

# Machine Learning como estrategia pedagógica lúdica para planeación de producción

Leila Nayibe Ramírez\*, Ana María Villamil\*\*,  
Andrea Patricia Vásquez\*\*\*, & Mariluz Osorio-Quiceno\*\*\*\*

Recibido: 08 - 05 - 2020 / Aceptado: 21 - 05 - 2020 / Publicado: 26 - 06 - 2020

## Resumen:

Este artículo describe una estrategia pedagógica basada en la lúdica “The Product X, The Product Z, Production Laboratory” diseñada por Schesinger, que busca que el estudiante de ingeniería industrial comprenda con mayor facilidad los conceptos de MRP y Machine learning y que, del mismo modo, pueda implementarlos en su proceso de aprendizaje. Se realizó un análisis con varios modelos matemáticos, para identificar el resultado que se ajusta mejor a las predicciones sobre el tamaño de las órdenes de producto y tipo de producto. En la realimentación realizada con los estudiantes que participaron en la lúdica, se evidenció que el proceso fue satisfactorio, pues calificaron a los conocimientos adquiridos por encima del 75%.

## Abstract

This article describes a pedagogical strategy based on the playful “The Product X, The Product Z, Production Laboratory” designed by SCHE-SINGER, which seeks to make it easier for the industrial engineering student to understand the concepts of MRP and Machine learning and also to implement them in their learning process. An analysis was performed with several mathematical models, to identify the result that best matched the predictions to the size of the product orders and product type. In the feedback made with the students who participated in the play, it became evident that the process was satisfactory, as they rated the acquired knowledge above 75%.

## Palabras clave:

planeación de los requerimientos de materiales, Machine learning, Python, lúdica

**Cómo citar:** Ramírez, L., Villamil, A., Vásquez, A. y Osorio, M. (2020). Machine Learning como estrategia pedagógica lúdica para planeación de producción. *Hashtag*, (16), 65-83

**Keywords:** Planning of material requirements, Machine Learning, Python, playful

**Declaración de conflictos de interés:** las autoras declaran no tener ningún conflicto de interés

\* Docente, facultad de Ingeniería, Universidad Libre, Bogotá, Colombia. leylan.ramirez@unilivre.edu.co  
\*\* Estudiante, facultad de Ingeniería, Universidad Libre, Bogotá, Colombia. anam-villamil@unilivre.edu.co  
\*\*\* Estudiante, facultad de Ingeniería, Universidad Libre, Bogotá, Colombia. andrea-p-vasquez@unilivre.edu.co  
\*\*\*\* Docente, facultad de Ingeniería, Universidad El Bosque, Bogotá, Colombia. mosorio@unbosque.edu.co

## Introducción

A lo largo de los años se ha visto cómo las clases magistrales predominan en la enseñanza, ocasionando en los estudiantes una limitante para interactuar, trabajar en equipo, ser creativos o simplemente comprender con claridad lo que se pretende enseñar (Hernández, 2015). Por ello, el panorama actual de la enseñanza de la ingeniería sugiere el uso de métodos educativos donde el estudiante practique lo que aprendió en el aula para afianzar ese conocimiento.

De acuerdo con el artículo de González (2015) “los juegos didácticos constituyen una técnica participativa de la enseñanza, encaminada a desarrollar en los estudiantes métodos de dirección y conducta correcta, para estimular así la disciplina con un adecuado grado de decisión y autodeterminación”

Las lúdicas son procesos de apoyo pedagógico que se utilizan activamente, incluso en la enseñanza del sistema de inventarios, ya que permiten al jugador tomar decisiones sobre tener o no inventarios en la simulación que, a futuro se convertirá en un problema real, y se verá reflejado positiva o negativamente a las utilidades de la compañía (Rodríguez & Ramos, 2016).

Por otra parte, cada vez es más relevante para las empresas desarrollar modelos predictivos, pues son de ayuda al momento de interpretar una colec-

ción de datos y se sirven de áreas como estadística, probabilidad, investigación de datos y recuperación de información. Para este propósito, se utilizan técnicas de Machine Learning (Chang, Cohen & Ostdiek, 2018; Orozco, 2018).

Además, dentro de los procesos de gestión de la producción, su planificación es una actividad relevante en la toma de decisiones de las organizaciones, porque le permite establecer la cantidad de suministros y satisfacer las necesidades de los materiales necesarios para cumplir con las expectativas de la demanda, lograr su eficacia a través de herramientas como el MRP y equilibrar la relación entre proveedores y clientes. El alcance de la actividad de planificación ha permitido el desarrollo de programas de gestión como el Enterprise Resource Planning (ERP) que se incorpora en casi todos los programas de gestión empresarial modernos (Katu, 2020).

Teniendo en cuenta lo anterior, se presenta en este artículo una estrategia pedagógica que pretende facilitar en el estudiante el proceso de aprendizaje, simulando escenarios de producción con fichas lego en las que se apoya el proceso de formación para profundizar en los conceptos enseñados en el aula de clase y transmitir al estudiante conocimientos que contribuyan a la mejora continua de los procesos en la cadena de abastecimiento.

## Metodología

Teniendo en cuenta lo expuesto anteriormente, se contempló el desarrollo de una estrategia pedagógica a partir de una lúdica que simula una planta de producción, donde el objeto para la simulación de producción son las fichas de lego; la estrategia in-

cluye conceptos de MRP y Machine Learning. Estos últimos propuestos en esta investigación como alternativa de actualización de los contenidos de materias como planificación y control de la producción.

Fig. 1. Ciclo estrategia pedagógica



Fuente: Elaboración propia

Los productos son una adaptación de lo propuesto en Osorio Quiceno & Jaramillo (2006). Esta lúdica permite ver con facilidad el comportamiento de los inventarios, ya que simula la cantidad de producto, el nivel y control de inventarios y el consumo de materias primas.

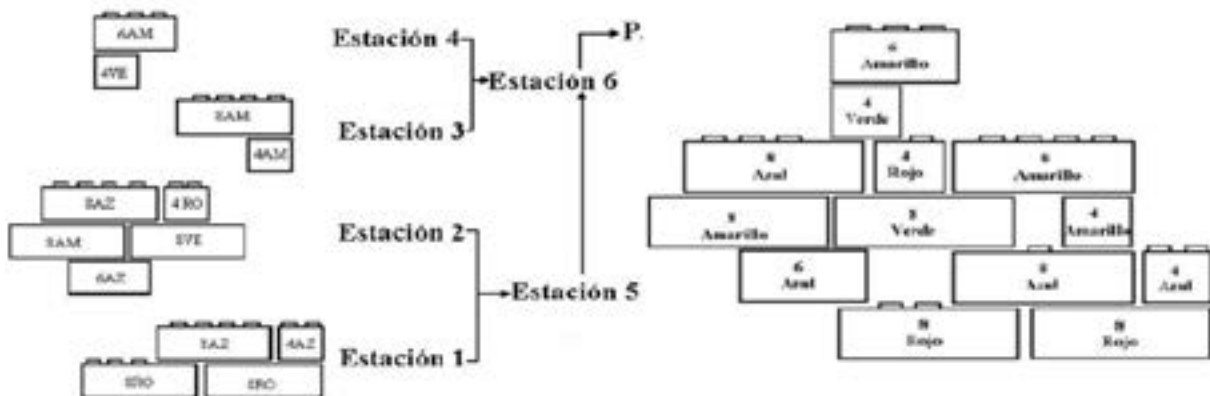
El proyecto tuvo lugar en la sede el bosque de la Universidad Libre (Bogotá) en la Facultad de Ingeniería Industrial, donde participaron 35 de

estudiantes de la materia control de producción.

### Desarrollo de la lúdica

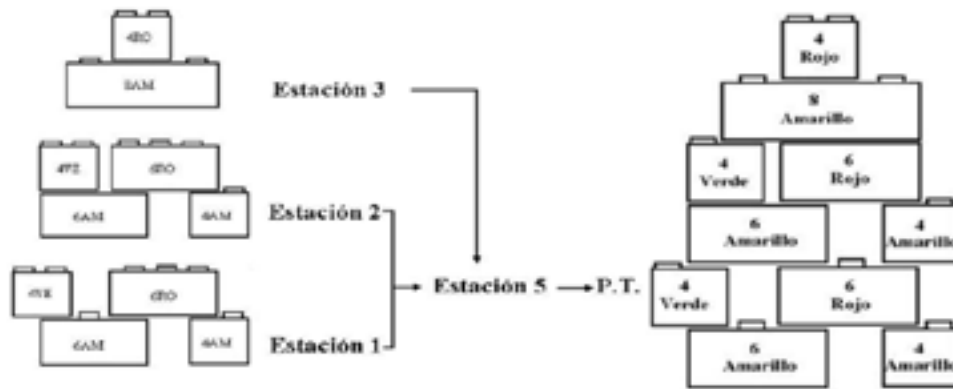
El proceso de producción consiste en elaborar dos tipos de productos, el X de 13 fichas y el producto Z de 10 fichas. La planta cuenta con 6 estaciones, conformadas por 4 estaciones de subensambles para X y 3 para Z y el restante son estaciones de ensamble (Ver Figuras 2 y 3).

Fig. 2. Producto X - Ensamble y producto terminado



Fuente: (Osorio Quiceno & Jaramillo, 2006)

Fig. 3. Producto Z - Ensamble y producto terminado



Fuente: (Osorio Quiceno & Jaramillo, 2006)

La materia prima requerida (fichas de lego) se encuentra ubicada dentro de contenedores en las estaciones 1, 2, 3 y 4, en la que, a su vez, se realizan los subensambles. (Osorio Quiceno & Jaramillo, 2006)

Las órdenes de producción y producto determinado se generan a partir de números aleatorios como parte de una función de distribución de probabilidad, en la que cada número aleatorio corresponde a una pro-

babilidad de ocurrencia de un evento. Los productos son fabricados en lotes de producción de tamaños iguales a 5, 10, 15 o 20 unidades. La estación número 1 genera un subensamble y su modelo se encuentra disponible en esta sección. Los datos correspondientes a la generación de la orden, Lead Time, tipo de producto y cantidad, que se producirá, son registrados en el tablero de control de la producción (Osorio Quiceno & Jaramillo, 2006) (Ver Tabla No. 1).

Tabla No. 1 Tablero de Control de la Producción

Time	W.O.	CAR	X	Z	Q.L.T.	L.T.
0	1					
1	2					
2	3					
3	4					
4	5					
5	6					
6	7					
7	8					
8	9					
9	10					

Fuente: (Osorio Quiceno & Jaramillo, 2006)

## Técnicas de Machine Learning empleadas

La actividad lúdica descrita en Osorio Quiceno & Jaramillo (2006) se ha ejecutado en los últimos 4 años aproximadamente, y ha obtenido un histórico de datos que fueron llevados a Python a través de la aplicación de Jupyter (Caja, 2020; Pedregosa et al., 2011) para modelación de diferentes herramientas de predicción utilizadas en Machine Learning como perceptrón multicapa, perceptrón multicapa con regresión lineal, clasificación con árboles de decisión y regresiones gaussianas.

El propósito de la investigación es incorporar estos conceptos como parte de la construcción de herramientas para la estimación de variables que apoyan la decisión en la planificación de producción como el tamaño de la orden que está relacionada con la demanda, así como el tipo de producto de interés para el cliente. A continuación, se detallan cada una de las herramientas de Machine Learning.


### Perceptrón multicapa

Definida como una red neuronal que se caracteriza por estar agrupada por capas de diferentes niveles -de entrada, ocultas y de salida- que la conforma un grupo de neuronas (Haykin, 2004).

Las neuronas de la capa de entrada son las encargadas de recibir las señales o patrones del exterior para propagarlas en las capas ocultas y pasarlas, finalmente, por la capa de salida, que proporciona la respuesta a las señales o patrones recibidos.

Las neuronas de una capa se conectan a las neuronas de la siguiente capa, es decir que su estructura es hacia adelante. Generalmente, las neuronas de la red están conectadas por capas. Se dice entonces que existe conectividad total o que la red está totalmente conectada (Haykin, 2004).

Figura. 4



Fuente: (Haykin 2004)

### Perceptrón multicapa con regresión lineal

El modelo perceptrón multicapa con regresión lineal tiene una relación entre modelos estadísticos y los modelos de redes neuronales. Estos pueden ser aplicados en el análisis estadístico a los proble-

mas de predicción (análisis de regresión). Las redes neuronales pueden ser entendidas como modelos generales de regresión que buscan predecir valores futuros de una o varias variables (dependientes o respuestas). Los modelos clásicos de regresión

lineal y no lineal pueden ser modelados y analizados a través de las redes neuronales (Ranjeeth, Latchoumi & Paul, 2020).

#### Clasificación de árboles de decisión

De acuerdo con (Calancha & Abgar, 2021.), "El Árbol de Decisiones es una técnica enmarcada dentro del desarrollo de métodos y sistemas de razonamiento utilizados en investigaciones de inteligencia artificial y programación de aplicaciones, por su estructura son fáciles de comprender y analizar" (p. 2).

El objetivo de los árboles de decisión es construir un método que, a partir de una colección de variables, prediga el valor de otra (Haykin, 2004); permite hacer un análisis rápido de las consecuencias de las posibles decisiones. Dentro de esta técnica se pueden identificar dos categorías.:

Árboles de clasificación: Son modelos donde la variable de destino puede tomar un conjunto finito de valores. Las hojas representan etiquetas de clase y las ramas representan las conjunciones de características que conducen a esas etiquetas de clase (Haykin, 2004).

Árboles de regresión: Son modelos donde la variable de destino puede tomar valores continuos, generalmente, números reales. (Haykin, 2004).

#### Regresiones Gaussianas

Las regresiones Gaussianas son utilizadas para buscar una probabilidad total; la suma de las columnas es igual a 1. En esta regresión se utilizó NAIVE BAYES, más conocida como estadística bayesiana. Para esta probabilidad se busca evidencia para apoyar la hipótesis de partida o, por el contrario, establecer una nueva hipótesis alterna. Este planteamiento recibe el nombre de Bayes y es de carácter inferencial debido a que, a partir de una muestra y del teorema, se puede comparar para concluir acerca de la población de la que proviene la muestra (Murphy, Mesa, Rivera & Romero, 2011).

El teorema de Bayes relaciona la probabilidad de que suceda un evento y que, a su vez, sucede otro. Esto se denomina probabilidad condicionada y el teorema de Bayes conjuga las probabilidades condicionales para hallar las probabilidades inversas (Soto, 2011).

La ecuación (1) del teorema de Bayes (Wiper n.d.) es la siguiente:

$$P(D) = \frac{P(h)P(h)}{P(D)} \quad (1)$$

$P(h)$ : Es la probabilidad de que la hipótesis  $h$  sea cierta (independientemente de los datos). Esto se conoce como la probabilidad previa de  $h$ .

$P(D)$ : Probabilidad de los datos (independientemente de la hipótesis). Esto se conoce como probabilidad previa.

$P(h|D)$ : Es la probabilidad de la hipótesis  $h$  dada los datos  $D$ . Esto se conoce como la probabilidad posterior.

$P(D|h)$ : Es la probabilidad de los datos  $d$  dado que

la hipótesis  $h$  era cierta. Esto se conoce como probabilidad posterior.

Para implementar las técnicas con los datos históricos recopilados en el laboratorio, se analizaron los datos de los productos  $X$  y  $Z$  por separado y, después, juntos como colección de datos para el entrenamiento de los algoritmos propuestos. Las variables de entrada son los minutos que tardan en construirse los diferentes lotes de producto y las variables de salida son el tamaño de la orden (W.O.) y tipo de producto ( $X, Z$ ).

## Resultados

### Análisis descriptivo estadístico

La metodología busca mostrar la información suministrada de modo ordenado, claro, y sencillo mediante gráficas y medios visuales, donde se extraen características representativas de los datos que evidencian tendencias y comportamientos (Cogno-data, 2019). Esto es fundamental para entender el comportamiento de las variables. A continuación, se detallan las variables analizadas y sus descriptores estadísticos. Para su mayor comprensión, se explican los siguientes valores:

**WO:** Orden de trabajo

**QLT:** Tiempo prometido de entrega

**LT:** Tiempo de entrega del producto terminado

### Producto X

En promedio la orden de trabajo para el producto X es de 10.9 unidades donde el tiempo de entrega en promedio es de 1.96 minutos con una desviación estándar de 1,45 minutos.

Tabla No. 2: Resultado del producto X

	W.O.	Q.L.T.	LT(Minutos)
Conteo	161,00	161,00	161,00
Media	10,93	1,83	1,96
$\sigma$	5,92	0,77	1,45
Min	5,00	1,00	0,29
25%	5,00	1,00	1,00
50%	10,00	2,00	1,37
75%	15,00	2,00	2,53
Max	20,00	3,00	6,28

Fuente: Elaboración propia

El tiempo mínimo que se tarda en realizar el producto X es de 0,29 minutos, el 25% de los datos es menor a 1 minuto, el 50%, a 1,37 minutos y el 75%, a 2,53 minutos. El valor máximo que puede tomar la variable LT es de 6,28 minutos. Esto se debe a que se fabrican lotes diferentes de 5, 10,15 y 20.

### Producto Z

En promedio la orden de trabajo para el producto Z es de 11.35 unidades, en la que el tiempo de entrega en promedio es de 1.70 minutos con una desviación estándar de 1,11 minutos.

Tabla No. 3: Resultado del producto Z

	W.O.	Q.L.T.	LT(Minutos)
Conteo	80,00	80,00	80,00
Media	11,35	1,82	1,70
$\sigma$	5,58	0,68	1,11
Min	5,00	1,00	0,27
25%	5,00	1,00	1,06
50%	10,00	2,00	1,25
75%	15,00	2,00	2,18
Max	20,00	3,00	5,50

Fuente: Elaboración propia

El tiempo mínimo, que se demora en realizar el producto Z, es de 0,27 minutos, el 25% de los datos de es menor a 1,06 minuto, el 50% es de 1,25 minutos y el 75% de 2,18 minutos. El valor máximo que puede tomar la variable LT es 5,5 minutos. Esto se debe a que se fabrican lotes diferentes de 5, 10,15 y 20. Además que la dificultad de la construcción del producto es menos compleja que el producto X.

#### Producto XZ

Teniendo en cuenta la totalidad de unidades de producto, en promedio 0.67 unidades, son del producto X y 0.33 unidades para el producto Z, cuyo tiempo de entrega, en promedio, para ambos productos es de 1.87 minutos con una desviación estándar de 1,87 minutos.

Tabla No. 4: Resultado del producto XZ

	W.O.	X	Z	Q.L.T.	LT(Minutos)
Conteo	241,00	241,00	241,00	241,00	241,00
Media	11,05	0,67	0,33	1,82	1,87
$\sigma$	5,79	0,47	0,47	0,74	1,38
Min	5,00	0,00	0,00	1,00	0,27
25%	5,00	0,00	0,00	1,00	1,02
50%	10,00	1,00	0,00	2,00	1,30
75%	150,00	1,00	1,00	2,00	2,50
Max	20,00	1,00	1,00	3,00	6,28

Fuente: Elaboración propia



El tiempo máximo que se obtiene al realizar los productos X y Z es de 6,28 minutos y el mínimo de 0,27 minutos.

### Diagrama de frecuencia


Es una herramienta que se utiliza para establecer la frecuencia con que se presenta el evento en una categoría de datos considerada como clases. Este diagrama permite visualizar la frecuencia de un evento mediante un diagrama de barras obtenido a partir de los datos observados en el laboratorio control de la producción; en este caso específico, cada barra representa la frecuencia con que se pre-

sentan los tiempos de espera en minutos. Esto es de utilidad, porque permite:

- Construir una base de datos de valores, para determinar el valor máximo y mínimo, con el que se cree un análisis estadístico descriptivo de la variable.
- Calcular el número de intervalos en el que se divide el rango que abarca desde el valor mínimo hasta el máximo.
- Identificar oportunidades de mejora.
- Estudiar los resultados.
- Planear mejoras continuas.

### Producto X

Figura 5. Diagrama de frecuencia de X (LT - Minutos)




Fuente: Elaboración propia

Como se observa en la gráfica, el eje y representa la frecuencia y el eje x, el tiempo que se tarda en hacerse el producto (LT minutos): se inicia en 0.46 minutos con una frecuencia de 35 veces para el pro-

ducto X; el diagrama presenta un decrecimiento notorio en la frecuencia 3.5 a 14.51. El histograma sugiere una distribución de probabilidad asimétrica y no coincidente con la normalidad de los datos.

## Producto Z

Figura 6. Diagrama de frecuencia de Z (LT - Minutos)




Fuente: Elaboración propia

Por otro lado, para el producto Z, se observa que el tiempo se eleva significativamente alrededor de 1 minuto. Esto significa mayores registros de los datos en este rango: en la clase de 4 a 5 minutos, la frecuencia de los datos disminuye. Se puede decir

que la experiencia en la construcción del producto minimiza el tiempo de su realización, así como el número de lotes de producto se puede concentrar en las cantidades de 5 y 10 unidades.

## Producto XZ

Figura 7. Diagrama de frecuencia de XZ (LT - Minutos)



Fuente: Elaboración propia

En esta gráfica se puede identificar el tiempo del producto terminado para los productos X (azul) versus el producto Z (naranja), en los que el mejor rendimiento lo tiene el producto Z en términos de tiempo. Los datos se comportan asimétricos y no sugieren un comportamiento bajo una distribución de probabilidad normal.

### Diagramas de correlación

Los diagramas de correlación son una descripción gráfica utilizada para la interpretación de datos. Con este sistema se puede verificar la relación entre dos variables (Weisstein n.d.) o parámetros de un problema. Se utiliza para identificar si existe dependencia entre dos magnitudes o parámetros.

La correlación permite establecer la relación lineal entre dos variables para variables cuantitativas y aleatorias (Weisstein, 2006.). Para su estimación se tuvo en cuenta los resultados históricos de varios


laboratorios para obtener muestras y calcular el coeficiente de correlación muestral del que se obtienen valores diferentes.

### Producto X

En la gráfica de W.O. se puede ver que la relación es positiva, ya que hay un incremento en Y que puede ser causado por X. Como en la tabla de datos inicial, se controló a X, esto se ve reflejado en el comportamiento de Y.

En la figura 8 de LT (minutos) con respecto a W.O. (orden de trabajo), manifiesto en el cuadrante inferior izquierdo, la información se concentra en las órdenes de 20 unidades y se identifican también comportamientos atípicos donde los datos se salen del patrón de observación; no es posible determinar una tendencia, pero se puede realizar el agrupamiento de los datos, ya que las cantidades de producto son discretas (Moscote & Quintana, 2008).

Figura 8. Diagrama de correlación de X



Fuente: Elaboración propia

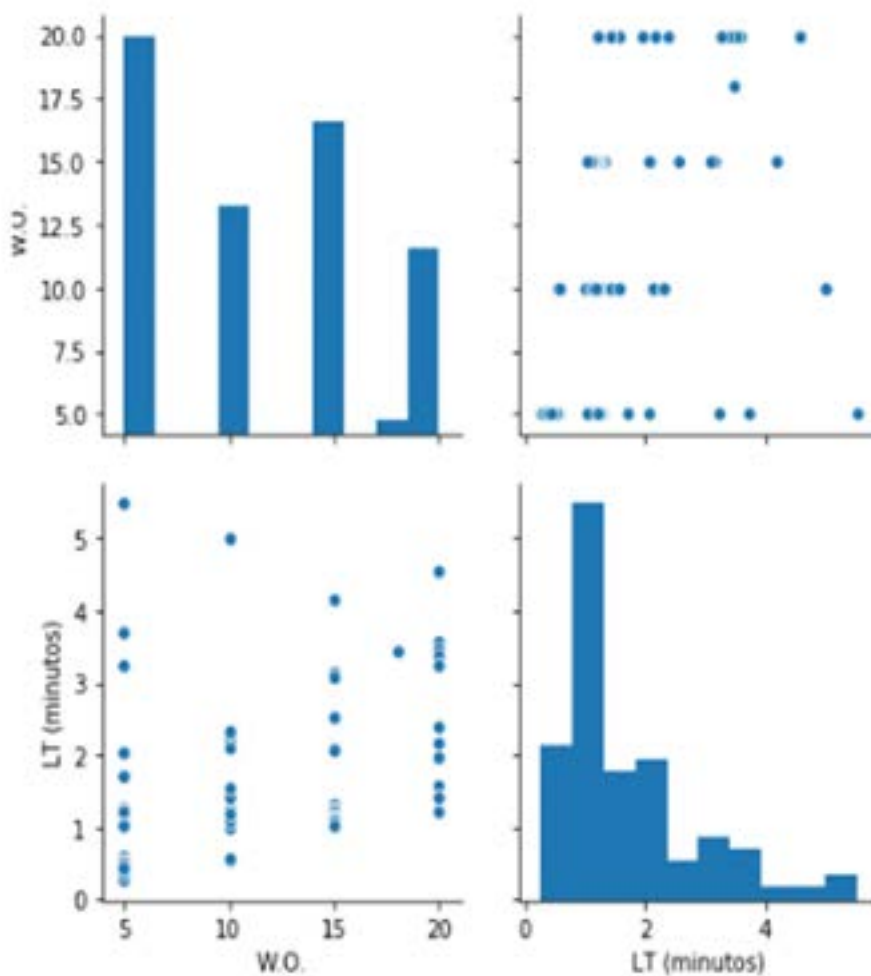
**Producto Z**

Para el producto Z, en la gráfica de la relación entre LT (minutos) con respecto a W.O. (orden de trabajo), expuesto en el cuadrante superior derecho, se evidencia tanto la relación positiva, con una dispersión significativa de los datos, así como el aumento de los datos atípicos en cada uno de los tamaños de lote realizados para este juego. Cuando los lotes

son de 20 unidades, la dispersión disminuye y los datos se concentran más. Se obtiene un efecto contrario, cuando los lotes son de 5 unidades.

No se puede sugerir un patrón de tendencia para los datos, ya que están agrupados; los análisis de clúster son una opción recomendada para mejorar el análisis de las variables.

Figura 9. Diagrama de correlación de Z




Fuente: Los autores

**Producto XZ**

Al considerar la colección de datos en conjunto, se observa menos dispersión de la información iden-

tificación concentración en tiempos específicos, así como menos datos atípicos (Ver Figura 10)

Figura 10. Diagrama de correlación de XZ



Fuente: Elaboración propia


### Comportamiento de los datos

#### Producto XZ

Contiene información sobre la cantidad de veces que se ejecutó el programa de dos productos. las variables representan el número de ensamble correspondiente. A su vez, son clasificados en dos categorías: Producto X y Producto Z. Al analizar el comportamiento de los productos, se puede apreciar que su comportamiento es aleatorio, tie-

ne intervalos de crecimiento y de decrecimiento sin seguir ningún patrón específico. Se evidencia que para el producto X la cantidad de veces, que se ejecutó el programa, aumentó a 6 minutos (tiempo de producción); además se confirma que la menor cantidad de corridas corresponde al producto Z (Ithandehuil, 2006).

Figura 11. Comportamiento de datos de XZ



Fuente: Elaboración propia

### Ajuste de los modelos por Machine Learning

El coeficiente de determinación ajustado o R cuadrado se utiliza para ver la efectividad que tie-

nen las variables independientes con respecto a la variable dependiente como muestra la siguiente ecuación (Marco Sanjuán, s.f.).

$$R_a^2 = 1 - \left[ \left( \frac{n-1}{n-k-1} \right) * (1 - R^2) \right] \quad (2)$$

$R_a^2$ = R cuadrado ajustado o coeficiente de determinación ajustado

$R^2$ = R cuadrado o coeficiente de determinación

n= Número de observaciones de la muestra

k= Número de variables independientes

El coeficiente de determinación ajustado compara modelos aplicados a las variables independientes de un estudio y permite su comparación homogénea (Minitab 2019).

El R-cuadrado siempre está entre 0 y 1: entre más cerca esté a 1 sus valores, esto significa que su ajuste es mejor.

Teniendo en cuenta lo mencionado y aplicando dicho ajuste a los modelos matemáticos utilizados, se determina que para el R ajustado tanto del producto X como del producto Z, el mejor modelo de empleo compete a la clasificación con árboles de decisión teniendo en cuenta su ajuste de 0.919 y 0.925 respectivamente.

Tabla No. 5: R ajustado para los productos XZ

Técnica	R ajustado Producto x	R ajustado Producto z
Perceptrón multicapa	0.337	0.162
Perceptrón multicapa con regresión	-2.511	-4.096
Clasificación con árboles de decisión	0.919	0.919
Regresiones Gaussianas	0.602	0.4

Fuente: Elaboración propia

De igual modo que en la tabla anterior, para el producto de XZ, el mejor ajuste corresponde a la clasificación con árboles de decisión con un valor de 0.86.

Tabla No. 6: R ajustado para los productos XZ

Técnica	R ajustado Producto XZ
Perceptrón multicapa	0.668
Perceptrón multicapa con regresión	-2.711
Clasificación con árboles de decisión	0.863
Regresiones Gaussianas	0.668

Fuente: Elaboración propia

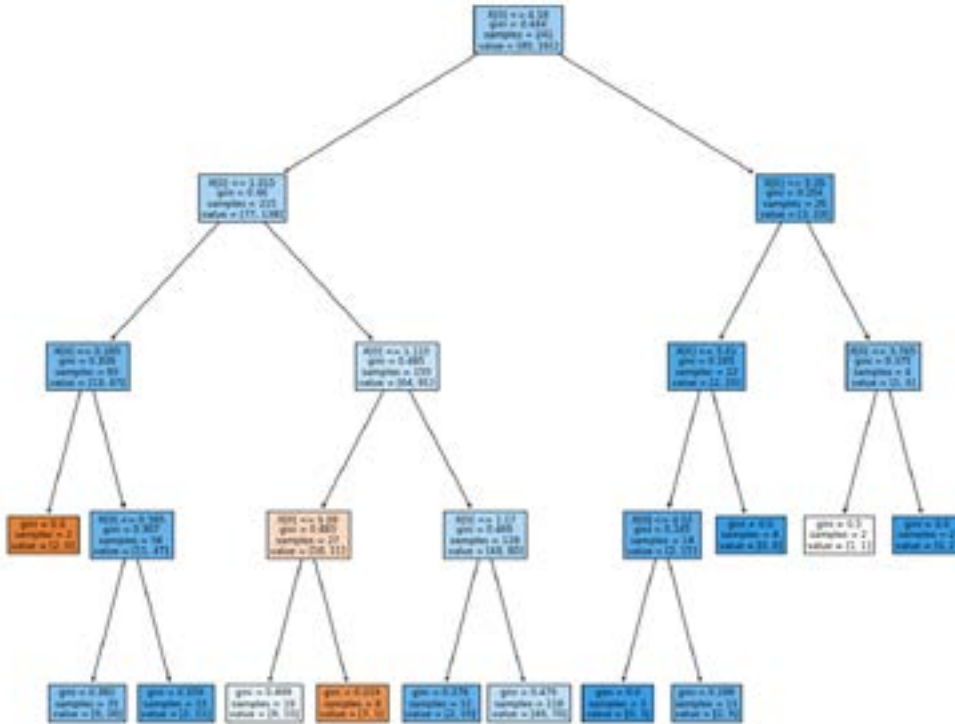
El árbol de clasificación utiliza el algoritmo de índice de Gini para cuantificar la varianza total de las clases en el nodo y crear puntos de división, también se conoce como una medida de impureza.

$$Gini(D) = 1 - \sum_{i=1}^m P_i^2 \quad (3)$$

Donde,  $p_i$  es la probabilidad de que una tupla en  $D$  pertenezca a la clase  $C_i$ .

El índice de Gini comprende la división binaria para cada atributo.

Figura 12. Árbol de decisión para los productos XZ



Fuente: Elaboración propia

En la Figura 12, se observa el modelo de predicción obtenido por árboles de clasificación. Cada nodo interno tiene una regla de decisión que divide los datos. La relación de Gini mide la impureza del nodo. De acuerdo al resultado obtenido, se interpreta que, cuando el tiempo de producción de X es menor a 4.18 min., existe la posibilidad que solo 161 unidades sean de este modelo y que los siguientes niveles se agrupen de acuerdo a la ganancia de la información; cuando el tiempo de producción de X es menor a 1.17 minutos en una demanda de 128 unidades, solo sólo 80 unidades pertenecerán a X. Para establecer el tamaño del lote se considera que, de acuerdo a la información obtenida, para producir lotes de 20 unidades en X, el tiempo promedio se encuentra en 3.87 minutos.

A través del modelo clasificación con árboles de decisión, se logró pronosticar tanto las órdenes de trabajo como para el producto (X y Z). Estos fue-

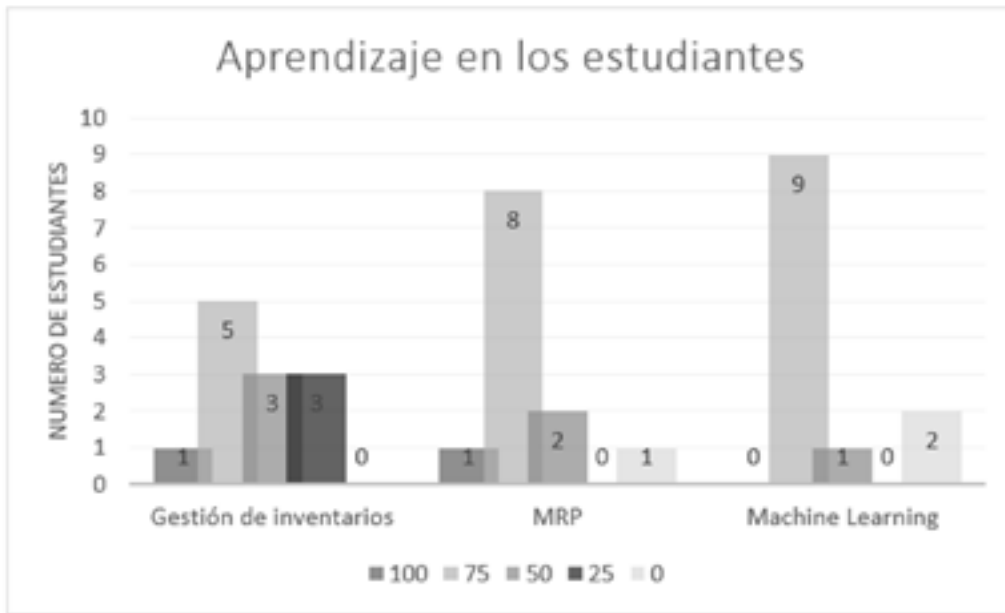
ron probados, a su vez, en la aplicación de la lúdica (Osorio Quiceno & Jaramillo, 2006) con los estudiantes de VIII semestre de la materia control de la producción en el 2 periodo de 2020, que presupuso un ajuste fue del 86%.

Cabe destacar que, para este periodo, el país estuvo confinado un periodo confinamiento por la COVID-19. Por esto, la lúdica debió ser realizada de manera virtual, con el apoyo de herramientas como LEGO Digital Designer (Lego n.d.) y Anydesk.

Exceptuando algunas fallas de internet, la lúdica se pudo realizar con normalidad y fue satisfactoria en cuanto a las predicciones del modelo elegido y la enseñanza de los conceptos de MRP y Machine Learning. Esto se deduce de los resultados arrojados por la encuesta realizada a los estudiantes al finalizar la lúdica.



Figura 13. Aprendizaje en los estudiantes



Fuente: Elaboración propia

## Conclusiones

Luego de haber ejecutado varias veces los datos en el programa Python y de utilizar varios modelos matemáticos, se concluyó que la técnica más precisa para este estudio corresponde a la Clasificación con árboles de decisión, pues se observa en el análisis descriptivo que la relación entre variables no es lineal y genera agrupamientos de información que puede ser mejor interpretados con este modelo.

Una de las preguntas en la encuesta aplicada al finalizar la actividad, tuvo la finalidad de indagar sobre el estilo de aprendizaje de los estudiantes. Este sondeo arrojó que el 83%, adquiere el conocimiento de modo pragmático, es decir, mediante la práctica.

Se les pidió a los estudiantes asignarse una calificación cuantitativa a lo comprendido de los temas propuestos a partir de los siguientes parámetros: malo (0%), bueno (25%), aceptable (50%), sobresa-

liente (75%) y excelente (100%). Teniendo en cuenta los resultados por encima del 75%, se determinó que el aprendizaje fue del 50% en Gestión de Inventarios, 75% en MRP y 75% en Machine Learning, como se evidencia en la figura 13.

En este ejercicio, el programa Python jugó un papel importante en cuanto la predicción de órdenes de trabajo y producto, ya que acerca al estudiante a un escenario más realista y permitió tomar decisiones con respecto a tener un inventario de seguridad apoyado en las predicciones o simplemente aguardar a el pedido real del cliente.

Para el equipo que decidió contar con un inventario de seguridad, apoyado en las predicciones, su tiempo de alistamiento y entrega del producto fue mejor en un 43% con respecto al equipo que consideró el pedido real del cliente.

## Referencias

- Caja García, O. (2020). *Librería Python para el aprendizaje y la implementación de redes neuronales* (Doctoral dissertation, Universitat Politècnica de València). Recuperado de <https://riunet.upv.es/handle/10251/152226>
- Calancha, C., & Abgar, N. (2011). *Breve aproximación a la técnica de árbol de decisiones*. Recuperado de <https://niefcz.files.wordpress.com/2011/07/breve-aproximacion-a-la-tecnica-de-arbol-de-decisiones.pdf>.
- Chang, S., Cohen, T. & Ostdiek, B. (2018). What is machine learning?. *Physical Review D*. (97). Recuperado de <https://journals.aps.org/prd/abstract/10.1103/PhysRevD.97.056009>
- Cognodata (2019). ¿Qué Es El Análisis Descriptivo?. Recuperado de <https://www.cognodata.com/que-es-analisis-descriptivo/>
- González, Nelson Vladimir Yepes (2015). La educación lúdica en los procesos de enseñanza aprendizaje de los ingenieros industriales." *Encuentro Internacional de Educación en Ingeniería*.
- Haykin, S. (2004). *Neural Networks. A Comprehensive Foundation*. Vol. 2. Prentice Hall.
- Hernández Cruz, Harold. (2015). La Lúdica En El Aula de Ingeniería. Revisión de Experiencias. *Revista de Ingeniería, Matemáticas y Ciencias de La Información*. 2(3):67-71.
- Ithandehuil C. & Crisólogo, D. (2006). Lectura e Interpretación de Gráficas Socialmente Compartidas. *Revista Latinoamericana de Investigación en matemática educativa*.
- Katuu, S. (2020). New Review of Information Networking Enterprise Resource Planning: Past, Present, and Future." *New Review of Information Networking* 25(1):37-46. Doi: 10.1080/13614576.2020.1742770.
- Marco, F. J. (s.f.) R cuadrado ajustado: coeficiente de determinación ajustado. Recuperado de <https://economipedia.com/definiciones/r-cuadrado-ajustado-coeficiente-de-determinacion-ajustado.html>
- Minitab. (18 de abril de 2019). Análisis de Regresión: ¿Cómo Puedo Interpretar El R-Cuadrado y Evaluar La Bondad de Ajuste? [Entrada de blog]. Recuperado de <https://blog.minitab.com/es/analisis-de-regresion-como-puedo-interpretar-el-r-cuadrado-y-evaluar-la-bondad-de-ajuste>
- Moscote, O., and & Quintana, R. (2008). *Estadística I: Programa administracion publica territorial*.
- Murphy, K. P. (2006). Naive bayes classifiers. *University of British Columbia*, 18(60), 1-8.

- Mesa L., Lozano, M. R., & Davila, J.. (2011). Descripción general de la Inferencia Bayesiana y sus aplicaciones en los procesos de gestión. *La simulación al Servicio de la Academia*, 2, 1-28.
- Orozco, J. A. (2018). Machine Learning y su importancia en la actualidad. Recuperado de <https://www.ipade.mx/2018/08/30/machine-learning-y-su-importancia-en-la-actualidad/>
- Quiceno, M. O., & Jaramillo, C. (2006). Utilización de la lúdica para la enseñanza del MRP I. *Scientia et technica*, 3(32). Doi: <https://doi.org/10.22517/23447214.6289>.
- Pedregosa, F. et al. (2011). Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research* 12:28, 25–30.
- Ranjeeth, S., Latchoumi, T. P., & Paul, P. V. (2021). Optimal stochastic gradient descent with multilayer perceptron based student's academic performance prediction model. *Recent Advances in Computer Science and Communications (Formerly: Recent Patents on Computer Science)*, 14(6), 1728-1741.
- Rodriguez, A. M. P., Mejia, K. A. P., & Ramos, A. F. S. (2016). Propuesta de un juego de mesa como herramienta didáctica para la explicación de conceptos de control de inventarios en programas de ingeniería industrial. *Revista educación en ingeniería*, 11(21), 45-50.
- Soto, G. R. (2011). El teorema de Bayes. *Revista De Educación Matemática*, 26(3), 3-25.
- Weisstein, E. W. (2006). Correlation coefficient. Recuperado de <https://mathworld.wolfram.com/>.
- Wiper, M. (s.f.). Probabilidad condicionada y el teorema de BAYES ¿Cambiarías de Puerta? Recuperado de [http://halweb.uc3m.es/esp/Personal/personas/mwiper/documenta/Spanish/Teoria\\_Est\\_El/tema4\\_orig.pdf](http://halweb.uc3m.es/esp/Personal/personas/mwiper/documenta/Spanish/Teoria_Est_El/tema4_orig.pdf)