

ESTADÍSTICA INFERENCIAL PARA LAS CIENCIAS SOCIALES

Escrito por:

Ricardo Martín Gómez Arce
Blanca Flor Robles Pastor
María del Pilar Ríos García
María Peregrina Cruzado Vallejos
Víctor Humberto Mattos Núñez
Julio Mariano Chávez Milla

www.editorialmarcaribe.es

ISBN: 978-9915-698-22-9



Estadística inferencial para las ciencias sociales

Ricardo Martín Gómez Arce, Blanca Flor Robles Pastor, María del Pilar Ríos García, Maria Peregrina Cruzado Vallejos, Víctor Humberto Mattos Núñez, Julio Mariano Chávez Milla

© Ricardo Martín Gómez Arce, Blanca Flor Robles Pastor, María del Pilar Ríos García, Maria Peregrina Cruzado Vallejos, Víctor Humberto Mattos Núñez, Julio Mariano Chávez Milla, 2025

Primera edición: Agosto, 2025

Editado por:

Editorial Mar Caribe

www.editorialmarcaribe.es

Av. General Flores 547, Colonia, Colonia-Uruguay.

Diseño de portada: Yelitza Sánchez Cáceres

Libro electrónico disponible en:

<https://editorialmarcaribe.es/ark:/10951/isbn.9789915698229>

Formato: electrónico

ISBN: 978-9915-698-22-9

ARK: [ark:/10951/isbn.9789915698229](https://editorialmarcaribe.es/ark:/10951/isbn.9789915698229)

**Atribución/Reconocimiento-
NoComercial 4.0 Internacional:**

Los autores pueden autorizar al público en general a reutilizar sus obras únicamente con fines no lucrativos, los lectores pueden utilizar una obra para generar otra, siempre que se dé crédito a la investigación, y conceden al editor el derecho a publicar primero su ensayo bajo los términos de la licencia [CC BY-NC 4.0](https://creativecommons.org/licenses/by-nc/4.0/).

**Editorial Mar Caribe, firmante
Nº 795 de 12.08.2024 de la
Declaración de Berlín:**

"... Nos sentimos obligados a abordar los retos de Internet como medio funcional emergente para la distribución del conocimiento. Obviamente, estos avances pueden modificar significativamente la naturaleza de la publicación científica, así como el actual sistema de garantía de calidad...." (Max Planck Society, ed. 2003., pp. 152-153).

[Editorial Mar Caribe-Miembro de OASPA:](#)

Como miembro de la Open Access Scholarly Publishing Association, apoyamos el acceso abierto de acuerdo con el código de conducta, transparencia y mejores prácticas de [OASPA](#) para la publicación de libros académicos y de investigación. Estamos comprometidos con los más altos estándares editoriales en ética y deontología, bajo la premisa de «Ciencia Abierta en América Latina y el Caribe».



OASPA

Editorial Mar Caribe

Estadística inferencial para las ciencias sociales

Colonia, Uruguay

2025

Sobre los autores y la publicación

Ricardo Martín Gómez Arce

 <https://orcid.org/0000-0003-2763-4399>

Universidad Nacional de Trujillo, Perú

Blanca Flor Robles Pastor

 <https://orcid.org/0000-0002-7686-2825>

*Universidad Nacional Toribio Rodríguez de
Mendoza de Amazonas, Perú*

María del Pilar Ríos García

 <https://orcid.org/0000-0002-0236-6810>

Universidad Nacional de Tumbes, Perú

Maria Peregrina Cruzado Vallejos

 <https://orcid.org/0000-0001-7809-4711>

Universidad César Vallejo, Perú

Víctor Humberto Mattos Núñez

 <https://orcid.org/0009-0004-6048-2870>

*Universidad Nacional Toribio Rodríguez de Mendoza
de Amazonas, Perú*

Julio Mariano Chávez Milla

 <https://orcid.org/0000-0002-2335-8457>

*Universidad Nacional Toribio Rodríguez de
Mendoza de Amazonas, Perú*

Resultado de la investigación del libro:

Publicación original e inédita, cuyo contenido es el resultado de un proceso de investigación realizado antes de su publicación, ha sido doble ciego de revisión externa por pares, el libro ha sido seleccionado por su calidad científica y porque contribuye significativamente al área del conocimiento e ilustra una investigación completamente desarrollada y completada. Además, la publicación ha pasado por un proceso editorial que garantiza su estandarización bibliográfica y usabilidad.

Sugerencia de citación: Gómez, R.M., Robles, B.F., Ríos, M., Cruzado, M.P., Mattos, V.H., y Chávez, J.M. (2025). *Estadística inferencial para las ciencias sociales*. Colonia del Sacramento: Editorial Mar Caribe. <https://editorialmarcaribe.es/ark:/10951/isbn.9789915698229>

Índice

Introducción	6
Capítulo I	9
Estadística Inferencial en Ciencias Sociales: Fundamentos, Métodos y Aplicaciones	9
1.1 Principios básicos de estadística inferencial	10
1.2 Evaluación Estadística en Ciencias Sociales: Aplicación de la Prueba de Bondad de Ajuste Multinomial y la Prueba de Dixon	15
1.3 Prueba de Cochran-Mantel-Haenszel: Aplicaciones y Relevancia en las Ciencias Sociales	24
Capítulo II	30
Análisis de Supervivencia en Estudios Demográficos: Metodologías, Aplicaciones y Futuras Perspectivas	30
2.1 Análisis de Supervivencia en Demografía: Un Estudio Integral	30
2.2 Curvas de Kaplan-Meier: Herramientas Esenciales para el Análisis de Datos en Ciencias Sociales	36
2.3 Prueba de Rango Logarítmico y la Regresión de Cox: Herramientas Esenciales para el Análisis en Ciencias Sociales	42
Capítulo III	49
Modelos Dinámicos Poblacionales en Salud Pública: Aplicaciones, Desafíos y Futuras Perspectivas	49
3.1 Introducción a los modelos dinámicos poblacionales	49
3.2 Modelado Dinámico Poblacional: Aplicación de Ecuaciones Diferenciales Ordinarias y Parciales	56
3.3 Sistemas Dinámicos en las Ciencias Sociales: Modelos, Análisis y Desafíos	64
Capítulo IV	72
Modelos Descriptivos, Inferenciales y Predictivos en las Ciencias Sociales: Una Guía para la Investigación y la Toma de Decisiones	72
4.1 Introducción a los modelos en ciencias sociales	72

4.2 Evaluación de la Normalidad en Ciencias Sociales: Un Análisis de la Prueba de Shapiro-Wilk y Otras Metodologías	80
4.3 Estimación de Densidad del Núcleo: Métodos y Aplicaciones en las Ciencias Sociales	87
Conclusión.....	95
Bibliografía.....	98

Introducción

En el ámbito de las ciencias sociales, la estadística inferencial juega un papel decisivo, discernir y afirmar sobre grupos más amplios a partir del análisis de un subconjunto de estos, esto es especialmente relevante en disciplinas como la sociología, la psicología, la economía y la educación, donde a menudo es impracticable o imposible recopilar datos de toda la población. La capacidad de realizar inferencias válidas a partir de muestras adecuadamente seleccionadas es esencial para la elaboración de políticas, la evaluación de programas y la comprensión de fenómenos sociales complejos.

El principio clave de la estadística inferencial es la relación entre la muestra y la población, pues, la selección adecuada de la muestra es concluyente, ya que una muestra mal seleccionada puede llevar a conclusiones erróneas. Existen diversos métodos de muestreo, incluidos el muestreo aleatorio, el muestreo estratificado y el muestreo por conveniencia, cada uno con sus ventajas y desventajas en función del tipo de estudio que se esté llevando a cabo.

A tener en cuenta, distinguir entre estadística descriptiva e inferencial, la primera se enfoca en la recopilación, organización y presentación de datos de manera que se facilite su comprensión, utilizando herramientas como gráficos, tablas y medidas de tendencia central. En contraste, la estadística inferencial se centra en el análisis y la interpretación de los datos. Es decir, si bien que la primera se limita a describir lo que se observa, la segunda condesciende en predecir y concluir, basada en evidencias, lo que es vital para la toma de decisiones informadas en el ámbito social.

A través del análisis de datos históricos y actuales, los académicos consiguen identificar correlaciones y patrones que contribuyen a una mejor comprensión de fenómenos sociales complejos, como la migración, la violencia, la tasa de mortalidad o el consumo de sustancias en un espacio muestral. Mediante que el uso de modelos de regresión, evalúa la relación entre diferentes variables y predice tendencias en función del tiempo.

A través de los cuatro capítulos que componen el libro: Fundamentos de la estadística inferencial, análisis de supervivencia en estudios demográficos, modelos dinámicos y toma de decisiones a partir de lo inferencial; se esbozan las aplicaciones prácticas de la estadística inferencial en la investigación social, el análisis de políticas públicas, y el estudio de tendencias de comportamiento que destacan su relevancia en la comprensión y mejora de la sociedad. En este sentido, la inferencia no es más que una competencia indispensable para los investigadores, para abordar preguntas complejas y contribuir al desarrollo de soluciones basadas en evidencia.

El objetivo de la investigación, evaluar los fundamentos de la estadística inferencial para el análisis de las ciencias sociales, guía de investigación y toma de decisiones informadas, con énfasis en tres de los métodos más utilizados en la inferencia estadística: las pruebas de hipótesis, los intervalos de confianza, y la regresión y correlación.

Además, se exploran las distribuciones más comunes en inferencia estadística como la distribución normal, binomial, t de Student, entre otras. Por lo que se busca trascender en un marco interpretativo y literario de los resultados basados en datos representativos o no. Por ende, la comprensión de cómo funcionan estas distribuciones y cómo se aplican en el contexto de la

investigación social es clave para cualquier analista de datos en las ciencias sociales.

Capítulo I

Estadística Inferencial en Ciencias Sociales: Fundamentos, Métodos y Aplicaciones

La estadística inferencial permite a los académicos hacer generalizaciones y tomar decisiones sobre una población más amplia basándose en un conjunto limitado de datos. A través de diversas técnicas y métodos, esta disciplina proporciona las herramientas necesarias para analizar muestras, estimar parámetros poblacionales y probar hipótesis, convirtiéndose en un componente esencial dentro del ámbito de las ciencias sociales.

La estadística inferencial se define como el proceso de utilizar datos de una muestra para hacer inferencias o conclusiones sobre una población más grande. A diferencia de la estadística descriptiva, que se enfoca en resumir y describir las características de un conjunto de datos, la estadística inferencial se basa en la teoría de la probabilidad y permite realizar estimaciones, predicciones y pruebas de hipótesis (Barreto, 2012). Este enfoque es decisivo en las ciencias sociales, donde las poblaciones pueden ser grandes y complejas, y donde estudiar a todos los individuos puede ser impracticable o imposible.

La estadística inferencial desempeña un papel crucial en las ciencias sociales, ya que muchas investigaciones en este ámbito buscan comprender fenómenos a partir de muestras representativas. A través de la inferencia estadística, los académicos pueden extraer conclusiones que no solo son

válidas para la muestra estudiada, sino que incluso se pueden generalizar a la población en su conjunto. Esto es vital para la formulación de políticas, la evaluación de programas y la comprensión de dinámicas sociales, entre otros aspectos.

Para entender cómo se utilizan los datos en la investigación, es fundamental conocer las diferencias entre estadística descriptiva e inferencial. La estadística descriptiva se centra en la recopilación, presentación y resumen de datos a través de medidas como la media, la mediana y la desviación estándar, sin hacer inferencias más allá de los datos observados. En contraste, la estadística inferencial se adentra en el análisis y la interpretación de los datos, permitiendo a los académicos aplicar técnicas de muestreo y pruebas estadísticas para realizar generalizaciones y tomar decisiones informadas basadas en datos limitados.

1.1 Principios básicos de estadística inferencial

Para comprender cómo se aplica la estadística inferencial en las ciencias sociales, es fundamental explorar sus principios básicos, que incluyen el muestreo y la población, la estimación de parámetros y las pruebas de hipótesis. El muestreo es el proceso mediante el cual se selecciona un subconjunto de individuos o elementos de una población más grande para realizar un estudio. La población se refiere al conjunto completo de individuos que comparten características comunes y sobre los cuales se desea obtener información (López, 2004). En las ciencias sociales, las poblaciones pueden ser diversas, desde grupos demográficos específicos hasta comunidades enteras.

Existen varios métodos de muestreo, como el muestreo aleatorio simple, el muestreo estratificado y el muestreo por conveniencia, cada uno con sus ventajas y desventajas. La elección del método de muestreo influye

directamente en la representatividad de la muestra y, por ende, en la validez de las inferencias realizadas. Un muestreo adecuado asegura que los resultados sean generalizables a la población objetivo, lo que es crucial para la investigación en ciencias sociales.

Una vez que se ha obtenido una muestra, el siguiente paso es estimar parámetros poblacionales, como la media, la varianza o la proporción. La estimación puede ser puntual o por intervalo. La estimación puntual proporciona un único valor como mejor estimación del parámetro, mientras que la estimación por intervalo ofrece un rango dentro del cual se espera que se encuentre el parámetro poblacional con un cierto nivel de confianza.

Para ilustrar, si un investigador desea estimar la media de ingresos de un grupo social específico, puede calcular la media de ingresos a partir de una muestra y utilizarla como una estimación puntual. Sin embargo, para proporcionar un contexto más robusto, el investigador de igual forma podría calcular un intervalo de confianza, que le permitiría comunicar la incertidumbre asociada a esa estimación.

Las pruebas de hipótesis son una herramienta fundamental en la estadística inferencial que autoriza a los académicos evaluar afirmaciones sobre la población basándose en los datos de la muestra. Este proceso implica formular una hipótesis nula (H_0), que generalmente representa una afirmación de "no efecto" o "no diferencia", y una hipótesis alternativa (H_1), que sugiere lo contrario.

A través de la recolección de datos y el análisis estadístico, los académicos pueden determinar si hay suficiente evidencia en la muestra para rechazar la hipótesis nula a favor de la alternativa. Esto se realiza mediante el cálculo de un valor p , que indica la probabilidad de observar los datos si la

hipótesis nula es verdadera. Un valor p bajo (comúnmente menor a 0.05) sugiere que hay evidencia suficiente para rechazar la hipótesis nula.

En síntesis, los principios básicos de la estadística inferencial, que incluyen el muestreo y la población, la estimación de parámetros y las pruebas de hipótesis, son fundamentales para realizar investigaciones válidas y significativas en las ciencias sociales. A través de estos métodos, los académicos pueden obtener conclusiones más amplias sobre fenómenos sociales complejos y contribuir al entendimiento de las dinámicas que rigen las interacciones humanas.

La estadística inferencial ofrece una variedad de métodos analíticos que consienten a los académicos obtener conclusiones significativas a partir de datos muestrales. Estos métodos son fundamentales para el análisis de datos en ciencias sociales, ya que permiten la generalización de hallazgos a poblaciones más amplias.

El análisis de regresión es una técnica que acepta examinar la relación entre una variable dependiente y una o más variables independientes. Este método es particularmente útil para predecir valores y comprender la naturaleza de las relaciones entre variables (Hernández, 2012). En las ciencias sociales, se utiliza para estudiar cómo factores como la educación, el ingreso y el entorno social pueden influir en variables como el bienestar, la salud o el comportamiento de las personas. Existen diferentes tipos de análisis de regresión, incluyendo la regresión lineal simple y múltiple, así como la regresión logística, que se emplea cuando la variable dependiente es categórica.

El análisis de varianza, conocido como ANOVA, es un método estadístico que permite comparar las medias de tres o más grupos para

determinar si existen diferencias significativas entre ellos. Este enfoque es esencial en investigaciones sociales donde se busca entender el impacto de diferentes tratamientos o condiciones en un resultado específico. Lo más importante, un investigador podría utilizar ANOVA para evaluar si hay diferencias en el rendimiento académico entre estudiantes de diferentes programas educativos. ANOVA se basa en la partición de la variabilidad total en componentes atribuibles a diferentes fuentes, lo que transige evaluar la hipótesis nula de que todas las medias son iguales.

Los modelos de efectos mixtos son herramientas poderosas que combinan efectos fijos y aleatorios, permitiendo a los académicos manejar la complejidad de los datos que involucran múltiples niveles de agrupamiento. Estos modelos son especialmente útiles en el análisis de datos jerárquicos, donde las observaciones pueden estar anidadas dentro de grupos, como estudiantes dentro de escuelas o pacientes dentro de hospitales. En el contexto de las ciencias sociales, los modelos de efectos mixtos acceden ajustar por variabilidad entre grupos y, a la vez, evaluar el impacto de variables a nivel individual. Esto proporciona una comprensión más matizada de las dinámicas sociales y permite hacer inferencias más robustas.

Los métodos de análisis en estadística inferencial son esenciales para el desarrollo de investigaciones significativas en las ciencias sociales. Estos métodos no solo aprueban a los académicos realizar inferencias sobre poblaciones a partir de muestras, sino que asimismo facilitan la comprensión de relaciones complejas entre variables. La elección del método adecuado dependerá de la naturaleza de los datos y de las preguntas de investigación planteadas.

La estadística inferencial se ha convertido en una herramienta indispensable en el ámbito de las ciencias sociales. Su capacidad para hacer generalizaciones sobre una población a partir de una muestra autoriza a los académicos obtener conclusiones significativas y fundamentadas. Esto es especialmente crucial en un campo donde las dinámicas sociales son complejas y multifacéticas (Veiga et al., 2020). Al aplicar métodos inferenciales, los académicos pueden identificar tendencias, relaciones y patrones que serían imposibles de discernir a partir de datos descriptivos aislados. Por lo tanto, la estadística inferencial no solo dignifica el análisis de fenómenos sociales, sino que todavía proporciona una base sólida para la formulación de políticas y la toma de decisiones informadas.

A pesar de su importancia, la interpretación de los resultados obtenidos a través de la estadística inferencial presenta varios desafíos, es decir, la significación estadística no siempre implica relevancia práctica; es crucial que los académicos consideren el contexto social y cultural en el que se inscriben sus hallazgos. Además, la dependencia de modelos estadísticos puede llevar a la omisión de variables importantes que afectan los resultados. Por ello, es fundamental que los académicos mantengan una actitud crítica y reflexiva respecto a sus análisis y estén dispuestos a revisar sus conclusiones a la luz de nueva evidencia o cambios en el contexto.

Es evidente que la estadística inferencial seguirá evolucionando, especialmente con el avance de la tecnología y el aumento de la disponibilidad de datos. El uso de técnicas de análisis más sofisticadas, como el aprendizaje automático y la inteligencia artificial, permitirá a los académicos abordar preguntas complejas de manera más eficiente y precisa. Además, la integración de enfoques interdisciplinarios y la colaboración entre científicos sociales y estadísticos será decisivo para enriquecer el análisis de datos y

mejorar la validez de las inferencias realizadas. La creciente importancia de la transparencia y la reproducibilidad en la investigación también impulsará un cambio hacia prácticas más rigurosas y éticas en la aplicación de la estadística inferencial.

Las estadística inferencial no solo es esencial para la investigación social actual, sino que también se encuentra en un punto de inflexión que promete transformar la forma en que entendemos y analizamos el comportamiento humano y las dinámicas sociales en procesos por venir.

1.2 Evaluación Estadística en Ciencias Sociales: Aplicación de la Prueba de Bondad de Ajuste Multinomial y la Prueba de Dixon

En el ámbito de las ciencias sociales, las pruebas estadísticas desempeñan un papel fundamental en la interpretación y análisis de datos. Estas herramientas aceptan a los académicos evaluar hipótesis, identificar patrones y realizar inferencias sobre la población a partir de muestras limitadas. La importancia de las pruebas estadísticas radica en su capacidad para proporcionar evidencias empíricas que respaldan las teorías y suposiciones formuladas en investigaciones sociales.

Las pruebas estadísticas son esenciales para garantizar la validez y la confiabilidad de los resultados en las ciencias sociales. A través de estas pruebas, los académicos pueden determinar si las diferencias observadas en los datos son significativas o si podrían ser el resultado del azar. Esto es especialmente crítico en campos como la sociología, la psicología y la economía, donde las decisiones basadas en datos pueden tener un impacto significativo en políticas públicas y prácticas sociales. Además, las pruebas estadísticas consienten a los académicos explorar relaciones complejas entre variables, ayudando a desentrañar la naturaleza de fenómenos sociales.

Los objetivos de la investigación en ciencias sociales son diversos y multidimensionales. En general, buscan comprender procederes, actitudes y estructuras sociales. A través de métodos cuantitativos, los académicos pueden formular y probar hipótesis, contribuyendo al desarrollo de teorías que expliquen fenómenos sociales. Asimismo, los estudios en ciencias sociales a menudo están orientados a la identificación de problemas sociales, la evaluación de programas o políticas y la promoción de cambios positivos en la sociedad. En este contexto, contar con herramientas estadísticas adecuadas es indispensable para alcanzar resultados significativos y relevantes.

Dentro de las diversas pruebas estadísticas disponibles, la prueba de bondad de ajuste multinomial y la prueba de Dixon son dos herramientas útiles que se aplican en contextos específicos de investigación social. La prueba de bondad de ajuste multinomial se utiliza para determinar si la distribución observada de una variable categórica se ajusta a una distribución teórica esperada, permitiendo a los académicos evaluar hipótesis relacionadas con la distribución de los datos.

Por otro lado, la prueba de Dixon es especialmente valiosa en la detección de valores atípicos en un conjunto de datos. En ciencias sociales, donde los datos pueden estar influenciados por diversos factores, identificar y manejar estos valores extremos es crucial para asegurar que los análisis reflejen con precisión la realidad social. Ambas pruebas, no obstante distintas en su enfoque, proporcionan a los académicos herramientas robustas para el análisis de datos y la toma de decisiones informadas en sus estudios.

La prueba de bondad de ajuste multinomial es una herramienta estadística utilizada para determinar si una serie de observaciones categóricas se ajustan a una distribución teórica específica. Esta prueba es esencial cuando

se trabaja con variables cualitativas que pueden ser clasificadas en más de dos categorías (Pérez, 2004). A diferencia de la prueba de bondad de ajuste chi-cuadrado, que se aplica a distribuciones binomiales, la prueba multinomial transige analizar múltiples categorías simultáneamente.

Teóricamente, la prueba se fundamenta en la comparación entre la frecuencia observada de cada categoría y la frecuencia esperada, que se calcula según una distribución teórica. Se utiliza la siguiente fórmula para calcular la estadística de prueba:

$$\chi^2 = \sum \frac{(O_i - E_i)^2}{E_i}$$

donde (O_i) representa la frecuencia observada en la categoría (i) y (E_i) es la frecuencia esperada. El resultado se compara con una distribución chi-cuadrado con $(k-1)$ grados de libertad, donde (k) es el número de categorías.

La prueba de bondad de ajuste multinomial es ampliamente utilizada en las ciencias sociales para analizar datos categóricos. En particular, en estudios de opinión pública, los académicos pueden desear saber si la distribución de respuestas a una encuesta se ajusta a una distribución esperada en función de teorías previas o investigaciones anteriores. Asimismo, en estudios demográficos, esta prueba puede ayudar a identificar si las proporciones de diferentes grupos socioeconómicos en una muestra coinciden con las proporciones en la población general.

Además, en investigaciones sobre comportamiento del consumidor, esta prueba permite a los analistas verificar si la distribución de preferencias

de productos se alinea con las expectativas basadas en datos de mercado anteriores. La versatilidad de la prueba de bondad de ajuste multinomial la convierte en una herramienta invaluable para validar hipótesis y teorías en diversas áreas dentro de las ciencias sociales. Para ilustrar la aplicación de la prueba de bondad de ajuste multinomial, consideremos un estudio que investiga las preferencias de los consumidores en cuanto a tipos de bebidas (agua, refrescos, jugos y té). Supongamos que, en una encuesta de 200 personas, se obtuvieron las siguientes frecuencias observadas:

- Agua: 50
- Refrescos: 70
- Jugos: 40
- Té: 40

Los académicos, basándose en datos de mercado previos, establecen las siguientes frecuencias esperadas, suponiendo que las preferencias deberían ser equitativas entre las cuatro opciones:

- Agua: 50
- Refrescos: 50
- Jugos: 50
- Té: 50

Utilizando la fórmula de la estadística de prueba, calculamos χ^2 :

$$\chi^2 = \frac{(50 - 50)^2}{50} + \frac{(70 - 50)^2}{50} + \frac{(40 - 50)^2}{50} + \frac{(40 - 50)^2}{50}$$

\]

\[

$$X^2 = 0 + \frac{400}{50} + \frac{100}{50} + \frac{100}{50} = 0 + 8 + 2 + 2 = 12$$

\]

Con 3 grados de libertad (4 categorías - 1), el valor crítico de χ^2 se puede consultar en una tabla de chi-cuadrado. Si el valor calculado de 12 excede el valor crítico, se rechazará la hipótesis nula, sugiriendo que las preferencias de los consumidores no se ajustan a la distribución esperada. Este tipo de análisis es crucial para comprender mejor las dinámicas del comportamiento del consumidor y las tendencias en el mercado, aportando valiosas percepciones para la toma de decisiones estratégicas en el ámbito social y comercial.

La prueba de Dixon, también conocida como la prueba del rango de Dixon o el test de Dixon para la detección de valores atípicos, es un método estadístico diseñado para identificar observaciones que se desvían significativamente del resto de un conjunto de datos. Esta prueba es particularmente valiosa en el ámbito de las ciencias sociales, donde los datos pueden verse afectados por errores de medición o por la influencia de valores extremos.

La metodología de la prueba de Dixon se basa en el cálculo de un estadístico que compara la diferencia entre el valor sospechoso y el valor más cercano del conjunto de datos. Se considera un valor atípico si esta diferencia es lo suficientemente grande en relación con la dispersión de los datos. La prueba puede aplicarse tanto a conjuntos de datos pequeños como a grandes,

si bien es más efectiva cuando el tamaño de la muestra es reducido (Mendenhall et al., 2010).

En las ciencias sociales, la prueba de Dixon se utiliza para limpiar los datos antes de realizar análisis más complejos. En efecto, en estudios de encuestas, un investigador podría encontrar respuestas que no se alinean con el comportamiento esperado o con la lógica del contexto social. La identificación y eliminación de estos valores atípicos puede mejorar la precisión de los análisis subsecuentes, permitiendo que las conclusiones que se extraigan sean más representativas de la población estudiada.

Además, esta prueba es útil en la validación de modelos estadísticos, donde la presencia de valores extremos puede influir en la estimación de parámetros y en la inferencia estadística. Por lo tanto, su aplicación es esencial para garantizar la integridad de los resultados en investigaciones que abordan temas como la pobreza, la educación, la salud pública y otros fenómenos sociales.

Para ilustrar la aplicación de la prueba de Dixon, consideremos un estudio que investiga los niveles de satisfacción laboral entre empleados de una empresa. Supongamos que, tras la recolección de datos, se obtiene una serie de puntuaciones de satisfacción en una escala del 1 al 10. Al analizar los datos, el investigador encuentra una puntuación de 1 que parece anómala en comparación con las demás, que oscilan entre 6 y 10.

Aplicando la prueba de Dixon, se calcularía la diferencia entre la puntuación de 1 y la puntuación más cercana, que es 6. Si esta diferencia es suficientemente significativa en relación con la variabilidad del conjunto de datos, la puntuación de 1 se clasificaría como un valor atípico. En este caso, el investigador podría decidir excluir esta observación del análisis para evitar

que afecte la interpretación de los resultados sobre la satisfacción laboral de los empleados.

Este ejemplo resalta la importancia de la prueba de Dixon en el análisis de datos sociales, ya que permite a los académicos abordar de manera sistemática y rigurosa la presencia de valores extremos, asegurando que sus conclusiones reflejen con mayor precisión la realidad social que se estudia. La prueba de bondad de ajuste multinomial y la prueba de Dixon son herramientas estadísticas que, pese a que comparten el objetivo de analizar datos en el contexto de las ciencias sociales, presentan diferencias fundamentales en su enfoque y aplicación.

La prueba de bondad de ajuste multinomial se utiliza principalmente para determinar si las proporciones observadas en diferentes categorías de un conjunto de datos se ajustan a las proporciones esperadas bajo una hipótesis nula. Es una prueba que evalúa la adecuación de un modelo teórico frente a los datos empíricos, siendo especialmente útil en situaciones donde las variables son categóricas y se busca entender la distribución de frecuencias.

En contraste, la prueba de Dixon es una prueba de detección de valores atípicos, diseñada para identificar anomalías en datos que se distribuyen normalmente. Su objetivo es asegurar la integridad de los datos antes de realizar un análisis más profundo, enfocándose en la identificación de puntos de datos que se desvían significativamente del resto de la muestra. Mientras que la prueba multinomial se centra en la relación entre categorías y sus frecuencias, la prueba de Dixon se ocupa de la calidad de los datos, asegurando que los resultados obtenidos no estén sesgados por la presencia de valores atípicos.

La elección entre la prueba de bondad de ajuste multinomial y la prueba de Dixon depende en gran medida del tipo de datos que se están analizando y de los objetivos específicos de la investigación. La prueba multinomial es ideal cuando se desea comparar distribuciones observadas con distribuciones esperadas, especialmente en estudios donde las variables son categóricas y se busca validar modelos teóricos (Romaina, 2012). Específicamente, en una investigación sobre preferencias políticas, un investigador podría utilizar la prueba multinomial para ver si la distribución de votos se ajusta a lo que se esperaría según encuestas previas.

Por otro lado, la prueba de Dixon resulta más apropiada en situaciones donde se sospecha que pueden existir valores atípicos que puedan distorsionar los resultados. La idea central es, en estudios de salud pública, donde se analizan datos de ingresos o condiciones de salud, la presencia de un valor atípico puede influir significativamente en la media y, por lo tanto, en las conclusiones del estudio. En tales casos, aplicar la prueba de Dixon antes de realizar otras pruebas estadísticas es fundamental para garantizar la validez de los resultados.

Ambas pruebas ofrecen herramientas valiosas para los académicos en ciencias sociales, cada una con su propia relevancia y aplicación. La prueba de bondad de ajuste multinomial acepta a los académicos validar teorías y modelos, lo que es esencial para el avance del conocimiento en el campo. Al proporcionar evidencia empírica sobre la distribución de datos categóricos, ayuda a fundamentar decisiones y políticas basadas en esos hallazgos.

Por su parte, la prueba de Dixon juega un papel crucial en el aseguramiento de la calidad de los datos. En las ciencias sociales, donde los datos a menudo provienen de encuestas o estudios observacionales, la

identificación y gestión de valores atípicos es esencial para garantizar la fiabilidad de las conclusiones. La capacidad de detectar y tratar estos valores atípicos admite a los académicos presentar resultados más robustos y confiables, lo que a su vez fortalece la credibilidad de la investigación en ciencias sociales. Tanto la prueba de bondad de ajuste multinomial como la prueba de Dixon son esenciales en el arsenal estadístico de los académicos sociales, y su correcta aplicación puede tener un impacto significativo en la calidad y la validez de las conclusiones obtenidas en estudios sociales.

La aplicación de pruebas estadísticas, como la prueba de bondad de ajuste multinomial y la prueba de Dixon, juega un papel crucial en la validación y análisis de datos en las ciencias sociales. La prueba de bondad de ajuste multinomial permite a los académicos evaluar si un conjunto de datos se ajusta a una distribución esperada, facilitando la comprensión de patrones en la conducta social. Por otro lado, la prueba de Dixon se ha destacado como una herramienta eficaz para identificar y manejar valores atípicos, lo que es fundamental para mantener la integridad de los análisis en contextos donde los datos pueden ser susceptibles a anomalías.

Las implicaciones de estas herramientas estadísticas son significativas para el campo de las ciencias sociales. Una correcta aplicación de la prueba de bondad de ajuste multinomial puede ayudar a los académicos a realizar inferencias más precisas sobre la población estudiada, lo que a su vez puede influir en la formulación de políticas y en la comprensión de fenómenos sociales complejos. Además, el uso de la prueba de Dixon es vital para asegurar que los resultados obtenidos no se vean distorsionados por valores extremos, permitiendo así conclusiones más robustas y confiables.

Es fundamental que los académicos en ciencias sociales continúen explorando y perfeccionando el uso de estas pruebas estadísticas. Se sugiere llevar a cabo estudios comparativos que evalúen la eficacia de la prueba de bondad de ajuste multinomial y la prueba de Dixon en diferentes contextos sociales y culturales. Asimismo, la integración de estas pruebas en metodologías mixtas podría ofrecer una perspectiva más holística sobre los fenómenos estudiados. Por último, se invita a la comunidad académica a investigar nuevas adaptaciones y combinaciones de estas pruebas para abordar los desafíos emergentes en el análisis de datos sociales, garantizando que las herramientas estadísticas evolucionen junto con las complejidades de la realidad social.

1.3 Prueba de Cochran-Mantel-Haenszel: Aplicaciones y Relevancia en las Ciencias Sociales

La prueba de Cochran-Mantel-Haenszel (CMH) es una herramienta estadística que transige evaluar la asociación entre dos variables categóricas mientras se controla por una o más variables de confusión. Esta prueba es fundamental en el análisis de datos en contextos donde los académicos desean determinar si existe una relación significativa entre las variables de interés, considerando otras variables que podrían influir en dicha relación (Yu y Gastwirth, 2008).

La importancia de la prueba CMH en las ciencias sociales radica en su capacidad para proporcionar resultados más precisos y confiables en estudios observacionales. En campos como la salud pública, la educación y la sociología, donde los datos son frecuentemente no experimentales y pueden estar sujetos a múltiples factores confusos, la prueba CMH ofrece una

metodología robusta para desentrañar las complejidades de las relaciones entre variables.

Los autores buscan a través de este capítulo, proporcionar una visión integral sobre la prueba de Cochran-Mantel-Haenszel, abordando sus fundamentos estadísticos, sus diversas aplicaciones en las ciencias sociales y la relevancia de sus resultados. Lo más resaltante, se destacará cómo esta prueba puede contribuir a una mejor comprensión de fenómenos sociales complejos y ofrecer recomendaciones para su uso en investigaciones a corto plazo.

La prueba de Cochran-Mantel-Haenszel (CMH) es una herramienta estadística fundamental para el análisis de datos en las ciencias sociales, especialmente cuando se trata de investigar la asociación entre variables categóricas mientras se controla por otros factores que podrían influir en la relación observada. Para comprender su aplicación y utilidad, es necesario explorar algunos de sus fundamentos estadísticos.

La asociación se refiere a la relación que puede existir entre dos variables. En el contexto de la prueba CMH, se busca determinar si existe una asociación significativa entre una variable independiente y una variable dependiente, considerando la influencia de una o más variables confusoras. Las variables confusoras son aquellas que están relacionadas con ambas variables de interés y que, si no se controlan, pueden sesgar los resultados del análisis.

La prueba CMH permite evaluar la asociación entre las variables mientras se ajusta por estos confusores, lo que resulta en estimaciones más precisas y robustas. A través de la estratificación, se pueden analizar los datos en subgrupos que son homogéneos respecto a los confusores, facilitando así

una evaluación más clara de la relación entre las variables de interés. La aplicación de la prueba CMH es particularmente útil en estudios observacionales donde se puede observar la relación entre variables sin manipularlas. Para utilizar la prueba de manera efectiva, es importante cumplir con algunos criterios:

- i. *Diseño de estudio adecuado:* La prueba CMH es más adecuada para estudios que utilizan diseños de tablas de contingencia, donde se pueden clasificar las observaciones en varias categorías.
- ii. *Variables categóricas:* Las variables a analizar deben ser categóricas, lo que significa que se agrupan en categorías discretas (por ejemplo, sí/no, tratamiento/control).
- iii. *Independencia de las observaciones:* Las observaciones dentro de cada estrato deben ser independientes entre sí. Esto garantiza que los resultados reflejen adecuadamente la relación entre las variables sin interferencias de datos relacionados.

La interpretación de los resultados obtenidos mediante la prueba CMH se basa en el cálculo de un estadístico que compara las proporciones observadas en diferentes grupos. Un valor p asociado al estadístico permite determinar si la asociación observada es estadísticamente significativa. Generalmente, un valor p menor a 0.05 se considera indicativo de una asociación significativa, lo que sugiere que la relación entre las variables no es producto del azar (Kempf, 2005). Además del valor p , es decisivo considerar la magnitud de la asociación, que puede evaluarse a través de medidas como el odds ratio (OR). Esta medida proporciona información sobre la fuerza de la asociación entre las variables y admite realizar inferencias sobre la naturaleza de la relación.

Los fundamentos estadísticos de la prueba CMH son esenciales para su correcta aplicación en las ciencias sociales. Comprender el concepto de asociación, los criterios de aplicación y la interpretación de resultados permite a los académicos utilizar esta herramienta de manera efectiva, contribuyendo a la obtención de conclusiones más precisas y significativas en sus estudios.

La prueba de Cochran-Mantel-Haenszel (CMH) es una herramienta estadística valiosa que encuentra múltiples aplicaciones en el ámbito de las ciencias sociales. Su capacidad para controlar confusores y evaluar la asociación entre variables categóricas en diferentes estratos la convierte en una opción preferida para investigar fenómenos complejos.

En el campo de la salud pública, la prueba CMH se utiliza frecuentemente para analizar la relación entre factores de riesgo y resultados de salud, controlando simultáneamente por variables de confusión. En particular, se ha aplicado en estudios que investigan la relación entre el consumo de tabaco y la incidencia de enfermedades respiratorias, donde se controla por la edad y el sexo de los participantes. Al estratificar los datos en función de estas variables, los académicos pueden obtener estimaciones más precisas de la asociación entre el tabaquismo y las enfermedades, lo que permite una mejor comprensión de los riesgos asociados y la formulación de políticas de salud más efectivas.

En el ámbito educativo, la prueba CMH ha sido utilizada para evaluar el impacto de diferentes metodologías de enseñanza en el rendimiento académico de los estudiantes. Para ilustrar, un estudio podría analizar cómo el uso de tecnologías digitales influye en los resultados de aprendizaje, controlando por factores como el nivel socioeconómico y el entorno escolar. Esta aplicación transige a los académicos desentrañar las dinámicas complejas

que afectan el aprendizaje y desarrollar estrategias pedagógicas más efectivas, adaptadas a las necesidades de diversos grupos de estudiantes.

La sociología, como disciplina centrada en la comprensión de las interacciones humanas y las estructuras sociales, se beneficia enormemente de la prueba CMH. Un ejemplo de su aplicación es el análisis de la relación entre el estatus socioeconómico y la participación en actividades comunitarias. Al estratificar por variables como la edad y el género, los sociólogos pueden identificar patrones de comportamiento y participación que podrían pasar desapercibidos en un análisis más simplista. Esto no solo enaltece el entendimiento de las dinámicas sociales, sino que también proporciona información valiosa para la formulación de políticas que fomenten la inclusión y la cohesión social.

En síntesis, la prueba de Cochran-Mantel-Haenszel ofrece un marco robusto para el análisis de datos en las ciencias sociales, permitiendo a los académicos abordar preguntas complejas de manera más efectiva. La prueba CMH se ha convertido en una herramienta clave para analizar las relaciones entre variables y avanzar en el conocimiento social.

La prueba de Cochran-Mantel-Haenszel (CMH) se ha establecido como una herramienta fundamental en el análisis estadístico dentro de las ciencias sociales. Su capacidad para evaluar la asociación entre variables categóricas, controlando simultáneamente los efectos de variables confusoras, la convierte en un recurso invaluable en estudios observacionales (Moral y Valle, 2023). Es importante resaltar cómo la CMH permite desentrañar patrones complejos en los datos, ofreciendo una forma robusta de analizar la relación entre variables en múltiples estratos o grupos. Las aplicaciones en salud pública, educación

y sociología demuestran su versatilidad y capacidad para abordar preguntas de investigación trascendentales en contextos variados.

A pesar de su utilidad, la prueba CMH no está exenta de limitaciones. En primer lugar, su aplicación requiere que se cumplan ciertos supuestos, como la independencia de las observaciones y el tamaño adecuado de las muestras, lo que puede representar un desafío en algunos estudios. Además, la prueba se enfoca en la asociación entre variables sin proporcionar información sobre la causalidad, lo que puede llevar a interpretaciones erróneas si no se considera el contexto completo del estudio. Por último, la CMH puede verse limitada en su capacidad para manejar variables continuas, lo que restringe su aplicabilidad en ciertos escenarios.

Para maximizar el potencial de la prueba CMH en futuras investigaciones, es recomendable que los académicos sigan algunas directrices. En primer lugar, es crucial realizar un diseño riguroso del estudio que garantice el cumplimiento de los supuestos estadísticos. Además, se sugiere complementar la CMH con otros métodos estadísticos que permitan explorar relaciones causales y el efecto de variables continuas. Por último, se debe fomentar la capacitación en análisis estadístico entre los académicos de ciencias sociales, asegurando que comprendan tanto las fortalezas como las limitaciones de la prueba CMH, para que puedan aplicarla de manera adecuada y efectiva en sus investigaciones.

La prueba de Cochran-Mantel-Haenszel representa una herramienta poderosa y relevante en el arsenal estadístico de las ciencias sociales. Su capacidad para desglosar datos complejos y controlar confusores la posiciona como un recurso esencial para comprender mejor las dinámicas sociales y contribuir a la formulación de políticas basadas en evidencia

Capítulo II

Análisis de Supervivencia en Estudios Demográficos: Metodologías, Aplicaciones y Futuras Perspectivas

2.1 Análisis de Supervivencia en Demografía: Un Estudio Integral

El análisis de supervivencia es una técnica estadística fundamental en el campo de la demografía y otras disciplinas sociales, utilizada para estudiar el tiempo hasta que ocurre un evento de interés, como la muerte, el matrimonio o la enfermedad. A través de este enfoque, los académicos pueden examinar no solo si un evento sucede, sino de igual forma cuándo tiene lugar, proporcionando una visión más profunda sobre la dinámica de las poblaciones y sus características.

El análisis de supervivencia se refiere a un conjunto de métodos estadísticos diseñados para analizar datos donde el resultado de interés es el tiempo hasta que ocurre un evento específico. Este campo se originó en la medicina, donde se utilizaba para estudiar el tiempo hasta la muerte de pacientes o la aparición de enfermedades (Arribalzaga, 2007). Ahora bien, su aplicación ha crecido en otras áreas, incluidas la biología, la economía y, por supuesto, la demografía. En este contexto, el evento de interés puede ser la mortalidad, el cambio de estado civil, la migración, entre otros.

La relevancia del análisis de supervivencia en la demografía radica en su capacidad para proporcionar información valiosa sobre la estructura y el comportamiento de las poblaciones. A través de este análisis, los demógrafos

pueden identificar patrones de mortalidad, evaluar la esperanza de vida y analizar cómo factores como la edad, el género y el nivel socioeconómico influyen en la longevidad. Además, el análisis de supervivencia admite el estudio de cohortes específicas y el seguimiento de cambios en el tiempo, lo que resulta esencial para la planificación de políticas públicas y la asignación de recursos.

El análisis de supervivencia se centra en la duración del tiempo hasta que ocurre un evento de interés, típicamente la muerte, pero asimismo puede incluir cualquier otro evento, como el fracaso de un tratamiento o la recaída de una enfermedad. Para llevar a cabo este análisis, existen diversas metodologías que permiten a los académicos modelar y entender los patrones de supervivencia en diferentes poblaciones.

Los modelos de regresión de Cox, todavía conocidos como modelos de riesgos proporcionales de Cox, son una de las herramientas más poderosas en el análisis de supervivencia. Este enfoque semiparamétrico permite examinar la relación entre la duración hasta el evento y una o más variables independientes, sin la necesidad de especificar la forma de la función de riesgo. Esto significa que los académicos pueden identificar qué factores aumentan o disminuyen el riesgo de un evento, mientras se controlan otras variables.

La popularidad del modelo de Cox radica en su flexibilidad y capacidad para manejar datos censurados, es decir, casos en los que el evento no ha ocurrido durante el periodo de estudio. Lo más importante, en estudios demográficos, este modelo puede utilizarse para analizar cómo factores como la edad, el género o el nivel educativo afectan la tasa de mortalidad en diferentes grupos poblacionales.

El análisis de Kaplan-Meier es otra técnica fundamental en el análisis de supervivencia, especialmente útil para estimar la función de supervivencia a partir de datos censurados. Esta metodología transige representar gráficamente la probabilidad de supervivencia en el tiempo y es particularmente valiosa en estudios donde los programas de interés son relativamente raros.

La curva de supervivencia de Kaplan-Meier se construye a partir de los tiempos de evento y de censura, proporcionando una visualización clara de cómo las tasas de supervivencia cambian con el tiempo. Además, permite realizar comparaciones entre diferentes grupos, utilizando la prueba de log-rank para evaluar si las diferencias observadas son estadísticamente significativas (Errandonea, 2024). Esto es especialmente relevante en el análisis demográfico, donde se pueden comparar tasas de supervivencia entre diferentes cohortes o condiciones socioeconómicas.

Los métodos paramétricos en el análisis de supervivencia suponen que la duración hasta el evento sigue una distribución específica, como la normal, exponencial o Weibull. Estas metodologías pueden ser particularmente útiles cuando se tienen razones teóricas o empíricas para creer que los datos se ajustan a una determinada distribución.

Los modelos paramétricos suelen ser más eficientes que los no paramétricos cuando se cumplen sus supuestos, ya que pueden proporcionar estimaciones más precisas y, en algunos casos, permitir la inclusión de covariables de manera más directa. Aun así, su uso requiere una validación cuidadosa de los supuestos de distribución, lo que puede ser un desafío en aplicaciones demográficas donde la naturaleza de los datos puede ser compleja. Estas metodologías ofrecen herramientas valiosas para comprender

y modelar la duración hasta el evento en estudios demográficos, permitiendo a los académicos extraer conclusiones significativas sobre los patrones de supervivencia en diversas poblaciones y contextos.

El análisis de supervivencia ha demostrado ser una herramienta invaluable en el ámbito de la demografía, permitiendo a los académicos obtener una comprensión más profunda de diferentes fenómenos relacionados con la vida y la muerte en las poblaciones.

El análisis de supervivencia es fundamental para el estudio de las tasas de mortalidad en diversas poblaciones. A través de la utilización de técnicas como el modelo de regresión de Cox y el análisis de Kaplan-Meier, los demógrafos pueden estimar la probabilidad de supervivencia en distintos grupos poblacionales en el tiempo. Esto resulta particularmente útil para identificar variaciones en la mortalidad según factores como la edad, el género y el entorno socioeconómico. Así como, se ha observado que las tasas de mortalidad pueden diferir significativamente entre regiones urbanas y rurales, lo que indica la influencia de la ubicación geográfica y las condiciones de vida sobre la supervivencia.

Otro aspecto relevante del análisis de supervivencia es su aplicación en el estudio de la longevidad. Los académicos pueden utilizar estas metodologías para identificar factores que contribuyen a una vida más larga en diferentes comunidades. A través del análisis de cohortes, se pueden observar las características comunes de aquellos individuos que alcanzan edades avanzadas, así como las condiciones de salud y estilos de vida que prevalecen en estas poblaciones longevas. Este tipo de análisis puede proporcionar información valiosa para el desarrollo de políticas de salud

pública y programas de bienestar que fomenten hábitos de vida saludables y mejoren la calidad de vida en la vejez.

El análisis de supervivencia también admite examinar el impacto de factores socioeconómicos en la mortalidad y la longevidad, los estudios que incorporan variables como el nivel educativo, el ingreso y el acceso a servicios de salud han revelado que las desigualdades socioeconómicas tienen un efecto significativo en la esperanza de vida (Hincapié y Londoño, 2023). Vale la pena mencionar que las personas con niveles educativos más bajos y tasas de pobreza más altas también suelen tener tasas de mortalidad más altas.

Este tipo de análisis ayuda a iluminar algunas disparidades en salud; así que al menos ahora hay hechos, incluso si nuestros líderes no pueden resistirse a proporcionar un servicio de palabra para la causa de la justicia en salud pública. Mientras tanto, el análisis de supervivencia puede utilizarse en muchos casos de estudios demográficos, desde el estudio de las tasas de mortalidad hasta la comprensión de la longevidad y los factores de impacto para varios grupos económicos.

Estas aplicaciones son fundamentales para abordar las desigualdades en salud y mejorar la calidad de vida de las poblaciones. Además, hemos analizado aplicaciones específicas en estudios demográficos, como la evaluación de tasas de mortalidad, el análisis de longevidad y el impacto de factores socioeconómicos. Estos estudios no solo ayudan a comprender mejor las dinámicas poblacionales, sino que también informan políticas de salud pública y estrategias de intervención dirigidas a mejorar la calidad de vida y la esperanza de vida en diferentes contextos socioculturales.

A pesar de los avances en el análisis de supervivencia, persisten varios retos que limitan su aplicación y efectividad, en muchas regiones, la falta de

registros precisos sobre mortalidad y condiciones socioeconómicas dificulta la realización de análisis robustos. Además, la heterogeneidad en las poblaciones puede complicar la interpretación de los resultados, ya que los factores que afectan la supervivencia pueden variar significativamente entre diferentes grupos demográficos.

Otra dificultad consiste en la sofisticación inherente a los modelos estadísticos empleados en el análisis de supervivencia. Aunque herramientas como el modelo de Cox son poderosas, requieren un nivel considerable de conocimiento estadístico y comprensión de los supuestos subyacentes. Esto puede ser una barrera para los académicos menos experimentados, limitando la aplicación del análisis de supervivencia en estudios demográficos más amplios.

Por ende, es esencial que la investigación en análisis de supervivencia se enfoque en mejorar la calidad de los datos disponibles y en desarrollar métodos que sean más accesibles para una variedad de académicos. La integración de tecnologías emergentes, como la inteligencia artificial y el aprendizaje automático, podría ofrecer nuevas perspectivas y enfoques para el análisis de grandes volúmenes de datos demográficos, permitiendo identificar patrones complejos que antes eran difíciles de discernir.

Además, se debería fomentar la colaboración interdisciplinaria entre demógrafos, epidemiólogos, sociólogos y estadísticos para enriquecer el análisis y la interpretación de los datos. Esto no solo podría mejorar la comprensión de los factores que afectan la supervivencia de las poblaciones, sino asimismo contribuir a la formulación de políticas más efectivas que aborden las desigualdades en salud y bienestar.

En tanto, el análisis de supervivencia se presenta como una herramienta invaluable en la demografía, con un potencial significativo para contribuir a la comprensión de los fenómenos poblacionales. Ante los desafíos demográficos y sociales, es fundamental continuar investigando y mejorando estas metodologías para que respondan a las nuevas necesidades de la sociedad.

2.2 Curvas de Kaplan-Meier: Herramientas Esenciales para el Análisis de Datos en Ciencias Sociales

Las curvas de Kaplan-Meier son una herramienta estadística fundamental en el análisis de supervivencia, que permite estimar la probabilidad de que un evento ocurra en el tiempo. Su desarrollo, que se atribuye a Edward L. Kaplan y Paul Meier en 1958, ha revolucionado la forma en que los académicos abordan el análisis de datos longitudinales, especialmente en contextos donde el tiempo hasta la ocurrencia de un evento es de interés.

En términos simples, la curva de Kaplan-Meier es un gráfico que representa la función de supervivencia de un grupo de individuos en el tiempo. Cada punto en la curva refleja la proporción de individuos que han sobrevivido hasta un tiempo específico, considerando tanto los eventos observados como los datos censurados. Este enfoque concede a los académicos visualizar y analizar la duración hasta que un evento de interés, como la muerte, un fracaso o cualquier otro desenlace, ocurre en una población determinada.

La capacidad de manejar datos censurados es una de las principales ventajas de las curvas de Kaplan-Meier. En muchas investigaciones, no todos los sujetos de estudio experimentan el evento de interés durante el periodo de

observación. En particular, en un estudio sobre la duración de la vida de pacientes con una enfermedad crónica, algunos pacientes pueden retirarse del estudio antes de que se produzca el evento. La curva de Kaplan-Meier permite incluir estos individuos en el análisis, ofreciendo una estimación más precisa de la función de supervivencia.

En el ámbito de las ciencias sociales, las curvas de Kaplan-Meier se utilizan para analizar una variedad de fenómenos, desde la duración de la vida en diferentes poblaciones hasta el tiempo hasta un evento significativo en contextos sociales. En efecto, pueden aplicarse en estudios sobre la duración del desempleo, el tiempo hasta el matrimonio o la estabilidad de relaciones interpersonales. Su capacidad para comparar grupos de igual forma las hace útiles en estudios longitudinales, donde se busca entender cómo diferentes factores pueden influir en la probabilidad de que ocurra un evento específico en el espacio temporal.

El análisis de supervivencia es un enfoque estadístico utilizado para examinar el tiempo transcurrido hasta que ocurre un evento de interés, como la muerte, la recuperación de una enfermedad o el fracaso de un producto. En el contexto de las ciencias sociales, este tipo de análisis permite a los académicos estudiar fenómenos que dependen del tiempo, como la duración de matrimonios, la permanencia en el empleo o el tiempo hasta que una persona se involucra en un comportamiento específico (Vega, 2019). La variable principal en el análisis de supervivencia es el "tiempo hasta el evento", que puede estar sujeto a censura, es decir, situaciones en las que no se observa el evento para algunos individuos durante el período de estudio.

La curva de Kaplan-Meier es una herramienta visual que representa la probabilidad de supervivencia temporal. Su cálculo se basa en el principio de

que la probabilidad de supervivencia en un tiempo dado es igual a la probabilidad de supervivencia en el tiempo anterior multiplicada por la probabilidad de no experimentar el evento en ese momento. La fórmula general para calcular la probabilidad de supervivencia es:

$$S(t) = \prod_{i=1}^n \left(1 - \frac{d_i}{n_i}\right)$$

donde $S(t)$ es la probabilidad de supervivencia hasta el tiempo t , d_i es el número de eventos que ocurren en el tiempo i , y n_i es el número de individuos en riesgo justo antes del tiempo i . Esta fórmula transige construir la curva de Kaplan-Meier, que se representa gráficamente mostrando la proporción de individuos que sobreviven a través del tiempo.

La interpretación de la curva de Kaplan-Meier es fundamental para la comprensión de los resultados del análisis de supervivencia. Cada escalón en la curva representa un evento que ha ocurrido, y la altura de la curva en cualquier punto del tiempo indica la probabilidad acumulada de supervivencia hasta ese momento. Una curva que desciende lentamente indica una mayor probabilidad de supervivencia, mientras que una curva que desciende rápidamente sugiere una mayor tasa de eventos adversos. Además, es posible comparar diferentes curvas de Kaplan-Meier para diferentes grupos, lo que admite evaluar si hay diferencias significativas en la supervivencia entre ellos.

Esto es especialmente valioso en estudios sociales donde se busca entender cómo diferentes factores (como el género, la edad o el nivel socioeconómico) pueden influir en la duración de ciertos fenómenos. Las curvas de Kaplan-Meier han encontrado un lugar destacado en el análisis de datos en ciencias sociales, ofreciendo herramientas valiosas para entender

fenómenos complejos relacionados con el tiempo hasta que ocurre un evento de interés

El uso indiscutible de las curvas de Kaplan-Meier radica en estudios demográficos que analizan la mortalidad y la longevidad en diferentes poblaciones. Estas curvas conceden a los académicos visualizar la probabilidad de supervivencia de un grupo específico en periodos determinados, considerando variables como la edad, el género, el estado socioeconómico o la ubicación geográfica. Específicamente, al estudiar la esperanza de vida en distintas comunidades, las curvas de Kaplan-Meier pueden ayudar a identificar desigualdades en la salud y la mortalidad, proporcionando una base sólida para la formulación de políticas de salud pública.

Las curvas de Kaplan-Meier incluso son útiles en el análisis de tiempo hasta el evento en investigaciones sociales, donde el evento puede ser cualquier cosa desde la finalización de un programa educativo hasta la deserción escolar o la entrada en el mercado laboral. Estos análisis consienten a los académicos observar patrones y tendencias en el tiempo que transcurre hasta que ocurren acontecimientos significativos, lo que puede ofrecer información crítica sobre factores que influyen en el éxito o el fracaso en contextos sociales (Errandonea, 2024). En efecto, en estudios sobre la violencia doméstica, las curvas pueden mostrar el tiempo que tarda una víctima en buscar ayuda, lo que puede ayudar a identificar intervenciones efectivas.

Las curvas de Kaplan-Meier son herramientas poderosas para la comparación de grupos en estudios longitudinales. Al permitir la comparación de la supervivencia entre diferentes grupos—lo más importante, aquellos que han recibido distintas intervenciones o aquellos que provienen

de diferentes contextos socioeconómicos—los académicos pueden evaluar la efectividad de programas específicos o políticas sociales. Esta comparación es fundamental para entender cómo diferentes factores pueden influir en la probabilidad de que ocurra un evento, ya sea positivo o negativo, de manera temporal.

En suma, las curvas de Kaplan-Meier ofrecen un marco analítico robusto y flexible que se puede aplicar a una variedad de contextos en las ciencias sociales, permitiendo una exploración más profunda de los factores que afectan la duración de acontecimientos significativos en la vida de las personas y las comunidades. A pesar de su utilidad y popularidad en el análisis de datos, las curvas de Kaplan-Meier presentan varios desafíos y limitaciones que los académicos deben considerar al aplicarlas en las ciencias sociales.

El modelo de Kaplan-Meier se basa en ciertas suposiciones que pueden no cumplirse en todos los contextos. De las suposiciones más críticas, se hace referencia a la tasa de riesgo constante por periodos para cada grupo en el análisis. Esto significa que, con el paso del tiempo, las características que afectan al evento de interés permanecen prácticamente constantes. Aun así, en estudios sociales, las dinámicas pueden variar debido a factores externos, como cambios en políticas sociales o condiciones económicas. Ignorar estas variaciones puede llevar a conclusiones erróneas.

El manejo de datos censurados es otro desafío importante. En estudios de supervivencia, los datos censurados se refieren a casos en los que no se ha observado el evento de interés (por ejemplo, la muerte o la salida de un grupo) antes de que termine el periodo de estudio. Si bien el modelo de Kaplan-Meier está diseñado para manejar datos censurados, la forma en que se gestionan

estos datos puede afectar la interpretación de los resultados. Si un gran número de observaciones está censurado, esto puede limitar la capacidad del análisis para hacer inferencias precisas sobre la población en general.

Definitivamente, la interpretación de los resultados de las curvas de Kaplan-Meier puede ser compleja. Si bien estas curvas proporcionan una representación visual clara de la probabilidad de supervivencia en el tiempo, los académicos deben tener cuidado al comunicar sus hallazgos. Las diferencias observadas entre grupos pueden no ser estadísticamente significativas, y es fundamental contextualizar los resultados dentro del marco teórico y empírico de la investigación social. Además, la sobreinterpretación de las curvas puede llevar a malentendidos sobre las relaciones causales, especialmente si no se considera la influencia de variables confusoras.

Pese a que las curvas de Kaplan-Meier son herramientas valiosas para el análisis de datos en ciencias sociales, es esencial que los académicos sean conscientes de sus limitaciones y desafíos. Una comprensión profunda de estas cuestiones puede contribuir a una interpretación más precisa y a una utilización más efectiva de este método en la investigación social. Las curvas de Kaplan-Meier han demostrado ser una herramienta valiosa en el ámbito de las ciencias sociales, permitiendo a los académicos explorar y visualizar datos relacionados con la duración de acontecimientos críticos y el tiempo hasta la ocurrencia de ciertos fenómenos.

Con el avance del análisis de datos, las curvas de Kaplan-Meier incorporan técnicas estadísticas y computacionales novedosas. La incorporación de modelos más complejos que consideren variables adicionales y la interacción entre factores puede ofrecer una comprensión más

profunda de los fenómenos sociales. Además, la integración de software avanzado y herramientas de visualización puede facilitar la interpretación de resultados, haciendo que los hallazgos sean más accesibles para un público más amplio. La investigación futura podría explorar cómo estas curvas pueden adaptarse a diferentes contextos culturales y sociales, ampliando así su aplicabilidad.

En general, las curvas de Kaplan-Meier no solo son esenciales para el análisis de datos en estudios de salud y epidemiología, sino que su relevancia se extiende a una amplia gama de disciplinas dentro de las ciencias sociales. Proporcionan un marco robusto para entender la dinámica del tiempo y la duración de eventos en poblaciones, permitiendo a los académicos abordar preguntas complejas sobre la supervivencia y el comportamiento humano. El uso de herramientas analíticas es clave para guiar políticas y prácticas que beneficien a la sociedad ante retos sociales cambiantes.

2.3 Prueba de Rango Logarítmico y la Regresión de Cox: Herramientas Esenciales para el Análisis en Ciencias Sociales

La investigación en ciencias sociales enfrenta con frecuencia el desafío de analizar datos complejos que no se ajustan a los supuestos de las técnicas estadísticas tradicionales. En este contexto, la prueba de rango logarítmico y la regresión de Cox emergen como herramientas poderosas que permiten a los académicos abordar estos desafíos de manera eficaz.

La prueba de rango logarítmico es un método estadístico no paramétrico utilizado para comparar distribuciones de datos ordinales. A diferencia de las pruebas paramétricas, que requieren supuestos sobre la normalidad de los datos, la prueba de rango logarítmico se centra en los rangos de los datos, lo que la convierte en una opción adecuada para

situaciones en las que los datos no cumplen con estos supuestos (Ramírez y Polack, 2020). Este enfoque permite a los académicos identificar diferencias significativas entre grupos, siendo especialmente útil en estudios donde las variables no son continuas o donde se manejan categorías ordinales.

La regresión de Cox, conocida como modelo de riesgos proporcionales de Cox, es una técnica estadística utilizada para investigar la relación entre la duración hasta que ocurre un evento y una o varias variables predictoras. Este modelo es particularmente útil en estudios de supervivencia, donde el objetivo es analizar el tiempo que transcurre hasta que se produce un evento de interés, como la muerte, la recaída de una enfermedad o cualquier otro evento relevante en el contexto social. La regresión de Cox no asume que la relación entre el tiempo y las covariables sea lineal, lo que le otorga una gran flexibilidad y la hace adecuada para una amplia variedad de aplicaciones en ciencias sociales.

La combinación de la prueba de rango logarítmico y la regresión de Cox ofrece a los académicos en ciencias sociales un conjunto robusto de herramientas para el análisis de datos. Estas técnicas tienden a revelar ideas sobre cómo se relacionan las variables, pero también pueden ayudar a encontrar patrones y tendencias en los datos que no se detectarían utilizando herramientas más tradicionales. La posibilidad de analizar datos ordinales y modelar el tiempo hasta el evento es una gran ventaja para muchas aplicaciones en este campo, donde la comprensión de relaciones complejas es crucial.

Al emplear estas estrategias, tanto reducen el pseudo del diálogo como buscan proporcionar un mensaje más preciso y fundamentado para su disciplina, y un mejor enfoque de toma de decisiones basado en evidencia. La

prueba de rango logarítmico ha ganado reconocimiento en el ámbito de las ciencias sociales debido a su capacidad para abordar y analizar datos ordinales de manera efectiva.

Entre las aplicaciones más empleadas de la prueba de rango logarítmico es el análisis de datos ordinales. Este tipo de datos, caracterizado por tener una jerarquía o un orden, es común en encuestas y estudios sociales donde se mide la satisfacción, la percepción o la opinión de los individuos. La prueba permite evaluar si existen diferencias significativas entre las distribuciones de dos o más grupos ordinales. En particular, en un estudio sobre la satisfacción laboral, se puede utilizar la prueba de rango logarítmico para comparar las respuestas de empleados de diferentes departamentos y determinar si las diferencias en la satisfacción son estadísticamente significativas.

Además de su utilidad en el análisis de datos ordinales, la prueba de rango logarítmico es eficaz para estudiar la relación entre variables. Permite a los académicos identificar patrones y correlaciones en datos que no cumplen con los supuestos de normalidad requeridos por otras pruebas estadísticas más comunes, como la ANOVA. Conviene destacar, un investigador podría utilizar la prueba de rango logarítmico para analizar la relación entre el nivel de educación y la percepción de la calidad de vida en diferentes grupos socioeconómicos, ayudando a revelar procederes sobre cómo estas variables interactúan en contextos sociales específicos.

Para ilustrar el impacto de la prueba de rango logarítmico en las ciencias sociales, se pueden considerar varios ejemplos de investigaciones recientes. Un estudio podría enfocarse en la evaluación de programas de intervención social, donde se analizan las respuestas de los participantes antes

y después de la intervención. La prueba de rango logarítmico permitiría determinar si las mejoras en las percepciones son significativas y si varían según diferentes características demográficas.

Otro ejemplo sería la investigación sobre actitudes hacia políticas públicas, donde los académicos podrían utilizar la prueba para comparar la percepción de diferentes grupos sobre la efectividad de una política específica. Al analizar los datos de manera ordinal, se pueden obtener conclusiones más robustas y matizadas acerca de la opinión pública en relación a temas críticos.

La prueba de rango logarítmico ofrece un enfoque versátil y poderoso para el análisis de datos en las ciencias sociales, desde la evaluación de la satisfacción hasta el estudio de relaciones complejas entre variables, sus aplicaciones son variadas y contribuyen significativamente a la comprensión de fenómenos sociales. La regresión de Cox se ha convertido en una herramienta esencial para académicos que buscan comprender no solo si ciertos factores tienen un impacto en la ocurrencia de eventos, sino todavía cuándo ocurren esos acontecimientos en relación con otros factores.

Las principales ventajas de la regresión de Cox está en su capacidad para modelar el tiempo hasta que se produce un evento, lo que la convierte en una opción ideal para estudios que implican seguimiento por periodos determinados (Abd ElHafeez et al., 2021). Para ilustrar, en investigaciones sobre la duración del desempleo, los académicos pueden utilizar el modelo de Cox para analizar cómo diferentes variables, como la educación, la edad y la experiencia laboral, afectan el tiempo que una persona permanece desempleada antes de encontrar un nuevo trabajo. Este enfoque proporciona

no solo una visión sobre la probabilidad de que un evento ocurra, sino asimismo sobre el momento en que es más probable que suceda.

La regresión de Cox también se utiliza para comparar diferentes grupos en estudios de supervivencia, lo que es especialmente relevante en contextos donde se buscan diferencias en la duración de eventos entre poblaciones. Así como, un estudio que examine la tasa de supervivencia de pacientes con una enfermedad crónica puede utilizar este modelo para comparar la efectividad de diferentes tratamientos. Al hacerlo, los académicos pueden ajustar por diversas covariables, permitiéndoles obtener estimaciones más precisas sobre cómo las características de los pacientes y los tratamientos influyen en la supervivencia.

La interpretación de los coeficientes en un modelo de regresión de Cox es fundamental para entender los riesgos asociados a diferentes variables; en este modelo, el coeficiente de una variable indica la relación entre esa variable y el riesgo de que ocurra el evento de interés, entonces, un coeficiente positivo sugiere un aumento en el riesgo, mientras que un coeficiente negativo indica una disminución en el riesgo (Córdova y Yurevna, 2019). Esta interpretación es crucial para los académicos sociales, ya que les concede extraer conclusiones sobre cómo factores como el nivel socioeconómico, el acceso a servicios de salud o la educación impactan en el tiempo hasta que ocurre un evento, ofreciendo información valiosa para la formulación de políticas y la intervención social.

En síntesis, la regresión de Cox es una herramienta poderosa en el análisis de datos en las ciencias sociales, proporcionando un marco robusto para explorar las relaciones entre variables y el tiempo hasta que ocurren eventos. Su aplicación en estudios de supervivencia y en el modelado de

tiempos hasta programas admite a los académicos obtener resultados significativos que pueden tener un impacto real en la comprensión y mejora de situaciones sociales.

La prueba de rango logarítmico y la regresión de Cox son herramientas estadísticas poderosas que han transformado el análisis de datos en las ciencias sociales. Estas metodologías consienten abordar la complejidad de los datos ordinales y de supervivencia, facilitando una comprensión más profunda de las relaciones entre variables.

La prueba de rango logarítmico se presenta como una técnica ideal para el análisis de datos que no siguen distribuciones normales, especialmente en contextos donde las variables son ordinales o donde los supuestos de otras pruebas estadísticas más comunes no se cumplen. Su capacidad para identificar patrones y relaciones significativas en conjuntos de datos complejos ha demostrado ser invaluable en investigaciones sociales, desde estudios sobre actitudes hasta análisis de tendencias en poblaciones específicas.

Por otro lado, la regresión de Cox se destaca en el modelado de tiempos hasta un evento, convirtiéndose en una herramienta esencial en estudios de supervivencia. Su enfoque en la comparación de grupos y la interpretación de coeficientes de riesgo ofrece a los académicos una visión clara de cómo diferentes factores pueden influir en la probabilidad de que ocurra un evento de interés en el espacio-tiempo. Este enfoque ha sido fundamental en la evaluación de intervenciones sociales, la salud pública y otros campos donde el tiempo hasta un evento es un factor crítico.

Con el avance de las ciencias sociales, es importante que quienes investigan conozcan y utilicen estas técnicas estadísticas. La capacidad de

utilizar adecuadamente la prueba de rango logarítmico y la regresión de Cox no solo mejorará la calidad de los análisis, sino que también contribuirá a una interpretación más robusta de los resultados, permitiendo una mejor toma de decisiones basada en evidencia.

Ahora bien, la combinación de estas herramientas proporciona una base sólida para el avance del conocimiento en ciencias sociales. Fomentar la capacitación en estas metodologías y su aplicación en investigaciones a corto plazo es un paso decisivo para enfrentar los complejos desafíos que presentan las dinámicas sociales contemporáneas. La integración de técnicas estadísticas avanzadas en estudios sociales no solo amplía el horizonte del análisis, sino que incluso enaltece la comprensión de fenómenos, promoviendo así una sociedad más informada y consciente.

Capítulo III

Modelos Dinámicos Poblacionales en Salud Pública: Aplicaciones, Desafíos y Futuras Perspectivas

3.1 Introducción a los modelos dinámicos poblacionales

Los modelos dinámicos poblacionales son herramientas matemáticas y computacionales que acceden analizar y predecir el comportamiento de las poblaciones en un ciclo estacional. Estas herramientas se basan en la representación de interacciones complejas entre individuos dentro de una población, así como en la influencia de factores ambientales y sociales. La dinámica de estas interacciones puede dar lugar a patrones de crecimiento, disminución y fluctuaciones en la población, así como a la propagación de enfermedades y a las respuestas ante intervenciones de salud pública.

Los modelos dinámicos poblacionales se caracterizan por su capacidad para simular cómo las poblaciones cambian con el tiempo, considerando diversos factores como tasas de natalidad, mortalidad, migración y la interacción entre diferentes grupos dentro de la población. Estos modelos pueden ser deterministas, donde se utilizan ecuaciones matemáticas para predecir resultados específicos, o estocásticos, donde se incorporan elementos de aleatoriedad para reflejar la incertidumbre inherente a los sistemas biológicos y sociales (Rojas y Araya, 2019).

En el ámbito de la salud pública, los modelos dinámicos poblacionales son trascendentales para la comprensión y gestión de enfermedades infecciosas, la planificación de recursos sanitarios y la evaluación de

intervenciones de salud. Al ofrecer una representación visual y cuantitativa de cómo se comportan las poblaciones en respuesta a diferentes factores, estos modelos transigen a los académicos y responsables de políticas de salud tomar decisiones informadas que pueden mejorar la salud de la población. Así como, a través de la simulación de la propagación de enfermedades, se pueden identificar estrategias efectivas para mitigar brotes y optimizar la distribución de recursos limitados.

A través de un análisis exhaustivo, se espera proporcionar un marco que permita entender mejor cómo estos modelos pueden ser utilizados para mejorar la salud pública y contribuir a la formulación de políticas efectivas. Además, se discutirán las perspectivas a corto plazo en la investigación y aplicación de estos modelos, enfatizando la necesidad de una continua evolución en su desarrollo y uso. Los modelos dinámicos poblacionales han demostrado ser herramientas fundamentales en el control de enfermedades, permitiendo a los académicos y responsables de salud pública entender y predecir la propagación de patógenos, evaluar intervenciones y optimizar recursos.

La modelización de la propagación de epidemias es una de las aplicaciones más reconocidas de los modelos dinámicos poblacionales. Estos modelos permiten simular cómo un patógeno se disemina a través de una población, tomando en cuenta factores como la tasa de transmisión, la susceptibilidad de la población y las interacciones sociales. Un ejemplo destacado es el modelo SIR (Susceptibles, Infectados, Recuperados), que divide a la población en tres grupos y utiliza ecuaciones diferenciales para describir el flujo entre estos estados. A través de simulaciones, los académicos pueden prever picos de infección, identificar grupos de riesgo y evaluar el

impacto de diferentes estrategias de control, como el distanciamiento social y el aislamiento de casos.

Los modelos dinámicos también son esenciales para simular intervenciones de salud pública, como campañas de vacunación, implementación de medidas de control de infecciones y programas de educación comunitaria. Al modelar diferentes escenarios, los responsables de la salud pueden anticipar cómo estas intervenciones afectarán la propagación de enfermedades y la salud de la población (Gawande et al., 2025). Hay que hacer notar, un modelo puede simular la introducción de una vacuna en una población específica y predecir la reducción en la incidencia de la enfermedad, lo que ayuda a tomar decisiones informadas sobre la asignación de recursos y el diseño de campañas de vacunación.

A través de la modelización, se pueden evaluar no solo la eficacia de una vacuna en condiciones controladas, sino asimismo su impacto en la población en general. Esto incluye considerar factores como la cobertura de vacunación, la duración de la inmunidad y la aparición de variantes del patógeno. Los modelos aprueban a los académicos analizar cómo diferentes niveles de cobertura de vacunación pueden afectar la propagación de la enfermedad y, por lo tanto, informan las políticas de vacunación a nivel nacional y global.

Las aplicaciones de modelos dinámicos poblacionales en el control de enfermedades son numerosas y variadas. Desde la comprensión de la propagación de epidemias hasta la evaluación de intervenciones sanitarias y la efectividad de vacunas, estos modelos proporcionan información valiosa que puede guiar las decisiones en salud pública y contribuir a la mejora de la salud de la población. Empero, para maximizar su utilidad, es fundamental

continuar desarrollando estos modelos y adaptarlos a las realidades cambiantes de las enfermedades y las poblaciones. La planificación de recursos de salud es fundamental para garantizar que las poblaciones tengan acceso a la atención médica necesaria. En un contexto de creciente demanda y limitación de recursos, los modelos dinámicos poblacionales ofrecen herramientas valiosas para la proyección y gestión de estos recursos.

Los modelos dinámicos poblacionales consienten estimar las necesidades a mediano plazo de atención médica en función de diversos factores, como el crecimiento demográfico, las tendencias epidemiológicas y los cambios en el comportamiento de salud de la población. Estos modelos pueden simular diferentes escenarios, facilitando la anticipación de picos de demanda, como los que pueden ocurrir durante brotes de enfermedades o en períodos de crisis, como desastres naturales. Al entender mejor estas proyecciones, los responsables de la toma de decisiones pueden planificar adecuadamente la infraestructura de salud, asegurando que haya suficiente personal médico, camas de hospital y suministros disponibles para satisfacer las necesidades de la población.

Una vez que se han proyectado las necesidades de atención médica, es esencial optimizar la distribución de los recursos disponibles para maximizar su efectividad. Los modelos dinámicos pueden ayudar a identificar las áreas geográficas y demográficas que requieren atención prioritaria. Lo más importante, mediante el uso de simulaciones, es posible determinar la ubicación más efectiva para nuevos centros de salud o la asignación de recursos a diferentes programas de salud pública. Esta optimización no solo mejora el acceso a la atención médica, sino que también contribuye a una utilización más eficiente de los recursos, reduciendo el desperdicio y mejorando los resultados de salud en la población.

La evaluación económica es un componente crítico en la planificación de recursos de salud. Los modelos dinámicos poblacionales autorizan realizar análisis de costos y beneficios al simular el impacto de diferentes intervenciones de salud pública y la asignación de recursos. Estos análisis ayudan a los responsables de la formulación de políticas a comprender el retorno de la inversión en diferentes programas y a priorizar aquellos que ofrecen el mayor beneficio para la salud a un costo razonable. Al integrar datos sobre costos, eficacia y resultados de salud, los modelos pueden informar decisiones sobre la financiación y la implementación de programas de salud, lo que resulta en un sistema de salud más sostenible y efectivo.

Los modelos dinámicos poblacionales son herramientas esenciales en la planificación de recursos de salud, permitiendo proyecciones precisas, optimización en la distribución de recursos y análisis económicos. Al utilizar estos modelos, los sistemas de salud pueden adaptarse mejor a las necesidades cambiantes de la población, garantizando que se brinde atención adecuada y oportuna a todos (Fiveable, 2025).

Los modelos requieren información precisa y actualizada sobre la población, la incidencia de enfermedades, las tasas de mortalidad y otros factores relevantes. A pesar de, en muchas regiones, especialmente en países en desarrollo, los datos pueden ser escasos, incompletos o sesgados. Esto puede llevar a resultados imprecisos y a decisiones de salud pública que no se basan en la mejor evidencia disponible. Además, la falta de estandarización en la recopilación de datos puede dificultar la comparación entre diferentes estudios y contextos.

La incertidumbre es inherente a cualquier modelo predictivo, y los modelos dinámicos poblacionales no son una excepción. Las proyecciones

realizadas a partir de estos modelos pueden variar significativamente en función de los supuestos utilizados y de las variables incluidas en el análisis. Factores como cambios en el comportamiento humano, la aparición de nuevas variantes de patógenos o la implementación de políticas de salud pública pueden alterar drásticamente los resultados esperados. Esta incertidumbre puede complicar la toma de decisiones, ya que los responsables de la salud pública deben considerar no solo los resultados más probables, sino todavía los escenarios alternativos que podrían surgir.

Cada población presenta características únicas que pueden influir en la efectividad de los modelos dinámicos. Factores sociodemográficos, culturales, económicos y ambientales pueden afectar la propagación de enfermedades y la respuesta a intervenciones de salud pública. Por lo tanto, un modelo que funcione bien en un contexto específico puede no ser aplicable en otro. La adaptación de modelos a las particularidades locales requiere un profundo conocimiento de la población en cuestión y una calibración cuidadosa de los parámetros del modelo. Sin esta adaptación, el riesgo de implementar estrategias ineficaces o incluso perjudiciales aumenta considerablemente.

No obstante, los modelos dinámicos poblacionales son herramientas valiosas en la salud pública, es crucial reconocer y abordar sus desafíos y limitaciones. La calidad de los datos, la incertidumbre en las proyecciones y la necesidad de contextualización son aspectos clave que deben ser considerados para maximizar la efectividad de estos modelos en la toma de decisiones de salud pública.

Estos modelos no solo conceden una comprensión más profunda de la propagación de enfermedades y los factores que influyen en la salud poblacional, sino que también sirven como herramientas clave para la

planificación y optimización de recursos sanitarios. Desde la simulación de intervenciones hasta la evaluación de la efectividad de las vacunas, los modelos dinámicos ofrecen un marco robusto para informar decisiones críticas en salud pública. Sin embargo, incluso hemos identificado desafíos significativos, como la calidad de los datos, la incertidumbre inherente a las proyecciones y la necesidad de adaptar los modelos a contextos locales específicos.

La investigación continua en el campo de los modelos dinámicos poblacionales es esencial para mejorar su precisión y aplicabilidad. El avance tecnológico y el mayor acceso a datos acceden mejorar los modelos para representar con mayor precisión las complejas interacciones humanas y los factores sociales que influyen en la salud. Además, la colaboración entre académicos, responsables de políticas y profesionales de la salud será fundamental para garantizar que los modelos desarrollados sean prácticos y útiles en la toma de decisiones. La formación de redes interdisciplinarias y la promoción de programas de capacitación en modelado poblacional pueden contribuir a un uso más efectivo de estas herramientas en el corto plazo. Para maximizar el impacto de los modelos dinámicos en la salud pública, se recomienda lo siguiente:

- i. Fomentar la inversión en infraestructura de datos que garantice la calidad y la accesibilidad de la información necesaria para el modelado.*
- ii. Promover la adaptación de los modelos a las realidades locales, asegurando que se consideren factores como la cultura, la economía y el sistema de salud en cada contexto.*
- iii. Implementar un enfoque de evaluación continua que permita ajustar los modelos y las intervenciones en función de los resultados observados.*

- iv. Establecer canales de comunicación efectivos entre académicos y responsables políticos para que los modelos y sus hallazgos se traduzcan en acciones concretas y efectivas en la salud pública.*

Los modelos dinámicos poblacionales representan una herramienta poderosa en la lucha por mejorar la salud de las poblaciones. Con una investigación y aplicación adecuadas, tienen el potencial de transformar la manera en que enfrentamos los desafíos en salud pública, promoviendo un enfoque más proactivo y basado en evidencias en la gestión de la salud a nivel global.

3.2 Modelado Dinámico Poblacional: Aplicación de Ecuaciones Diferenciales Ordinarias y Parciales

El estudio de las dinámicas poblacionales es fundamental para comprender cómo cambian las poblaciones de organismos vivos y cómo interactúan con su entorno, en un periodo determinado. En este contexto, las ecuaciones diferenciales emergen como herramientas matemáticas esenciales que permiten modelar este tipo de fenómenos (Miranda, 2014). Estas ecuaciones describen la relación entre una variable y sus tasas de cambio, lo que resulta particularmente útil para representar el crecimiento, la interacción y la regulación de las poblaciones.

Las ecuaciones diferenciales se clasifican en dos grandes categorías: las ecuaciones diferenciales ordinarias (EDO) y las ecuaciones diferenciales parciales (EDP). Mientras que las EDO se centran en funciones de una sola variable, las EDP abordan situaciones en las que las variables dependen de múltiples factores, como el tiempo y el espacio. Esta distinción es crucial, ya que la elección entre una u otra puede influir significativamente en la precisión y aplicabilidad de los modelos desarrollados.

El modelado poblacional a través de ecuaciones diferenciales no solo permite predecir el crecimiento de poblaciones, sino que asimismo facilita el análisis de fenómenos como la competencia entre especies, la depredación, la migración y la propagación de enfermedades. Además, estos modelos pueden integrarse con datos empíricos para ajustar las predicciones y mejorar la comprensión de las dinámicas ecológicas.

Las ecuaciones diferenciales ordinarias (EDO) son herramientas matemáticas fundamentales para describir cómo las cantidades cambian en función de una variable independiente, generalmente el tiempo. En el contexto del modelado poblacional, las EDO consienten representar la dinámica de las poblaciones a través de relaciones que vinculan la tasa de cambio de la población con su tamaño actual. Esto resulta crucial para entender y predecir el comportamiento de las poblaciones bajo diferentes condiciones ambientales y factores externos. Una EDO es una ecuación que involucra funciones desconocidas de una variable independiente y sus derivadas. En términos generales, una EDO de primer orden puede expresarse como:

$$\left[\frac{dy}{dt} = f(t, y) \right]$$

donde (y) es la función desconocida, (t) es la variable independiente (usualmente el tiempo), y $(f(t, y))$ es una función que describe cómo cambia (y) en función de (t) y de (y) mismo. Las EDO pueden clasificarse según su orden (el número máximo de derivadas que aparecen en la ecuación) y su grado (la potencia más alta a la que se eleva la derivada).

Las características de las EDO incluyen su capacidad para ser resueltas mediante métodos analíticos o numéricos, dependiendo de la complejidad de la función (f) y de las condiciones iniciales del problema. Son

especialmente útiles en el modelado poblacional porque acceden describir procesos en los que la tasa de cambio de la población depende directamente de su tamaño. En el ámbito del crecimiento poblacional, uno de los modelos más conocidos es el modelo de crecimiento exponencial, que se puede representar mediante la siguiente EDO:

$$\left[\frac{dN}{dt} = rN \right]$$

donde (N) es la población, (r) es la tasa de crecimiento intrínseca, y (t) es el tiempo. Esta ecuación indica que la tasa de cambio de la población es proporcional al tamaño actual de la población. Al resolver esta EDO, se obtiene la solución:

$$\left[N(t) = N_0 e^{rt} \right]$$

donde (N_0) es la población inicial en $(t = 0)$. Este modelo es aplicable en situaciones donde los recursos son abundantes y las condiciones ambientales son favorables. Aun así, en entornos donde los recursos son limitados, el modelo logístico se convierte en una opción más adecuada. Este se representa como:

$$\left[\frac{dN}{dt} = rN \left(1 - \frac{N}{K}\right) \right]$$

donde (K) es la capacidad de carga del medio ambiente. Este modelo muestra un rápido crecimiento poblacional al inicio, que se ralentiza y se estabiliza al acercarse a la capacidad de carga. Las EDO también se utilizan en modelos más complejos dentro de la ecología, como la predación y la competencia entre especies. Un ejemplo clásico es el modelo de Lotka-Volterra, que describe la dinámica de poblaciones de depredadores y presas. Las EDO en este modelo son:

Para la presa:

$$\left[\frac{dX}{dt} = \alpha X - \beta XY \right]$$

Para el depredador:

$$\left[\frac{dY}{dt} = \delta XY - \gamma Y \right]$$

donde (X) representa la población de presas, (Y) la población de depredadores, y $(\alpha, \beta, \delta, \gamma)$ son parámetros que describen las tasas de crecimiento y muerte. Este sistema de EDO permite estudiar cómo las interacciones entre dos especies afectan sus poblaciones en un plazo determinado.

Las EDO son fundamentales en el modelado dinámico poblacional, proporcionando una base sólida para entender y predecir las fluctuaciones en las poblaciones en función del tiempo. Su aplicabilidad en diversos contextos ecológicos demuestra su versatilidad y relevancia en el estudio de la biología y la conservación.

Las Ecuaciones Diferenciales Parciales (EDP) son herramientas matemáticas fundamentales en el análisis de sistemas complejos donde las variables dependen de múltiples dimensiones. A diferencia de las Ecuaciones Diferenciales Ordinarias (EDO), que involucran derivadas con respecto a una sola variable independiente, las EDP describen fenómenos en los que las funciones dependen de varias variables independientes, lo que las hace particularmente útiles en el modelado de dinámicas poblacionales que cambian en el tiempo y el espacio (Mejía et al., 2025).

Una EDP es una ecuación que relaciona una función desconocida de múltiples variables y sus derivadas parciales. Estas ecuaciones son esenciales para describir fenómenos que varían no solo en el tiempo, sino también en el espacio, como la dispersión de una población a través de un hábitat. Las

propiedades de las EDP incluyen su linealidad, homogeneidad y el orden de las derivadas parciales involucradas, lo que determina la complejidad del sistema a modelar. Dado que las EDP pueden ser de distintos tipos (elípticas, hiperbólicas y parabólicas), la elección del tipo adecuado es crucial para la precisión y utilidad del modelo.

Las EDP son especialmente valiosas en el estudio de dinámicas poblacionales porque permiten modelar situaciones donde las interacciones entre individuos y su entorno son complejas. Un ejemplo significativo es el modelo de difusión de una población en un área geográfica, donde se pueden observar fenómenos como la migración y la competencia por recursos. Además, las EDP pueden ser utilizadas para modelar la propagación de enfermedades en poblaciones, donde la tasa de infección puede depender no solo del tiempo, sino también de la ubicación espacial de los individuos.

Otro campo importante es el estudio de la dinámica de poblaciones en ecosistemas que presentan variaciones espaciales y temporales, como en el caso de especies en peligro de extinción o ecosistemas que responden a cambios climáticos. La modelización de estas dinámicas a menudo requiere de EDP para captar adecuadamente las interacciones entre las especies y su entorno.

La resolución de EDP puede ser un desafío, dado que no siempre se dispone de soluciones analíticas. Ahora bien, existen métodos numéricos que conceden abordar estas ecuaciones de manera efectiva. Técnicas como el método de elementos finitos, el método de diferencias finitas y aproximaciones espectrales son comúnmente utilizadas para obtener soluciones aproximadas en situaciones donde las soluciones exactas son difíciles de encontrar.

En el contexto de modelos ecológicos, la implementación de estas técnicas numéricas ha permitido a los académicos simular y predecir el comportamiento de poblaciones bajo diferentes escenarios, como cambios en el hábitat, introducción de especies invasoras o efectos de la conservación. Este enfoque ha llevado a una comprensión más profunda de las dinámicas poblacionales y ha facilitado la toma de decisiones informadas en la gestión de recursos naturales y conservación de la biodiversidad.

En síntesis, las EDP son herramientas poderosas en el modelado de dinámicas poblacionales, capaces de capturar la complejidad de las interacciones en entornos multidimensionales. Su aplicación efectiva consiente no solo entender mejor las dinámicas actuales, sino todavía anticipar futuros cambios en las poblaciones y sus hábitats. La modelación de dinámicas poblacionales es un campo complejo que puede abordarse desde diferentes perspectivas matemáticas. En este sentido, las Ecuaciones Diferenciales Ordinarias (EDO) y las Ecuaciones Diferenciales Parciales (EDP) ofrecen herramientas distintas, cada una con sus propias ventajas y desventajas.

Las EDO son particularmente útiles en modelos donde se considera una única variable independiente, como el tiempo, esto las hace idóneas para representar sistemas poblacionales en los que se busca entender el crecimiento o decrecimiento de una población en función del tiempo. Entre las principales ventajas de las EDO está su menor complejidad matemática, lo que autoriza obtener soluciones analíticas o numéricas con mayor facilidad. Sin embargo, su principal desventaja es la limitación de su aplicación a fenómenos que no dependen de múltiples variables independientes o de la interacción espacial (Contreras y Torres, 2016).

Por otro lado, las EDP son capaces de modelar situaciones donde las dinámicas poblacionales están influenciadas por múltiples variables, como el espacio y el tiempo. Esto las convierte en una herramienta poderosa para comprender fenómenos como la dispersión de especies, la competencia entre poblaciones o la propagación de enfermedades. Sin embargo, la complejidad de las EDP encima puede ser una desventaja significativa; su resolución suele requerir técnicas avanzadas y, en muchos casos, solo se puede obtener soluciones numéricas.

Existen situaciones específicas en las que el uso de EDO es más apropiado que el de EDP. Conviene destacar, en modelos sencillos de crecimiento poblacional, como el modelo de Malthus o el modelo logístico, las EDO proporcionan una representación clara y efectiva del crecimiento en función del tiempo. Estos modelos son útiles en contextos donde se puede asumir que la población es homogénea y que se encuentra en un entorno constante, sin variaciones espaciales significativas. En tales casos, las EDO permiten realizar predicciones más directas y comprensibles sobre el comportamiento de la población en función del tiempo.

En contraste, las EDP son más efectivas en situaciones que implican procesos espaciales o interacciones complejas entre diferentes poblaciones. Para ilustrar, en el estudio de la migración de especies, donde las dinámicas poblacionales están influenciadas por la distribución geográfica y las interacciones con otras especies en distintos hábitats, las EDP admiten modelar estas variaciones de forma más precisa. Otro caso relevante es el modelado de enfermedades infecciosas, donde la propagación puede depender tanto del tiempo como de la ubicación geográfica de los individuos. En estos escenarios, las EDP proporcionan un marco más adecuado para capturar la complejidad del fenómeno.

La elección entre EDO y EDP en el contexto del modelado poblacional depende de la naturaleza del fenómeno que se desea estudiar. Mientras que las EDO ofrecen simplicidad y claridad en contextos unidimensionales, las EDP destacan en situaciones que requieren una comprensión más profunda de las interacciones espaciales y temporales. La capacidad de combinar ambos enfoques puede ser, a menudo, la clave para obtener modelos más robustos y representativos de las dinámicas poblacionales en la naturaleza.

El modelado dinámico poblacional es una herramienta fundamental en la ecología y en las ciencias biológicas en general, ya que permite comprender y predecir el comportamiento de las poblaciones en ciclos. Las ecuaciones diferenciales, tanto ordinarias como parciales, ofrecen un marco matemático robusto para captar la complejidad de las interacciones biológicas y ambientales que influyen en el crecimiento y la dinámica de las poblaciones.

Las Ecuaciones Diferenciales Ordinarias (EDO) se han demostrado particularmente eficaces para modelar sistemas donde la interacción entre las poblaciones se limita a cambios en el tiempo, como en el caso del crecimiento exponencial o logístico de una especie en un entorno donde no hay variaciones espaciales significativas. Su simplicidad en términos de resolución y su capacidad para ofrecer predicciones claras las convierte en una opción preferida en muchas aplicaciones iniciales de modelado poblacional.

Por otro lado, las Ecuaciones Diferenciales Parciales (EDP) son indispensables cuando se considera la variabilidad espacial en la dinámica poblacional. Estas ecuaciones permiten no solo modelar el crecimiento poblacional a través del tiempo, sino incluso capturar la dispersión, la interacción entre diferentes especies y la influencia de factores ambientales que varían en el espacio. En situaciones donde las poblaciones no están

distribuidas uniformemente o donde las interacciones entre individuos y su entorno son complejas, las EDP son la herramienta más adecuada.

La elección entre EDO y EDP depende del contexto específico del problema de modelado. Mientras que las EDO son ideales para modelos más simples y directos, las EDP ofrecen la flexibilidad necesaria para abordar escenarios más complejos y realistas. La comprensión de las ventajas y desventajas de cada tipo de ecuación consiente a los académicos y ecologistas seleccionar el enfoque más eficaz para sus estudios (Tenorio et al., 2013). El avance científico y las nuevas técnicas aseguran que las ecuaciones diferenciales sigan siendo clave para modelar dinámicas poblacionales y enfrentar los retos de la biología y conservación.

3.3 Sistemas Dinámicos en las Ciencias Sociales: Modelos, Análisis y Desafíos

Los sistemas dinámicos son estructuras complejas que evolucionan en el tiempo, caracterizadas por la interacción de múltiples componentes que pueden influirse mutuamente. En el contexto de las ciencias sociales, estos sistemas condescienden modelar y comprender fenómenos como el comportamiento humano, las relaciones sociales y la dinámica de grupos. La creciente complejidad social exige herramientas para entender sus dinámicas internas.

Desde una perspectiva matemática y computacional, los sistemas dinámicos se estudian a través de ecuaciones que representan las relaciones entre las variables involucradas. Estas ecuaciones pueden ser lineales o no lineales, y su análisis proporciona información valiosa sobre cómo los cambios en un componente del sistema pueden afectar a otros, así como al sistema en su conjunto. Esta capacidad de modelar interacciones complejas es

particularmente relevante en las ciencias sociales, donde los fenómenos no suelen ser aislados, sino que están imbricados en una red de influencias recíprocas.

Un aspecto fundamental de los sistemas dinámicos es su naturaleza temporal; es decir, que no solo se estudian los estados de un sistema en un momento dado, sino que también se considera cómo esos estados cambian con el tiempo. Esto permite explorar patrones de comportamiento, ciclos de retroalimentación y otras dinámicas que son esenciales para entender fenómenos sociales como la difusión de innovaciones, la propagación de movimientos sociales y las dinámicas económicas.

A través de ejemplos específicos en economía y sociología, se ilustrará cómo estos modelos pueden proporcionar una visión más profunda de la realidad social y ayudar a abordar problemas complejos. Así, se establecerá un marco de referencia para comprender la dinámica de sistemas en contextos sociales, así como sus implicaciones y desafíos en el análisis y la toma de decisiones.

Los modelos de sistemas dinámicos son herramientas fundamentales en el estudio de fenómenos complejos en las ciencias sociales. Estos modelos autorizan representar y comprender cómo varían las interacciones entre distintos elementos a lo largo del tiempo. Un modelo de sistema dinámico es una representación matemática que describe cómo las variables de un sistema interactúan y cambian con el tiempo. Estas representaciones pueden ser tanto continuas, utilizando ecuaciones diferenciales, como discretas, a través de ecuaciones en diferencias. Las características más destacadas de estos modelos incluyen:

- i. *Temporalidad*: Los modelos se centran en el cambio temporal, lo que transige observar cómo las decisiones y programas pasados influyen en el presente.
- ii. *Interconexión*: Los modelos reflejan la interdependencia entre diferentes variables, subrayando que un cambio en una parte del sistema puede tener efectos en otras.
- iii. *No linealidad*: Muchos sistemas sociales son inherentemente no lineales, lo que significa que las relaciones entre variables no siempre son proporcionales o predecibles.

En economía, los modelos de sistemas dinámicos han sido ampliamente utilizados para analizar y prever comportamientos de mercado, ciclos económicos y el impacto de políticas. Por ejemplo:

- **Modelo de Solow**: Este modelo de crecimiento económico ilustra cómo la acumulación de capital, el crecimiento de la población y el progreso tecnológico influyen en el crecimiento a largo plazo de una economía. A través de ecuaciones diferenciales, se puede analizar cómo las variaciones en la tasa de ahorro afectan el nivel de producción y el consumo en series temporales.

- **Modelos de equilibrio general**: Estos modelos analizan cómo diferentes mercados interactúan entre sí, considerando la oferta y la demanda en múltiples sectores. Permiten evaluar el impacto de cambios en políticas fiscales o monetarias y cómo estos afectan a toda la economía.

En sociología, los modelos de sistemas dinámicos se utilizan para entender fenómenos como la difusión de innovaciones, el comportamiento colectivo y la dinámica de grupos sociales. Algunos ejemplos son:

- **Modelo de difusión**: Este tipo de modelo se utiliza para estudiar cómo las nuevas ideas o tecnologías se propagan a través de una población. Los

modelos pueden simular la adopción de innovaciones, teniendo en cuenta factores como la influencia social y la comunicación entre individuos.

- **Modelos de dinámica de poblaciones:** Estos modelos analizan cómo las tasas de natalidad, mortalidad y migración afectan la estructura demográfica de una sociedad. Acceden prever cambios en la población y su impacto en la economía y en la política social.

Los modelos de sistemas dinámicos son esenciales para el análisis de fenómenos complejos en las ciencias sociales, proporcionando un marco teórico que facilita la comprensión de las interacciones y cambios por periodos determinados. El análisis de la dinámica de sistemas es una herramienta crucial para comprender cómo interactúan diferentes variables en contextos sociales, económicos y políticos. A través de este análisis, se pueden explorar las relaciones complejas y no lineales que caracterizan a las dinámicas sociales, lo que consiente a los académicos y tomadores de decisiones obtener una visión más clara de los fenómenos en estudio.

Los métodos de análisis cuantitativo son esenciales para el estudio de sistemas dinámicos, ya que permiten medir y evaluar las relaciones entre variables a través de datos numéricos. Estos métodos incluyen el uso de ecuaciones diferenciales, modelos estadísticos y análisis de series temporales. En el contexto de las ciencias sociales, el análisis cuantitativo puede ayudar a identificar tendencias, patrones y correlaciones en datos sociales, económicos y demográficos. Hay que hacer notar, mediante el uso de modelos econométricos, los académicos pueden examinar cómo las políticas económicas afectan el crecimiento del empleo o el ingreso de diferentes grupos sociales. La capacidad de estos métodos para manejar grandes

volúmenes de datos y realizar predicciones es fundamental para el desarrollo de modelos precisos y útiles.

La simulación es otra herramienta poderosa en el análisis de la dinámica de sistemas y asiente a los académicos crear modelos computacionales que imitan el comportamiento de sistemas reales por periodos. Por lo que, es posible explorar cómo diferentes variables interactúan y cómo los cambios en una parte del sistema pueden afectar al todo (Izquierdo et al., 2008). Existen diversas plataformas y software que facilitan la simulación de sistemas complejos, como Vensim o Stella. Estas herramientas son particularmente útiles en ciencias sociales, donde los sistemas a menudo son intrínsecamente complejos y están sujetos a la influencia de múltiples factores. Para ilustrar, en el ámbito de la sociología, se pueden simular interacciones sociales para entender fenómenos como la difusión de innovaciones o la propagación de movimientos sociales.

La interpretación de los resultados obtenidos a través del análisis y la simulación es un paso crítico en el estudio de sistemas dinámicos; no solo se trata de observar patrones y tendencias, sino de comprender qué significan en el contexto social, económico o político en el que se inscriben. Es fundamental que los académicos sean cuidadosos al interpretar los resultados, ya que los modelos son simplificaciones de la realidad y pueden no capturar todas las complejidades del sistema observado. Además, es importante comunicar los hallazgos de manera clara y accesible, de modo que los tomadores de decisiones y otros actores relevantes puedan utilizar la información de manera efectiva. La colaboración entre académicos, responsables de políticas y la sociedad civil puede enriquecer el proceso interpretativo y fomentar la aplicación práctica de los resultados.

El análisis de la dinámica de sistemas proporciona herramientas valiosas para entender y abordar problemas complejos en las ciencias sociales. A través de métodos cuantitativos, simulaciones y una interpretación cuidadosa de los resultados, los académicos pueden ofrecer estrategias significativas que contribuyan a la formulación de políticas más efectivas y a la comprensión de los fenómenos sociales en toda su complejidad. El estudio de los sistemas dinámicos en las ciencias sociales ofrece un marco valioso para entender la complejidad de las interacciones humanas y sociales. Empero, este enfoque también presenta diversas implicaciones y desafíos que deben ser considerados por los académicos y tomadores de decisiones.

Los fenómenos sociales son inherentemente complejos y multifacéticos, lo que puede dificultar la creación de modelos que capturen adecuadamente todas las variables y relaciones pertinentes. La selección de parámetros y la calibración de modelos son procesos que requieren un profundo entendimiento del sistema en estudio. Además, los modelos pueden volverse obsoletos rápidamente debido a cambios en el contexto social, lo que plantea la necesidad de actualizaciones continuas y de una evaluación crítica de su validez en un tiempo determinado.

Los modelos de sistemas dinámicos pueden influir significativamente en la toma de decisiones a nivel político, económico y social. Sin embargo, la interpretación de los resultados puede ser problemática. Los decisores pueden verse tentados a confiar excesivamente en las predicciones de un modelo sin considerar sus limitaciones. Esto puede llevar a la implementación de políticas ineficaces o incluso perjudiciales. Por lo tanto, es crucial que los responsables de la formulación de políticas comprendan no solo los resultados de los modelos, sino también las suposiciones y las incertidumbres

que los acompañan. La integración de la experiencia cualitativa con el análisis cuantitativo puede ayudar a mitigar este riesgo.

El avance de los sistemas dinámicos en ciencias sociales abre nuevas áreas de investigación para comprender mejor las dinámicas sociales. En efecto, la incorporación de herramientas de inteligencia artificial y aprendizaje automático en la modelación de sistemas dinámicos promete mejorar la capacidad predictiva y la adaptabilidad de los modelos. Además, la exploración de la intersección entre sistemas dinámicos y otros enfoques interdisciplinarios, como la teoría de redes y la dinámica de sistemas complejos, puede ofrecer nuevas perspectivas sobre cómo entender y abordar problemas sociales contemporáneos.

Si bien el uso de sistemas dinámicos en las ciencias sociales presenta numerosos beneficios, encima plantea desafíos significativos que requieren atención cuidadosa. La capacidad de modelar y analizar dinámicas complejas puede transformar la forma en que entendemos la sociedad, siempre y cuando se reconozcan y se aborden las limitaciones inherentes a este enfoque.

Los sistemas dinámicos ofrecen un marco robusto y versátil para comprender y analizar fenómenos complejos en las ciencias sociales. A través de la formalización de interacciones y la representación de variables en modelos matemáticos, se autoriza una exploración más profunda de dinámicas sociales, económicas y comportamentales. Los modelos de sistemas dinámicos no solo contribuyen a la interpretación de datos históricos, sino que también facilitan la simulación de escenarios a mediano plazo, lo que resulta invaluable en la formulación de políticas y en la toma de decisiones estratégicas (Ramírez y Juárez, 2009).

Ahora bien, como se ha discutido, el uso de estos modelos no está exento de desafíos. La complejidad inherente a los sistemas sociales, la disponibilidad y calidad de los datos, así como la necesidad de validar los modelos ante la incertidumbre, representan obstáculos significativos. Además, la interpretación de los resultados requiere un enfoque crítico y multidisciplinario, dado que las soluciones propuestas a menudo tienen implicaciones éticas y sociales que no pueden ser pasadas por alto.

Es evidente que la investigación en este campo debe centrarse en mejorar la precisión y la aplicabilidad de los modelos de sistemas dinámicos. La integración de técnicas avanzadas de análisis de datos, como el aprendizaje automático y la inteligencia artificial, podría abrir nuevas vías para abordar problemas sociales complejos. Asimismo, fomentar la colaboración entre disciplinas permitirá una comprensión más holística de las dinámicas en juego.

En general, los sistemas dinámicos en las ciencias sociales no solo son una herramienta poderosa para el análisis y la predicción, sino incluso un punto de partida para un diálogo más amplio sobre cómo interactúan los diversos factores en nuestras sociedades. La continua exploración y refinamiento de estos modelos es esencial para enfrentar y construir un escenario más informado y sostenible.

Capítulo IV

Modelos Descriptivos, Inferenciales y Predictivos en las Ciencias Sociales: Una Guía para la Investigación y la Toma de Decisiones

4.1 Introducción a los modelos en ciencias sociales

En el campo de las ciencias sociales, los modelos desempeñan un papel fundamental en la comprensión y análisis de fenómenos complejos que afectan a las sociedades. Funcionan como representaciones simplificadas de la realidad, permitiendo a los académicos captar dinámicas que, de otro modo, serían difíciles de observar. La creación y utilización de modelos es esencial para abordar cuestiones sociales, ya que facilitan la formulación de hipótesis, la identificación de patrones y la predicción de tendencias a mediano plazo.

La importancia de los modelos en la investigación radica en su capacidad para traducir situaciones sociales complejas en términos más manejables. Al hacerlo, ofrecen un marco para la interpretación de datos y la construcción de teorías. Aun así, esta simplificación no está exenta de desafíos; los modelos pueden influir en la manera en que se entienden y abordan los problemas sociales. Por lo tanto, es crucial que los académicos sean conscientes de las limitaciones inherentes a cada tipo de modelo.

A través de un análisis detallado de cada uno de estos enfoques, se pretende proporcionar una visión integral de cómo los modelos contribuyen a la investigación y al conocimiento en este ámbito. Además, se discutirán las

aplicaciones prácticas de estos modelos, así como sus respectivas limitaciones y posibilidades de mejora.

Los modelos descriptivos en ciencias sociales son herramientas que permiten representar y resumir características y patrones observables de un fenómeno social, sin buscar establecer relaciones causales. Su principal objetivo es proporcionar un entendimiento claro de la realidad a través de la recolección y análisis de datos (Canales, 2006). Estos modelos se centran en la descripción de los hechos tal como se presentan, facilitando la identificación de tendencias, patrones en grupos o poblaciones.

Entre las características de los modelos descriptivos, se destacan su capacidad para organizar y presentar información de manera clara y comprensible, así como su utilidad para generar hipótesis y preguntas de investigación. No pretenden hacer predicciones ni inferencias más allá de lo que los datos observados pueden revelar, lo que los convierte en una base esencial para cualquier análisis más profundo.

Un ejemplo clásico de un modelo descriptivo es el uso de estadísticas demográficas para describir la composición de una población en términos de edad, género, nivel educativo y estado civil. Estos datos pueden ser presentados mediante gráficos, tablas y mapas, permitiendo a los académicos visualizar y comunicar la información de manera efectiva.

Otro ejemplo es el análisis de encuestas de opinión pública, donde se recopilan datos sobre las actitudes y preferencias de los ciudadanos respecto a diversos temas, como la política, la economía o la salud. Los resultados de estas encuestas se presentan en forma de porcentajes y promedios, lo que consiente una interpretación rápida de las tendencias en la opinión pública.

Además, los modelos descriptivos todavía se aplican en estudios de comportamiento del consumidor, donde se analizan patrones de compra y preferencias de los clientes en función de variables demográficas y socioeconómicas. Esto ayuda a las empresas y organizaciones a comprender mejor a su audiencia y a adaptar sus estrategias de marketing.

A pesar de su utilidad, los modelos descriptivos presentan ciertas limitaciones, este es, que no condescienden establecer relaciones de causa y efecto, lo que significa que no pueden explicar por qué ocurren ciertos fenómenos. Esto puede llevar a interpretaciones erróneas si se asume que la descripción de un fenómeno implica necesariamente un entendimiento de sus causas subyacentes.

Además, los modelos descriptivos dependen en gran medida de la calidad y la representatividad de los datos utilizados. Si los datos son incompletos o sesgados, las conclusiones derivadas de estos modelos pueden ser engañosas. Por último, es importante señalar que los modelos descriptivos pueden limitarse a un contexto específico, lo que podría dificultar la generalización de los hallazgos a otras poblaciones o situaciones.

En síntesis, los modelos descriptivos son fundamentales para la investigación en ciencias sociales, ya que permiten una comprensión inicial y detallada de los fenómenos sociales. A pesar de, es crucial combinarlos con otros enfoques, como los modelos inferenciales y predictivos, para obtener una visión más completa y robusta de la realidad social.

Los modelos inferenciales son herramientas estadísticas que admiten a los académicos hacer generalizaciones sobre una población a partir de una muestra representativa. Estos modelos se basan en la teoría de la probabilidad y buscan establecer relaciones y patrones entre variables, lo que permite la

formulación de hipótesis y la validación de teorías existentes. A diferencia de los modelos descriptivos, que simplemente describen características observadas, los modelos inferenciales asientan hacer afirmaciones más robustas y fundamentadas sobre la dinámica social, lo cual es fundamental en el ámbito de las ciencias sociales (Veiga et al., 2020).

Existen diversas técnicas estadísticas que se enmarcan dentro de los modelos inferenciales. Entre las más comunes se encuentran la regresión lineal y múltiple, que autorizan explorar la relación entre una variable dependiente y una o más variables independientes. Otras técnicas incluyen el análisis de varianza (ANOVA), que se utiliza para comparar las medias de tres o más grupos, y la prueba de chi-cuadrado, que evalúa la asociación entre variables categóricas. La selección de la técnica adecuada depende de la naturaleza de los datos y de las preguntas de investigación planteadas.

El uso de intervalos de confianza y pruebas de hipótesis es fundamental en este contexto, ya que consiente a los académicos determinar la significancia estadística de los resultados obtenidos y, por ende, la validez de las inferencias realizadas. Estos métodos ayudan a mitigar el riesgo de error al generalizar los hallazgos de la muestra a la población en su conjunto.

Los modelos inferenciales tienen aplicaciones amplias y variadas en la investigación social. Se utilizan, conviene destacar, en estudios de opinión pública para inferir las preferencias de un electorado a partir de encuestas; en investigaciones sobre el impacto de políticas sociales, donde se busca evaluar los efectos de una intervención en una población específica; o en estudios de comportamiento, donde se exploran las relaciones entre variables sociodemográficas y actitudes.

La capacidad de estos modelos para proporcionar conclusiones que trascienden los datos observados es especialmente valiosa en un campo donde las dinámicas complejas a menudo requieren un análisis profundo y riguroso. Sin embargo, es crucial que los académicos reconozcan las limitaciones inherentes a los modelos inferenciales, como la posibilidad de sesgos en la selección de muestras o la falta de control sobre variables externas, lo que puede afectar la validez de las inferencias realizadas.

El uso adecuado de modelos inferenciales, combinado con un diseño de investigación sólido y una interpretación crítica de los resultados, permite a los científicos sociales contribuir con conocimientos valiosos que informen la práctica y la política en el ámbito social.

Los modelos predictivos son herramientas analíticas que se utilizan para anticipar resultados basándose en patrones identificados a partir de datos históricos. Estos modelos se fundamentan en la premisa de que los sucesos pasados y las tendencias observadas pueden ofrecer información valiosa para prever conductas en el tiempo. En las ciencias sociales, los modelos predictivos permiten a los académicos y responsables de políticas comprender cómo variables específicas pueden influir en fenómenos sociales, económicos o culturales.

Entre las características más destacadas de los modelos predictivos es su capacidad para manejar grandes volúmenes de datos. Con el avance de la tecnología y el desarrollo de algoritmos de aprendizaje automático, estos modelos pueden procesar información compleja y extraer patrones que, de otro modo, podrían pasar desapercibidos. Además, suelen incluir múltiples variables, lo que les permite capturar la interacción entre diferentes factores y proporcionar predicciones más precisas. Existen diversas herramientas y

algoritmos que se emplean en la construcción de modelos predictivos. Entre los más comunes se encuentran:

- i. *Regresión logística*: Este método se utiliza principalmente para predecir resultados binarios y es particularmente útil en estudios sociales donde se busca determinar la probabilidad de que ocurra un evento específico, como la participación electoral o la adopción de comportamientos saludables (Reyes et al., 2007).
- ii. *Árboles de decisión*: Esta técnica permite dividir los datos en segmentos basándose en decisiones sucesivas, lo que facilita la interpretación de los resultados y la identificación de las variables más relevantes en el proceso de toma de decisiones.
- iii. *Redes neuronales*: Inspiradas en el funcionamiento del cerebro humano, las redes neuronales son especialmente eficaces para manejar datos no lineales y complejos. Se utilizan en aplicaciones como el análisis de sentimientos en redes sociales o la identificación de patrones de comportamiento en grandes conjuntos de datos.
- iv. *Máquinas de soporte vectorial (SVM)*: Este algoritmo es útil para clasificar datos y encontrar la mejor línea o hiperplano que separe diferentes clases de información, siendo aplicable en diversos contextos sociales, como la segmentación de mercados o la identificación de grupos de riesgo (Murillo, 2021).

La implementación de modelos predictivos en las ciencias sociales ha transformado la forma en que se toman decisiones, estos modelos acceden a los académicos y responsables de políticas anticipar problemas y oportunidades, facilitando la creación de intervenciones más efectivas y basadas en evidencia. Específicamente, en el ámbito de la salud pública, los

modelos predictivos pueden ayudar a predecir brotes de enfermedades, permitiendo a las autoridades implementar medidas preventivas a tiempo.

Asimismo, en el campo de la educación, estos modelos pueden identificar factores que influyen en el rendimiento académico de los estudiantes, permitiendo a las instituciones desarrollar estrategias de apoyo personalizado. Sin embargo, es importante tener en cuenta que las predicciones no son infalibles y deben interpretarse con cautela. La calidad de los datos y la elección del modelo adecuado son trascendentales para obtener resultados fiables.

Los modelos predictivos son una herramienta poderosa en las ciencias sociales, ofreciendo una forma de anticipar y gestionar comportamientos y tendencias. Su utilización consciente y fundamentada puede marcar la diferencia en la formulación de políticas y la implementación de estrategias sociales efectivas.

Cada uno de estos enfoques ofrece herramientas únicas que admiten a los académicos comprender mejor los fenómenos sociales y formular hipótesis fundamentadas. Los modelos descriptivos nos proporcionan una visión clara y detallada de los datos, mientras que los modelos inferenciales nos consienten hacer generalizaciones y estimaciones basadas en muestras. Por otro lado, los modelos predictivos, al incorporar técnicas avanzadas de análisis de datos y algoritmos, ofrecen la posibilidad de anticipar procederes en contextos sociales complejos. Ahora bien, también hemos identificado las limitaciones inherentes a cada tipo de modelo, lo que subraya la necesidad de un enfoque crítico y reflexivo en su aplicación.

En primer lugar, la integración de diferentes tipos de modelos puede enriquecer el análisis y proporcionar una comprensión más matizada de los

fenómenos sociales. Al combinar modelos descriptivos con inferenciales y predictivos, los académicos pueden abordar preguntas complejas y ofrecer respuestas más robustas y fundamentadas. Además, la creciente disponibilidad de datos y herramientas tecnológicas abre nuevas oportunidades para la investigación social, permitiendo la implementación de modelos más sofisticados y adaptativos que reflejen la dinámica cambiante de la sociedad.

Para avanzar en el campo de las ciencias sociales, es esencial fomentar un enfoque interdisciplinario que combine teorías y métodos de diversas disciplinas. Se recomienda que los nacientes estudios no solo se centren en el desarrollo de nuevos modelos, sino encima en la evaluación crítica de los existentes, considerando su aplicabilidad y limitaciones en contextos específicos. Asimismo, es fundamental que los académicos se mantengan actualizados sobre los avances en tecnologías de datos y análisis, aprovechando herramientas emergentes como la inteligencia artificial y el aprendizaje automático para mejorar la precisión y la efectividad de sus modelos. Entonces, la colaboración entre académicos, profesionales y responsables de políticas es clave para garantizar que los hallazgos de la investigación se traduzcan en decisiones informadas que beneficien a la sociedad en su conjunto.

Los modelos descriptivos, inferenciales y predictivos son pilares esenciales en el estudio de las ciencias sociales. Su correcta aplicación y desarrollo son trascendentales para entender y abordar los desafíos sociales contemporáneos, lo que requiere un compromiso continuo con la investigación rigurosa y la innovación metodológica.

4.2 Evaluación de la Normalidad en Ciencias Sociales: Un Análisis de la Prueba de Shapiro-Wilk y Otras Metodologías

En el ámbito de la estadística, la normalidad se refiere a la distribución de los datos en una forma que se asemeja a la famosa curva de campana, conocida como la distribución normal o gaussiana. Este concepto es fundamental porque muchas técnicas estadísticas, como las pruebas t y el análisis de varianza (ANOVA), asumen que los datos siguen una distribución normal. Cuando esta suposición no se cumple, los resultados obtenidos pueden ser engañosos y conducir a conclusiones erróneas. Por lo tanto, determinar si un conjunto de datos se ajusta a una distribución normal es un paso esencial en cualquier análisis estadístico.

La relevancia de las pruebas de normalidad se vuelve aún más crítica en la investigación social, donde los datos a menudo se recogen a partir de encuestas, cuestionarios y observaciones. En este campo, la variabilidad y la heterogeneidad de los datos pueden ser amplias, lo que hace que las suposiciones sobre la normalidad sean especialmente desafiantes. Hay que hacer notar, en estudios sobre actitudes, características demográficas, los académicos deben asegurarse de que los métodos estadísticos que utilizan sean apropiados para la distribución de sus datos. De lo contrario, las inferencias que se realicen pueden no reflejar la realidad social que se intenta analizar.

La prueba de Shapiro-Wilk es una de las herramientas más utilizadas para evaluar la normalidad de un conjunto de datos, desarrollada por Samuel Shapiro y Martin Wilk en 1965, esta prueba se basa en la comparación entre la distribución de los datos observados y una distribución normal teórica. El principio fundamental de la prueba es que, si los datos siguen una

distribución normal, los valores ordenados de los datos deberían coincidir estrechamente con los valores esperados de una distribución normal.

El estadístico de la prueba, denotado como W , se calcula a partir de la relación entre la varianza de las observaciones y la varianza de los residuos de la regresión lineal ajustada a los datos. Un valor de W cercano a 1 indica que los datos se distribuyen de manera normal, mientras que valores más bajos sugieren desviaciones significativas de la normalidad (Sánchez et al., 2024).

El procedimiento para aplicar la prueba de Shapiro-Wilk es relativamente sencillo. Inicialmente, se ordenan los datos en forma ascendente y se calcula el estadístico de la prueba W . Este cálculo implica los siguientes pasos:

- a.* Ordenar los datos: Se disponen los datos de la muestra en orden ascendente.
- b.* Calcular la media y la varianza de la muestra.
- c.* Calcular el estadístico W : Se utiliza la fórmula específica que incluye los coeficientes de Shapiro-Wilk, que dependen del tamaño de la muestra y se obtienen de tablas predefinidas.
- d.* Determinar el valor p : A partir del valor W calculado, se obtiene el valor p correspondiente que se compara con un nivel de significancia preestablecido (comúnmente 0.05).

La prueba se puede aplicar a muestras pequeñas ($n < 50$) y medianas ($n < 2000$). Empero, se recomienda tener precaución en muestras muy grandes, ya que incluso pequeñas desviaciones de la normalidad pueden resultar en un valor p significativo. La interpretación de los resultados de la prueba de Shapiro-Wilk se basa en el valor p obtenido. Si el valor p es menor que el nivel

de significancia elegido (por ejemplo, 0.05), se rechaza la hipótesis nula, lo que indica que los datos no siguen una distribución normal. Por otro lado, si el valor p es mayor que el nivel de significancia, no se puede rechazar la hipótesis nula y se considera que los datos son consistentes con una distribución normal.

Es importante tener en cuenta que la prueba de Shapiro-Wilk es sensible al tamaño de la muestra. En muestras pequeñas, puede no detectar desviaciones de la normalidad, mientras que en muestras grandes, puede rechazar la normalidad incluso con pequeñas discrepancias. Por lo tanto, es recomendable utilizar esta prueba en combinación con métodos gráficos, como histogramas o gráficos Q-Q, para obtener una evaluación más completa de la normalidad de los datos en el contexto de la investigación social. Aparte de la prueba de Shapiro-Wilk, existen otras pruebas que aceptan evaluar la normalidad de un conjunto de datos. Cada una de estas pruebas tiene características únicas que pueden ser más apropiadas en diferentes contextos de investigación.

La prueba de Kolmogorov-Smirnov (K-S) es una de las pruebas de normalidad más utilizadas en estadística. Su fundamento se basa en la comparación entre la función de distribución empírica de la muestra y la función de distribución acumulativa de una distribución normal teórica. El método de cálculo implica determinar la máxima diferencia (D) entre estas dos funciones. Si esta diferencia es mayor que un umbral crítico, se rechaza la hipótesis nula de que los datos provienen de una distribución normal. El beneficio de la prueba K-S es que se puede aplicar a muestras de cualquier tamaño, aunque su sensibilidad puede verse afectada en muestras pequeñas.

La prueba de Anderson-Darling es otra alternativa que se centra en las colas de la distribución, lo que la hace especialmente útil en situaciones donde la normalidad en las colas es crucial, como en la evaluación de riesgos. Esta prueba es una modificación de la prueba K-S, ya que otorga más peso a las diferencias en las colas de la distribución. El cálculo de la prueba de Anderson-Darling implica el uso de una estadística que combina la discrepancia entre la distribución empírica y la normal teórica, proporcionando un valor que se compara con valores críticos específicos para determinar la normalidad. Esta prueba es generalmente más potente que la K-S, especialmente en muestras pequeñas.

La prueba de Lilliefors es una adaptación de la prueba de Kolmogorov-Smirnov diseñada específicamente para situaciones en las que la media y la varianza de la población no son conocidas y deben estimarse a partir de la muestra. Esto la convierte en una opción valiosa en las ciencias sociales, donde los datos frecuentemente no cumplen con los supuestos necesarios para realizar otras pruebas (Sánchez et al., 2024). El método de cálculo es similar al de la prueba K-S, pero se ajusta para tener en cuenta las estimaciones de la media y la varianza. La prueba de Lilliefors es particularmente útil para muestras pequeñas y medianas, y su aplicabilidad en contextos sociales la convierte en una herramienta esencial para los académicos.

Cada una de estas pruebas de normalidad tiene sus propias ventajas y limitaciones, lo que las hace adecuadas para diferentes contextos y tamaños de muestra. La elección de la prueba más adecuada dependerá de las características específicas de los datos analizados y del objetivo de la investigación. En el análisis de datos en las ciencias sociales, la elección de la prueba de normalidad adecuada puede influir significativamente en los resultados y conclusiones de una investigación.

i. *Prueba de Shapiro-Wilk:*

- Ventajas: El punto de partida de la prueba de Shapiro-Wilk es su alta potencia para detectar desviaciones de la normalidad, especialmente en muestras pequeñas. Es ampliamente utilizada y aceptada en la comunidad científica.

- Desventajas: Aun así, su principal limitación es que puede ser sensible a la presencia de valores atípicos, lo que puede afectar su validez. Además, se recomienda su uso principalmente para muestras de tamaño menor a 2000, ya que su rendimiento puede decrecer con tamaños de muestra más grandes.

ii. *Prueba de Kolmogorov-Smirnov:*

- Ventajas: Esta prueba es flexible, ya que puede aplicarse no solo para evaluar la normalidad, sino también para comparar dos distribuciones. Su simplicidad en el cálculo la convierte en una opción atractiva.

- Desventajas: Sin embargo, puede ser menos potente que la prueba de Shapiro-Wilk, especialmente en muestras pequeñas. Además, la versión clásica de esta prueba tiene una menor capacidad para detectar desviaciones en la cola de la distribución.

iii. *Prueba de Anderson-Darling:*

- Ventajas: Esta prueba es considerada más robusta que la de Kolmogorov-Smirnov, ya que pone mayor énfasis en las colas de la distribución. Esto la hace ideal para detectar desviaciones en situaciones donde los extremos son críticos.

- Desventajas: No obstante, su complejidad en el cálculo puede ser una barrera para algunos académicos, y su interpretación puede no ser tan intuitiva como la de otras pruebas.

iv. *Prueba de Lilliefors:*

- Ventajas: Se basa en la prueba de Kolmogorov-Smirnov, pero está diseñada específicamente para situaciones donde los parámetros de la distribución no son conocidos. Esto la hace útil en casos prácticos donde se debe asumir que la media y la desviación estándar son desconocidas.

- Desventajas: Al igual que la prueba de Kolmogorov-Smirnov, puede tener limitaciones en la detección de desviaciones en las colas de la distribución.

La elección de la prueba de normalidad adecuada puede depender del tamaño de la muestra y de las características de los datos, la idea central es, la prueba de Shapiro-Wilk es preferida en estudios con muestras pequeñas, mientras que la prueba de Kolmogorov-Smirnov se puede utilizar en muestras más grandes. La prueba de Anderson-Darling es recomendable cuando se sospecha que hay desviaciones en las colas, y la prueba de Lilliefors es adecuada cuando se trabaja con datos donde los parámetros son inciertos.

En investigaciones sociales, como encuestas sobre actitudes o procedimientos, es común encontrarse con datos que deben ser evaluados por su normalidad. En particular, un investigador que analiza la distribución de respuestas en una escala Likert podría optar por la prueba de Shapiro-Wilk para validar la normalidad de los datos antes de aplicar técnicas paramétricas. En otro caso, si un sociólogo está comparando dos grupos en términos de puntajes en una prueba estandarizada, podría utilizar la prueba de Kolmogorov-Smirnov para determinar si las distribuciones difieren significativamente.

La comparación de metodologías para pruebas de normalidad es crucial para garantizar la validez de los análisis estadísticos en las ciencias sociales. La correcta selección de la prueba no solo depende de las

características de los datos, sino también del objetivo del análisis y del contexto de la investigación. En el ámbito de las ciencias sociales, la normalidad de los datos es un supuesto fundamental en muchas técnicas estadísticas.

En teoría, la selección de la prueba de normalidad adecuada depende de varios factores, incluyendo el tamaño de la muestra, la naturaleza de los datos y el contexto de la investigación. La prueba de Shapiro-Wilk, así como, es altamente efectiva para muestras pequeñas y es preferida en muchas situaciones debido a su potencia. Sin embargo, investigaciones con muestras grandes pueden beneficiarse de la robustez de la prueba de Kolmogorov-Smirnov o de la sensibilidad de Anderson-Darling para detectar desviaciones en las colas de la distribución.

Recomendamos a los académicos que, antes de aplicar cualquier técnica estadística, realicen una evaluación cuidadosa de la normalidad de sus datos. Esto no solo mejora la calidad de los resultados, sino que incluso contribuye a la credibilidad de la investigación social en su conjunto. Asimismo, es aconsejable complementar el uso de pruebas formales con métodos gráficos, como histogramas o gráficos Q-Q, que proporcionan una visualización intuitiva de la distribución de los datos.

Por último, es importante recordar que, en algunos casos, los datos pueden no seguir una distribución normal. En tales circunstancias, los académicos deben estar preparados para considerar enfoques alternativos, como transformaciones de datos o técnicas estadísticas no paramétricas, que no dependen de supuestos de normalidad. Al adoptar un enfoque riguroso y reflexivo hacia las pruebas de normalidad, los académicos sociales estarán

mejor equipados para tomar decisiones informadas y fundamentadas, contribuyendo así al avance del conocimiento en sus respectivos campos.

4.3 Estimación de Densidad del Núcleo: Métodos y Aplicaciones en las Ciencias Sociales

La estimación de densidad del núcleo es una técnica estadística utilizada para estimar la función de densidad de probabilidad de una variable aleatoria. Esta metodología se ha convertido en una herramienta fundamental en diversas disciplinas, incluidas las ciencias sociales, donde la comprensión de la distribución de los datos es crucial para la interpretación y análisis de fenómenos sociales complejos (Wang, 2021).

La estimación de densidad del núcleo se basa en la idea de suavizar las observaciones de datos para crear una representación continua de la distribución subyacente. En lugar de depender de los métodos tradicionales, como los histogramas, que pueden ser influenciados por la elección del ancho de los intervalos, la estimación de densidad del núcleo utiliza funciones kernel para asignar un peso a cada observación. Este enfoque autoriza obtener una visualización más fluida y precisa de la distribución de los datos, facilitando la identificación de patrones y tendencias.

En las ciencias sociales, la estimación de densidad del núcleo es especialmente valiosa debido a la naturaleza compleja y a menudo no lineal de los datos que se analizan. Las encuestas, estudios de mercado y otras investigaciones a menudo generan conjuntos de datos que contienen variaciones significativas. La capacidad de estimar la densidad de estos datos ayuda a los académicos a comprender mejor las dinámicas sociales, las preferencias de los consumidores y las tendencias demográficas. Además, los resultados obtenidos mediante esta técnica pueden influir en la formulación

de políticas y en la toma de decisiones estratégicas en contextos sociales y económicos.

La estimación de densidad es una técnica estadística fundamental en el análisis de datos, especialmente en las ciencias sociales, donde la interpretación de la distribución de variables es crucial para entender tendencias. A criterio de los autores, existen varios métodos para llevar a cabo esta estimación, cada uno con sus propias características, ventajas y desventajas:

i. Descripción del método

El método de kernel, o estimación de densidad de kernel (KDE, por sus siglas en inglés), es una técnica no paramétrica que asiente estimar la función de densidad de una variable aleatoria. Este método se basa en la idea de colocar una función de forma (kernel) sobre cada punto de datos en el conjunto, y luego sumar estas funciones para obtener una estimación suave de la densidad. Comúnmente se utilizan funciones gaussianas como kernels, aunque existen otras opciones, como el kernel de Epanechnikov o el de uniforme.

ii. Ventajas y desventajas

El método de kernel tiene la capacidad de proporcionar una estimación suave de la densidad sin asumir una forma específica para la distribución subyacente. Esto lo hace especialmente útil en situaciones donde la forma de la distribución no es conocida a priori. A pesar de, una desventaja significativa es la elección del ancho de banda, que puede influir drásticamente en la estimación. Un ancho de banda demasiado pequeño puede llevar a una estimación ruidosa, mientras que uno demasiado grande puede ocultar características importantes de los datos.

iii. Aplicaciones en datos sociales

En las ciencias sociales, la estimación de densidad de kernel se ha utilizado en el análisis de datos de encuestas, donde permite visualizar la distribución de respuestas a preguntas complejas. También es útil en estudios de movilidad social, donde se pueden identificar patrones de distribución de ingresos o riqueza en ciclos establecidos.

iv. Construcción de histogramas

Los histogramas son una de las herramientas más simples y clásicas para la estimación de densidad. Se construyen dividiendo el rango de los datos en intervalos (o "bins") y contando el número de observaciones que caen dentro de cada intervalo. La altura de cada barra en el histograma representa la frecuencia de los datos en ese rango. Para estimar la densidad, la frecuencia puede ser normalizada dividiendo por el número total de observaciones y el ancho del intervalo.

v. Limitaciones del enfoque

A pesar de su simplicidad, el enfoque de histogramas presenta varias limitaciones. La elección del número de intervalos y su ancho puede afectar significativamente la forma del histograma, lo que puede conducir a interpretaciones erróneas de la distribución de los datos. Además, los histogramas tienden a ser menos precisos que otros métodos, como el de kernel, especialmente cuando se trata de conjuntos de datos más pequeños.

vi. Uso en análisis de datos

Los histogramas son útiles en el análisis exploratorio de datos, donde proporcionan una representación visual rápida de la distribución de variables. En ciencias sociales, se utilizan frecuentemente para analizar la

distribución de respuestas en encuestas, como la edad, el ingreso o la educación, permitiendo a los académicos identificar patrones y anomalías en los datos.

vii. Modelos estadísticos comunes

Los métodos paramétricos implican la asunción de una forma específica para la distribución de los datos, como la normal, la exponencial o la binomial. Estos modelos se caracterizan por un conjunto limitado de parámetros que se estiman a partir de los datos. La estimación de densidad en este contexto se realiza ajustando el modelo a los datos y utilizando la función de densidad resultante.

viii. Supuestos y condiciones

Los métodos paramétricos requieren que se cumplan ciertos supuestos sobre los datos, como la normalidad o la independencia. Si estos supuestos no son válidos, las estimaciones pueden ser inexactas o engañosas. Por lo tanto, es crucial realizar pruebas de ajuste y verificar la validez de los supuestos antes de aplicar estos métodos.

ix. Ejemplos de aplicación

En las ciencias sociales, los métodos paramétricos son ampliamente utilizados en la modelización de relaciones entre variables, como en estudios de regresión donde se busca entender el impacto de variables independientes sobre una variable dependiente. Asimismo, se aplican en análisis de varianza (ANOVA) para comparar medias entre grupos, lo cual es esencial en investigaciones sobre políticas sociales y evaluaciones de programas.

La elección del método de estimación de densidad depende del tipo de datos y del objetivo del análisis. Cada método tiene sus ventajas y desventajas,

y su correcta aplicación puede facilitar una comprensión más profunda de las dinámicas sociales. La estimación de densidad del núcleo (EDK) ha demostrado ser una herramienta valiosa en diversas áreas de las ciencias sociales. Su capacidad para proporcionar una representación más precisa de la distribución de datos permite a los académicos obtener información más significativa sobre patrones y tendencias en contextos sociales

x. Interpretación de resultados

La EDK juega un papel crucial en el análisis de encuestas, donde los académicos necesitan entender la distribución de respuestas en una población. Al aplicar métodos de estimación de densidad, los analistas pueden identificar áreas donde las respuestas son más concentradas, facilitando la interpretación de los resultados. Esto es especialmente útil cuando los datos contienen una gran cantidad de respuestas discretas que pueden no reflejar adecuadamente la complejidad de las opiniones de los encuestados.

xi. Casos de estudio relevantes

Un ejemplo notable se encuentra en el análisis de encuestas electorales, donde la EDK ha sido utilizada para visualizar la distribución de votos en diferentes regiones. Esto ayuda a los analistas identificar patrones geográficos y segmentar a los votantes según preferencias políticas, lo que a su vez puede influir en estrategias de campaña y movilización electoral.

xii. Impacto en decisiones políticas

La capacidad de visualizar y analizar la distribución de respuestas a través de la EDK puede tener un impacto significativo en la toma de decisiones políticas. Los responsables de formular políticas pueden utilizar

esta información para entender mejor las necesidades y preocupaciones de los ciudadanos, y así diseñar iniciativas más efectivas y dirigidas.

xiii. Segmentación de clientes

En el ámbito de la investigación de mercado, la estimación de densidad del núcleo permite a las empresas segmentar a sus clientes de manera más precisa. Mediante la identificación de grupos de consumidores con características similares, las organizaciones pueden adaptar sus productos y servicios a las necesidades específicas de cada segmento.

xiv. Tendencias de consumo

La EDK encima se emplea para analizar tendencias de consumo, ayudando a identificar cambios en las preferencias de los consumidores a lo largo del tiempo. Esto es particularmente relevante en mercados dinámicos, donde las empresas deben estar atentas a las fluctuaciones en la demanda para mantenerse competitivas.

xv. Optimización de estrategias de marketing

Al utilizar la EDK para comprender mejor la distribución de datos de clientes, las empresas pueden optimizar sus estrategias de marketing. La idea central es, al identificar áreas geográficas con una alta concentración de consumidores potenciales, una empresa puede dirigir sus campañas publicitarias a esas regiones específicas, maximizando así el retorno de inversión.

xvi. Distribución de poblaciones

La estimación de densidad del núcleo es fundamental en estudios demográficos, donde se busca entender la distribución de poblaciones en distintas áreas. Al aplicar la EDK, los demógrafos pueden visualizar la

concentración de residentes en diferentes regiones, lo que les autoriza hacer inferencias sobre la urbanización, la planificación de servicios públicos y el desarrollo urbano.

xvii. *Análisis de migraciones*

La EDK todavía se aplica en el análisis de migraciones, ayudando a los académicos a rastrear patrones de movimiento poblacional. A través de la estimación de densidad, se pueden identificar áreas con un alto flujo de migrantes y comprender las razones detrás de estos movimientos, lo que es esencial para el desarrollo de políticas migratorias y la planificación regional.

xviii. *Proyecciones futuras*

Ahora bien, la EDK se utiliza para realizar proyecciones demográficas, permitiendo a los académicos anticipar cambios en la población en un espacio temporal. Esto es crucial para la planificación de recursos y servicios, así como para la formulación de políticas que respondan a las necesidades futuras de la sociedad. La estimación de densidad del núcleo ofrece aplicaciones prácticas y significativas en diversas áreas de las ciencias sociales, desde el análisis de encuestas hasta la investigación de mercado y estudios demográficos. Su capacidad para proporcionar representaciones más precisas de datos permite a los académicos y profesionales tomar mejores decisiones informadas, contribuyendo así al avance del conocimiento en el ámbito social.

Desde su definición y conceptos básicos hasta su relevancia y aplicación práctica en diversas áreas, hemos destacado cómo esta metodología no solo facilita la comprensión de la distribución de datos, sino que también asiente obtener estrategias valiosas que pueden influir en decisiones importantes. La estimación de densidad del núcleo se ha mostrado como un método poderoso en comparación con otras técnicas tradicionales,

como los histogramas, debido a su capacidad para ofrecer una representación más suave y continua de la distribución de datos. A pesar de sus limitaciones, los métodos de estimación de densidad, ya sean kernel, histogramas o paramétricos, aportan una variedad de enfoques que se pueden adaptar a diferentes contextos y tipos de datos en las ciencias sociales.

Las aplicaciones discutidas, que abarcan desde el análisis de encuestas hasta la investigación de mercado y estudios demográficos, ilustran la versatilidad de la estimación de densidad del núcleo. Estos métodos no solo aceptan a los académicos comprender mejor las tendencias y patrones en los datos, sino que también tienen un impacto tangible en la formulación de políticas, estrategias de marketing y proyecciones demográficas.

La estimación de densidad del núcleo se ha consolidado como una herramienta esencial en la investigación social, ofreciendo un enfoque robusto para analizar y visualizar datos complejos. La expansión de los datos hará que estos métodos sean cada vez más relevantes, por lo que la investigación en esta área se enriquecerá con nuevas técnicas y enfoques que integren la estimación de densidad con herramientas de aprendizaje automático y análisis de big data, lo que permitirá a los científicos sociales abordar preguntas aún más complejas y relevantes en un mundo en constante cambio.

Conclusión

La estadística inferencial se exploró como herramienta fundamental para el análisis en las ciencias sociales, permitiendo a los investigadores extraer conclusiones significativas a partir de muestras limitadas y hacer generalizaciones sobre poblaciones más amplias. Con base en la evidencia teórica, se discernió sus principios comprensivos y básicos, como el muestreo, la estimación de parámetros y las pruebas de hipótesis, los cuales forman la base del análisis estadístico y métodos de análisis aplicados en este campo, como el análisis de regresión, el análisis de varianza (ANOVA) y los métodos no paramétricos, que proporcionan diferentes enfoques para interpretar datos sociales.

Hoy en día, el uso de técnicas de análisis más sofisticadas, como el aprendizaje automático y la inteligencia artificial, en sinergia con la inferencia y la heurística converge en dar respuesta a problemas complejos de manera eficiente y precisa. Además, la integración de enfoques interdisciplinarios y la colaboración entre científicos sociales y estadísticos es decisivo para enriquecer el análisis de datos y mejorar la validez de las inferencias realizadas.

Para los autores, la relevancia de las pruebas de normalidad se vuelve aún más crítica en la investigación social, donde los datos con frecuencia se recogen a partir de encuestas, cuestionarios y observaciones. Por lo tanto, la variabilidad y la heterogeneidad de los datos pueden ser amplias, lo que hace que las suposiciones sobre la normalidad sean especialmente desafiantes. Hay que hacer notar, en estudios sobre actitudes, características demográficas, los académicos deben asegurarse de que los métodos estadísticos que utilizan

sean apropiados para la distribución de sus datos y afirmación de teorías con base en la interpretabilidad de los resultados.

Por ende, la comprensión de los resultados obtenidos a través del análisis y la simulación es un paso crítico en el estudio de sistemas dinámicos; no solo se trata de observar patrones y tendencias, sino de comprender qué significan en el contexto social, económico o político en el que se inscriben. Es decir, explorar patrones de comportamiento, ciclos de retroalimentación y otras dinámicas que son esenciales para entender fenómenos sociales como la difusión de innovaciones, la propagación de movimientos sociales y las dinámicas económicas.

En contexto, es esencial que la investigación social basada en análisis de supervivencia se enfoque en mejorar la calidad de los datos disponibles y en desarrollar métodos que sean más accesibles para una variedad de situaciones. Por lo que la integración de tecnologías emergentes, como la inteligencia artificial y el aprendizaje automático, podría ofrecer nuevas perspectivas y enfoques para el análisis de grandes volúmenes de datos demográficos, permitiendo identificar patrones complejos que antes eran difíciles de discernir.

En conclusión, los fenómenos sociales son inherentemente complejos y multifacéticos, lo que puede dificultar la creación de modelos que capturen adecuadamente todas las variables y relaciones pertinentes. He aquí la utilidad principal de la estadística inferencial plasmada en el libro, pues, la selección de parámetros y la calibración de modelos son procesos que requieren un profundo entendimiento del sistema en estudio. En consecuencia, los modelos pueden volverse obsoletos rápidamente debido a

cambios en el contexto social, lo que plantea la necesidad de actualizaciones continuas y de una evaluación crítica de su validez en un tiempo determinado.

Finalmente, se recomienda estudiar exhaustivamente los principios de la prueba de Cochran-Mantel-Haenszel (CMH), tratadas en el capítulo uno, que transige en evaluar la asociación entre dos variables categóricas mientras se controla por una o más variables de confusión. Esta prueba es fundamental en el análisis de datos en contextos donde los académicos desean determinar si existe una relación significativa entre las variables de interés, considerando otras variables que podrían influir en dicha relación.

Bibliografía

Abd ElHafeez, S., D'Arrigo, G., Leonardis, D., Fusaro, M., Tripepi, G., & Roumeliotis, S. (2021). Methods to Analyze Time-to-Event Data: The Cox Regression Analysis. *Oxidative medicine and cellular longevity*, 2021, 1302811. <https://doi.org/10.1155/2021/1302811>

Arribalzaga, E.B. (2007). Interpretación de las curvas de supervivencia. *Revista chilena de cirugía*, 59(1), 75-83. <https://dx.doi.org/10.4067/S0718-40262007000100013>

Barreto-Villanueva, A. (2012). El progreso de la Estadística y su utilidad en la evaluación del desarrollo. *Papeles de población*, 18(73), 241-271

Canales, M. (2006). *Metodologías de investigación social. Introducción a los oficios*. Santiago: Lom Ediciones

Contreras, O.F., y Torres, H. (2016). *Crecimiento económico y desarrollo social*. Guadalajara: Centro Universitario de Ciencias Sociales y Humanidades de la Universidad de Guadalajara

Córdova Olivera, P., y Yurevna Nikolaeva, M. (2019). Modelo de Cox multinivel estratificado con interacción por índice de riqueza para análisis de riesgo de muerte de niños menores de cinco años - ENDSA 2008. *Investigación & Desarrollo*, 19(2), 109-126

Errandonea, G. (2024). Método de Kaplan-Meier. Análisis de supervivencia por modelado parcial: Una alternativa metodológica para el estudio de las trayectorias estudiantiles en educación superior. *Páginas de Educación*, 17(2), e4115. <https://doi.org/10.22235/pe.v17i2.4115>

Fiveable. (2025). "3.1 Population growth models – Environmental Biology." Edited by Becky Bahr, Fiveable. <https://library.fiveable.me/environmental-biology/unit-3/population-growth-models/study-guide/dzmDvelH9WIyvT3D>

Gawande, M. S., Zade, N., Kumar, P., Gundewar, S., Weerarathna, I. N., & Verma, P. (2025). The role of artificial intelligence in pandemic responses: from epidemiological modeling to vaccine development. *Molecular biomedicine*, 6(1), 1. <https://doi.org/10.1186/s43556-024-00238-3>

Hernández, Z. (2012). *Métodos de análisis de datos*. Logroño: Universidad de Logroño

Hincapié-Mesa, F.A., y Londoño-Roldán, J.C. (2023). Impacto de la desigualdad de ingresos en la esperanza de vida y la salud en Colombia. *Revista Científica General José María Córdova*, 21(42), 429–451. <https://doi.org/10.21830/19006586.1142>

Izquierdo, L.R., Galán, J.M., Santos, J.I., y Del Olmo, R. (2008). Modelado de sistemas complejos mediante simulación basada en agentes y mediante dinámica de sistemas. *EMPIRIA. Revista de Metodología de las Ciencias Sociales*, (16), 85-112

Kempf Leonard, K. (2005) *Encyclopedia of social measurement*. Amsterdam, Miamisburg, OH: Elsevier; ScienceDirect online distributor. Available at: <https://www.sciencedirect.com/referencework/9780123693983/encyclopedia-of-social-measurement>

Kempf Leonard, K. (2005) *Encyclopedia of social measurement*. Amsterdam, Miamisburg, OH: Elsevier ; ScienceDirect online distributor. Available at:

<https://www.sciencedirect.com/referencework/9780123693983/encyclopedia-of-social-measurement>

López, P.L. (2004). Población muestra y muestreo. *Punto Cero*, 09(08), 69-74

Mejía, A., Brito, L., Arequipa, E., y Mora, A., (2025). Análisis de Ecuaciones Diferenciales como Herramienta Fundamental para Entender y Modelar Sistemas Dinámicos en la Educación Superior: Aplicación en Ingeniería y Matemáticas Avanzadas. *Reincisol*, 4(7), 4940-4960. [https://doi.org/10.59282/reincisol.V4\(7\)4940-4960](https://doi.org/10.59282/reincisol.V4(7)4940-4960)

Mendenhall, W., Beaver, R., y Beaver, B. (2010). *Introducción a la probabilidad y estadística*. Ciudad de México: Cengage Learning Editores

Miranda, I. (2014). Modelación matemática de la dinámica de poblaciones: desarrollo histórico y uso práctico en Cuba. *Revista de Protección Vegetal*, 29(3), 157-167

Moral de la Rubia, J., y Valle, A. (2024). Seasonal variations in city color preferences incorporating sex and age factors. *Journal of Asian Architecture and Building Engineering*, 11(3). <https://doi.org/10.1080/13467581.2024.2366829>

Murillo Castañeda, R.A. (2021). Implementación del método máquinas de soporte vectorial en bases de datos espaciales para análisis de clasificación supervisada en imágenes de sensores remotos. *Revista cartográfica*, (102), 27-42. <https://doi.org/10.35424/rcarto.i102.830>

Pérez, C. (2004). *Técnicas de Análisis Multivariante de Datos. Aplicaciones con SPSS®*. Madrid: Pearson

Ramírez, A., y Polack, A.M. (2020). Estadística inferencial. Elección de una prueba estadística no paramétrica en investigación científica. (2020). *Horizonte*

De La Ciencia, 10(19), 191-208. <https://doi.org/10.26490/uncp.horizonteciencia.2020.19.597>

Ramírez, J.C., y Juárez, D. (2009). La nueva escalada matemática: El impacto reciente de la teoría de sistemas dinámicos en Economía. *Economía mexicana. Nueva época*, 18(1), 71-103

Reyes Rocabado, J., Escobar Flores, C., Duarte Vargas, J., y Ramirez Peradotto, P. (2007). Una aplicación del modelo de regresión logística en la predicción del rendimiento estudiantil. *Estudios pedagógicos (Valdivia)*, 33(2), 101-120. <https://dx.doi.org/10.4067/S0718-07052007000200006>

Rojas-Castro, H., y Araya-Crisóstomo, S. (2019). Medidas de conservación ex situ: Un enfoque metapoblacional a partir del modelo clásico de Levins. *Gayana (Concepción)*, 83(1), 46-56. <https://dx.doi.org/10.4067/S0717-65382019000100046>

Romaina, J.C. (2012). *Estadística experimental. Herramientas para investigación*. Tacna: Universidad Privada de Tacna

Sánchez-Solis, Y., Raqui-Ramirez, C., Huaroc-Ponce, E. y Huaroc-Ponce, N. (2024). Importancia de Conocer la Normalidad de los Datos Utilizados en los Trabajos de Investigación por Tesis. *Revista Tecnológica-Educativa Docentes 2.0*, 17(2), 404-413. <https://doi.org/10.37843/rted.v17i2.554>

Tenorio Villalon, A.F., Martín Caraballo, A.M., Paralera Morales, C., y Contreras Rubio, I. (2013). Ecuaciones diferenciales y en diferencias aplicadas a los conceptos económicos y financieros. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 16, 165-199

Vega-Cauich, J.I. (2019). El análisis de supervivencia como técnica para la evaluación de la validez predictiva en la psicología jurídica. *Anuario de Psicología Jurídica*, 29, 1-10. <https://doi.org/10.5093/apj2018a11>

Veiga., N., Otero., L., y Torres., J. (2020). Reflexiones sobre el uso de la estadística inferencial en investigación didáctica. *InterCambios. Dilemas y transiciones de la Educación Superior*, 7(2), 94-106. <https://doi.org/10.2916/inter.7.2.10>

Wang, Y. (2021). Bivariate kernel density estimation for environmental contours at two offshore sites. *Ships and Offshore Structures*, 17(12), 2734–2744. <https://doi.org/10.1080/17445302.2021.2017163>

Yu, B., y Gastwirth, J.L. (2008). Un método para evaluar la sensibilidad de la prueba de Cochran-Mantel-Haenszel a un factor de confusión no observado. *Transacciones filosóficas. Serie A, Ciencias matemáticas, físicas y de ingeniería*, 366 (1874), 2377–2388. <https://doi.org/10.1098/rsta.2008.0030>

De esta edición de **“Estadística inferencial para las ciencias sociales”**, se terminó de editar en la ciudad de Colonia del Sacramento en la República Oriental del Uruguay el 05 de agosto de 2025

EST. 2021 **EMC**
EDITORIAL MAR CARIBE

ESTADÍSTICA INFERENCIAL PARA LAS CIENCIAS SOCIALES

ISBN: 978-9915-698-22-9



www.editorialmarcaribe.es