

Machine Learning applied to Projected Financial Statements (PFS)

Coster Bellido-Zea, Bachiller¹, Bertha Villalobos-Meneses, Doctor², Carlos Alfaro-Rodriguez, Maestro³, Anna Grados-Espinoza, Maestro⁴, Nestor Gomero-Ostos, Doctor⁵, Fernando Hoyos-Rivas, Doctor⁶, Francisco Ramirez-Veliz, Doctor⁷.

^{1,2,3,4,5,6,7} Universidad Nacional del Callao, coster.bellido@gmail.com, bmvillalobosm@unac.edu.pe, chalafaror@unac.edu.pe, akgradose@unac.edu.pe, ngomeroo@unac.edu.pe, fahoyosr@unac.edu.pe, jframirezv@unac.edu.pe

Abstract.- Projected financial statements represent one of the most reliable sources when it comes to making decisions involving the company's long-term performance. Therefore, finding methods to optimize their preparation and accuracy is the holy grail of financial accounting. The objective of this research is to use machine learning in projected financial statements, in order to obtain more accurate data through training in a tetradimensional space or also called Euclidean space of n dimensions.

Keyword.-Artificial intelligence, projected financial statements, machine learning, scikit learn.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).

Machine Learning aplicado a los Estados Financieros Proyectados (EFP)

Coster Bellido-Zea, Bachiller¹, Bertha Villalobos-Meneses, Doctor², Carlos Alfaro-Rodriguez, Maestro³, Anna Grados-Espinoza, Maestro⁴, Nestor Gomero-Ostos, Doctor⁵, Fernando Hoyos-Rivas, Doctor⁶, Francisco Ramirez-Veliz, Doctor⁷.

^{1,2,3,4,5,6,7} Universidad Nacional del Callao, coster.bellido@gmail.com, bmvillalobosm@unac.edu.pe, chalafaror@unac.edu.pe, akgradose@unac.edu.pe, ngomeroo@unac.edu.pe, fahoyosr@unac.edu.pe, jframirezv@unac.edu.pe

Resumen: Los estados financieros proyectados representan una de las fuentes más fiables, cuando se trata de tomar decisiones que involucren el buen desenvolvimiento de la empresa a largo plazo. Por lo que encontrar métodos que optimicen su elaboración y precisión, es el santo grial de la contabilidad financiera.

El objetivo de esta investigación es utilizar el aprendizaje automático en los estados financieros proyectados, para poder obtener datos más precisos a través de un entrenamiento en un espacio tetradimensional o también llamado espacio euclidiano de n dimensiones.

Palabra clave: Inteligencia artificial, estados financieros proyectados, machine learning, scikit learn.

I) INTRODUCCIÓN

La empresa Alicorp S.A.A en una empresa de bienes de consumo que prepara sus estados financieros de forma trimestral, para que puedan ser presentadas a las entidades reguladoras del Perú, como a todos aquellos agentes externos que puedan necesitar de dicha información.

Para tal fin, la entidad hace uso de la información recopilada del ejercicio contable y sobre ella se aplica los ratios financieros, que por varios años se ha ido utilizando como medida estándar de las proyecciones financieras.

El problema a este método estándar, es que no contempla la información de los años anteriores, dentro de su cálculo financiero. Por lo que se entiende que la información brindada no es correcta ni oportuna, para una buena presentación de un estado financiero proyectado.

Por tal motivo, esta investigación busca brindar una forma de poder elaborar un estado financiero, tomando en consideración todos los años significativos de los ejercicios contables, a un costo mínimo, utilizando el aprendizaje automático como método de automatización y precisión.

Además, el aprendizaje automático nos permite poder trabajar con dos tipos de datos; los datos etiquetados y los datos no etiquetados. El primero es para entrenar el modelo bajo un patrón definido, y el segundo bajo sus propias reglas y condiciones.

Asimismo, esta investigación no solo se limita a una sola empresa, sino que sus repercusiones involucran a todas aquellas empresas que elaboran estados financieros de acuerdo a las NIIF (Normas internacionales de información financiera).

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).

II) APRENDIZAJE AUTOMÁTICO

La necesidad de poder ir cada vez más rápido, nos llevó a poder construir algoritmos que procesen grandes cantidades de información, y que al mismo tiempo puedan separar entre toda esta multitud de información lo que es bueno y lo que no.

Los algoritmos son las primeras ideas que se nos viene a la mente, cuando pensamos en el aprendizaje automático. Su sintaxis son las instrucciones que se le da a la computadora para que pueda realizar una acción en particular y nos dé una respuesta en función a la petición que se le ordenó [1]

El aprendizaje automático está diseñado para poder simular las habilidades de los seres humanos, como son: La escritura, el lenguaje, la visión etc. Todas estas técnicas son desarrolladas en diferentes campos de la estadística, salud, robótica y en su conjunto en toda la ciencia.

Dependiendo de los enfoques, y de los diferentes objetivos que se pueda tener, los modelos pueden estar diseñados bajo una estructura lineal o polinomial. El uso de cada uno de estos modelos dependerá del comportamiento de los datos, así como de la respuesta de dicho modelo frente al desarrollo o comportamiento que pueda tener la información.

III) REGRESIÓN LINEAL

tengan una estructura similar a la ecuación $f(\theta) = \theta_0 + A \cdot \theta_1$. El modelo representa una función con variable "A". Donde los coeficientes θ_0 y θ_1 representan los parámetros del modelo.

Habitualmente, los modelos lineales hacen uso de las proyecciones al realizar sumas ponderadas con un conjunto de variables de entrada o también llamados características, más una constante llamada *intercept* o sesgo como se muestra a continuación. [2]

$$\hat{Y} = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$$

Existen tres formas generales de poder representar una regresión en función de su pendiente:

- 1) Cuando su pendiente es positiva, la recta irá de izquierda a derecha de forma ascendente.
- 2) Cuando la pendiente es negativa, la recta se moverá de derecha a izquierda.
- 3) Cuando su pendiente es cero o nulo, la recta es una línea horizontal.




Fig. 1 Pendiente positiva en una regresión lineal

IV) FUNCIÓN COSTO

También llamado como el error al cuadrado o función costo del error. Esta medida nos indica que tan bien se comporta el modelo frente a los datos suministrados en un espacio de n dimensiones.

La función costo tiene como objetivo poder obtener el error entre el valor esperado y el valor real suministrado, con la intención de poder optimizar los parámetros o coeficientes de toda la red. [3]

$$\text{Minimizar } \frac{1}{2m} \sum_{i=1}^m (h_0(x^i) - y^i)^2 \quad (2)$$

La siguiente expresión $h_0(x^i) = \theta_0 + \theta_1(x^i)$ representa la estructura de una regresión lineal que trata de explicar el comportamiento de un conjunto de datos en un espacio de n dimensiones.




Fig. 2 Función costo en un espacio bidimensional

Por otro lado, la función costo se puede dilucidar como un indicador de precisión de la función de hipótesis.

V) DESCENSO DEL GRADIENTE

El algoritmo del descenso del gradiente sirve para poder entrenar un conjunto de datos, y estos luego puedan responder a patrones similares o diferentes con una tasa de asertividad significativo.

Además, en el proceso de iteración permanente, los parámetros se van modificando, hasta dar con la solución más óptima para el modelo, esto sucede cuando $J(\theta_0, \theta_1) = 0$. [4]




Fig. 3 Descenso del gradiente en un espacio tridimensional

El paso más alto representa el punto de inicio del entrenamiento, a medida que se va iterando o aprendiendo, el modelo va convergiendo hasta llegar a un mínimo local o posición óptima, donde la función costo es igual a cero.

El proceso del descenso del gradiente reduce la función costo, lo que provocará un movimiento a lo largo del gráfico en dirección del mínimo absoluto.

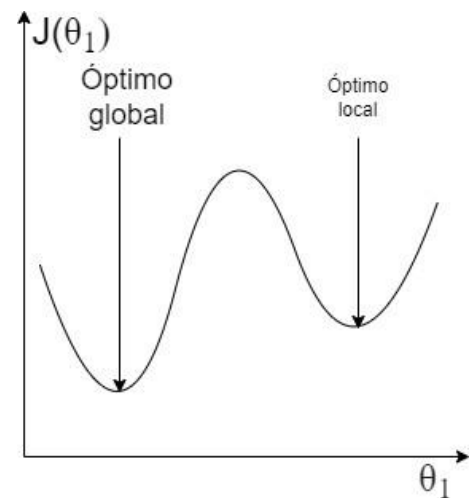


Fig. 4 Mínimo local o global

Definiéndola desde una perspectiva matemática, sería de la siguiente forma: Tendríamos que obtener el valor de la función costo $J(\theta_0, \theta_1)$, para minimizarlo en el proceso de entrenamiento $Min J(\theta_0, \theta_1)$. A medida que reducimos el valor, los parámetros obtenidos producto de la iteración estarán más cerca del valor esperado que requiere el modelo para poder predecir con mayor exactitud. Esto sucederá cuando el valor de la función costo tienda a cero o sea igual a cero $J(\theta_0, \theta_1) = 0$.

VI) COEFICIENTE DE APRENDIZAJE

Se utiliza para poder tener el control de las actualizaciones que tiene el modelo en el proceso de entrenamiento.

Si α es un valor pequeño, la pendiente se moverá muy lento, lo que provocará en el modelo un consumo excesivo de recursos computacionales, producto de los cálculos matriciales que el algoritmo tendrá que realizar.

Por otro lado, mientras más tiempo se tenga al modelo entrenándose, este se vuelve más robusto frente a los nuevos datos que se le pueda dar.




Fig. 5 Coeficiente de aprendizaje grande

Si el valor de α es grande, el descenso del gradiente puede divergir o nunca llegar al valor óptimo, debido a que sus pasos de convergencia son tan grandes que saltan entre dos puntos sin dar lugar a poder disminuir su función costo.

A medida que se produce el entrenamiento, la pendiente respecto a la curva va disminuyendo, de forma paralela, el descenso de la pendiente se va desacelerando, debido a la disminución de la función costo. Ya que en esta dimensión existe una curvatura del espacio, la pendiente va realizando recorridos más cortos cada vez más, provocando en esta una mayor iteración en aquellos puntos cercanos al mínimo local o global.




Fig. 6 Ajuste del descenso del gradiente

La convergencia de la función costo se puede dar en un espacio bidimensional, tanto por el lado izquierdo como por el lado derecho. En ambos casos el proceso de convergencia será igual con excepción del signo de la pendiente.

Si en algún momento en el proceso de iteración o convergencia cayéramos en un mínimo local; el modelo quedaría estancado y su proceso de aprendizaje quedaría reducido al valor que obtiene sus parámetros en ese espacio o punto de convergencia.

Cuando el modelo comienza a iterar el proceso de convergencia comienza a manifestarse en el valor de la pendiente. En un espacio tridimensional, topográficamente hablando lo podríamos notar como la tangentes a la curva de un cerro, a medida que la función costo va disminuyendo el modelo va encontrando zonas planas y no tan planas, que representarían los mínimos locales del espacio. Si el coeficiente de aprendizaje fuera muy pequeño el recorrido que se realizaría sobre ese espacio llano sería muy pequeño, por lo que la probabilidad de poder caer en el centro de dicho espacio sería muy alta. Mientras que, si usáramos un coeficiente más grande, fácilmente podríamos rodear o saltar dicha zona y así evitar el estancamiento de la optimización del modelo.

VII) ECUACIÓN NORMAL

Es un proceso analítico, que utiliza la regresión lineal a partir de la función costo de mínimos cuadrados. Con la intención de poder dar con el valor de θ sin utilizar el descenso del gradiente.

$$\theta = (X^T X)^{-1} * (X^T y) \tag{3}$$

De la ecuación de arriba:

θ : Parámetro de la hipótesis que la definen

X: Valor que toma la característica de entrada

Y: El valor de salida de cada instancia

A. Matemática detrás de la ecuación

Dada la ecuación de la hipótesis:

$$h(\theta) = \theta_0 x_0 + \theta_1 x_1 + \dots + \theta_n x_n$$

donde observamos que,

- n : Es el valor numérico que representa un grupo de datos
- X_0 : 1 (por defecto)

Debido a que esto es una operación de producto escalar, entre las variables θ y x , lo podemos describir de la siguiente forma.

$$h(\theta) = \theta^T x$$

El siguiente paso consiste en poder disminuir la función costo a su mínimo valor, que en este caso es el valor de cero.

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h(x^i) - y^i)^2$$

Donde lo podemos definir como:

- x^i : Es el valor que se le entrega i^{th}
- m : Conjunto de instancias del entrenamiento
- n : Conjunto de características del grupo de datos
- y^i : La devolución esperada i^{th}

A continuación, representamos la función costo bajo una estructura vectorial.

$$\begin{bmatrix} h_0(x^0) & y^0 \\ h_0(x^1) & y^1 \\ \vdots & \vdots \\ h_0(x^m) & y^m \end{bmatrix}$$

Por fines prácticos se ha ignorado el $\frac{1}{2m}$, ya que esta no tendrá un impacto significativo en el cálculo que se vaya a realizar, dentro de la operación matricial. Su utilización se dio para poder hallar el valor numérico del descenso del gradiente.

$$\begin{bmatrix} \theta^T(x^0) \\ \theta^T(x^1) \\ \vdots \\ \theta^T(x^m) \end{bmatrix} - y$$

Desarrollando la estructura de forma matricial, lo podemos describir de la siguiente manera.

$$\begin{bmatrix} \theta_0 & \theta_1 & \dots & \theta_n \\ x_0 & x_1 & & x_n \\ 1 & 1 & & 1 \\ \vdots & \vdots & & \vdots \\ x_0 & x_1 & & x_n \end{bmatrix} - y$$

Donde la variable X_j^i representa el valor numérico de la característica j^{th} en una posición de entrenamiento i^{th} . Por lo que la estructura se puede representar de la siguiente forma:

$$X \theta - y$$

Debido a que la multiplicación escalar no es igual a la multiplicación vectorial, para este último se tiene que utilizar su transpuesta y luego realizar la multiplicación matricial, para poder dar con el resultado.

$$(X \theta - y)^T (X \theta - y)$$

De esta manera, la función costo se definiría como:

$$Cost = (X \theta - y)^T (X \theta - y)$$

B. Desarrollando la ecuación:

$$\frac{\partial J_\theta}{\partial \theta} = \frac{\partial}{\partial \theta} [(X \theta - y)^T (X \theta - y)]$$

$$\frac{\partial J_\theta}{\partial \theta} = 2X^T X \theta - 2X^T y$$

La derivada parcial nos permitirá poder hallar el valor más bajo de la función costo, y con ella los parámetros más óptimos para el modelo esperado.

$$Cost'(\theta) = 0$$

Por lo tanto, la estructura de la ecuación quedaría de la siguiente manera.

$$2X^T X \theta - 2X^T y = 0$$

$$2X^T X \theta = 2X^T y$$

Despejando el coeficiente o el parámetro θ :

$$(X^T X)^{-1} (X^T X) \theta = (X^T X)^{-1} (X^T y)$$

Al realizar la división y la multiplicación por su inversa, la estructura matricial quedaría de la siguiente manera.

$$\theta = (X^T X)^{-1} (X^T y)$$

VIII) LOS ESTADOS FINANCIEROS PROYECTADOS

Es un conjunto de información estructurado y definido bajo normativas contables como las NIC (Normas Internacionales de contabilidad) y las NIIF (Normas internacionales de información financiera).

Esta información es preparada con la intención de poder informar las actividades económicas de la empresa y tener el visto bueno de los agentes reguladores. [5]

Es importante distinguir que los estados financieros contienen las actividades cotidianas de la empresa y las actividades que se piensa realizar. Por otra parte, también podemos distinguir que estos documentos normativos están sujetas a ciertos criterios como son los activos, pasivos y patrimonio. Los activos son los recursos presentes como resultado de sucesos pasados que van a generar un beneficio económico futuro. Por otro lado, los pasivos son todas las obligaciones que se tenga con terceros a una fecha determinada. Por último, el patrimonio es la diferencia entre el activo y el pasivo, es decir los activos propios de la empresa. [6]

IX) BALANCE

El balance financiero es el documento que nos permite poder visualizar la rentabilidad y la solvencia de una empresa, ya que estos nos permiten ver los derechos de la empresa, sus obligaciones y sus reservas de capital.

Asimismo, dentro de ella podemos notar que se cumple la ecuación contable o también llamada la identidad de balance: $\text{Activo} = \text{Pasivo} + \text{Patrimonio}$. El lado izquierdo está relacionado a todos aquellos recursos que la entidad controla en su giro del negocio. Por lo que se espera que estos generen ganancias a corto y largo plazo, debido a su utilización como un bien físico o como un instrumento financiero.

En muchos de los casos las entidades no cuentan con liquidez o dinero en efectivo de forma inmediata, por lo que tienen que recurrir a entidades financieras para que puedan pedir prestado una cierta cantidad de dinero a una fecha determinada. Esta operación genera una cuenta por pagar, o comúnmente llamado una obligación financiera (pasivo).

Si bien este dinero no nos pertenece, nos ayudará a poder cubrir nuestros gastos, a un corto plazo y poder seguir con nuestras actividades del giro del negocio.

Por otra parte, para el caso del patrimonio, estos cuentan con los siguientes instrumentos:

- Los fondos que todos los accionistas han aportado o siguen aportando, como capital de la empresa.
- Las ganancias producto del giro del negocio que se ha tenido desde que se fundó la entidad,

también llamado, capitalización del ejercicio contable.



Desde el punto de vista de los accionistas, el capital que se tiene representa la propiedad sobre los activos de una entidad. Asimismo, la descripción de la ecuación contable se puede dar en función al uso de los fondos que se pueda tener.

Los activos y pasivos se dividen en corriente y no corriente:

1. Los activos corriente son todos aquellos bienes que se espera que se puedan negociar en un plazo no mayor a un año. Estos activos también representan las mercancías que se negocian del día a día y las que generan los ingresos más altos para la entidad.
2. Los pasivos corriente son todas las obligaciones que se espera liquidar en un plazo no mayor a un año. Estas deudas representan los financiamientos o las cuentas por cobrar que se les brinda a los clientes, con la intención de que estos puedan tener un servicio adicional y se puedan fidelizar a la empresa.
3. Los activos no corrientes, son todos aquellos bienes o servicios que se espera que se vayan a realizar pasado el año, estos servicios representan inversiones a largo plazo, ventas con condición de pago a plazos mayores o acuerdos de compra venta que duran años. Si bien estas actividades no son tan concurrencias, en muchos de los casos cada operación suele generar ingresos mayores a los servicios del giro del negocio
4. Los pasivos no corrientes, son todas aquellas obligaciones mayores a un año que se tenga con terceros o relacionados. Las empresas a medida que van creciendo, van necesitando más recursos por lo que sus establecimientos no les dan abasto, en consecuencia, tienen que recurrir a grandes montos de financiamiento, a plazos de pagos relativamente grandes, que puedan cubrir lo necesitado financieramente.

CUADRO 1
RESUMEN DESCENSO DEL GRADIENTE

Método del Descenso del Gradiente			
Dep. Variable	IV-Trimestre	R-Cuadrado	0.985
Modelo	Mínimos cuadrados ordinarios	R-Cuadrado (ajustado)	0.984
Método	Descenso del gradiente	Precisión	0.438
N° de observaciones	160	Error	0.200
D. Modelo	3	N° Iteración	7200

Variables	Coefficiente	Desviación	Varianza	Curtosis	Skew
I-Trimestre	0.350962285	739091.7932	5.46257E+11	10.99	2.79
II-Trimestre	0.350962285	761053.2802	5.79202E+11	10.36	2.75
III-Trimestre	0.350962285	801638.5694	6.42624E+11	7.05	2.38
Intercep	0.001848779				

X) RESULTADOS DEL DESCENSO DEL GRADIENTE

Para el desarrollo de la investigación se utilizó el modelo de los mínimos cuadrados ordinarios, este modelo nos devolverá una matriz con un conjunto de valores, donde estos valores numéricos se encontrarán en un espacio bidimensional o también llamado espacio euclidiano de n dimensiones. Todos aquellos valores unidimensionales, como son los vectores columnas y los vectores filas, tendrán que ser llevados a un espacio bidimensional para que se puedan realizar todas las operaciones con los valores de entrenamiento. La finalidad de este modelo es poder obtener los coeficientes matriciales que puedan describir el comportamiento de los datos que, en este caso son el estado de situación financiera.

El modelo utiliza como variable dependiente el IV-Trimestre de los estados financieros, a su vez, cuenta con 3 variables independientes que son los 3 primeros trimestres de los estados financieros entre los años (2018-2019).

Asimismo, el modelo nos demuestra una eficacia del 98%, con un ajuste del mismo valor.

La precisión nos arroja un valor del 43% y el error del algoritmo en un 20%, lo que nos demuestra que el modelo puede explicar el 80% de los datos históricos suministrados como entrada. La asimetría de Fisher nos indica que la mayoría de los datos, se encuentran concentrados en la parte de derecha de la curva, mientras que la curtosis nos demostraría que la curva tiene una estructura de espiga.

A medida que el número de iteraciones va aumentando, el valor de la función costo va disminuyendo, debido a que el modelo va aprendiendo y por ende sus predicciones son muchos más precisas que el entrenamiento anterior. Cada

paso del entrenamiento consta de 160 ejemplos con las que el modelo entrenará en un espacio de n dimensiones.

En la Fig. 8, podemos observar que para la iteración número 500, la función costo adopta un valor cercano a cero. Lo que nos demuestra que el modelo se adapta rápidamente a los datos suministrados, produciendo un menor consumo en los recursos computacionales que se pueda tener para entrenar al modelo.

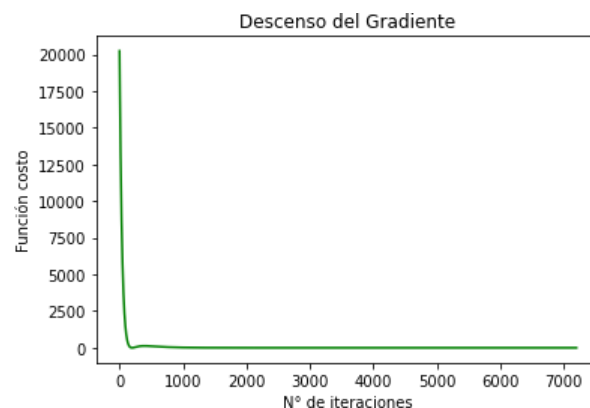


Fig. 8 Convergencia del descenso del gradiente

XI) RESULTADOS DE LA ECUACIÓN NORMAL

También llamado mínimos cuadrados ordinarios, para este método se utilizó 160 observaciones, tres variables independientes que son los tres primeros trimestres de los estados financieros de los años (2018-2021). Los resultados nos demuestran una eficiencia del 99.3% al igual que en el ajuste, con una precisión del 64.9% y un error del 13.8%, lo que representa que el modelo puede explicar el 86.2% de la información que se le ha proporcionado.

CUADRO 2
RESUMEN ECUACIÓN NORMAL

Método de Ecuación Normal			
Dep. Variable	IV-Trimestre	R-Cuadrado	0.993
Modelo	Mínimos Cuadrados Ordinarios	R-Cuadrado (ajustado)	0.993
Método	Ecuación Normal	Precisión	0.649
N° de observaciones	160	Error	0.138
D. Modelo	3	Cant. Cálculos	1

Variables	Coefficiente	Desviación	Varianza	Curtosis	Skew
I-Trimestre	-0.024242	739091.7932	5.46257E+11	10.99	2.79
II-Trimestre	0.155451	761053.2802	5.79202E+11	10.36	2.75
III-Trimestre	0.865216	801638.5694	6.42624E+11	7.05	2.38
Intercept	0.000932				

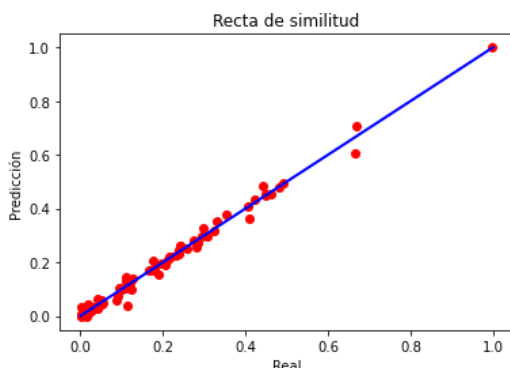


Fig. 9 Recta de similitud entre la predicción y los valores reales

La recta de similitud, nos muestra la precisión del modelo para poder describir el comportamiento de los datos históricos en un plano bidimensional. La recta azul representa el espacio ideal donde los datos son proyectados de forma perfecta por el modelo.

Podemos observar que los datos históricos tienen un comportamiento lineal al igual que la estructura del modelo y que además se encuentran muy cerca de esta, lo que nos indica que el modelo ha sabido aprender y discernir el comportamiento de los datos suministrados.

XII)Conclusiones

Con el aprendizaje automático se pudo demostrar una nueva manera de poder realizar estados financieros proyectados, sin que esta pueda tener algún inconveniente por la cantidad de variables que se pueda utilizar o por el poder computacional que se pueda necesitar para entrenar al modelo.

Ambos métodos nos brindan soluciones complementarias al tratamiento de los datos históricos, por un lado, el descenso del gradiente nos permite poder entrenar un modelo más robusto y con una gran cantidad de variables en un espacio n dimensional, mientras que el método de la ecuación normal, nos brinda un método más analítico centrado a datos históricos más concurrentes en un tiempo mínimo a un costo computacional reducido.

En este sentido, se recomienda a todas las empresas que utilizan la normativa contable de las NIIF (Normas Internacionales de Información Financiera), utilizar el aprendizaje automático para poder obtener datos más precisos al momento de poder proyectar sus índices financieros. Todo ello con el objetivo de poder entregar a sus usuarios externos como internos, datos significativos acorde al criterio normado por las entidades reguladoras de nuestro país.

La práctica de todas estas acciones, nos llevará a poder tener un mejor control de nuestros activos, pasivos y patrimonio, como los ingresos y gastos que se pueda tener en el ejercicio contable.

De este modo, tendremos una repercusión positiva a nivel macroeconómico que puedan provocar políticas desreguladoras a medida que se valla capitalizando e invirtiendo en el país.

XIII) REFERENCIAS

- [1] A. T. Norman, *Aprendizaje Automático En Acción*. Litres, 2019.
- [2] Aurélien Géron, *Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow*. 2019.
- [3] D. Calvo, «Función de coste - Redes neuronales», *Diego Calvo*, 10 de diciembre de 2018. <https://www.diegocalvo.es/funcion-de-coste-redes-neuronales/> (accedido 5 de septiembre de 2022).
- [4] P. Pandey, «Gradient Descent: A Quick, Simple Introduction | Built In», 22 de agosto de 2022. <https://builtin.com/data-science/gradient-descent> (accedido 6 de septiembre de 2022).
- [5] E. Zamora, «▷ Los Estados Financieros 【Qué, Cuáles son y Ejemplos】 », *CONTABILIDAE*, 28 de marzo de 2021. <https://www.contabilidae.com/estados-financieros/> (accedido 5 de septiembre de 2022).
- [6] G. De Franco, S. P. Kothari, y R. S. Verdi, «The Benefits of Financial Statement Comparability: the benefits of financial statement comparability», *J. Account. Res.*, vol. 49, n.º 4, pp. 895-931, sep. 2011, doi: 10.1111/j.1475-679X.2011.00415.x.