

# Evaluación de Herramientas para Predicciones en Regresión Lineal: Estudio con Datos del INCUCAI

Carlos Bateca, Roxana Martínez, Victoria Agnelli

Universidad Abierta Interamericana (UAI), Centro de Altos Estudios en Tecnología Informática (CAETI), Av. Montes de Oca 745, Buenos Aires, Argentina  
{CarlosAlberto.BatecaCaicedo, Victoria.Agnelli}@alumnos.uai.edu.ar,  
Roxana.Martinez@uai.edu.ar

**Abstract.** Este estudio compara herramientas como Power BI, Python y Microsoft Excel, para implementar modelos de regresión lineal utilizando datos públicos del INCUCAI sobre donación de órganos y tejidos. Se comparan herramientas en términos de aspectos de criterios de precisión, facilidad de uso y visualización. La metodología utilizada incluye la recolección manual de datos del portal del INCUCAI y su procesamiento en las herramientas seleccionadas. Los resultados del análisis comparativo proporcionan recomendaciones sobre la herramienta más adecuada para el análisis predictivo en el contexto de salud pública en Argentina, brindando un caso de estudio.

**Keywords:** Open data; Salud Pública; INCUCAI; Donantes Órganos y Tejidos

## 1 Introducción

La regresión lineal es una técnica estadística fundamental que es utilizada para modelar y analizar relaciones entre variables. Su simplicidad y eficacia la han convertido en una herramienta fundamental en varios campos de la industria, por ejemplo: desde ambientes tecnológicos hasta enfoques en ciencias de salud. Dentro del contexto de salud, el tratamiento de la predicción precisa en variables críticas es vital para una adecuada planificación. Este trabajo se basa sobre un caso de estudio sobre las tasas de donación de órganos y tejidos. Para esto se utilizan datos públicos que se encuentran disponibles en el sitio web del Instituto Nacional Central Único coordinador de Ablación e Implante (INCUCAI) [1]. Éste proporciona diversos datos sobre procuración y trasplantes de órganos en la Argentina, lo que permite llevar a cabo distintos enfoques de análisis predictivos.

El objetivo de este estudio es evaluar y comparar diferentes herramientas utilizadas para lograr implementar modelos de regresión lineal utilizando datos públicos del INCUCAI. Las herramientas seleccionadas son: Microsoft Excel, Power BI y Python, con las que se analizarán aspectos para un estudio sobre el rendimiento y la aplicabilidad de los modelos predictivos con regresión lineal. Este análisis comparativo se centrará en algunos criterios de evaluación incluyendo precisión de las predicciones, facilidad de uso, instalación y visualización de los datos. Una vez

analizado estos datos con las herramientas, se identificará cual es la herramienta más adecuada para un mejor análisis de este tipo de datos.

## 2 Trabajos Relacionados

En aspectos de trabajos relacionados, existen estudios que han explorado el uso de herramientas de análisis de datos para la implementación de modelos de regresión lineal en varios contextos. Sin embargo, pocos han comparado explícitamente la efectividad de diferentes herramientas utilizando un conjunto de datos específico. Excel fue identificado como una de las herramientas más accesibles y fáciles de utilizar para el análisis estadístico básico [2] [3], es decir, si bien es adecuado para usuarios no técnicos, varios trabajos de investigación [4] [5], indican que es posible realizar análisis avanzados en aspectos de modelos de regresión lineal, pero se encontraron limitaciones significativas para manejar grandes volúmenes de datos. Por lo que, esta herramienta es posible compararla con otras más robustas. En lo que respecta a Python, existen estudios enfocados en el uso de Python para el análisis predictivo en el sector de la salud [6] [7] [8], destacando la flexibilidad y potencia de bibliotecas como Pandas y Scikit-learn. Sin embargo, faltan comparaciones de herramientas no basadas en programación, lo que limita la aplicabilidad de sus hallazgos a profesionales sin conocimientos técnicos avanzados. Por otra parte, no se trabajan con aspectos de visualización en detalle, lo que es fundamental para la interpretación de resultados. En lo que respecta a Power BI, se utiliza para la inteligencia de negocios y visualización de datos [9], y brinda características avanzadas para la creación de dashboard interactivos e integración de diversas fuentes de datos [10], pero no hay estudios que profundicen análisis estadísticos detallados, como la regresión lineal. Power BI se compara con herramientas especializadas en análisis predictivo.

Las falencias identificadas en estos estudios incluyen la falta de comparaciones directas entre herramientas diversas, la importancia de la facilidad de uso para usuarios no técnicos, y la falta de enfoque en la visualización de resultados de análisis predictivos. Para trabajar estos aspectos, este trabajo propone un análisis comparativo integral de Excel, Python y Power BI, utilizando un conjunto de datos de salud pública proporcionado por el INCUCAI. El estudio evaluará no solo la precisión de los modelos de regresión lineal, sino también la facilidad de uso, eficiencia y capacidades de visualización de cada herramienta.

## 3 Metodología

En lo que respecta a la *descripción del caso de estudio*, la investigación se centra en diversas herramientas de evaluación en predicción de regresión, utilizando un conjunto de datos obtenidos del sitio web del INCUCAI (Instituto Nacional Central Único Coordinador de Ablación e Implante) [1], este Instituto es el encargado de regular y coordinar las actividades relacionadas con la donación y el trasplante de órganos en la Argentina. El conjunto de datos se extrajo específicamente de la

plataforma de informes INCUCAI/SINTRA/Central de Reportes [11], a la que se puede acceder a través del Reporte de donantes de órganos y tejidos por periodo. Este conjunto de datos públicos contiene detalles sobre los donantes de órganos y tejidos en diferentes períodos de tiempo. Para este caso se analizaron variables como la cantidad de donantes, el tipo de órgano, tejido donado la ubicación geográfica de los donantes, como otros factores demográficos y clínicos. Estos datos procesados son fundamentales para comprender las tendencias y patrones en lo que respecta a la donación de órganos y tejidos, ya que esto conlleva desarrollar modelos predictivos que ayudan a mejorar la planificación en cuanto a los recursos sobre salud pública.

En lo que respecta a los *Métodos de Recolección de datos*, éstos fueron extraídos desde INCUCAI [11], se utilizaron las opciones de exportación, ya que no se presentan en formatos abiertos, sino que deben ser descargados en forma manual. Antes de ser descargado el reporte de donantes de órganos y tejidos por período, la plataforma muestra algunos posibles filtros que son los criterios de evaluación, siendo éstos: tipo de consulta período de evaluación o bien establecimiento origen. Una vez seleccionados los criterios, se tuvo que seleccionar la lista de salida del reporte indicando tipos de agrupación, por ejemplo: por clasificación, provincia, motivo de muerte, nacionalidad, sexo entre otras. Posteriormente, se muestran los resultados arrojados con la posibilidad de exportarlo a un archivo XLS.

En lo que respecta al *análisis de datos*, se utilizaron 3 (tres) herramientas principales: Excel, Python y Power BI. La elección de cada una de estas tiene que ver con diferentes enfoques, éstas son amigables, y tienen aspectos sencillos para la implementación de modelos de regresión lineal. Se utilizaron las funciones de análisis de datos y regresión lineal que se encuentran disponibles. Para Excel, se tuvo en cuenta su facilidad de uso y accesibilidad como una aplicación estándar para el manejo de planillas de cálculo, sin la necesidad de tener conocimientos avanzados de programación, además, se tuvo presente las funciones de análisis de datos integradas en la utilización de la instalación de plugins para el análisis de datos en regresión lineal. Para Python, se tuvo en cuenta su flexibilidad y potencia analítica, además de la utilización de bibliotecas específicas de visualización y modelado de datos que se encuentran integradas para los modelos de regresión lineal. Otro de los focos que se tuvo en cuenta, fueron las funcionalidades en aspectos de técnicas de limpieza de datos para el dataset trabajado (siguiente sección). Finalmente, Power BI, se seleccionó como una herramienta amigable de visualización interactiva de datos en las que se incluyen funciones avanzadas de análisis y modelados de datos. Básicamente, la combinación de estas herramientas brinda un contexto sobre la implementación y evaluación de los modelos de regresión, para aspectos de accesibilidad, usabilidad, potencia para análisis de datos y visualizaciones.

#### **4 Caso de Estudio: INCUCAI**

En esta sección se desarrolla la descripción de las herramientas utilizadas para el caso de estudio, y el proceso de implementación con cada herramienta.

### 4.1 Excel

En el caso de la implementación en Excel se agrupa el dataset por provincia, previo al análisis. Para esta agrupación se utiliza una columna con todos los años que contiene el dataset sin repetirse, para éstos, copiaremos la columna año y eliminaremos duplicados, utilizando la inclusión de una función *SUMAR.SI(Columna Año; Columna Distinct\_Año; Columna Efectivos)*. En aspectos de Pronóstico de Series para generar una previsión al grafico original en Excel, es necesario calcular una columna adicional con valores calculados para la previsión. Se utilizará la función “Pronostico” la cual tiene dos variantes: a) *Lineal*: Tiene un propósito lineal y asume linealidad entre la variable dependiente y la independiente, incluyendo en ocasiones tendencias lineales, pero sin tomar en cuenta componentes estacionales o patrones cíclicos de manera explícita; b) *ETS (Error, Trend, Seasonality)*: Son modelos más flexibles y se adaptan a diferentes patrones de error, tendencia y estacionalidad haciéndolos más adecuados para series temporales que presenten variabilidad no lineal o patrones estacionales. Para este caso implementaremos el pronóstico ETS, ya que nuestro grafico no presentan una evolución lineal definida. Para el pronóstico ETS existe la función: *PRONOSTICO.ETS(celda del año que queremos pronosticar; columna Sum\_Efectivos; columna Distinct\_Año)*.



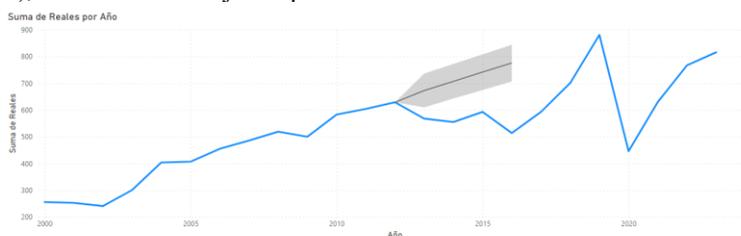
**Fig. 1.** Como podemos observar, el valor de  $R^2$  es 0.7533 por lo que no sería contundente su estacionalidad, visualmente no hay un comportamiento cíclico claro.

Se analizan los años rangos 2022-2015 como datos de entrenamiento y aplicaremos la función para ver que tanto se acerca a la realidad en esos años. Ahora, para los valores pronosticados se determina el error absoluto medio (MAPE), para ello se calcula la variación de cada uno respecto al valor real, con la función ABS y luego su promedio. Para ello, se agrega una línea de tendencia y se determina su fórmula lineal, con ello determinaremos  $R^2$  (al cuadrado) y su valor dará un indicio de la probabilidad de que la serie sea estacional. Siendo más probable a estacionalidad si el valor de R cuadrado se acerca a 1, esto se observa en la Figura 1. Excel es una herramienta idónea para usuarios que carecen de conocimientos y habilidades que requieren otros sistemas más complejos [18], y que no siempre son de fácil acceso, por lo que representa una alternativa más accesible para el procesamiento de datos.

## 4.2 Power BI

Para esta implementación se usarán datos establecidos previamente sin modificación alguna, ya que la agrupación será el objeto visual que usemos posteriormente. Una vez cargado, se representan en un gráfico de líneas para ver la serie de tiempo, tomando como eje x los años, y, como eje y las cantidades de donaciones reales. Sobre este gráfico se habilita la “previsión” y los siguientes parámetros a configurar: a) Unidades: En este caso cada punto nodo refiere a un año del eje x; b) Predecir duración: Determina la cantidad de puntos (En este caso años) que va a predecir el modelo, a partir del final del dataset; c) Omitir el ultimo: Determina en cual nodo comienza la previsión, omitiendo los anteriores d) Estacionalidad: Permite definir en unidades de puntos, la estacionalidad a considerar en el modelo; e) Intervalo de confianza: Indica la varianza que puede tomar la línea de previsión, es decir el margen de error que puede darse por arriba y por debajo de la misma. Para configurar las opciones de la previsión dividiremos el dataset en 2 partes: i) La primera parte con la mayor cantidad de datos posibles será sobre el que se base el modelo; ii) La segunda parte con el resto del dataset será contra la cual validaremos la previsión, y ajustaremos las configuraciones de esta hasta que se acerque más a la realidad. Finalmente, una vez configurado podremos aplicar el modelo a todo el dataset.

Para lograr esta división vamos a omitir los últimos “n” puntos para que la previsión se ubique más atrás en la línea de tiempo para que la previsión se base solamente en una porción del dataset (porción de entrenamiento), y, además, vamos a configurar de modo tal que se asemeje lo máximo posible a los años posteriores de la línea temporal. Al omitir 11 puntos, se ve como la previsión (línea gris) con las configuraciones actuales, se aleja considerablemente de la realidad (línea azul) (Figura 2), esto lo vamos a ajustar posteriormente con la estacionalidad.



**Fig. 2.** ¿Por qué omitimos 11 puntos?, la idea es ubicar el inicio de la predicción al final de una serie que tenga uniformidad a lo largo del tiempo, es decir que no tenga picos bruscos y se pueda observar a simple vista cierto patrón de comportamiento.

Entre los años 2016 y 2019 se experimentó un crecimiento rápido que no seguía la tendencia anterior, y luego de 2019 a 2020 una caída brusca seguramente debido a la pandemia COVID-19. Por lo que se ajustan las configuraciones en una tendencia más uniforme. En aspectos de *Configuración de estacionalidad*, dentro de la limitada configuración que podemos ajustar, vamos a cambiar la estacionalidad. Esto se refiere a patrones o fluctuaciones que se repiten en los datos a lo largo del tiempo en intervalos regulares. Luego de probar distintos valores para la estacionalidad tenemos algunos resultados. A continuación, se muestran los valores que se prevén para los años 2025-2028 en la Figura 3. El usuario ideal para el uso de Power BI es bastante

similar al de Excel en cuanto a nivel de conocimientos, y en pocos pasos es posible obtener resultados visibles. Desde nivel estudiantil siguiendo una guía docente para conectarse con los datos [19].



Fig. 3. Predicciones desde el año 2024 hasta el 2028 inclusive.

**Etapa predictiva [2023-2028]:** Este tramo comienza con 816 y termina con 868. A partir del 2024, se prevé una estabilidad hasta 2026 y a partir de allí comienza a crecer de forma continua como en la última etapa.

### 4.3 Python

Para esta implementación se utilizarán regresiones lineales utilizando el modelo SARIMAX en Python. Para ello tomaremos los datos del dataset previamente trabajado para su limpieza, y en concreto las columnas Año y Reales. Este dataset será tomado por el script desde un archivo csv. El procedimiento tiene 5 etapas:

**a) Importación de librerías necesarias:** Se especifican las librerías utilizadas para la lectura, entrenamiento y predicción de los datos. Éstas son: `import pandas as pd; import matplotlib.pyplot as plt; plt.style.use('seaborn-v0_8-darkgrid');` from statsmodels.tsa.stattools import adfuller; from statsmodels.tsa.stattools import kpss; from statsmodels.tsa.seasonal import seasonal\_decompose; from statsmodels.tsa.statespace.sarimax import SARIMAX; import warnings.

**b) Lectura y segmentación de los datos:** En esta etapa se realiza la lectura de los datos, su preparación y visualización, además de dividir el dataset en 2 partes: `datos_train` (datos de entrenamiento) y `datos_test` (datos de prueba).

**c) Pruebas de estacionalidad:** Analizamos la serie temporal en búsqueda de indicios de estacionalidad a través del uso de los test estadísticos ADF (Augmented Dickey-Fuller) y KPSS (Kwiatkowski-Phillips-Schmidt-Shin) junto con los valores *Estadístico ADF* y *P-value para cada una*. Se obtienen los siguientes resultados. Figura 4.



Fig. 4. Línea temporal original diferenciando la parte de TEST de la de TRAIN.

Para el test ADF se basa en que, en una serie temporal no estacionaria, las diferencias entre sus valores en los puntos en el tiempo, tampoco lo serán. En la Figura 5, se muestra el valor de Estadística ADF es negativo, lo que indica cierta tendencia a ser estacionaria, ya que entre más negativo sea este valor más evidencia hay contra la hipótesis nula. Para el caso del valor P, su valor es mayor comparado con un nivel de significancia común (0.05) por lo que no proporciona evidencia suficiente para rechazar la hipótesis nula (Si la serie temporal tiene una raíz unitaria, indicaría que la misma no es estacionaria). Por lo tanto, se necesitan argumentos adicionales para una conclusión más sólida. Con KPSS podemos evaluar estacionalidad, pero desde la tendencia estacionaria alrededor de una media fija. Como se observa en la Figura 5, existe el valor estadístico KPSS que es más cercano a cero (0) indicando una menor presencia de tendencia estacionaria en la serie temporal, mientras que cuando es más cercano a uno (1) indica una mayor presencia de tendencia estacionaria en la serie temporal. El valor de P al ser menor que un nivel de significancia común como 0.05, proporciona evidencia suficiente para rechazar la hipótesis nula de tendencia estacionaria alrededor de una media fija. Entonces a pesar de que el valor del estadístico KPSS muestre tendencias estacionarias, el valor de P indica lo contrario y sugiere que hay suficiente evidencia para rechazar la hipótesis nula de tendencia estacionaria y concluir que la serie es no estacionaria.

```
-----
ADF Statistic: -2.5591242971519117, p-value: 0.10174310478886611
KPSS Statistic: 0.6689443103007974, p-value: 0.016368699063563873
```

Fig. 5. Resultados de test ADF y KPSS.

**d) Entrenamiento:** Implementación del modelo predictivo sobre los datos de TEST, para ajustarlo al que mayor acercamiento tenga con los datos reales; Para el entrenamiento del modelo aplicaremos SARIMAX en la partición del dataset llamada “Train” y sus resultados serán comparados con la parte del dataset “Test”. Luego, utilizando el comando *auto\_arima* el cual forma parte del paquete *pmdarima*, se evalúa la serie temporal (datos\_train) para obtener el mejor modelo dentro de las diferentes combinaciones en los parámetros del modelo ARIMA. Los resultados con los parámetros del modelo ARIMAX sugeridos por el comando *auto\_arima*: SARIMAX(0, 1, 0)x(0, 1, 0, 12) sería entonces la configuración recomendada. Esto conlleva a la implementación del Script para implementar el modelo SARIMAX.

**e) Predicción:** Implementación del modelo entrenado anteriormente sobre la totalidad de la serie, para obtener la previsión final. Una vez configurado el modelo, lo volvemos a implementar, pero ahora sobre todo el dataset (data\_3). Luego, se grafica mediante script la predicción obtenida. Esto se muestra en la Figura 6.



Fig. 6. Script y Gráfico de la predicción final.

A través de la regresión lineal, se observa una fluctuación en el número de donantes durante estos años, con una notable disminución en 2027 y un aumento significativo hacia 2030.

### 5 Resultados

En la Tabla 1 se muestra una comparativa de los criterios de evaluación (A: Precisión; B: Facilidad de uso; C: Escalabilidad de datos; D: Nivel de Configuración; E: Presentación de datos; F: Licenciamiento).

**Tabla 1.** Criterios de evaluación de las 3 herramientas.

Excel	Power BI	Python
<b>A</b> Se obtuvo un % de error del 10% alejado de la realidad.	Se observa sombreado en gris el margen de error que puede tomar la previsión.	El modelo ARIMAX permite especificar parámetros que permiten mayor precisión.
<b>B</b> Usuarios sin conocimientos de programación.	Interfaz amigable para usuarios sin experiencia previa, el uso de código es opcional.	Usuarios con experiencia previa en lenguajes de programación.
<b>C</b> Cantidad limitada hasta 1.048.576 filas y 16.384 columnas por cada hoja.	Sin límite de volumen, con opción de trabajar con datos almacenados en la nube.	Sin límite de volumen dependiendo de los recursos físicos (Hardware).
<b>D</b> Más elevada que otras herramientas como PBI pero no llega al nivel de lenguajes de programación.	Su facilidad de uso implica pocas opciones de dato y configuración, limitándose a solo 4 ítems configurables.	Configuraciones a nivel de modelos estadísticos, que permiten moldear con mayor control y detalle.
<b>E</b> Varias opciones de representación, sin llegar al nivel de otras herramientas dedicadas a ello.	Es una herramienta diseñada para visualización de datos, por lo que su presentación en gráficos y diseño es destacable.	Los visuales no tienen tanta personalización e implican en desarrollo de código para su implementación.
<b>F</b> Herramienta licenciada para su versión desktop, y solo permite periodos de prueba como alternativa.	En su versión desktop es gratuita y no limita ninguna funcionalidad.	Se puede utilizar gran variedad de editores de código o IDEs disponibles de forma gratuita.

Según la Figura 7, se analiza cada una de las etapas que componen esta línea temporal referente a los donantes reales de órganos y tejidos. Para tal fin dividiremos el gráfico en partes, quedando de la siguiente manera:



**Fig. 7.** Etapas discriminadas por tramo.

**Etapa 1 [2000-2002]:** Este tramo comienza con 256 donantes y finaliza en 241. Se ve como una etapa estable con baja participación, puede atribuirse a lo novedades o poco conocido de los procedimientos médicos para esos años. El trasplante de órganos constituye actualmente una forma novedosa de terapéutica, planteando en la actualidad preocupación por los grandes costos en sociedades con recursos financieros escasos [12]. **Etapa 2 [2002-2016]:** Este tramo comienza con 241 donantes y finaliza en 514. La cifra estimada de donaciones por año se encuentra en el orden de 7 donantes por millón de habitantes, mientras que el número esperado para satisfacer la demanda oscila entre 20-30. [13]. Durante estos años se comienza a tomar en cuenta los efectos psicológicos que producen estos procedimientos tanto al donante como al receptor, y se implementan programas impulsados por INCUCAI [14]. Además de esto se establece legalmente que los ciudadanos mayores son donantes de órganos presuntos, salvo que se realice una expresa manifestación en sentido contrario. superando situaciones en donde familiares suplían su voluntad mediante una negativa. [15]. **Etapa 3 [2016-2019]:** Este tramo comienza con 514 y termina con 881. A partir de las iniciativas de años anteriores continúa aumentando la cantidad de participantes para los años posteriores hasta 2019 en gran medida por aprobaciones de leyes que regulan actividades relacionadas a la obtención y utilización de órganos, tejidos y células de origen humano en Argentina, Aprobada por unanimidad en ambas cámaras, la Ley 27.447 [16]. En el caso de menores, posibilita la obtención de autorización para la ablación por ambos progenitores o por aquel que se encuentre presente. **Etapa 4 [2019-2020]:** Este tramo comienza con 881 y termina con 446. Notoria caída de donaciones causada principalmente por la pandemia COVID-19, la cual provocó serias dificultades en el manejo de potenciales donantes sumado a los altos riesgos de contagio, sumado a esto la escasez de camas y lo costoso que es por sí solo el proceso de donación. Sin lugar a duda uno de los retos más controversiales y éticos es la transmisión cruzada de la enfermedad por COVID-19 en los centros hospitalarios por parte de los equipos de donación humana y trasplante [17]. **Etapa 5 [2020-2023]:** Este tramo comienza con 446 y termina con 816. Para este periodo se visualiza un recuperó en la cantidad de donaciones, casi hasta los niveles más altos en el año 2019, luego de los meses más críticos de la pandemia COVID-19.

## 6 Conclusiones

Cada una de las herramientas evaluadas tiene sus propias fortalezas y debilidades, que van desde soluciones rápidas y sencillas para usuarios inexpertos quienes solo deben conocer el análisis estadístico que se quiere implementar hasta requerir de conocimientos de programación adicionales que permiten mayor control. Power BI destaca por la facilidad de uso y sus visualizaciones, pero no ofrece más que las configuraciones preestablecidas para realizar las predicciones lineales, siendo esta opción la menos indicada de todas en cuanto a precisión y profundidad se refiere. Por otro lado, Excel también permite realizar gráficos de forma sencilla y dispone de varias funciones estadísticas muy útiles que se combinan para mejorar los resultados,

pero limitadas a las que dispone el software. Finalmente, para este análisis en cuanto a predicciones lineales, Python es la herramienta ideal por sobre las otras dos analizadas, principalmente porque es el usuario quien desarrolla su propia solución a medida, en lugar de utilizar las configuraciones previamente desarrolladas. El hecho de analizar los datos utilizando código fuente marca una diferencia importante respecto a Power BI y Excel, esta característica permitió integrar potentes funcionalidades a través de bibliotecas desarrolladas por la comunidad las cuales se mantienen y mejoran continuamente, además de su potencia para trabajar con grandes cantidades de datos, la hacen superior para el modelado predictivo y más preciso.

## Referencias Bibliográficas

1. INCUCAI - Instituto Nacional Central Único Coordinador de Ablación e Implante. Disponible en: <https://www.argentina.gob.ar/salud/incucaai>
2. Quirk, T. J. (2020). Excel 2019 for Educational and Psychological Statistics. Springer International Publishing.
3. Neyeloff, J. L., Fuchs, S. C., & Moreira, L. B. (2012). Meta-analyses and Forest plots using a microsoft excel spreadsheet: step-by-step guide focusing on descriptive data analysis. BMC research notes, 5, 1-6.
4. Salkind, N. J., & Frey, B. B. (2021). Statistics for people who (think they) hate statistics: Using Microsoft Excel. Sage publications.
5. Moreno Echavarría, R. B. (2012). Propuesta didáctica para la enseñanza de la estadística en los modelos de regresión lineal simple bajo un enfoque constructivista. Facultad de Ciencias.
6. Badawy, M., Ramadan, N., & Hefny, H. A. (2023). Healthcare predictive analytics using machine learning and deep learning techniques: a survey. Journal of Electrical Systems and Information Technology, 10(1), 40.
7. Zhao, Y., Qiao, Z., Xiao, C., Glass, L., & Sun, J. (2021). Pyhealth: A python library for health predictive models. arXiv preprint arXiv:2101.04209.
8. Mirjalili, V., & Raschka, S. (2020). Python machine learning. Marcombo.
9. Prada Penagos, C. (2023). Diagnóstico de la incidencia de la calidad del aire en la prevalencia de enfermedades respiratorias, mediante el uso de datos abiertos y el análisis bajo la herramienta Power BI, en la ciudad de Bogotá.
10. Uscátegui, J. F. B., & Guzmán, I. Y. P. (2021). Análisis de datos con Power Bi, R-Rstudio y Knime. Ra-Ma Editorial.
11. INCUCAI – SINTRA - Central de Reportes y Estadísticas del SINTRA (CRESI). Disponible en: <https://cresi.incucaai.gov.ar/IniciarCresiFromSintra.do>
12. Fermín García Marcos (2001). Aspectos Éticos en Trasplante de Órganos. Cuadernos de Bioética 2001/2. Disponible en: <https://aebioetica.org/revistas/2001/2/45/253.pdf>
13. Silvia Natenson (2005). Donación de órganos: una mirada psicológica. Disponible en: <https://dspace.palermo.edu/dspace/handle/10226/419>
14. Torres, Martín (2009). Sistema nacional de procuración de órganos y tejidos para trasplante. Disponible en: <https://repositorio.uca.edu.ar/handle/123456789/1499>
15. Brizuela, A. G. (2016). La donación de órganos en Argentina. In Iure, 1.
16. Argentina.gob.ar – Ley 27.447. Ley de Trasplante de Órganos, Tejidos y Células. Disponible en: <https://www.argentina.gob.ar/sites/default/files/ley-27447.pdf>
17. Méndez-Martínez, F. (2021). Los Retos de la Donación de Órganos Durante el Brote de COVID-19. Revista Salud y Administración, 8(24), 45-51.
18. Pérez González, Luis Orlando (2006). Microsoft Excel: una herramienta para la investigación.
19. Barrios, S. (2024). Análisis y visualización de datos sobre una herramienta de software. Práctica introductoria en Power BI.