

Machine Learning para la Gestión de Activos: Predicción de Vida Útil en Equipos Tecnológicos Educativos

Yenit Carolina Gómez Ardila ¹ yenitc.gomez@utadeo.edu.co

Jorge Ivan Romero-Gelvez ² jorgei.romerog@utadeo.edu.co

^{1,2} Facultad de Ciencias Naturales e Ingeniería

Universidad Jorge Tadeo Lozano

Bogotá, Colombia

Resumen

Resumen - Este estudio utiliza técnicas de Machine Learning para predecir la vida útil de los activos de la Universidad Jorge Tadeo Lozano utilizados para la enseñanza. Se analizó un conjunto de datos que incluye varias características de los activos, como el costo, la fecha de adquisición, y la vida útil estimada. Se aplicaron varios métodos, incluyendo agrupamiento K-Means, Análisis de Componentes Principales (PCA), Regresión Lineal, Random Forest y Support Vector Regression, para identificar patrones y predecir la vida útil de los activos. Los resultados indican que hay diferencias significativas en la vida útil de los activos entre los diferentes clusters identificados. Además, se encontró que los modelos de regresión pueden predecir con precisión la vida útil de los activos. Estos hallazgos tienen implicaciones importantes para la gestión de los activos universitarios y proporcionan una base para futuras investigaciones en este campo.

Palabras clave - Machine Learning, obsolescencia, gestión de activos, predicción de vida útil, depreciación, IoT, análisis de clusters, regresión.

Resumen

Abstract - This study utilizes Machine Learning techniques to predict the lifespan of the assets of the Universidad Jorge Tadeo Lozano used for teaching. A dataset that includes various characteristics of the assets, such as cost, acquisition date, and estimated lifespan, was analyzed. Several methods were applied, including K-Means clustering, Principal Component Analysis (PCA), Linear Regression, Random Forest, and Support Vector Regression, to identify patterns and predict the lifespan of the assets. The results indicate that there are significant differences in the lifespan of the assets between the different clusters identified. Moreover, it was found that regression models can accurately predict the lifespan of the assets. These findings have important implications for the management of university assets and provide a foundation for future research in this field.

Keywords - Machine Learning, asset management, lifespan prediction, cluster analysis, regression, Universidad Jorge Tadeo Lozano.

1. Introducción

1.1. Antecedentes y Justificación del Estudio

En la gestión de activos universitarios, es fundamental tener una comprensión precisa de la vida útil de los activos utilizados para la enseñanza [Durán and Durán \(2019\)](#). La duración de vida útil de los activos puede tener un impacto significativo en la planificación financiera y en la toma de decisiones estratégicas de la universidad [Mohammadifardi et al. \(2019\)](#). Además, la mayoría de las universidades cuentan con una amplia gama de activos utilizados para la enseñanza, como equipos de laboratorio, tecnología de la información y herramientas educativas [Kunwar \(2020\)](#).

Sin embargo, determinar la vida útil de estos activos puede ser un desafío, ya que depende de múltiples factores, como el costo, la fecha de adquisición y la estimación de vida útil. Investigaciones previas han demostrado que las técnicas de aprendizaje automático pueden aplicarse con éxito en la predicción de la vida útil de activos. Por ejemplo, [Gu et al. \(2020\)](#) aplicaron varios modelos de aprendizaje automático para predecir la vida útil de activos en el mercado de valores estadounidense basándose en múltiples factores. Estos estudios han demostrado el potencial del aprendizaje automático en predecir con precisión la vida útil de activos y sus aplicaciones en diversos campos.

La obsolescencia ha implicado un desafío tecnológico [Moon et al. \(2022\)](#) dentro de la Universidad de Bogotá Jorge Tadeo Lozano frente al uso de los equipos de cómputo asignados a la academia durante los periodos del 2019 al 2022. Por lo anterior, se hace necesario considerar la vida útil de los equipos de cómputo de la universidad, que están asignados a la enseñanza de los estudiantes, evaluar si aún proporcionan el valor adecuado para el desarrollo de la academia y tomar medidas para que los activos sean más adaptables a los cambios o necesidades del mercado [Velásquez and Vergara \(2023\)](#).

Esto denota un desafío a medida que surgen tecnologías más nuevas y eficientes en una línea de tiempo afectada por el fabricante, las normas Niif [Arrieta et al. \(2023\)](#) y su clasificación de vidas útiles, el avance de la revolución 4.0 y la expectativa del mercado académico. Es importante visibilizar a las directivas de la universidad esta problemática de la obsolescencia y su incidencia en una enseñanza innovadora, para evaluar las medidas acertadas en el

modo de adquisición y administración de sus activos fijos, prediciendo los futuros niveles de obsolescencia, controlando o minimizando el impacto financiero y ambiental que puede generar una decisión de mantenerse innovador en este campo.

La gestión eficiente de los activos es una tarea crucial para cualquier institución, y las universidades no son una excepción [Feng et al. \(2022\)](#). La vida útil de los activos, especialmente los utilizados para la enseñanza, puede influir significativamente en la planificación de los recursos y en la calidad de la educación. Sin embargo, predecir la vida útil de estos activos puede ser un desafío debido a la variedad de factores que pueden influir en ella, como el uso, el mantenimiento, y los avances tecnológicos. En este contexto, los métodos de Machine Learning pueden proporcionar herramientas valiosas para analizar los datos disponibles y hacer predicciones precisas.

Iniciaremos con la definición de obsolescencia tomado desde la perspectiva propuesta por las NIIF en sus vidas útiles, continuando con la programación de obsolescencia creada por los fabricantes y la obsolescencia dictada por la continua evolución de las tecnologías 4.0, luego trataremos de cuantificar estos conceptos cualitativos aplicando técnicas de Machine Learning como el agrupamiento K-Means, el Análisis de Componentes Principales, la Regresión Lineal, Random Forest y Support Vector Regression para predecir futuras fechas de obsolescencia de los equipos de cómputo de la UJTL y finalizaremos con las conclusiones de este estudio.

1.2. Objetivos del Estudio

El objetivo es evaluar la vida útil de los activos utilizados para fines educativos en la Universidad Jorge Tadeo Lozano desde 2019 hasta 2022. Mediante técnicas de aprendizaje automático, buscamos identificar patrones en los datos y desarrollar modelos de regresión que puedan predecir la vida útil de los activos basándose en sus características, fechas de puesta en servicio, ciclos de mantenimiento, longevidad según la política contable NIIF de la universidad, comparaciones entre fabricantes, entre otros. Además:

- Evaluar si estos dispositivos aún proporcionan un valor adecuado para el desarrollo académico y las necesidades actuales.
- Tomar medidas para hacer que los activos sean más adaptables a cambios o requisitos del mercado.

- Pronosticar las vidas útiles de los activos y gestionar/controlar/minimizar el impacto financiero y ambiental asociado con mantenerse innovador en este campo.
- Obsolescencia dominada por la mejora de la funcionalidad (FIDO): el fabricante debe cambiar los productos para mantener la competencia en el mercado con otro fabricante similar.

Los cuatro tipos de obsolescencia pueden afectar solo a una parte de la instalación. Si la obsolescencia de una parte de la instalación condiciona la vida útil de la misma, se debe realizar una evaluación sobre la oportunidad de cambiar dicha parte.

2. Estado del Arte

2.1. Definición Vida Útil de los activos

La “vida útil” no es término que pueda estandarizar en un concepto único general. La vida útil es una variable que debe determinarse dentro del costo-beneficio de cualquier inversión a gran escala [Marquez et al. \(2021\)](#)

En el desarrollo de éste estudio, hablaremos de La “vida útil” en tres puntos de vista, la vida útil determinada por el fabricante, en el uso de los elementos requeridos para el ensamblaje de los activos, los cuales determina la vida útil del activo por la obsolescencia de los componentes de fabricación [Marquez et al. \(2021\)](#), como el estudio realizado por Marquez y Martínez en la vida útil de telescopios de la NASA los cuales están calculados bajo los parámetros dados por los fabricantes en los compuestos que hacen parte en la fabricación de éstos activos. Aunque aquí también se abre en debate, de la amplitud de la vida útil dada por un programa estricto de mantenimiento con personal calificado, los cuales podrán permitir dar una ampliación o mayor durabilidad a los activos fijos, garantizando la integridad de la estructura del AF. La vida útil establecida por las normas NIIF, la cual se basa en el tiempo estimado de uso que el activo va a tener en la empresa. [de Normas Internacionales de Contabilidad \(2009\)](#), y la vida útil dada por el creciente incremento de la tecnología en esta última revolución 4.0 [Teoh et al. \(2023\)](#)

Una de las variables que afecta la vida útil de los activos es la Obsolescencia. De acuerdo al estudio de Marquez, Martínez y Miranda, establecen cuatro tipos

- Logística: las piezas (materiales, software o fabricación) no se pueden adquirir
- Funcional: el sistema o subsistema aún funciona, pero los requisitos han cambiado, entonces, el sistema o subsistema está obsoleto porque la función, el rendimiento o la confiabilidad son diferentes.
- Tecnológico: hay componentes avanzados todos los días. Esto puede ser un problema si es necesario comprar piezas de repuesto al fabricante, ya que solo podrían estar disponibles componentes más avanzados.

2.2. Las NIIF

Basada en la sección 17 Propiedades, Planta y Equipo de las NIIF para PYMES la cual es una base de la actual política contable de Propiedad Planta y Equipo de la universidad, [Lozano \(2016\)](#) la vida útil de los activos esta dada por el número de periodos en los cuales se espera la entidad los use, siendo este argumento de las NIIF muy al parecer de las PYMES. A demás la misma esta sujeta a revisión por parte de la entidad en que los casos de sus expectativas actuales sean diferentes puede modificar el valor residual, el método de depreciación o la vida útil como un cambio de estimación contable de acuerdo con los parágrafos 10.15 y 10.18 de la norma. [de Normas Internacionales de Contabilidad \(2009\)](#)

Para determinar la vida útil de un activo, una entidad deberá considerar todos los factores siguientes: (a) La utilización prevista del activo. (b) El desgaste físico esperado, que dependerá de factores operativos tales como el número de turnos de trabajo en los que se utilizará el activo, el programa de reparaciones y mantenimiento, y el grado de cuidado y conservación mientras el activo no está siendo utilizado. (c) La obsolescencia técnica o comercial procedente de los cambios o mejoras en la producción, o de los cambios en la demanda del mercado de los productos o servicios que se obtienen con el activo. (d) Los límites legales o restricciones similares sobre el uso del activo, tales como las fechas de caducidad de los contratos de arrendamiento relacionados

Basado en lo anterior, expuesto por la norma Propiedad Planta y Equipo de NIIF para PYMES, es claro que la norma no expresa una vida útil específica, sino que expone una serie de variables para tener en cuenta por las PYMES y así, establecer sus propias vidas útiles. La norma habla no solo del uso como factor, sino los posibles mantenimientos; sin un patrón de mantenimientos para los equipos, serían un equipo inútil antes del tiempo proyectado para su uso. También la norma aclara que los cambios en el mercado genera una obsolescencia la cual debe ser tenida en cuenta, por las constantes mejoras del mercado o las constantes demandas que se generan en los

activos, que hacen generar en sus fabricantes nuevas y constantes mejoras. Esto quiere decir que la norma lo advierte, pero lo deja en manos de la empresa, la decisión y revisión de las variables, para establecer el mejor método de depreciación de conformidad al beneficio de sus estados financieros.

Revisando esto, podríamos decir que las NIIF no intervienen directamente en nuestro problema de estudio, antes bien, advierten de las variables que pueden afectar las decisiones financieras, con respecto a las inversiones que realizan las PYMES y da una apertura a que se tomen las mejores decisiones para los estados financieros de la organización. A esto le denominan como los juicios profesionales pertinentes para contabilizar la depreciación de propiedades, planta y equipo y pueden incluir lo siguiente: distribuir el monto inicialmente reconocido en cuanto a una partida de propiedades, planta y equipo a sus componentes principales que, deben depreciarse por separado; estimar la vida útil de la partida (o la parte significativa de la partida) de propiedades, planta y equipo; estimar el valor residual de la propiedad, planta y equipo (o la parte significativa de la partida); y determinar el método de depreciación adecuado que refleje el patrón en el cual la entidad espera consumir la propiedad, planta y equipo (o la parte significativa de la partida). [de Normas Internacionales de Contabilidad \(2009\)](#)

Las normas NIIF también establecen lineamientos para el reconocimiento, evaluación de los activos en los estados financieros, requiriendo evaluaciones periódicas físicas y valoraciones, para establecer cambios de valor del activo ante estados financieros, con el fin de evaluar cambios que indiquen una pérdida de valor o una revaloración por mejoras y mantenimientos que alarguen la vida útil de los mismos

2.3. Revolución 4.0

La revolución 4.0 esta dada por la integración de tecnologías digitales como inteligencia artificial (IA), robótica, internet de las cosas (IoT), big data, información en la nube y otras aplicaciones. En el contexto de la enseñanza en las universidades, el impacto de la integración de estas herramientas tecnológicas genera un impacto en la forma que se llevan a cabo las actividades de enseñanza, investigación y en la necesidad de adquirir nuevos activos o actualizar los existentes para adaptarse a la demanda cambiante de la educación y la investigación.

Este avance tecnológico afecta en la vida útil de los activos, afecta en el periodo que se espera que genere beneficios económicos para la universidad.

A continuación, mencionaremos algunas herramientas que nos ofrece el IoT y la revolución 4.0 para la gestión de los activos fijos de la Universidad:

- La aplicación del RFID y el almacenamiento en la nube [Andrioli et al. \(2017\)](#), se pueden integrar para el control y gestión de los activos, control de mantenimientos y existencia, monitoreo de mantenimientos predictivos, incorporando sensores a estos dispositivos a través del IoT recopilando datos en tiempo real y generando respuestas sobre el estado y el rendimiento de los activos. Generando información mas precisa para la toma de decisiones, solucionando problemas antes que los mismos se presenten o antes que se conviertan en fallas mayores. Prolongando la vida útil de los activos al mantener condiciones óptimas de funcionamiento. Claro que, y se aclara, se evita la obsolescencia por daños, pérdidas de inventario, o mala administración de los activos; esto es solo una parte “controlable” de nuestro problema de investigación, ya que, como veremos, la vida útil y la obsolescencia no solo se da por estas razones, sino por otros factores.

- Construcción de un modelo de gestión propio de los activos. Cuando se construye un sistema de gestión de activos propio, con confiabilidad de la información, la gestión de la universidad puede volverse mas estratégica, sencilla, clara, racional frente a sus gastos y a la expectativa de lo que desea generar en el valor de sus activos y el impacto de ellos en la educación. Esto a su vez, contribuye en la sostenibilidad del negocio, bajo la premisa de ser innovadores sin afectar las decisiones financieras que ello implica. En la investigación realizada por Leandro Andrioli, De la Rosa entre otros, ofrecen una solución bajo el modelo ACMA – Control y Gestión Automático de los activos. Este modelo genera un control de múltiples unidades con sensores RFID, combinados con información en línea con almacenamiento en la nube, generando estimaciones del uso actual de la red, congestión de la misma, consumo eléctrico, velocidad de datos entre otros. [Andrioli et al. \(2017\)](#)

- Mejora en eficiencia energética: el IoT permite monitorear y controlar de forma inteligente sistemas de iluminación, climatización y consumo de energía de equipos; reduciendo los costos operativos. Al aumentar la eficiencia energética, los activos pueden funcionar de manera más sostenible y extender su vida útil.

- Actualización y reemplazo oportuno: la revolución 4.0 esta marcada por una aceleración en los



Figura 1: La revolución Industrial 4.0 (Consejo Colombiano de Seguridad 2020)

avances tecnológicos; significando en una obsolescencia acelerada. Es necesario que la universidad este atenta a estos cambios de la tecnología y evalúe continuamente la necesidad de realizar actualizaciones o reemplazos oportunos para mantenerse innovador en el mercado.

Estas transformaciones digitales intensivas en los activos pueden mostrarnos un lado oscuro en la vida útil de los activos y en la correcta gestión de los mismos. Un estudio analizó los esfuerzos de transformación digital en las organizaciones. La digitalización y la globalización han sido consideradas las dos disrupciones más importantes en la gestión estratégica de los últimos 40 años, a través de la transformación de los modelos de negocio de las empresas. [Buck et al. \(2023\)](#). La idea en este estudio se enfoca en no creer la que transformación digital asume que tiene un impacto positivo en las organizaciones. Aquellas organizaciones o industrias donde basan sus actividades y generación de valor en sus activos, una transformación digital implica desafíos estratégicos y organizacionales. Esta transformación viene con intersecciones de las herramientas dadas por la revolución 4.0

El núcleo de la Industria 4.0 está relacionado con la interacción de las tecnologías de la información y la comunicación, por tanto, se limita principalmente a las mejoras de los procesos. [Buck et al. \(2023\)](#). El desarrollo de esta industria allana el camino para desarrollar productos y servicios innovadores altamente personalizados. Dentro de estas intersecciones se pueden aplicar:

1. IoT y Big Data: es la conexión de dispositivos a través de internet generando datos en tiempo real los cuales pueden ser analizados para obtener información y tomar decisiones. La gestión de los activos se puede basar en la interacción

de estas dos tecnologías prediciendo el fallo de los equipos de fabricación, estableciendo el mantenimiento de los activos y utilizando el Machine Learning o aprendizaje automático.

2. IA y Robótica: el Machine Learning o aprendizaje automático y redes neuronales permiten sistemas más autónomos basados en redes neuronales y patrones establecidos que permiten respuestas o decisiones inteligentes y adaptables de acuerdo a las variables dadas; aumentando la eficiencia, productividad en cualquier campo. (LinkedIn Learning Corporatio 2023)
3. Realidad Virtual (RV) y Realidad Aumentada (RA): esta interacción está revolucionando la forma en que interactuamos con el mundo digital y el mundo físico. Estas tecnologías son aplicables en la formación y capacitación, simulación de escenarios que permiten visualizar información en tiempo real, generando instrucciones paso a paso.
4. Impresión 3D y Fabricación aditiva: esto está transformando la forma en que se fabrican componentes y productos. Permite la creación de objetos tridimensionales a partir de modelos digitales, reduciendo costos de producción, facilitando las mejoras y la personalización evitando desperdicios en el proceso.
5. Blockchain y Ciberseguridad: conocido por su aplicación en las criptomonedas, encuentra aplicaciones en seguridad, gestión de datos, permitiendo registros seguros y transparentes, protegiendo la identidad de datos evitando fraudes.

Es claro que pueden existir muchas más interacciones dentro de esta revolución 4.0. A medida que la tecnología avanza desarrollando nuevas innovaciones; pero como lo decíamos antes, cada vez que avanzan estas tecnologías genera un hoyo negro que absorbe todo lo que ve y así como genera soluciones avanzadas, a otros sistemas o campos puede generar necesidades, desactualizaciones y estableciendo metas más altas para ser cada vez más innovador.

Si bien la transformación digital puede conducir a un aumento de la eficiencia, la innovación, en el sector educativo crea valor en la interfaz del consumidor generando un impacto positivo o negativo, dependiendo de esa innovación para desarrollar su potencial como profesional.

Existen en varias industrias la presión para enfrentarse a estas mejoras que van a pasos agigantados, en donde es necesario, atender la necesidad del

consumidor sin afectar los inversionistas o accionistas siendo sostenibles financiera y ambientalmente, porque sí, hay que pensar en la generación de “trash” o basura electrónica en la ejecución de sus actividades. Las empresas deberán buscar la incorporación de tecnologías digitales que reduzcan o eliminen el daño ambiental [Buck et al. \(2023\)](#).

3. Metodología

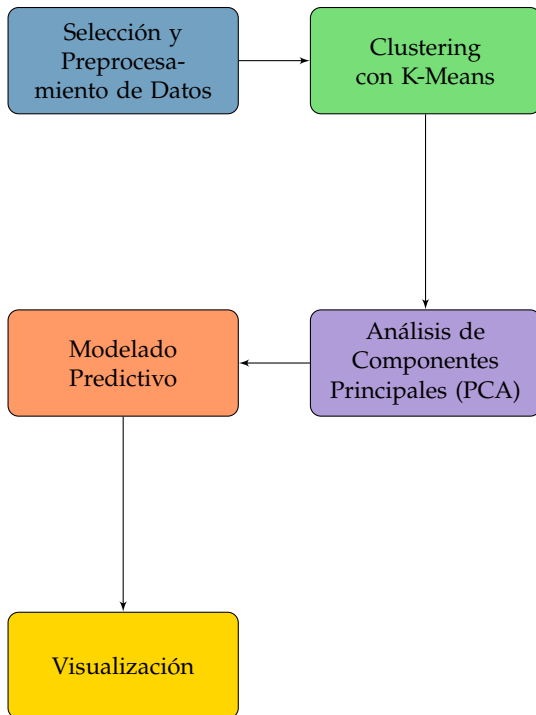


Figura 2: Secuencia de implementación metodológica

3.1. Selección y Preprocesamiento de Datos

El dataset fue proporcionado por la Universidad Jorge Tadeo Lozano, conteniendo datos relativos a equipos de computación utilizados en la universidad. La preselección de datos implicó el uso de librerías como pandas y openpyxl para cargar y visualizar los datos iniciales. Se añadió una nueva columna denominada VIDA ÚTIL RESTANTE calculada a partir de las columnas FIN DEPRECIACIÓN y DEPRN START DATE. Posteriormente, se seleccionaron y transformaron las columnas ORIGINAL COST y LIFE IN MONTHS para ser utilizadas en los análisis subsecuentes, haciendo imputaciones para los

valores faltantes y estandarizando los datos con la ayuda de StandardScaler.

3.2. Clustering con K-Means

Se utilizó el algoritmo K-Means para identificar clusters en el dataset. El número óptimo de clusters se estableció en tres. Se realizaron varias iteraciones del análisis, en cada una de las cuales se refinaron las variables seleccionadas y los parámetros del modelo.

3.3. Análisis de Componentes Principales (PCA)

Para reducir la dimensionalidad de los datos y permitir una visualización clara de los clusters, se aplicó un Análisis de Componentes Principales (PCA) con dos componentes principales. Se etiquetaron las observaciones según el cluster asignado por K-Means y se visualizó en un scatter plot, mostrando claramente los grupos definidos.

3.4. Modelado Predictivo

Para predecir la VIDA ÚTIL RESTANTE de los activos, se utilizaron tres modelos predictivos: Regresión Lineal, Random Forest y Support Vector Regression (SVR). Los modelos se entrenaron utilizando un conjunto de datos de entrenamiento que comprendía el 80% del dataset total, y se validaron con un conjunto de pruebas del 20% restante. La métrica para evaluar el rendimiento de cada modelo fue la raíz del error cuadrático medio (RMSE).

3.5. Visualización

A lo largo de las diferentes etapas del estudio, se utilizaron técnicas de visualización de datos, incluyendo scatter plots para visualizar los clusters identificados, y gráficos para verificar la distribución de las variables. Esto facilitó la interpretación de los resultados y permitió identificar patrones y tendencias en los datos.

4. Resultados

4.1. Resultados de K-Means y PCA

El método de agrupamiento jerárquico implementado, K-means basado en el algoritmo desarrollado por Yuan y Street [Marrero et al. \(2021\)](#), reveló la existencia de tres grupos en los datos, como se puede observar en la Figura 3. Cada uno de estos grupos

representa un conjunto de activos que comparten características similares. Esto sugiere diferencias significativas en la vida útil de los activos entre los grupos identificados. Estas conclusiones se respaldan mediante el Análisis Factorial de Componentes Principales, que demostró una clara separación de los activos dentro de los tres grupos identificados. Esto indica que los activos dentro cada grupo poseen rasgos y comportamientos distintivos que afectan su vida útil.

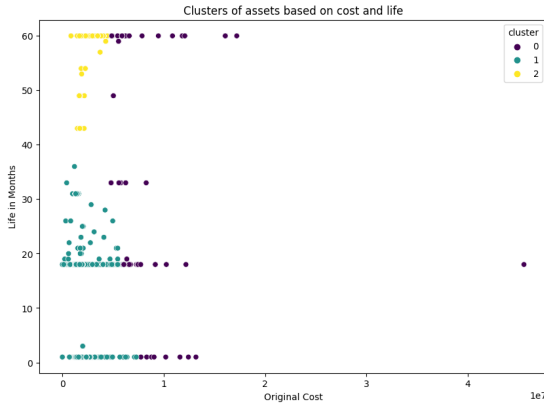


Figura 3: Agrupación de Activos según Costo y Vida Útil

La aplicación del Análisis de Componentes Principales permitió visualizar claramente la separación entre los clusters en un gráfico de dispersión bidimensional, tal y como muestra la Figura ??1. Esto proporciona una representación visual de las diferencias en las características y comportamientos de los activos dentro de cada grupo identificado. Además, se realizaron modelos de regresión lineal, Random Forest y Support Vector Regression para predecir la vida útil de los activos. Para la regresión lineal, se utilizó un enfoque de mínimos cuadrados ordinarios para ajustar una línea recta a los datos y predecir la vida útil de los activos. Para el modelo Random Forest, se utilizó un conjunto de árboles de decisión para predecir la vida útil de los activos.

4.2. Resultados de los Modelos de Regresión

Los modelos de regresión proporcionaron estimaciones precisas sobre la vida útil de los activos. Las estimaciones obtenidas mediante Regresión Lineal y Random Forest fueron altamente similares, mientras que las del Support Vector Regression mostraron ligeras diferencias. Estas variaciones podrían atribuirse a cómo cada modelo captura las relaciones

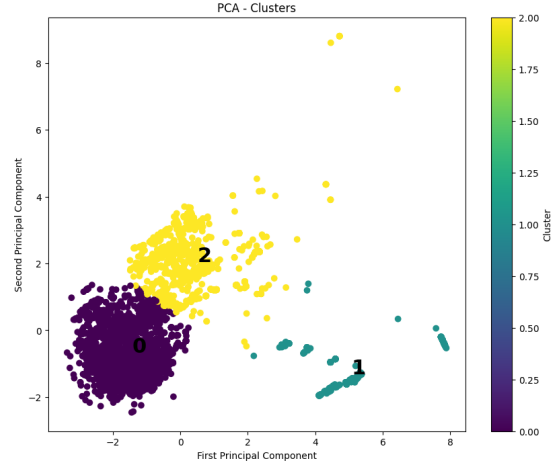


Figura 4: Gráfico de dispersión con Etiquetas de Clusters

entre las variables en estudio, como se muestra en la Figura 5.

Los resultados obtenidos en este estudio indican que existen diferencias significativas en la vida útil de los activos utilizados para la enseñanza en la Universidad Jorge Tadeo Lozano. Estas diferencias se respaldan mediante el análisis de Componentes Principales, que demostró una clara separación de los activos dentro de los tres grupos identificados. Esto indica que los activos dentro de cada grupo poseen rasgos y comportamientos distintivos que afectan su vida útil. Además, los modelos de regresión utilizados en este estudio demostraron ser eficaces para predecir la vida útil de los activos.




Figura 5: Comparación del Rendimiento de Modelos

5. Discusión

5.1. Interpretación de los Resultados

Los resultados de este estudio indican que es posible predecir la vida útil de los activos universitarios

utilizando técnicas de Machine Learning. Los modelos de regresión desarrollados en este estudio pueden proporcionar predicciones precisas.

Clúster	Modelo	Media	SEM
0	LR	21.2851	0.1386
	RF	21.2935	0.2226
	SVR	32.7681	0.1238
1	LR	59.5833	0.0589
	RF	60.0000	0.0000
	SVR	31.8966	0.0685
2	LR	57.5921	0.2059
	RF	57.3740	0.2121
	SVR	35.7079	0.2775

Cuadro 1: Comparación de la media y SEM de diferentes modelos de regresión agrupados por clúster.

En la tabla 1 se presenta una comparación detallada de tres modelos de regresión diferentes: Linear Regression, Random Forest y Support Vector Regression, agrupados por clústeres (0, 1 y 2). A continuación, se discuten los resultados obtenidos:

Linear Regression Para el clúster 0, el modelo muestra una media de 21.2851 con un SEM de 0.1386, indicando un buen grado de precisión en las predicciones. En el clúster 1 y 2, las medias son considerablemente más altas, siendo 59.5833 y 57.5921 respectivamente, con SEM relativamente bajos, lo que demuestra una consistencia en las predicciones del modelo.

Random Forest El modelo de Random Forest muestra un comportamiento similar al de la regresión lineal para los clústeres 0 y 2, con medias muy cercanas entre sí. Sin embargo, para el clúster 1, se alcanza una media exacta de 60.0000, y sorprendentemente, un SEM de 0.0000, indicando que todas las predicciones fueron exactamente iguales. Este resultado podría sugerir un sobreajuste del modelo para los datos del clúster 1.

Support Vector Regression En contraste con los otros dos modelos, el Support Vector Regression muestra medias más bajas para los clústeres 1 y 2, y una media más alta para el clúster 0. Esto indica que este modelo está interpretando y ajustándose a los datos de una manera significativamente diferente en comparación con los otros dos modelos.

General Al observar el error absoluto medio (MAE) global del Random Forest (0.1789), se puede inferir un rendimiento aceptable del modelo. Sin embargo, para una evaluación más precisa, sería beneficioso comparar este MAE con los de los otros dos mode-

los, lo que proporcionaría una comprensión más clara de cuál modelo está funcionando mejor en general.

Es importante considerar que los SEM altos en algunos clústeres indican una mayor dispersión de los errores, lo que puede señalar una menor confiabilidad en las predicciones del modelo correspondiente.

En conclusión, cada modelo presenta ventajas y desventajas únicas, y la selección del modelo óptimo dependería de factores adicionales específicos del contexto y los objetivos de la investigación. Sería prudente explorar más a fondo mediante técnicas como la validación cruzada para garantizar que el modelo seleccionado sea el más adecuado para los datos en cuestión.

5.2. Comparación con Otros Estudios

Aunque existen múltiples estudios que utilizan el Machine Learning para predecir la vida útil de diversos activos y equipos en diferentes industrias, esta investigación es única en su enfoque hacia los activos universitarios utilizados para la enseñanza. El análisis comparativo con estudios previos puede ser limitado debido a esta especificidad, pero los resultados son consistentes con la literatura existente en términos de la capacidad del Machine Learning para predecir la vida útil de los activos basándose en datos históricos y características de los activos.

5.3. Implicaciones Prácticas

Los hallazgos de este estudio tienen varias implicaciones prácticas. Para la Universidad Jorge Tadeo Lozano, y posiblemente para otras instituciones similares, los modelos desarrollados pueden ser utilizados para predecir la vida útil de sus activos de enseñanza, lo que puede facilitar una planificación y gestión de recursos más eficientes. Además, estos modelos pueden ser utilizados para identificar los activos que pueden necesitar mantenimiento o reemplazo, lo que puede ayudar a prevenir interrupciones en la enseñanza y a mejorar la calidad de la educación.

5.4. Limitaciones y Futuras Direcciones de Investigación

Aunque los resultados de este estudio son prometedores, existen algunas limitaciones. En primer lugar, el estudio se basó en datos de una única universidad, lo que puede limitar la generalización de los resultados. En segundo lugar, aunque los modelos de regresión proporcionaron predicciones precisas

de la vida útil de los activos, estos modelos pueden no capturar todas las posibles relaciones entre las variables, especialmente las no lineales. Futuras investigaciones podrían explorar el uso de otros métodos de Machine Learning, como las redes neuronales, que pueden ser capaces de capturar relaciones más complejas. Además, sería útil realizar estudios similares en otras universidades para ver si los hallazgos de este estudio se mantienen en diferentes contextos.

Regression para predecir la vida útil de los activos y subraya la importancia de su utilización para la eficacia en la gestión de los activos utilizados en la enseñanza de la Universidad Jorge Tadeo Lozano.

6. Conclusión

Este estudio académico demostró la eficacia de las técnicas de Machine Learning para predecir la vida útil de los activos universitarios utilizados en la enseñanza. Los resultados evidenciaron que los modelos de Regresión Lineal, Random Forest y Support Vector Regression pueden brindar predicciones precisas acerca del tiempo de duración de dichos activos, basándose en sus características. Además, se llevó a cabo un análisis de agrupamiento K-Means y el Análisis de Componentes Principales para identificar patrones en los datos y visualizar la estructura de manera efectiva.

Se identificó que algunos activos, a pesar de su corta vida útil pronosticada, todavía proporcionan un valor educativo adecuado en función de las necesidades actuales de la universidad. Esto sugiere que, en lugar de reemplazarlos de inmediato, se pueden tomar medidas para optimizar su uso y adaptarlos a los cambios en el entorno educativo, lo que podría generar ahorros significativos.

Nuestro estudio resalta la importancia de una gestión pro activa de los activos para minimizar el impacto financiero y ambiental. Los modelos de regresión han demostrado que la obsolescencia según la política contable NIIF y las prácticas de mantenimiento pueden influir considerablemente en la vida útil de los activos. Esto subraya la necesidad de adoptar estrategias de mantenimiento eficaces y alinear las políticas contables con la vida útil real de los activos, promoviendo así la sostenibilidad financiera y ambiental de la universidad.

Los hallazgos de este estudio tienen importantes implicaciones en la gestión de activos en la enseñanza y establecen una base sólida para futuras investigaciones en este campo académico. Sin embargo, es necesario llevar a cabo más investigaciones para explorar otros métodos y validar estos resultados en diversos contextos. En resumen, este estudio destaca la eficacia de las técnicas de Machine Learning como K-Means, Análisis de Componentes Principales, Regresión Lineal, Random Forest y Support Vector

Referencias

- Andrioli, L., da Rosa Righi, R., da Costa, C. A., and Graebin, L. (2017). Observing network performance and congestion on managing assets with rfid and cloud computing. *Journal of Computer and Communications*, 05:43–66.
- Arrieta, J. J. V., Guardo, F. A. P., and Cardozo, N. C. H. (2023). Implementación de las normas internacionales de información financiera (niif) para las pequeñas y medianas empresas (pymes) en colombia. *Contaduría y Administración*, 68:393.
- Buck, C., Clarke, J., de Oliveira, R. T., Desouza, K. C., and Maroufkhani, P. (2023). Digital transformation in asset-intensive organisations: The light and the dark side. *Journal of Innovation Knowledge*, 8:100335.
- de Normas Internacionales de Contabilidad, C. (2009). Fundación ifrs: Material de formación sobre la niif para las pymes.
- Durán, O. and Durán, P. A. (2019). Prioritization of physical assets for maintenance and production sustainability.
- Feng, Q., Ramli, R. M., and Liu, Y. (2022). The path of digital government and university asset intelligence value-added service driven by block chain technology.
- Gu, S., Kelly, B., and Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5):2223–2273.
- Kunwar, R. (2020). Impact of ict on adopting online education at higher education in nepal: A factual analysis.
- Lozano, U. J. T. (2016). Política contable propiedad, planta y equipo.
- Marquez, P., Martinez, O., and Miranda, J. M. (2021). Useful life of astrophysical scientific facilities. *World Journal of Engineering and Technology*, 09:804–815.
- Marrero, L., Carrizo, D., García-Santander, L., and Ulloa-Vásquez, F. (2021). Uso de algoritmo k-means para clasificar perfiles de clientes con datos de medidores inteligentes de consumo eléctrico: Un caso de estudio.
- Mohammadifardi, H., Knight, M. W., and Unger, A. J. A. (2019). Sustainability assessment of asset management decisions for wastewater infrastructure systems—implementation of a system dynamics model.
- Moon, K. S., Lee, H. W., and Kim, H. (2022). Adaptive data selection-based machine learning algorithm for prediction of component obsolescence. *Sensors*, 22.
- Teoh, Y. K., Gill, S. S., and Parlikad, A. K. (2023). Iot and fog computing based predictive maintenance model for effective asset management in industry 4.0 using machine learning. *IEEE Internet of Things Journal*, 10:2087.
- Velásquez, A. C. F. and Vergara, D. M. J. (2023). Análisis de la gestión de activos fijos en la universidad de antioquia.