hacer conclusiones sobre toda la población basadas en las características de la muestra.
8. **Privacidad y ética:** Respeta consideraciones de privacidad y ética, especialmente en áreas de investigación sensibles.
9. **Análisis:** Simplifica el análisis de datos, particularmente para conjuntos de datos grandes.

El muestreo es una herramienta práctica y esencial para que los investigadores obtengan información valiosa mientras manejan las limitaciones de costos y prácticas.

P62. ¿Cómo calculas el tamaño de muestra necesaria?

Se puede calcular el tamaño de muestra necesaria en 9 sencillos pasos:

1. Define tus objetivos de investigación y preguntas.
2. Elige un nivel de significancia (α) y el margen de error deseado (E).
3. Estima la variabilidad de la población (σ) o usa estimaciones conservadoras.
4. Determina el tamaño de la población (N).
5. Selecciona el tipo de muestreo (aleatorio o estratificado).
6. Elige la prueba o análisis estadístico.
7. Usa una fórmula o software para calcular el tamaño de muestra.
8. Considera las limitaciones prácticas y ajusta para la no respuesta.
9. Conduce el estudio, analiza los datos e interpreta los resultados.

Los cálculos del tamaño de muestra aseguran que tu estudio tenga suficientes datos para sacar conclusiones significativas mientras controlas errores y precisión.

P63. ¿Puedes darme la diferencia entre muestreo estratificado y muestreo por clusters?

La diferencia clave entre el muestreo estratificado y el muestreo por clusters radica en cómo se divide y se muestrea la población:

- **Muestreo estratificado:** Divide la población en subgrupos homogéneos (estratos) y selecciona muestras de cada estrato de manera independiente para asegurar representación de todos los subgrupos.
- **Muestreo por clusters:** Divide la población en clusters y selecciona aleatoriamente clusters para luego recolectar datos de todos los individuos/ ítems dentro de los clusters seleccionados.

P64. ¿Dónde se utilizan las estadísticas inferenciales?

Las estadísticas inferenciales se utilizan en varios campos y contextos para hacer predicciones, sacar conclusiones y hacer inferencias sobre poblaciones basadas en datos de muestra. Vamos a ver algunas áreas comunes y aplicaciones donde se utilizan las estadísticas inferenciales:

1. Investigación científica:

- Las estadísticas inferenciales son fundamentales en la investigación científica a través de disciplinas como biología, física, química y ciencias ambientales. Los investigadores usan pruebas estadísticas para analizar datos y sacar conclusiones sobre hipótesis.

2. Negocios y economía:

- Las empresas utilizan estadísticas inferenciales para investigaciones de mercado, pronósticos de ventas, control de calidad y toma de decisiones. Los modelos econométricos se aplican para analizar datos económicos y hacer recomendaciones políticas.

3. Salud y medicina:

- Los investigadores y profesionales de la salud utilizan estadísticas inferenciales para estudiar la efectividad de tratamientos, analizar datos de pacientes y sacar conclusiones sobre la prevalencia de enfermedades. Los ensayos clínicos dependen en gran medida de las estadísticas inferenciales.

4. Educación:

- En el campo de la educación, las estadísticas inferenciales se usan para evaluar la efectividad de métodos de enseñanza, evaluar puntajes de pruebas estandarizadas y tomar decisiones políticas sobre programas educativos.

5. Investigación de mercado y análisis de datos:

- Los investigadores de mercado utilizan estadísticas inferenciales para hacer predicciones sobre las preferencias del consumidor, las tendencias del mercado y el impacto de las campañas de marketing.

6. Finanzas e inversiones:

- En finanzas, las estadísticas inferenciales se utilizan para evaluar el riesgo de inversión, analizar datos del mercado de valores y estimar los precios futuros de los activos. La optimización de carteras y la gestión del riesgo dependen del modelado estadístico.

7. Justicia criminal y criminología:


- Los investigadores y las agencias de aplicación de la ley utilizan estadísticas inferenciales para analizar datos sobre el crimen, estudiar patrones de delitos y evaluar la efectividad de los programas de justicia penal.

8. Deportes y atletismo:

- En el análisis de deportes, las estadísticas inferenciales se utilizan para analizar el rendimiento de los jugadores, predecir los resultados de los juegos y tomar decisiones estratégicas en la gestión de deportes.

P65. ¿Qué son la población y la muestra en estadísticas inferenciales y cómo son diferentes?

En estadísticas inferenciales, los conceptos de “población” y “muestra” son fundamentales y juegan roles distintos:



Población:

- **Definición:** La población se refiere al grupo completo o colección de individuos, ítems o puntos de datos sobre los cuales deseas sacar conclusiones. Representa el conjunto más grande, a menudo teórico, que estás interesado en estudiar.
- **Características:**
 - La población puede ser finita (por ejemplo, todos los estudiantes en una escuela) o infinita (por ejemplo, todos los clientes potenciales en un mercado).
 - Incluye a cada individuo o elemento posible que caiga dentro del alcance de tu pregunta de investigación.
- **Propósito:** En las estadísticas inferenciales, la población es el objetivo final para sacar conclusiones y generalizaciones. Sin embargo, a menudo es impráctico o imposible recolectar datos de toda la población.

Muestra:

- **Definición:** Una muestra es un subconjunto más pequeño y cuidadosamente seleccionado de individuos, ítems o puntos de datos tomados de la población más grande. Es una porción representativa de la población utilizada para la recolección y análisis de datos.
- **Características:**
 - La muestra es un subconjunto finito y manejable de la población.
 - Se elige a través de un proceso sistemático, como muestreo aleatorio, muestreo estratificado o muestreo por conglomerados.
 - La muestra debe ser representativa de la población, lo que significa que debe reflejar la diversidad y las características de la población.
- **Propósito:** El propósito principal de tomar una muestra es la practicidad. A menudo es más factible, rentable y eficiente recolectar datos de una muestra en lugar de toda la población. Las estadísticas inferenciales usan datos de la muestra para hacer inferencias, predicciones o generalizaciones sobre la población más grande.

P66. ¿Cuál es la relación entre el nivel de confianza y el nivel de significancia en estadística?

La relación entre el nivel de confianza y el nivel de significancia en estadística es inversa y complementaria. Estos dos conceptos son esenciales en la prueba de hipótesis y la inferencia estadística.

Relación:

La relación entre ambos es complementaria, lo que significa que si aumentas uno, disminuyes el otro y viceversa.

Ejemplo:

- Si estableces un nivel de confianza del 95% ($1 - \alpha = 0.95$), el nivel de significancia sería 0.05 ($\alpha = 0.05$).
- Si estableces un nivel de confianza del 99% ($1 - \alpha = 0.99$), el nivel de significancia sería 0.01 ($\alpha = 0.01$).

Nivel de confianza	Nivel de significancia
El nivel de confianza (a menudo denotado como $1 - \alpha$) representa la probabilidad de que un intervalo de confianza calculado a partir de datos de muestra contenga el verdadero parámetro de la población.	El nivel de significancia (denotado como α) es la probabilidad de cometer un error de Tipo I en la prueba de hipótesis. También se conoce como el “nivel alfa” o “nivel de significancia”.
Es una medida de cuán seguros estás de que el intervalo que calculaste captura el parámetro verdadero que estás estimando.	Un error de Tipo I ocurre cuando rechazas incorrectamente una hipótesis nula verdadera. En otras palabras, representa la probabilidad de encontrar un resultado significativo (rechazar la hipótesis nula) cuando no hay un efecto real o diferencia en la población.
Los niveles de confianza comúnmente usados incluyen 90%, 95% y 99%.	Los niveles de significancia comúnmente usados son 0.05 (5%), 0.01 (1%) y 0.10 (10%).

P67. ¿Cuál es la diferencia entre la estimación puntual y la estimación por intervalo de confianza?

Estimación puntual	Estimación por intervalo de confianza
Definición: Una estimación puntual es un único valor que se utiliza para estimar un parámetro desconocido de la población, como la media de la población (μ) o la proporción de la población (p)	Definición: Una estimación por intervalo de confianza es un rango o intervalo de valores que se utiliza para estimar un parámetro de la población.
Propósito: Proporciona una “mejor suposición” o un valor numérico único para el parámetro	Propósito: Proporciona un rango de valores plausibles para el parámetro junto con un nivel de confianza (por ejemplo, intervalo de confianza del 95%). El intervalo de confianza refleja la incertidumbre asociada con la estimación y cuantifica cuán seguro estás de que el valor verdadero del parámetro cae dentro del intervalo.
Ejemplo: Si calculas la media de la muestra (\bar{x}) a partir de un conjunto de datos de muestra, \bar{x} en sí misma es una estimación puntual de la media de la población (μ).	Ejemplo: Un intervalo de confianza del 95% para la media de la población (μ) podría ser (60,70), lo que indica que tienes un 95% de confianza en que la verdadera media de la población se encuentra entre 60 y 70.

Diferencia clave:

- La principal diferencia entre una estimación puntual y una estimación por intervalo de confianza es que una estimación puntual proporciona un valor único, mientras que una estimación por intervalo de confianza proporciona un rango de valores.
- Las estimaciones puntuales son útiles para proporcionar una única estimación de un parámetro cuando necesitas un valor específico.
- Las estimaciones por intervalo de confianza son útiles cuando quieres transmitir la incertidumbre asociada con tu estimación y proporcionar un rango de valores dentro del cual es probable que caiga el parámetro.

P68. ¿Qué entiendes por los términos sesgado y no sesgado?

En estadística, los términos “sesgado” y “no sesgado” se utilizan para describir la precisión de un estimador al estimar un parámetro de la población. Estos términos se relacionan con cuán cerca está el valor esperado del estimador del verdadero valor (o valor de la población) del parámetro que se está estimando.

Sesgado	No sesgado
Un estimador estadístico se dice que es “sesgado” si, en promedio, sistemáticamente sobrestima o subestima el verdadero parámetro de la población.	Un estimador estadístico se considera “no sesgado” si, en promedio, proporciona estimaciones que son iguales al verdadero parámetro de la población.
En otras palabras, un estimador sesgado tiende a desviarse consistentemente del verdadero valor en una dirección específica (ya sea consistentemente alto o bajo).	En términos matemáticos, el valor esperado de un estimador no sesgado es igual al verdadero valor del parámetro de la población que se está estimando.
Los estimadores sesgados pueden resultar de fallas en el método de estimación o en el procedimiento de muestreo.	Los estimadores no sesgados son deseables porque, al repetirse el muestreo, proporcionan estimaciones precisas del parámetro de la población.
Al usar un estimador sesgado, es importante ser consciente de la dirección y magnitud del sesgo para ajustarlo en el análisis de datos o la toma de decisiones.	Aunque los estimadores no sesgados son preferidos, no siempre son alcanzables y, en algunos casos, los estimadores sesgados pueden ser la mejor opción disponible.

P69. ¿Cómo cambia el ancho del intervalo de confianza con el nivel de confianza?

El ancho de un intervalo de confianza cambia inversamente con el nivel de confianza y la precisión de la estimación. En otras palabras, a medida que aumentas el nivel de confianza o disminuyes la precisión (aumentas el margen de error), el ancho del intervalo de confianza aumenta, y viceversa.

P70. ¿Cuál es el significado del error estándar?

Expliquemos que onda con el error estándar en 5 sencillos pasos:

1. El error estándar de la media de la muestra representa la desviación estándar de la distribución de las medias muestrales.
2. Mide cuánto se espera que las medias muestrales individuales se desvíen de la verdadera media de la población (μ) en promedio.
3. La fórmula del error estándar de la media de la muestra depende de la desviación estándar de la población (σ) y del tamaño de la muestra (n) y se da por:

$$SE(\bar{x}) = \frac{\sigma}{\sqrt{n}}$$

4. A medida que el tamaño de la muestra (n) aumenta, el error estándar disminuye. Esto significa que las muestras más grandes tienden a producir medias muestrales que están más cerca de la verdadera media de la población.

El error estándar es un concepto crítico en las estadísticas inferenciales porque se utiliza para calcular intervalos de confianza y realizar pruebas de hipótesis.

Aquí se utiliza de la siguiente manera:

1. Intervalos de confianza: El error estándar se utiliza para calcular el margen de error para un intervalo de confianza. Un intervalo de confianza representa un rango de valores dentro del cual estás seguro de que cae el verdadero parámetro de la población.

2. Pruebas de hipótesis: En las pruebas de hipótesis, el error estándar se utiliza para calcular estadísticas de prueba, como la estadística t o la estadística z , que luego se comparan con valores críticos para evaluar la significancia de una diferencia observada o un efecto.

P71. ¿Qué es un error de muestreo y cómo se puede reducir?

El error de muestreo es un tipo de error que ocurre cuando una muestra se usa para estimar parámetros de la población, y la estimación difiere del verdadero valor de la población. Es la diferencia entre la estadística de la muestra (por ejemplo, media de la muestra o proporción de la muestra) y el parámetro de la población porque no podemos estudiar a todos en la población, por lo que usamos una muestra (grupo más pequeño) para hacer predicciones.

Algunas formas de reducir el error de muestreo pueden ser:

1. **Usa una muestra más grande:** Cuanto más grande sea la muestra, más cerca estará la estimación de la realidad.
2. **Elige aleatoriamente la muestra:** Asegúrate de que cada individuo en la población tenga la misma probabilidad de ser incluido en la muestra.
3. **Ten cuidado con las encuestas:** Anima a más personas a responder encuestas para asegurarte de que representen a toda la población.
4. **Usa métodos adecuados:** Sigue buenos métodos estadísticos para analizar los datos de tu muestra.

P72. ¿Cómo se relacionan el error estándar y el margen de error?

Sin tanto rollo, piensa en el error estándar (SE) como una medida de cuánto pueden variar los datos de la muestra con respecto al verdadero valor de la población. Es una medida de cuán incierta es nuestra estimación.

El margen de error (MDE o MOE) está directamente relacionado con el error estándar. Nos dice cuánto debemos sumar y restar de nuestra estimación de la muestra para crear un rango que probablemente incluya el verdadero valor de la población. Es una especie de buffer de seguridad alrededor de nuestra estimación.

Entonces, el error estándar nos dice acerca de la incertidumbre en nuestra estimación, y el margen de error nos dice el tamaño del buffer de seguridad que necesitamos para tener en cuenta esa incertidumbre. Si deseas un margen de error más estrecho, necesitas una estimación más precisa, lo que generalmente significa un tamaño de muestra más grande o un nivel de confianza más bajo.

P73. ¿Qué es la prueba de hipótesis?

La prueba de hipótesis es una técnica estadística fundamental utilizada para hacer inferencias y sacar conclusiones sobre poblaciones basadas en datos de muestra. Involucra un proceso estructurado de formular y probar hipótesis (declaraciones o afirmaciones) sobre parámetros de la población, como medias, proporciones o varianzas.

En la próxima pagina te dejo los componentes clave y pasos involucrados en la prueba de hipótesis:

Componentes de la prueba de hipótesis:

- Hipótesis nula (H_0)
- Hipótesis alternativa (H_a o H_1)
- Estadística de prueba
- Nivel de significancia (α)
- Región crítica o región de rechazo
- Valor p

Pasos en la prueba de hipótesis:

1. Formular las hipótesis
2. Recolectar datos
3. Calcular la estadística de prueba
4. Determinar la región crítica
5. Comparar la estadística de prueba con la región crítica
6. Calcular el valor p
7. Tomar una decisión
8. Sacar conclusiones

P74. ¿Qué es una hipótesis alternativa?


La hipótesis alternativa contradice la hipótesis nula. Típicamente establece lo que esperas encontrar en la población basándote en tu pregunta de investigación o hipótesis. Se denota como H_a o H_1 .

P75. ¿Cuál es la diferencia entre una prueba de hipótesis unilateral y bilateral?

Las pruebas de hipótesis unilaterales y bilaterales son dos enfoques diferentes utilizados en la prueba de hipótesis estadística para investigar preguntas de investigación o hipótesis. Se diferencian en términos de la direccionalidad de la pregunta de investigación y la forma en que evalúan la evidencia a partir de los datos de la muestra.

Comparemos ambas dos pa' ver cual es la diferencia:

Prueba de hipótesis unilateral	Prueba de hipótesis bilateral
Una prueba unilateral es una prueba estadística en la que la hipótesis alternativa solo tiene un extremo.	Una prueba bilateral se refiere a una prueba de significancia en la que la hipótesis alternativa tiene dos extremos.
La región de rechazo está en el extremo izquierdo o derecho.	La región de rechazo está en ambos extremos izquierdo y derecho.
Determina la relación entre variables en una sola dirección.	Determina la relación entre variables en cualquiera de las dos direcciones.
Los resultados son mayores o menores que un valor específico.	Los resultados son mayores o menores que ciertos rangos de valores.
Direccional: > o < (No es una carita)	No direccional: ≠



P76. ¿Qué es una prueba t de una muestra?

Una prueba t de una muestra es una prueba de hipótesis estadística utilizada para determinar si la media de un solo conjunto de datos es significativamente diferente de una media de población conocida o hipotetizada.

Prueba t de una muestra



¿Existe alguna diferencia entre un grupo y la población?

Es particularmente útil cuando tienes una muestra y deseas evaluar si representa una población con una media específica.

P77. ¿Qué significa el término grados de libertad (DF) en estadística?

En estadística, los grados de libertad (DF) se refieren al número de valores en el cálculo final de una estadística que son libres de variar. Los grados de libertad son un concepto fundamental en la prueba de hipótesis, los intervalos de confianza y varios análisis estadísticos. Se utilizan en varias pruebas estadísticas, como pruebas t, pruebas de chi-cuadrado y análisis de varianza (ANOVA).

El concepto de grados de libertad puede ser un poco abstracto, pero es esencial entenderlo porque afecta el comportamiento de las pruebas estadísticas y la interpretación de sus resultados. Así que intentemos explicarlo con bolitas y palitos en la siguiente página:

Pruebas T:

En una prueba t, los grados de libertad están relacionados con el tamaño de la muestra. Si tienes una muestra de tamaño “n”, entonces:

1. Prueba t de una muestra: Grados de libertad = $n - 1$
2. Prueba t de dos muestras: Grados de libertad = $n_1 + n_2 - 2$

Donde:

“n1” y “n2” son los tamaños de las muestras de los dos grupos que se comparan. Este “n1 + n2 - 2” representa el número de puntos de datos que son libres de variar después de estimar las medias de los dos grupos.

Pruebas Chi-Cuadrado:

En las pruebas chi-cuadrado, los grados de libertad están relacionados con el número de categorías que se comparan.

Para una prueba chi-cuadrado de independencia, los grados de libertad se calculan como:

$$\text{Grados de libertad} = (\text{filas} - 1) \times (\text{columnas} - 1)$$

Donde:

“filas” y “columnas” representan el número de categorías en las filas y columnas de la tabla de contingencia. Este cálculo refleja el número de categorías que pueden variar libremente.

ANOVA:

En el análisis de varianza (ANOVA), los grados de libertad están asociados con el número de grupos que se comparan.


1. Grados de libertad entre grupos: Están relacionados con el número de grupos menos uno.
2. Grados de libertad dentro de los grupos: Están relacionados con el tamaño total de la muestra menos el número de grupos.

Estos grados de libertad ayudan a determinar si hay diferencias significativas entre los grupos.

En esencia, los grados de libertad representan la flexibilidad o “libertad” en los datos o en el modelo estadístico. Entender los grados de libertad es crucial porque afectan la distribución de las estadísticas de prueba y, en consecuencia, la interpretación de los valores p y las conclusiones que se pueden sacar de los análisis estadísticos. Diferentes pruebas estadísticas tienen diferentes fórmulas para calcular los grados de libertad y se eligen para asegurar la validez de la prueba estadística que se está realizando.

P78. ¿Qué es el valor p en la prueba de hipótesis?

El valor p, abreviatura de “valor de probabilidad”, es un concepto crucial en la prueba de hipótesis en estadística. Mide la fuerza de la evidencia contra una hipótesis nula.



P79. ¿Cómo se puede calcular el valor p?

En general, calcular un valor p implica los siguientes 8 simples pasos:

1. Formular las hipótesis:

- Comienza definiendo tu hipótesis nula (H_0) y tu hipótesis alternativa (H_a). H_0 típicamente representa una afirmación de no efecto o ninguna diferencia, mientras que H_a sugiere que hay un efecto o diferencia.

2. Elegir una prueba estadística:

- Selecciona la prueba estadística adecuada basada en tu pregunta de investigación y el tipo de datos que tienes. La elección de la prueba depende de si estás comparando medias, probando proporciones, examinando asociaciones, etc.

3. Recolectar datos:

- Recolecta datos relevantes para tu análisis. Los datos deben coincidir con los supuestos y requisitos de la prueba estadística elegida.

4. Calcular la estadística de prueba:

- Calcula la estadística de prueba que corresponde a la prueba elegida. Esto implica usar fórmulas matemáticas específicas para la prueba.

5. Determinar la distribución de muestreo:

- Determina la distribución teórica de muestreo de la estadística de prueba bajo el supuesto de que la hipótesis nula es verdadera. Esta distribución depende del tipo de prueba que estás realizando (por ejemplo, t-distribución, chi-cuadrado, F-distribución, distribución normal).

6. Encontrar la estadística de prueba observada:

- Calcula la estadística de prueba observada usando tus datos.

7. Calcular el valor p:

- El valor p se calcula en base a la estadística de prueba observada y su distribución bajo la hipótesis nula.
 1. Para pruebas unilaterales (pruebas donde solo estás interesado en una dirección de un efecto), el valor p es la probabilidad de observar una estadística de prueba tan extrema o más en esa dirección.
 2. Para pruebas bilaterales (pruebas donde estás interesado en ambas direcciones de un efecto), el valor p es la probabilidad de observar una estadística de prueba tan extrema o más en cualquiera de las dos direcciones.

8. Comparar el valor p con el nivel de significancia (α alpha):

- Decide un nivel de significancia (α alpha), que típicamente se establece en 0.05 pero puede variar dependiendo del estudio.
- Compara el valor p con α . Si el valor p es menor que α , rechazas la hipótesis nula. Si el valor p es mayor o igual a α , no rechazas la hipótesis nula.
 1. Si el valor p es menor o igual a α , rechazas la hipótesis nula (concluyendo que hay evidencia a favor de la hipótesis alternativa).
 2. Si el valor p es mayor que α , no rechazas la hipótesis nula (evidencia insuficiente para apoyar la hipótesis alternativa).

Es importante notar que los cálculos específicos para la estadística de prueba y el valor p dependen de la prueba estadística elegida. Diferentes pruebas tienen diferentes fórmulas y supuestos. En la práctica, se utilizan a menudo software estadístico o calculadoras para realizar estos cálculos automáticamente, ya que pueden ser complejos para muchas pruebas. Además, al realizar pruebas de hipótesis, asegúrate de considerar los supuestos y limitaciones de la prueba elegida para asegurar la validez de tus resultados.

P80. Si hay una probabilidad del 30 por ciento de que veas un carro superdeportivo en cualquier intervalo de 20 minutos, ¿cuál es la probabilidad de que veas al menos un carro superdeportivo en un período de una hora (60 minutos)? 🏍️

- La probabilidad de no ver un superdeportivo en 20 minutos es:

$$1 - P(\text{Ver un superdeportivo}) = 1 - 0.3 = 0.7$$

- La probabilidad de no ver ningún superdeportivo en el período de 60 minutos es:

$$(0.7)^3 = 0.343$$

- Por lo tanto, la probabilidad de ver al menos un superdeportivo en 60 minutos es:

$$1 - P(\text{No ver ningún superdeportivo}) = 1 - 0.343 = 0.657$$

P81. ¿Cómo describirías un “valor p”?

Los valores p te ayudan a tomar decisiones sobre si los resultados de un análisis estadístico son estadísticamente significativos. No te dicen si la hipótesis nula es verdadera o falsa; en cambio, te informan sobre la probabilidad de observar los datos si la hipótesis nula fuera verdadera.

P82. ¿Cuál es la diferencia entre los errores de tipo I y tipo II?


Un error de tipo I (falso positivo) ocurre si un investigador rechaza una hipótesis nula que en realidad es verdadera en la población.

Un error de tipo II (falso negativo) ocurre si un investigador no logra rechazar una hipótesis nula que en realidad es falsa en la población.

Errores de tipo I	Errores de tipo II
La probabilidad de que rechaces una hipótesis nula que no debería haber sido rechazada.	La probabilidad de que no rechaces una hipótesis nula cuando debería haber sido rechazada.
Esto resultará en que decidas que dos grupos son diferentes o que dos variables están relacionadas cuando en realidad no lo están.	Esto resultará en que decidas que dos grupos no son diferentes o que dos variables no están relacionadas cuando en realidad lo están.
La probabilidad de un error de tipo I se llama alfa (α).	La probabilidad de un error de tipo II se llama beta (β).

P83. ¿Cuándo deberías usar una prueba t versus una prueba z?

- Una prueba z se utiliza para probar una hipótesis nula si la varianza de la población es conocida, o si el tamaño de la muestra es mayor a 30, para una varianza de población desconocida.
- Una prueba t se utiliza cuando el tamaño de la muestra es menor a 30 y la varianza de la población es desconocida.



P84. ¿Cuál es la diferencia entre la prueba F y la prueba ANOVA?

Las pruebas F y ANOVA (Análisis de Varianza) son pruebas estadísticas relacionadas, pero sirven para propósitos diferentes y se utilizan en diferentes contextos.

En la página que sigue les dejo una tablita comparativa para que chequen las diferencias. :)

Prueba F	Prueba ANOVA
<p>Propósito: La prueba F es una prueba estadística utilizada para comparar las varianzas de dos o más poblaciones o muestras.</p>	<p>Propósito: ANOVA, por otro lado, se usa para comparar las medias de tres o más grupos para determinar si hay diferencias significativas entre los grupos.</p>
<p>Número de Grupos: La prueba F se usa principalmente para comparar las varianzas de dos grupos. Se emplea comúnmente en el contexto de comparar las varianzas de dos grupos al probar la igualdad de las varianzas de la población (por ejemplo, en el contexto de la prueba de hipótesis de dos muestras).</p>	<p>Número de Grupos: ANOVA está específicamente diseñado para comparar las medias de tres o más grupos. Se usa cuando tienes múltiples grupos y deseas probar si hay diferencias significativas entre ellos.</p>
<p>Estadística de Prueba: La estadística de prueba para la prueba F sigue una distribución F, que es una distribución asimétrica hacia la derecha. La estadística F se calcula dividiendo la varianza de un grupo por la varianza de otro grupo.</p>	<p>Estadística de Prueba: ANOVA también usa una estadística F, pero el cálculo es diferente al de la prueba F. Evalúa la razón de la variación entre los grupos a la variación dentro de los grupos.</p>
<p>Casos de Uso: Los casos de uso comunes para la prueba F incluyen comparar las varianzas de dos grupos (prueba F para igualdad de varianzas), evaluar el ajuste de un modelo estadístico y realizar análisis de regresión (prueba F para ajuste general del modelo).</p>	<p>Casos de Uso: ANOVA se usa comúnmente en diseños experimentales donde tienes varios tratamientos o condiciones y deseas determinar si hay una diferencia estadísticamente significativa en las medias de estos grupos. A menudo se sigue con pruebas post-hoc para identificar qué grupo específico difiere de los demás.</p>

P85. ¿Qué es el remuestreo y cuáles son los métodos comunes de remuestreo?

El remuestreo es una serie de técnicas utilizadas en estadística para obtener más información sobre una muestra. Esto puede incluir volver a tomar una muestra o estimar su precisión. Con estas técnicas adicionales, el remuestreo mejora la precisión general y estima cualquier incertidumbre dentro de una población.

Les dejo algunos métodos de remuestreo en la siguiente página. :b

Métodos comunes de remuestreo:

1. Bootstrap:

- **Propósito:** El remuestreo Bootstrap se usa a menudo para estimar la distribución de muestreo de una estadística (por ejemplo, media, mediana, desviación estándar) o para construir intervalos de confianza.
- **Explicación:** En el remuestreo Bootstrap, seleccionas aleatoriamente datos de tu conjunto de datos con reemplazo para crear múltiples “muestras bootstrap” del mismo tamaño que el conjunto de datos original.

2. Validación Cruzada:

- **Validación Cruzada K-Fold:** En la validación cruzada, divides tus datos en “k” subconjuntos (folds). Iterativamente usas k-1 folds para entrenamiento y el fold restante para pruebas, repitiendo este proceso k veces.
- **Propósito:** La validación cruzada se usa ampliamente en el aprendizaje automático para evaluar el rendimiento del modelo, ajustar hiperparámetros y detectar el sobreajuste.

P86. ¿Cuál es la proporción de intervalos de confianza que no contendrán el parámetro de la población?

La proporción de intervalos de confianza que no contendrán el parámetro de la población (a menudo denotado como $1 - \text{nivel de confianza}$) es igual al nivel de significancia (α) elegido para construir los intervalos de confianza.

En otras palabras, si construyes un gran número de intervalos de confianza utilizando el mismo método y el mismo nivel de confianza (por ejemplo, nivel de confianza del 95%), y repites este proceso muchas veces, entonces aproximadamente el 5% de estos intervalos no contendrán el verdadero parámetro de la población.

P87. ¿Qué es una variable de confusión?

Una variable de confusión, también conocida como factor de confusión o confusor, es una variable en un estudio de investigación que está relacionada tanto con la variable independiente (la variable que se está estudiando o manipulando) como con la variable dependiente (el resultado o respuesta de interés). La presencia de una variable de confusión puede llevar a una interpretación errónea o incorrecta de la relación entre la variable independiente y la variable dependiente.

Explicación en términos simples:

Una variable de confusión es un factor adicional que puede distorsionar la relación observada entre dos variables al enmascarar o falsamente sugerir una conexión entre ellas.

Ejemplo de la variable de confusión:

Supongamos que estás estudiando la relación entre el consumo de café (variable independiente) y el riesgo de enfermedad cardíaca (variable dependiente). La edad es una variable de confusión porque está relacionada tanto con el consumo de café (ya que las personas de diferentes edades pueden beber diferentes cantidades de café) como con el riesgo de enfermedad cardíaca (ya que las personas mayores tienden a tener un mayor riesgo). Sin considerar la edad como una variable de confusión, podrías concluir erróneamente que el consumo de café afecta directamente el riesgo de enfermedad cardíaca.

P88. ¿Cuáles son los pasos que debemos seguir en la prueba de hipótesis?

La prueba de hipótesis es un proceso estructurado utilizado en estadística para hacer inferencias sobre parámetros de población basados en datos de muestra. Aquí están los pasos que típicamente se siguen en la prueba de hipótesis:

1. Formular las Hipótesis:

- Establece la hipótesis nula (H_0): Esta es una declaración de no efecto o ninguna diferencia. Representa la suposición predeterminada que deseas probar.
- Establece la hipótesis alternativa (H_a): Esta es la hipótesis para la cual deseas proporcionar evidencia, sugiriendo que hay un efecto, diferencia o relación en la población.

2. Elegir un Nivel de Significancia (α):

- Elige el nivel de significancia (α), que representa la probabilidad de cometer un error de Tipo I (rechazar la hipótesis nula cuando es verdadera). Las opciones comunes incluyen 0.05 (5%) y 0.01 (1%).

3. Recolectar y Analizar Datos:

- Recoge datos de muestra que sean relevantes para tu pregunta de investigación.
- Realiza el análisis estadístico apropiado basado en el tipo de datos y el diseño de la investigación. Este análisis depende de la prueba de hipótesis específica que estés realizando (por ejemplo, prueba t, prueba chi-cuadrado, ANOVA).

4. Calcular la Estadística de Prueba:

- Calcula la estadística de prueba basada en tus datos de muestra y la hipótesis nula. La estadística de prueba cuantifica cuán diferente es tu muestra de datos de lo que esperarías bajo la hipótesis nula.

5. Determinar la Región Crítica:

- Identifica la región crítica o región de rechazo en la distribución de probabilidad de la estadística de prueba. Esta es la gama de valores que llevarían a rechazar la hipótesis nula si la estadística de prueba cae dentro de ella.

6. Comparar la Estadística de Prueba con los Valores Críticos:

- Compara la estadística de prueba calculada con los valores críticos correspondientes al nivel de significancia elegido. Si la estadística de prueba cae en la región crítica, rechazas la hipótesis nula. De lo contrario, no la rechazas.

7. Calcular el Valor P:

- Alternativamente, puedes calcular el valor p, que es la probabilidad de observar una estadística de prueba tan extrema o más extrema que la observada, asumiendo que la hipótesis nula es verdadera.
- Si el valor p es menor o igual al nivel de significancia (α), rechazas la hipótesis nula.
- Si el valor p es mayor que α , no rechazas la hipótesis nula.

8. Tomar una Decisión:

- Basado en la comparación de la estadística de prueba (o valor p) con los valores críticos (o α), toma una decisión:
- Si rechazas la hipótesis nula, concluyes que hay evidencia a favor de la hipótesis alternativa.
- Si no rechazas la hipótesis nula, concluyes que no hay suficiente evidencia para apoyar la hipótesis alternativa.

9. Interpretar Resultados:

- Interpreta los resultados en el contexto de tu pregunta de investigación. Explica la significancia práctica de tus hallazgos y sus implicaciones.

10. Reportar Hallazgos:

- Comunica claramente tus resultados, incluyendo la estadística de prueba, el valor p (si se utiliza), la conclusión y cualquier medida de tamaño del efecto relevante, de manera clara y concisa.

P89. ¿Cómo describirías un “valor p” a una persona no técnica o en términos sencillos?

Explicar un valor p a una persona no técnica o en términos sencillos:

Imagina que eres un detective investigando un caso. Tienes a un sospechoso en juicio y quieres saber si hay suficiente evidencia para decir que son culpables.

El valor p es como una medida de cuán fuerte es tu evidencia contra el sospechoso. Te dice la probabilidad de obtener la evidencia que tienes si el sospechoso es inocente.

P90. ¿Qué significan interpolación y extrapolación? ¿Cuál es generalmente más precisa?

La interpolación y la extrapolación son dos técnicas matemáticas utilizadas para estimar valores dentro o fuera de un rango dado de puntos de datos conocidos. Sirven para diferentes propósitos y tienen distintos grados de precisión:

Interpolación	Extrapolación
Definición: La interpolación es el proceso de estimar un valor desconocido que existe dentro de una secuencia conocida de puntos de datos.	Definición: La extrapolación es el proceso de estimar un valor desconocido que existe fuera de una secuencia de puntos de datos conocidos.
Precisión: Generalmente, la interpolación es más precisa porque se basa en el rango de datos conocidos.	Precisión: La extrapolación es menos precisa porque implica hacer suposiciones más allá del rango de los datos conocidos.

¿Cuál es generalmente más precisa?

La interpolación es generalmente más precisa que la extrapolación. Aquí tienes el porqué:

- La interpolación estima valores dentro del rango de datos conocidos, donde has observado el patrón real o la relación entre los puntos de datos. Siempre que esta relación permanezca relativamente consistente, la interpolación tiende a proporcionar estimaciones razonablemente precisas.
- La extrapolación, por otro lado, implica predecir valores más allá del rango de datos conocidos, lo cual es inherentemente incierto. La extrapolación asume que el mismo patrón o tendencia continuará, y esta suposición puede no siempre ser verdadera, especialmente cuando los datos están sujetos a condiciones cambiantes o factores no observados.

P91. ¿Qué es un inlier?

Un inlier es un punto de datos en un conjunto de datos que se ajusta al patrón general o comportamiento de la mayoría de los puntos de datos. En otras palabras, un inlier es un punto que se considera típico o consistente con las características generales del conjunto de datos. Los inliers se contrastan con los outliers, que son puntos de datos que se desvían significativamente del comportamiento esperado o típico del conjunto de datos.

P92. Lanzaste una moneda sesgada ($p(\text{cara}) = 0.8$) cinco veces. ¿Cuál es la probabilidad de obtener tres o más caras?

Para comenzar con la pregunta, necesitamos 3, 4 o 5 caras para satisfacer los casos.

5 caras: Todos caras, así que: $\binom{4}{5}^5 = \frac{1024}{3125}$

4 caras: Todos menos 1 cara. Hay 5 formas de organizar esto:

$$\binom{4}{5}^4 * \binom{1}{5}^1 = 256/3125$$

Como hay 5 casos, tenemos 1280/3125.

3 caras: Todos menos 2 caras. Hay 10 formas de organizar esto:

$$\binom{4}{5}^3 * \binom{1}{5}^2 = 64/3125$$

Como hay 10 casos, tenemos 640/3125.

Sumamos todos los casos para obtener $(1024 + 1280 + 640)/3125 = 2944/3125$.

Tenemos una probabilidad de 2944/3125 o 0.94208 de obtener 3 o más caras.

P93. Las tasas de infección en un hospital por encima de 1 infección por 100 personas-día en riesgo se consideran altas. Un hospital tuvo 10 infecciones durante los últimos 1787 personas-día en riesgo. Da el valor p de la prueba correcta de una cola para determinar si la tasa de infección del hospital está por debajo del estándar.

Para encontrar el valor p de la prueba de una cola de si la tasa de infección del hospital está por debajo de la tasa de infección estándar de 1 infección por 100 personas-día en riesgo, puedes usar la distribución de Poisson. La distribución de Poisson es apropiada para modelar el número de eventos raros, como infecciones en un hospital, durante un intervalo conocido de tiempo.

Cómo calcular el valor p para esta prueba:

1. Calcula el número esperado de infecciones bajo la tasa estándar: Tasa de infección estándar = 1 infección por 100 personas-día.

$$\text{Infecciones esperadas: } (1787) \left(\frac{1}{100} \right) = 17.87$$

2. Usa la distribución de Poisson para encontrar la probabilidad de observar 10 o menos infecciones cuando el número esperado es 17.87. La función de masa de probabilidad de Poisson es:

$$P(X = x) = \frac{e^{-\lambda} * \lambda^x}{x!}$$

3. Calcula la probabilidad acumulada de observar 10 o menos infecciones:

$$P(X \leq 10) = \sum_{x=0}^{10} \frac{e^{-17.87} * 17.87^x}{x!}$$

4. Encuentra el valor p, que es la probabilidad de observar 10 o menos infecciones:

$$P(X \leq 10) = 0.033$$

Entonces, el valor p para la prueba de una cola de si la tasa de infección del hospital está por debajo de la tasa estándar de 1 infección por 100 personas-día en riesgo es aproximadamente 0.033. Este valor p indica una fuerte evidencia de que la tasa de infección del hospital está por debajo del estándar, ya que es menor que un nivel de significancia típico como 0.05.

P94. ¿Qué es la prueba Chi-cuadrado?

Una prueba chi-cuadrado es una prueba estadística utilizada para determinar si existe una asociación significativa o relación entre variables categóricas. Es particularmente útil para analizar datos que se pueden organizar en una tabla de contingencia, que es una representación tabular de los datos donde las filas y columnas corresponden a diferentes categorías o grupos.

P95. ¿Qué es la prueba ANOVA?

ANOVA, o Análisis de Varianza, es una prueba estadística utilizada para analizar las diferencias entre las medias de grupo en una muestra. Es una técnica poderosa y ampliamente utilizada para comparar medias de múltiples grupos para determinar si existen diferencias estadísticamente significativas entre ellos.

La idea principal detrás de ANOVA es dividir la varianza total en los datos en diferentes componentes, que se pueden atribuir a diferentes fuentes o factores.

P96. ¿Qué queremos decir con tomar una decisión basada en comparar el valor p con el nivel de significancia?

Tomar una decisión basada en comparar un valor p con un nivel de significancia implica determinar si la evidencia de una prueba estadística apoya o contradice una hipótesis nula.

- Si el valor p es menor o igual al nivel de significancia elegido (α), típicamente 0.05, sugiere que los resultados observados son estadísticamente significativos. En este caso, rechazas la hipótesis nula.
- Si el valor p es mayor que el nivel de significancia, sugiere que los resultados observados no son estadísticamente significativos. En este caso, no rechazas la hipótesis nula.

En resumen, es una forma de decidir si los datos proporcionan suficiente evidencia para desafiar una hipótesis específica o no.


P97. ¿Cuál es el objetivo de las pruebas A/B?

El objetivo de las pruebas A/B es comparar diferentes variaciones de un elemento digital (como una página web o una función de la aplicación) para determinar cuál funciona mejor en términos de un resultado específico, con el objetivo de optimizar ese elemento para mejorar la participación del usuario, conversiones u otras métricas deseadas.

P98. ¿Cuál es la diferencia entre un diagrama de caja y un histograma?

Los diagramas de caja y los histogramas son representaciones gráficas utilizadas en estadística para visualizar la distribución de los datos. Sin embargo, tienen diferentes propósitos y características:

Histograma	Diagrama de Caja
<p>Propósito: Los histogramas se utilizan para visualizar la distribución de datos continuos dividiéndolos en intervalos o bins y mostrando la frecuencia o el conteo de puntos de datos dentro de cada intervalo.</p>	<p>Propósito: Los diagramas de caja se utilizan para mostrar la distribución, la tendencia central y la dispersión (variabilidad) de un conjunto de datos. Son particularmente útiles para identificar outliers y comparar la distribución de múltiples conjuntos de datos.</p>
<p>Apariencia: Un histograma consiste en una serie de barras adyacentes, con el ancho de cada barra representando un rango de valores. La altura de cada barra representa la frecuencia o el conteo de puntos de datos en ese intervalo.</p>	<p>Apariencia: Un diagrama de caja consiste en una “caja” rectangular con una línea en su interior (la mediana) y “bigotes” que se extienden desde la caja. A veces, los puntos de datos individuales se representan como puntos.</p>
<p>Información: Los histogramas proporcionan una vista detallada de la forma de los datos, el centro, la dispersión, la asimetría y los modos potenciales.</p>	<p>Información: Un diagrama de caja proporciona información sobre la mediana, los cuartiles (percentiles 25 y 75), el rango intercuartílico (IQR) y la presencia de outliers.</p>
<p>Tipo de Datos: Los histogramas se utilizan principalmente para datos continuos, aunque se pueden adaptar para datos discretos ajustando los anchos de los intervalos.</p>	<p>Tipo de Datos: Los diagramas de caja son adecuados para resumir tanto datos continuos como categóricos.</p>
<p>Uso: Comúnmente utilizados para explorar la distribución de los datos, identificar patrones y evaluar las características de los datos.</p>	<p>Uso: Comúnmente utilizados para comparar distribuciones entre diferentes grupos o visualizar la dispersión de los datos.</p>



P99. ¿Qué es un intervalo de confianza y cómo lo interpretas?

Un intervalo de confianza es un concepto estadístico utilizado para estimar un rango de valores dentro del cual es probable que se encuentre un parámetro de la población (como una media, proporción o coeficiente de regresión) con un cierto nivel de confianza. Proporciona una medida de la incertidumbre o variabilidad asociada con la estimación de un parámetro a partir de una muestra de datos.

Interpretación de un intervalo de confianza:

Ejemplo: Supón que calculas un intervalo de confianza del 95% para la altura promedio de una población y obtienes el intervalo [165 cm, 175 cm].

Interpretación: Puedes interpretar este intervalo de confianza de la siguiente manera:

“Estamos 95% seguros de que la verdadera altura promedio de la población se encuentra dentro del rango de 165 cm a 175 cm.”


P100. ¿Cómo te mantienes al día con los nuevos conceptos en estadística?

Para mantenerse al día con los nuevos conceptos en estadística:

- **Leer Revistas:** Leer regularmente revistas y publicaciones estadísticas.
- **Cursos en Línea:** Tomar cursos en línea y seminarios web.
- **Conferencias:** Asistir a conferencias y talleres de estadística.
- **Unirse a Foros:** Participar en foros y comunidades estadísticas en línea.
- **Hacer Networking:** Conectar con estadísticos y científicos de datos.
- **Suscribirse:** Suscribirse a boletines y blogs de estadística.
- **Seguir a Investigadores:** Seguir a líderes estadísticos en redes sociales.
- **Aprendizaje Continuo:** Adoptar una cultura de aprendizaje continuo.

P101. ¿Qué es la correlación?

La correlación es una medida estadística utilizada para describir el grado en que dos o más variables cambian juntas o están relacionadas entre sí. En otras palabras, cuantifica la fuerza y dirección de la relación lineal entre dos o más variables.



Puntos clave sobre la correlación:

- **Coefficiente de Correlación:** La forma más común de medir la correlación es calculando el coeficiente de correlación, que se representa con el símbolo “r” o “ ρ ” (rho). El coeficiente de correlación es un valor numérico que varía entre -1 y 1, con las siguientes interpretaciones:
 1. Una correlación positiva ($r > 0$) indica que, a medida que una variable aumenta, la otra tiende a aumentar también.
 2. Una correlación negativa ($r < 0$) indica que, a medida que una variable aumenta, la otra tiende a disminuir.
 3. Un coeficiente de correlación de 0 ($r = 0$) sugiere que no hay relación lineal entre las variables.
- **Fuerza de la Correlación:** El valor absoluto del coeficiente de correlación ($|r|$) indica la fuerza de la relación. Los valores más cercanos a -1 o 1 representan correlaciones más fuertes, mientras que los valores más cercanos a 0 representan correlaciones más débiles.
- **Dirección de la Correlación:** El signo del coeficiente de correlación (+ o -) indica la dirección de la relación. Un coeficiente positivo significa que las variables se mueven en la misma dirección, mientras que un coeficiente negativo significa que se mueven en direcciones opuestas.
- **Diagramas de Dispersión:** Los diagramas de dispersión se utilizan a menudo para representar visualmente la relación entre dos variables. Los puntos en el gráfico representan puntos de datos, y el patrón que forman puede dar una indicación de la correlación.

P102. ¿Qué tipos de variables se utilizan para el coeficiente de correlación de Pearson?

El coeficiente de correlación de Pearson, a menudo denotado como “r,” se utiliza para medir la fuerza y la dirección de la relación lineal entre dos variables continuas. En otras palabras, se aplica cuando ambas variables que se están estudiando son cuantitativas y numéricas en la naturaleza.

P103. ¿Por qué no existe una “prueba t de 3 muestras”? ¿Por qué falla la prueba t con 3 muestras?

No existe una “prueba t de 3 muestras” dedicada porque las pruebas t tradicionales están diseñadas para comparar medias entre dos grupos, no tres. Cuando tienes tres o más grupos para comparar, generalmente utilizas análisis de varianza (ANOVA) o sus variaciones, que pueden determinar si hay diferencias estadísticamente significativas entre múltiples grupos. Las pruebas t se pueden aplicar para comparar pares de grupos dentro de un marco ANOVA, pero no se utilizan para comparar directamente tres grupos simultáneamente.

P104. ¿Cuál puede ser la razón de la no normalidad de los datos?

La no normalidad de los datos, es decir, que los datos no siguen una distribución normal (también conocida como distribución Gaussiana), puede ocurrir por varias razones. Es importante identificar las causas subyacentes de la no normalidad porque la elección del análisis estadístico y la interpretación de los resultados pueden depender de la distribución de los datos.

P105. ¿Cómo determinarás la prueba para los datos continuos?

Las pruebas comunes para analizar datos continuos en estadística incluyen:

- **Prueba T:** Utilizada para comparar medias entre dos grupos.
- **Análisis de Varianza (ANOVA):** Compara medias entre tres o más grupos.
- **Pruebas de Correlación:** Evalúan las relaciones entre variables continuas, por ejemplo, correlación de Pearson o correlación de rango de Spearman.
- **Análisis de Regresión:** Predice una variable continua basada en uno o más predictores.
- **Prueba Chi-cuadrado de Independencia:** Examina las asociaciones entre variables categóricas y continuas.
- **ANOVA con Medidas Repetidas:** Extensión de ANOVA para diseños de medidas repetidas o dentro de sujetos.
- **Análisis de Varianza Multivariada (MANOVA):** Extiende ANOVA para analizar múltiples variables dependientes simultáneamente.

La elección de la prueba depende de tu pregunta de investigación, distribución de los datos y diseño experimental.

Mucho éxito! :)