

## [221013] Modelo analítico de predicción de comportamiento en sistemas de manufactura

María Paula Barrera Camero<sup>a,c</sup>, Derly Yurley Beltrán Medina<sup>a,c</sup>, Laura Camila Paez Sierra<sup>a,c</sup>, Cristian Mauricio Calderón Cadena<sup>a,c</sup>, Jose Fernando Jimenez<sup>b,c</sup>

<sup>a</sup>Estudiante de Ingeniería Industrial

<sup>b</sup>Profesor, Director del Proyecto de Grado, Departamento de Ingeniería Industrial

<sup>c</sup>Pontificia Universidad Javeriana, Bogotá, Colombia

---

### Abstract

Manufacturing is one of the most important industries in the global economy. Today, it faces different challenges, such as the lack of development of flexible systems with high adaptability, the need to react to unexpected changes and the myopia present in the components of manufacturing systems. Myopia is one of the most important challenges facing manufacturing. Therefore, the objective of this work is to propose an autonomous predictive entity model that can predict the behavior and characteristics of system components in the short term and improve decision making and productivity in manufacturing systems. The model is developed in a system composed of a physical and virtual environment. The physical environment consists of a manufacturing system on a simulated platform. The virtual environment consists of an interface directed to the users who pilot the manufacturing system and manages the system to generate production orders and KPI predictions. Finally, an experimental observation study is performed in which the proposed model is applied to the manufacturing system and results in a 60% improvement in production decision making

*Keywords: Manufacturing, key performance indicators, manufacturing systems, temporal myopia, forecasting, simulated platform*

---

### 1. Justificación y planteamiento del problema.

Las empresas manufactureras representan una de las industrias más importantes en la actualidad, debido a su gran aporte a la economía global y al abastecimiento de bienes a los consumidores. Estas empresas en países industrializados representan un 30% del producto interno bruto, contribuyendo al desarrollo de tecnología, estudios de investigación e iniciativas de innovación. Por esta razón, la industria manufacturera busca responder a las necesidades de adaptación de las demandas de manufactura ágil, sistemas de fabricación flexible y sistemas con rápida respuesta en sus procesos de producción. (Israel *et al.*; Ding-yi *et al.*, 2019; Wang & Wei, 2019)

Asimismo, la industria manufacturera se enfrenta a una nueva revolución tecnológica y al cambio industrial impulsado por las tecnologías de la información y las comunicaciones. Estas tecnologías, tales como: Internet de las cosas, big data, inteligencia artificial, sistemas ciber-físicos (Pires *et al.*, 2020), entre otras, permiten mejorar la eficiencia y productividad en los procesos de producción y contribuyen al cumplimiento de las necesidades actuales de la industria de la manufactura. (Ding-yi *et al.*, 2019)

La industria manufacturera ha implementado sistemas de manufactura para conectar equipos inteligentes en redes de comunicación y lograr recopilar, analizar y procesar la información de la producción en tiempo real. De esta manera, los sistemas de manufactura permiten mejorar la eficiencia, aumentar la flexibilidad y ofrecer reactividad en los procesos producción, aportando a las necesidades de esta industria. (Fúquene-Retamoso *et al.*, 2007)

Sin embargo, los sistemas de fabricación inteligentes deben resolver los siguientes cinco desafíos para alcanzar su máximo potencial: En primer lugar, la predicción de la demanda real en un sistema de producción. La

demanda está sujeta a cambios debido a diversos factores tales como: precio, preferencias de los clientes, competencia, múltiples restricciones, etc. Estos factores conllevan una dificultad al modelar un sistema capaz de generar pronósticos acertados que se ajusten a las perturbaciones de la demanda. (Ni, 2015). En segundo lugar, el monitoreo de los datos de un sistema. Los sistemas de manufactura inteligente manejan un gran volumen de datos de entrada y salida. Así que, el monitoreo de los datos implica un obstáculo en la predicción de indicadores de desempeño. (Shi *et al.*, 2018). En tercer lugar, la conectividad de gemelos digitales. Los gemelos digitales emplean componentes de sistemas físicos y virtuales que están constantemente conectados, compartiendo datos y funciones. Posteriormente, los datos son recolectados para respaldar la ejecución de la simulación y el análisis de datos (Pires *et al.*, 2020). Por consiguiente, la conectividad de los gemelos digitales afecta al sistema productivo al que pertenecen.

En cuarto lugar, el comportamiento miope en los sistemas productivos actuales. El comportamiento miope, para las organizaciones manufactureras, es la consecuencia de la falta de “agudeza visual” de las condiciones, comportamientos y estados futuros de los sistemas productivos. El comportamiento miope se clasifica en dos tipologías. Por un lado, la miopía temporal que enfatiza en la falta de información que una máquina inteligente tiene sobre su futuro. Por otro lado, la miopía espacial que se entiende como la falta de información que una máquina inteligente tiene sobre su entorno. Ambos tipos de miopía implican limitaciones que no permiten que los sistemas inteligentes adquieran y procesen toda la información disponible para la toma de decisiones. (Zambrano *et al.*, 2011).

En quinto lugar, la definición de la arquitectura en sistemas de manufactura. En los sistemas de manufactura inteligente existen tres tipos de modelos: predictivo, reactivo y predictivo-reactivo. El modelo predictivo genera pronósticos al inicio de la producción, realizando un camino óptimo pero poco flexible a los cambios. El modelo reactivo toma decisiones en tiempo real, siendo flexible pero sin generar el camino óptimo posible (Villalba, 2020). El modelo predictivo-reactivo genera un programa de producción predictivo al inicio del proceso y se actualiza cada vez que ocurre una interrupción para reducir el efecto negativo en el rendimiento del sistema (Göppert *et al.*, 2021). Por consiguiente, el modelo predictivo y reactivo carecen de condiciones suficientes para acoplarse a la flexibilidad y optimalidad de los procesos de manufactura actuales. Por lo tanto, la industria manufacturera necesita un sistema que combine las características más ventajosas del modelo reactivo y predictivo.

De los cinco desafíos descritos anteriormente, en este documento se desarrollará el comportamiento miope, específicamente el tipo de miopía temporal, debido a su relevancia para los sistemas de manufactura. Al contribuir a una disminución de la miopía temporal, los sistemas de manufactura podrían tomar mejores decisiones en tiempo real, generando así, un beneficio tanto para los componentes del sistema como para el sistema en general. De igual forma, la información recolectada le permitiría a los sistemas de manufactura generar predicciones acertadas acerca de los panoramas que se pueden presentar en el futuro, con base en las decisiones del presente.

Por otro lado, la contribución a la miopía temporal genera aportes a otros desafíos planteados anteriormente, en los cuales no se profundizará en este documento. Estos desafíos son: modelación de análisis de datos, predicción de la demanda real en un sistema de producción y monitoreo de la acumulación de datos de los sistemas de manufactura.

Con la finalidad de contrarrestar la miopía temporal en un sistema de manufactura y, a su vez, aportar a otras problemáticas como se menciona anteriormente, es conveniente generar pronósticos en para establecer lo que puede pasar en un tiempo determinado. Por esta razón, los pronósticos se definen como el proceso mediante el cual se analizan datos y gráficos, para la toma de decisiones con respecto al futuro (Saxena *et al.*, 2012).

En la generación de pronósticos se utilizarán indicadores clave de rendimiento (KPI) para la previsión del comportamiento de un sistema en un instante de tiempo. Según Jeeretty *et al.*, (2019), los KPI son fundamentales a la hora de examinar los procesos de producción para establecer si el proceso está mejorando o no. Asimismo, para Chabane *et al.* (2020), los KPI se emplean para medir la actividad actual y monitorear el estado de los sistemas de producción. Por otro lado, para Xin-liang Xu en 2011, los KPI son una medida de gestión cuantitativa, que tiene como función principal muestrear, analizar y calcular los parámetros clave de entrada y salida del proceso productivo en una organización. En conclusión, los KPI son utilizados para

monitorear, medir y analizar el comportamiento del pasado y presente de un sistema de producción, pero no son empleados para generar pronósticos y prever el comportamiento en tiempo futuro de un sistema. Esta nueva aplicación de los KPI resulta útil para la solución de la miopía temporal, puesto que ayudaría a reducir el sesgo de información del sistema productivo frente a sus estados futuros, y de esta manera efectuar decisiones óptimas para los sistemas de manufactura.

De acuerdo con lo descrito anteriormente, el reto de este trabajo de grado es diseñar un mecanismo de previsión del comportamiento de sistemas de manufactura con indicadores clave de rendimiento (KPI). Por este motivo, el desarrollo de este se enfocará en la siguiente pregunta: ***¿Cómo un mecanismo de predicción e indicadores KPI puede contribuir a la disminución de la miopía temporal en los sistemas de manufactura?*** Asimismo, se plantean otras sub-preguntas que contribuyen a dar solución a esta problemática, las cuales son: *¿Cómo se vería afectada la toma de decisiones, si se tiene una previsión del comportamiento futuro de un sistema de manufactura?* y, *¿Cuáles indicadores clave de rendimiento son los más acertados para predecir y determinar las acciones con mayor beneficio para el sistema de manufactura?*

## **2. Antecedentes.**

Actualmente, los sistemas de manufactura buscan satisfacer el cambio en las demandas ágiles y flexibles, aumentando la eficiencia en producción, y la calidad del producto. Conforme a esto, los sistemas puedan contrarrestar la miopía temporal para contribuir a las necesidades de dichos sistemas. De tal manera, estos sistemas puedan prever en un instante de tiempo el comportamiento futuro, para mejorar los resultados finales de los procesos de producción. Asimismo, Zambrano *et al.*, (2011), desarrollaron un modelo para preservar el rendimiento en un sistema de manufactura inteligente, teniendo en cuenta el cambio de condiciones.

Para este trabajo de grado se realizó una exploración literaria para identificar los métodos más utilizados en la predicción del comportamiento en tiempo real de los sistemas de manufactura flexible, sus características, condiciones generales y resultados. Por consiguiente, en la exploración literaria se utilizaron bases de datos como IEEE Xplore, Springerlink, ACM y Science Direct. Con las siguientes palabras clave se encontraron 51 artículos de los últimos años (2007 a 2022): predicción, indicadores y fabricación. Luego de un filtrado de los artículos encontrados, se eligieron 21 de ellos, cuyos resultados se presentan a continuación (ver Tabla 1).

Tabla 1. Revisión literaria. Autoría propia.

Criterios	Criterio 1			Criterio 2				Criterio 3		Criterio 4		Criterio 5			Criterio 6						
	Análítica	Aprendizaje automático	Simulación	Heurística y metaheurística	Makespan o tiempo de fabricación de una orden de producción	Retraso máximo de una orden de producción	Lead time o tiempo de espera	Tiempo de flujo	Tiempo de permanencia en el buffer	Variables derivadas del error de previsión	Modelación predictiva	Modelación reactiva	Modelación predictiva-reativa	Tomar decisiones	Buscar alternativas	Nivel bajo	Nivel medio	Nivel alto	Estimación basada en datos instantáneos	Estimación basada en datos históricos	Estimación basada en ambos tipos
<b>Authors</b>																					
Sorjamaa, A. et al. (2007)	✓				✓					✓	✓			✓						✓	
Zambrano, G. et al. (2011)				✓	✓					✓		✓		✓				✓			✓
Shahzad, A. et al. (2012)			✓	✓	✓	✓	✓			✓		✓		✓				✓			✓
Zhang, Y. et al. (2015)		✓			✓							✓		✓				✓			✓
Kang, N. et al. (2015).	✓				✓				✓		✓			✓					✓		✓
Pfeiffer, A. et al. (2016)		✓	✓				✓			✓		✓		✓				✓			✓
Li, C. et al. (2016)				✓	✓	✓	✓			✓	✓			✓			✓		✓		✓
Janikova, D. et al. (2016)				✓	✓					✓	✓			✓			✓		✓		✓
de Jong, A. et al. (2017)	✓		✓		✓					✓		✓		✓				✓			✓
Matzka, S. (2018)	✓	✓								✓		✓		✓				✓			✓
Lin, C. Y. et al. (2019)	✓			✓	✓					✓	✓			✓			✓		✓		✓
Kuhnle, A. et al. (2019)		✓		✓	✓	✓						✓		✓				✓			✓
Wang, J. et al. (2019)				✓	✓					✓	✓			✓					✓		✓
Murphy, R. et al. (2019)		✓					✓			✓		✓		✓		✓			✓		✓
Kim, M. et al. (2019)		✓		✓	✓	✓	✓			✓		✓		✓			✓			✓	✓
Sonthited, P. et al. (2019)		✓		✓	✓	✓				✓	✓			✓				✓			✓
Yin, X. et al. (2020)		✓		✓	✓					✓		✓		✓				✓			✓
Wang, W. et al. (2021)	✓	✓			✓					✓		✓		✓			✓		✓		✓
Göppert, A. et al. (2021)		✓	✓	✓	✓					✓		✓		✓				✓			✓
Chabane, A. et al. (2021)	✓			✓	✓					✓	✓			✓				✓		✓	✓
Garrone, H. et al. (2022)			✓	✓	✓						✓			✓				✓		✓	✓

A partir de los resultados obtenidos en la búsqueda literaria, los artículos se clasificaron en seis criterios: el primer criterio se refiere a los métodos de predicción de KPI tales como: analítica, machine learning, simulación y heurísticas-metaheurísticas. El segundo criterio habla de los tipos de variables utilizadas en la modelación del sistema como: makespan, retraso máximo de una orden, tiempo de espera, tiempo de flujo, tiempo de residencia en buffer y error en el pronóstico. El tercer criterio denota los tipos de modelación: predictiva, reactiva o predictiva-reativa. El cuarto criterio habla de la predicción propuesta: toma de decisiones o búsqueda de alternativas. El quinto criterio indica los tres niveles de mitigación de la miopía temporal: bajo, medio y alto. Y finalmente, el sexto criterio hace referencia al modelo de estimación basado en datos históricos, instantáneos o en ambos.

Para una mejor comprensión, los artículos se analizaron y se dividieron en cinco categorías diferentes. La organización de las categorías responde a disminución de la miopía temporal, pronóstico de KPI basado en simulación, metaheurísticas y machine learning, pronóstico de KPI basado en la mezcla de metaheurísticas y machine learning, pronóstico de KPI basado en analítica con machine learning o analítica con heurísticas y metaheurísticas y pronóstico de KPI basado en machine learning y simulación.

### **2.1. Disminución de la miopía temporal**

En esta categoría se agrupan los artículos cuyo objetivo y/o finalidad es disminuir la miopía temporal. En la revisión literaria se encontró solo un artículo que referencia a las arquitecturas heterárquicas de los Sistemas de Manufactura Flexible (FMS). Los FMS buscan resolver la incapacidad de una entidad para adquirir y procesar la información en el sistema de manufactura. Este artículo tiene como objetivo preservar el rendimiento del modelo del sistema, mientras que una capa física agrupa productos para seguir el comportamiento prescrito, teniendo en cuenta el cambio de condiciones presentes. Sin embargo, en otro artículo, hacen referencia al desarrollo de un sistema de soporte de decisiones que utiliza metaheurística para generar una programación predictiva y reactiva (Meza *et al.*, 2020).

Esta categoría aporta información sobre las prácticas y consideraciones para el desarrollo del modelo analítico propuesto y resalta la importancia de una propuesta de entorno virtual. Esta propuesta se encuentra relacionada con programación predictiva-reactiva y del entorno físico con la capacidad de determinar el seguimiento de la programación ya sea establecida o automática.

### **2.2. Pronóstico de KPI basado en simulación, metaheurísticas y machine learning**

En esta categoría se encuentran los artículos cuyo objetivo y/o finalidad es el pronóstico de KPI basado en la combinación de simulación, metaheurísticas y machine learning. Shahzad & Mebarki(2012) desarrollaron un modelo que integra soluciones eficientes proporcionadas por la optimización, como la búsqueda tabú. De esta forma, obtener como resultado un conjunto de reglas capaces de aproximar soluciones eficientes para un problema de Job Shop Scheduling Problem. Asimismo, Sonthit et al., (2019) desarrollaron un sistema ciber físico integrado por un mundo físico y un mundo virtual, con el fin de predecir el rendimiento de resultados previstos en el sistema, e indicar la tendencia de cambio o irregularidades. Del mismo modo, Göpper *et al.*, (2021) desarrollaron un modelo con la capacidad de predecir las consecuencias de las acciones en tiempo real, ejecutando extensas simulaciones de eventos discretos. De tal manera que, gracias a la implementación de un modelo asociado a la inteligencia artificial con algoritmos de redes neuronales, poder determinar la planificación y el control de la producción en línea con indicadores de rendimiento como el makespan esperado.

Los artículos en esta categoría permiten la posibilidad de implementar simulación en los sistemas ciber físicos, con distintos algoritmos de machine learning y metaheurísticas, como redes neuronales y búsqueda tabú, incluyendo también, el autoaprendizaje de los sistemas de manufactura para la predicción de medidas de desempeño.

### **2.3. Pronóstico de KPI basado en la mezcla de metaheurísticas y machine learning.**

En esta categoría se encuentran los artículos cuyo objetivo y/o finalidad es el pronóstico de KPI basado en metaheurísticas y machine learning. Zhang *et al.*, (2015) presenta un método de predicción del estado de rendimiento del sistema de producción para el control de producción en tiempo real, mediante la aplicación de la teoría y los métodos de Redes Bayesianas Dinámicas (DBN). Asimismo, Li *et al.*, (2016) proponen el modelo de predicción mediante la combinación del modelo gris (GM) con la red neuronal artificial (ANN), para aprovechar al máximo las ventajas de la capacidad de una pequeña cantidad de datos disponibles para la extracción, la autoevaluación y autoaprendizaje. De igual forma, Janikova & Bezak, (2016) desarrollaron un modelo predictivo con la implementación de herramientas de inteligencia artificial y greddys, que describen el paso a paso del machine learning para verificar el grado en el que se acerca el modelo a un error muestral y sus diferentes medidas de desempeño. Además, Kim *et al.*, (2019) desarrollaron un modelo predictivo mediante técnicas apropiadas de pronóstico de la demanda comparando la técnica tradicional de análisis ARIMA de series de tiempo con el modelo de red no lineal. Finalmente, Yin *et al.*, (2020) desarrollaron un modelo predictivo que introduce la red neuronal Long short-term memory (LSTM) para tener en cuenta la información de datos históricos del rendimiento. De esta manera, el modelo integra la red Convolutional Neural Networks (CNN) y

el (LSTM) a través del método Adaboost para establecer un algoritmo de aprendizaje integrado de (CNN LSTM-Adaboost), que mejora la precisión de la predicción del modelo.

La información obtenida de esta categoría de artículos presentados, muestran una gran cantidad y variedad de algoritmos para la precisión y el rendimiento de KPI que podrían usarse en la modelación analítica, tales como Series de tiempo, Redes Bayesianas Dinámicas, algoritmos de redes neuronales y otros más complejos que combinan varios algoritmos a la vez, como el aprendizaje integrado de CNN LSTM-Adaboost.

#### **2.4. Pronóstico de KPI basado en analítica con machine learning o analítica con heurísticas y metaheurísticas**

En esta categoría se encuentran los artículos cuyo objetivo y/o finalidad es el pronóstico de KPI basado en analítica con machine learning o analítica con heurísticas y metaheurísticas. Matzka (2018) plantea un método analítico con machine learning que considera una gran cantidad de datos para la predicción de medidas de desempeño. De igual forma, propone cuantificar la calidad del proceso de producción, con el fin de optimizar la eficiencia del modelo predictivo. Asimismo, Wang *et al.*, (2021) desarrollan un método de asignación (PMRA), basado en la predicción del rendimiento de producción y la asignación de recursos, para predecir la producción y el estado de la misma. Por último, Chabane *et al.*, (2021) desarrollaron un modelo predictivo de KPI, que permite redirigir la toma de decisiones para garantizar la optimización del rendimiento y anticipar posibles interrupciones en el sistema de producción, por medio de modelación en redes de memoria a corto plazo (LSTM) y dispositivos inteligentes que tomen decisiones de manera automática y al instante.

Los modelos desarrollados en esta categoría de artículos permiten ver el estado de previsión futura, la eficiencia y la eficacia del modelo analítico. Además, permiten reducir las alternativas de toma de decisión y establecen un análisis predictivo de KPI basados en (RCPN), (PMRA), autoadaptable o en redes de memoria a corto plazo (LSTM).

#### **2.5. Pronóstico de KPI basado en machine learning y simulación.**

En esta categoría se encuentran los artículos cuyo objetivo y/o finalidad es el pronóstico de KPI basado en machine learning y simulación. Pfeiffer *et al.*, (2016) desarrollan un método para la selección de parámetros de ajuste que disminuyen el error en los pronósticos. De esta manera, el método efectúa la predicción fundamentada en múltiples modelos, basados en métodos de aprendizaje estadístico (regresión multivariante) y simulación de eventos discretos, con el propósito de anticipar desviaciones en un futuro cercano y generar autoaprendizaje de las máquinas inteligentes en los modelos de predicción.

En esta categoría de artículos resalta que el autoaprendizaje de las máquinas inteligentes permite prever las desviaciones de la predicción de KPI, tales como el WIP esperado y la autorregulación de los modelos de predicción en el sistema de soporte para la toma de decisiones, basados en simulaciones

Finalmente, como resultado ante los desafíos que se presentan para mitigar la miopía temporal, existe una gran variedad de métodos de resolución como la simulación, la analítica, las metaheurísticas y machine learning. De igual forma, la precisión, el rendimiento, la eficacia y eficiencia en los modelos analizados son algunas garantías que brindan la fiabilidad de los modelos reactivos en manufactura. Teniendo en cuenta las aproximaciones mostradas en la revisión literaria, este proyecto de grado pretende contribuir y posicionar una solución al problema de la miopía temporal.

### **3. Objetivos.**

#### **3.1. Objetivo general**

*Diseñar y desarrollar un mecanismo de previsión del comportamiento de sistemas de manufactura que, contribuyendo a la disminución de la miopía temporal, permite mejorar el pilotaje y toma de decisiones en el gerenciamiento de la producción para un usuario externo.*

#### **3.2. Objetivos específicos**

1. Identificar los requisitos y especificaciones de una plataforma simulada de un sistema de manufactura, que sirva como herramienta de prueba para el pilotaje de la producción.
2. Construir una plataforma simulada de un sistema de manufactura que, basado en una arquitectura de control distribuido, permita la inclusión de un mecanismo de previsión de comportamiento.
3. Desarrollar un mecanismo de previsión del comportamiento de sistemas de manufactura y KPI que contribuya a la disminución de la miopía temporal.
4. Realizar el acoplamiento del mecanismo de previsión del comportamiento en la plataforma simulada de un sistema de manufactura.
5. Validar de manera experimental el mecanismo propuesto, buscando evaluar la efectividad y contribución en el pilotaje y toma de decisiones de producción.

### **3.3. Declaración de diseño**

Desarrollo de un mecanismo de previsión del comportamiento basado en indicadores claves de rendimiento KPI 'S que permita disminuir la miopía temporal en un sistema de manufactura.

### **3.4. Requerimientos esperados de diseño**

Para el diseño a desarrollar, se deben satisfacer los siguientes requerimientos:

1. Una plataforma que permita simular un sistema de manufactura que, basado en una arquitectura de control distribuido, permita la inclusión de un mecanismo de previsión de comportamiento.
2. El mecanismo de previsión de los sistemas de manufactura debe utilizar KPI para el pronóstico del comportamiento.
3. El modelo de previsión del comportamiento basado en indicadores claves de rendimiento KPI debe ser flexible a los cambios de los sistemas de producción.
4. La aplicación del mecanismo de previsión de comportamiento en un sistema de manufactura debe presentar una disminución de la miopía temporal y una mejora en la toma de decisiones.

### **3.5. Restricciones de diseño**

El desarrollo del mecanismo de previsión está sujeta a las siguientes restricciones de diseño:

1. El enfoque principal en alguno de los tipos de producción, ya que, por el alcance del proyecto, el modelo no podrá abarcar la totalidad de prácticas de fabricación que actualmente existen.
2. Dado que el énfasis principal del modelo propuesto está relacionado principalmente con fines exploratorios, éste no tendrá en cuenta casos de estudio particulares que se hayan realizado por fuera de la literatura.
3. Las actividades del proyecto se realizarán de acuerdo con el cronograma estipulado, sin embargo, las fechas pueden tener alteraciones por condiciones exteriores o de fuerza mayor como aislamiento por COVID- 19.

### **3.6. Normas y estándares**

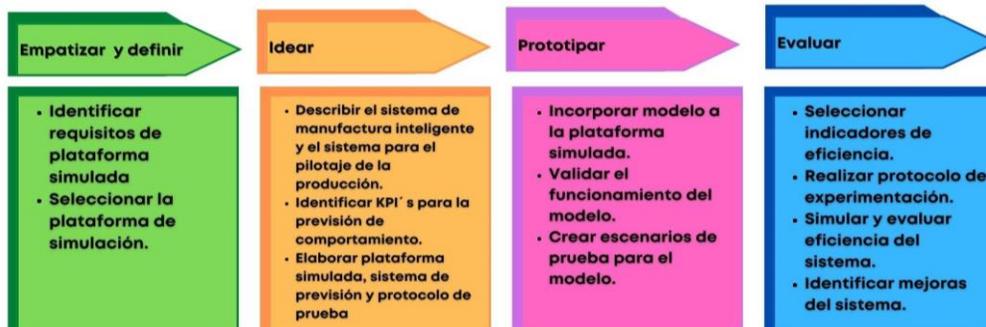
El modelo analítico propuesto tendrá en cuenta la norma ISO 15504 que prioriza la evaluación de mejora de procesos en modelos aplicados a software y que incluye un método de evaluación para el diseño de arquitectura que mejor se adapte a los sistemas de manufactura (El Emam, K., & Jung, H. W.2001).

## **4. Metodología.**

La metodología de este proyecto se fundamenta en la metodología *Design Thinking*. Esta metodología comprende cuatro fases (ver Figura 1). La primera fase identifica los requisitos de una plataforma de simulación que funcione como una herramienta de prueba para el pilotaje de un sistema de manufactura (*Empatizar y definir*). La segunda fase diseña un modelo de previsión del comportamiento de sistemas de manufactura y KPI (*Idear*). La tercera fase incorpora el modelo de previsión en la plataforma simulada (*Prototipar*). La cuarta fase

mide la disminución de la miopía temporal en la producción de la plataforma simulada con la aplicación del mecanismo de previsión del comportamiento (*Evaluar*).

Figura 1. Fases de metodología. Autoría propia.



#### 4.1. Identificación de los requisitos y especificaciones de una plataforma simulada de un sistema de manufactura.

El primer objetivo específico está alineado con la primera fase “*Empatizar y definir*” de la metodología *Design Thinking*. En esta sección se establecen los requisitos y especificaciones de la plataforma simulada de un sistema de manufactura.

Para la realización de este objetivo se requieren los siguientes apartados: el primer apartado selecciona el lenguaje de programación para la plataforma simulada a partir de la plataforma de simulación en Netlogo. El segundo apartado determina los requisitos y especificaciones de la plataforma simulada.

La plataforma de simulación se encuentra realizada en el programa Netlogo. Esta plataforma realiza la simulación de la producción de diferentes órdenes de producción, las cuales se encuentran dadas como parámetro en la codificación de la plataforma. Por consiguiente, la plataforma en Netlogo es un insumo dado por Jiménez, (2022) para la simulación de la producción del sistema de manufactura de este proyecto.

Para el desarrollo del primer apartado de este objetivo se realiza una matriz de priorización. La matriz establece el lenguaje de programación más adecuado para la conexión con la plataforma en Netlogo (ver Anexo 1). La matriz de priorización evalúa diferentes lenguajes de programación con base en los siguientes criterios: facilidad de interacción, acceso e integración a fuentes de datos, creación y visualización de datos, soporte entre la plataforma (Netlogo) y el lenguaje de programación (Python), licencia de uso, velocidad y adaptabilidad del programa (Morales et al., 2013).

El primer criterio hace referencia a la facilidad de interacción de una plataforma con un lenguaje de programación. Lo anterior teniendo en cuenta que el diseño de la plataforma simulada debe ser fácil, accesible y atractivo para el usuario. El segundo criterio comprende el acceso e integración a las fuentes de datos. Con base a esto, se requiere proporcionar comprensión, limpieza, seguimiento y transformación en la gestión de datos para disponer de una fuente de información confiable, consistente y que cumpla con los objetivos del modelo. El tercer criterio indica la creación y visualización de datos en una plataforma. En este sentido, es posible promover el uso de la plataforma simulada a través de elementos fácilmente controlados y visualizados a partir del lenguaje de programación empleado. El cuarto criterio comprende el soporte entre Netlogo y el lenguaje de programación. Dicho aspecto es fundamental para que la plataforma ejecute sus funciones utilizando un lenguaje simple, rápido y eficiente. El quinto criterio relaciona la licencia del lenguaje de programación, tomando a consideración que limita el uso de todas sus herramientas. El sexto y último criterio involucra la velocidad y adaptabilidad de la plataforma con el lenguaje de programación. De esta manera, las dos características le brindan efectividad a la simulación del modelo (Morales et al., 2013).

Para la selección del lenguaje de programación, se evalúan los criterios mencionados por medio del método de ponderación promedio (ver Tabla 2). Los puntajes asignados para la aplicación del método son los siguientes:

10 puntos con un valor recíproco de 0.1 puntos, 5 puntos con un valor recíproco de 0.2 puntos y 1 punto con un valor recíproco de 1 punto:

**Tabla 2.** *Peso ponderado para la selección del lenguaje de programación. Autoría propia.*

	Facilidad de Interacción	Acceso e integración de fuentes de datos	Creación de visualización de datos	Conectividad con Netlogo	Licencia completa	Velocidad	Adaptabilidad	Total	Peso ponderado definido
Facilidad de Interacción		5	1	5	5	1	1	18.00	0.23
Acceso e integración	0.2		1	5	1	5	5	17.20	0.22
Creación de visualización de datos	1	1		1	5	1	1	10.00	0.13
Conectividad con Netlogo	0.2	0.2	1		1	5	5	12.40	0.16
Licencia completa	0.2	1	0.2	1		0.2	0.2	2.80	0.04
Velocidad	1	0.2	1	0.2	5		1	8.40	0.11
Adaptabilidad	1	0.2	1	0.2	5	1		8.40	0.11
<b>Total</b>								77.2	1.00

Posteriormente, se calculan los pesos relativos de cada criterio para los diferentes lenguajes de programación como: *C++*, *Python*, *Visual Basic for Applications*, *Java* y *PHP*: (ver Tabla 3)

**Tabla 3.** *Recopilación de pesos relativos para la selección del lenguaje de programación. Autoría propia*

	Facilidad de Interacción	Acceso e integración de fuentes de datos	Creación de visualización de datos	Conectividad con Netlogo	Licencia completa	Velocidad	Adaptabilidad
<b>Python</b>	0.61	0.61	0.61	0.65	0.01	0.51	0.01
<b>C++</b>	0.13	0.27	0.27	0.12	0.23	0.15	0.23
<b>Java</b>	0.06	0.04	0.04	0.06	0.15	0.03	0.15
<b>PHP</b>	0.14	0.04	0.04	0.13	0.31	0.13	0.31
<b>Visual Basic for Applications (VBA)</b>	0.05	0.04	0.04	0.04	0.31	0.15	0.31

Por último, los diferentes lenguajes de programación considerados en la matriz se evalúan por medio de la factorización entre el promedio ponderado y el peso relativo de los diferentes lenguajes de programación como se observa en la Tabla 4.

**Tabla 4.** *Resultado final de la matriz de priorización para la selección del lenguaje de programación. Autoría propia.*

	Facilidad de Interacción	Acceso e integración de fuentes de datos	Creación de visualización de datos	Conectividad con Netlogo	Licencia completa	Velocidad	Adaptabilidad	Total
<b>Python</b>	0.14	0.14	0.08	0.10	0.00	0.06	0.001	0.52
<b>C++</b>	0.03	0.06	0.03	0.02	0.01	0.02	0.02	0.19
<b>Java</b>	0.01	0.0090	0.0052	0.01	0.01	0.00	0.02	0.06
<b>PHP</b>	0.03	0.01	0.01	0.02	0.01	0.01	0.03	0.13
<b>Visual Basic for Applications (VBA)</b>	0.01	0.01	0.01	0.01	0.01	0.02	0.03	0.09

De esta manera, el lenguaje de programación con mayor puntaje es Python (0.52), como se observa en la tabla 4.

Para el desarrollo del segundo apartado de este objetivo se implementa un “*Quality Function Deployment (QFD)*” con la finalidad de establecer los requisitos y especificaciones de la plataforma simulada (ver Anexo 2). Para ello, se investigan diferentes plataformas de simulación existentes en el mercado que cumplan con los requerimientos del usuario satisfactoriamente. Por lo tanto, se toma como ejemplo el sistema didáctico

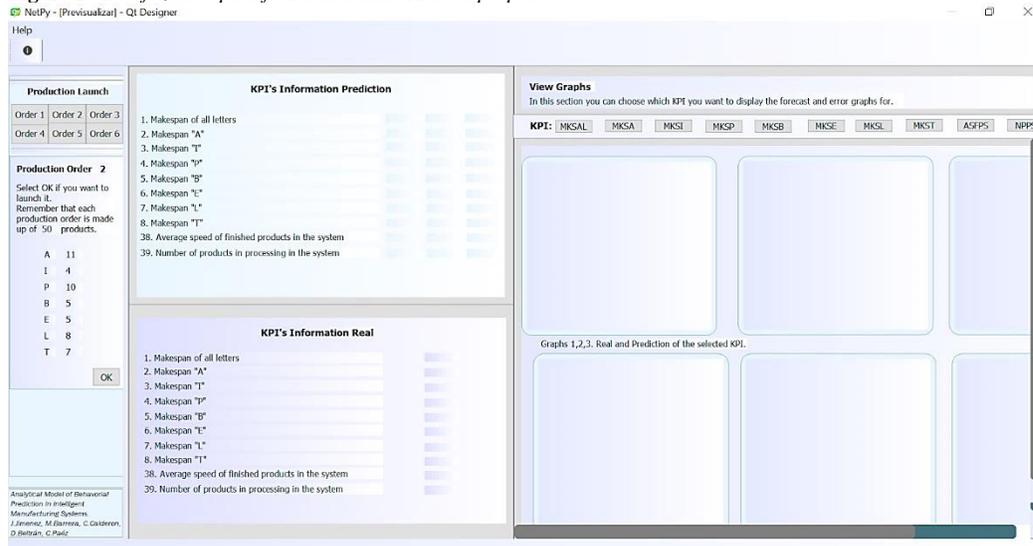
“Manufacturing Execution System (MES 4)” con una arquitectura reciente de las plataformas de aprendizaje de la industria 4.0 (FESTO, n.d).

A partir de las características de MES 4, se recopilan 12 requerimientos para su adopción en la plataforma de simulación a desarrollar (ver Anexo 2). Estos requerimientos son: creación de un menú general, opción de ayuda, opción de manejo de la producción, opción de lanzamiento de órdenes, opción de enlace entre Netlogo y Python, visualización de gráficas y datos de los indicadores de la producción, entre otros.

La plataforma de simulación comprende los requerimientos planteados a partir de MES 4. Además, la plataforma se desarrolla en el lenguaje de programación Python y ejecuta las órdenes de producción en Netlogo. En adición a ello, se requiere la creación de una interfaz que permita al usuario interactuar con la plataforma simulada. La elaboración de la interfaz de la plataforma simulada conlleva la utilización del programa para diseño QtDesigner y el lenguaje de programación Python. En este sentido, para visualizar la interfaz desde Python se hace uso del *binding* PyQt5. Dicho *binding* permite la implementación de botones, frames, widgets y la personalización del diseño de la interfaz desde Python.

De modo que, la interfaz cuenta con tres secciones principales. La primera sección se denomina “Production Launch”, en la cual se seleccionan las órdenes de producción a ejecutar. Luego, se encuentra la sección “Production Order” para visualizar el detalle de la orden de producción seleccionada. La segunda sección presenta los valores reales (*KPI information real*) y previstos (*KPI information prediction*) de los indicadores de desempeño. Por último, la tercera sección proyecta las gráficas (*View Graphs*) de los indicadores junto con sus predicciones. De igual forma, proyecta la gráfica del error de los pronósticos de los indicadores. En la siguiente figura se observa la interfaz desarrollada:

Figura 2. Interfaz de la plataforma simulada. Autoría propia.



## 4.2. Construcción de una plataforma simulada de un sistema de manufactura.

El segundo objetivo específico corresponde a la segunda fase “Idear” de la metodología “Design Thinking”. En esta sección, se construirá una plataforma de simulación para el pilotaje de la producción de un sistema de manufactura conforme a los requisitos descritos previamente en el capítulo 4.1.

Para el desarrollo de la plataforma de simulación, es necesario plantear el sistema de manufactura y la arquitectura de control del sistema.

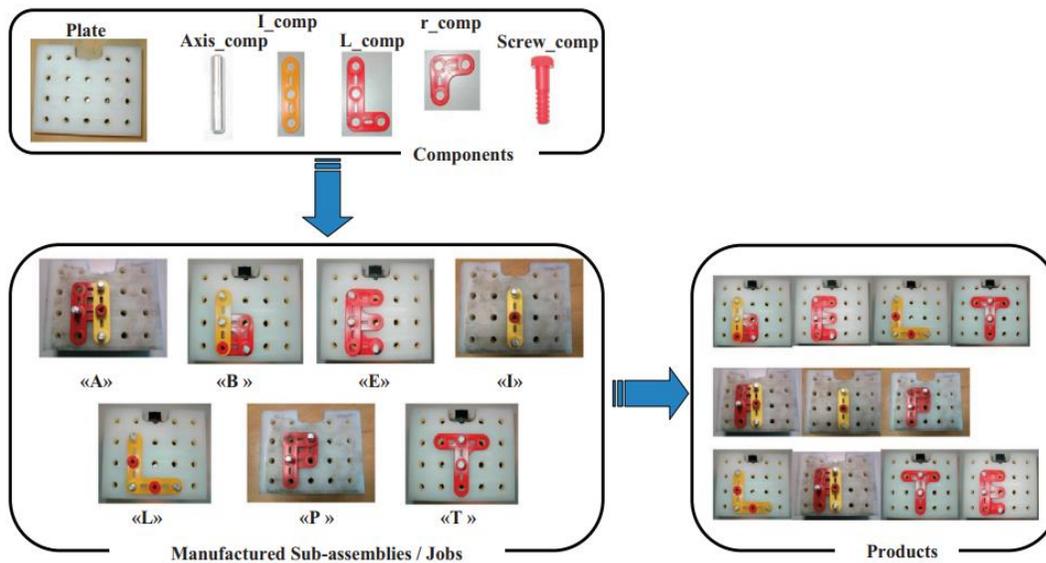
### 4.2.1. Sistema de manufactura de la plataforma simulada

El sistema de manufactura inteligente desarrollado por Trentesaux *et al.*, (2013) es un sistema basado en un

problema de “Flexible Job Shop Scheduling” implementado en una celda AIP-PRIMECA. Específicamente, este sistema de manufactura considera trabajos que van a ser procesados en diferentes máquinas. Cada trabajo tiene una secuencia de producción constituida por operaciones de manufactura que serán ejecutadas por una o más máquinas.

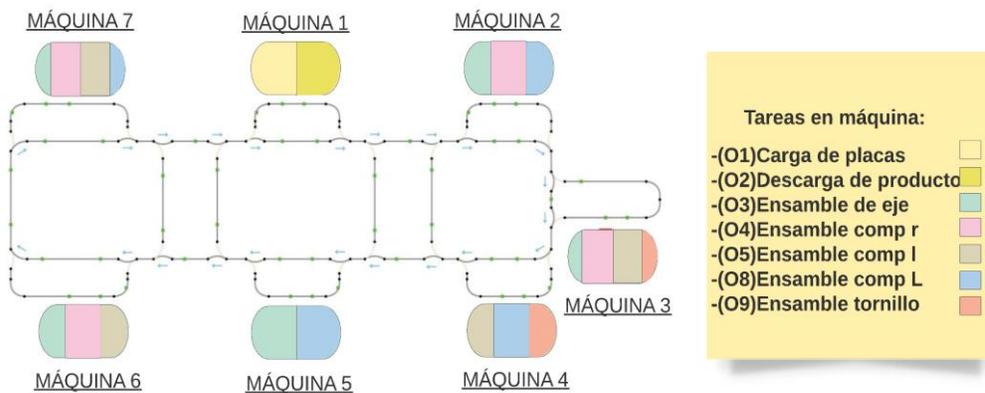
El sistema de manufactura está conformado por siete máquinas (M1, M2, M3, M4, M5, M6 Y M7), once nodos (n1, n2, n3, n4, n5, n6, n7, n8, n9, n10, n11), seis componentes (“Plate”, “Axis\_comp”, “I\_comp”, “L\_comp”, “r\_comp” y “screw\_comp”), siete tipos de productos (“B”, “E”, “L”, “T”, “A”, “I” y “P”) y ocho tipos de operaciones de fabricación (“Plate loading”, “Product unloading”, Axis, “r\_comp montaje”, “I\_comp montaje”, “L\_comp montaje”, “Screw\_comp”, “Inspection” y “Recovery”). (Ver Figura 3)

Figura 3. Productos y componentes del sistema, según el modelo propuesto por Trentesaux et al. (2013).



La distribución de planta del sistema de manufactura utiliza bandas transportadoras (Conveyors) para el desplazamiento de los productos en el sistema. Asimismo, cada máquina se encuentra ubicada en una posición fija y cuenta con ciertas operaciones ejecutables para la fabricación de los productos (Ver Figura 4).

Figura 4. Distribución de planta. Tareas de cada máquina. Autoría propia.



En adición, las máquinas se encuentran distribuidas y separadas a ciertas distancias entre sí dentro de la planta de producción (ver Tabla 1 en Anexo 3). Además, cada producto tiene una secuencia de ensamble y un número de operaciones específico (ver Tabla 2 en Anexo 3).

De igual manera, el sistema de manufactura está modelado con los siguientes conjuntos, parámetros y variables:

El conjunto de Letras  $L = \{A, B, E, I, L, P, T\}$  son los productos terminados del proceso de producción. Estos productos están compuestos por el conjunto de Materias Primas  $I = \{Lámina, Eje, Componente a, Componente l, Componente L, Tornillo\}$ , las cuales son procesadas por el conjunto de Máquinas  $M = \{m1, m2, m3, m4, m5, m6, m7\}$ . Adicionalmente, existe un conjunto de Procesos en Máquina  $R = \{Carga de placas, Descarga de producto, Ensamble de eje, Ensamble comp r, Ensamble comp l, ensamble comp L, Ensamble tornillo\}$  que desarrollan las operaciones necesarias para realizar cada tipo de producto. Por último, se tiene el conjunto de los Nodos  $N = \{1, 2, 3, \dots, 141\}$  que permiten visualizar las interacciones y realizar el seguimiento a los productos.

El modelo cuenta con los siguientes parámetros no binarios: Posición inicial de las máquinas  $Po_{m,n} \forall m \in M$  en el nodo  $n \in N$ , generación de productos  $Pop_n$  en el nodo  $n \in N$ , coordenadas  $PoN_n[x, y]$  en el nodo  $n \in N$ , lista de operaciones  $LS_l$ , tiempo de procesamiento  $Tp_{r,m}$  del proceso  $r \in R$  en la máquina  $m \in M$ , tiempo de traslado  $Tt_{n,\tilde{n}}$  del nodo  $n$  al nodo  $\tilde{n} / n, \tilde{n} \in N, n \neq \tilde{n}$  y la distancia  $Dn_{n,\tilde{n}}$  del nodo  $n$  al nodo  $\tilde{n}$ ;  $n, \tilde{n} \in N, n \neq \tilde{n}$ . En adición, se consideran los siguientes parámetros binarios:  $RMf_{r,m}$  1: El proceso  $r \in R$  puede realizarse en la máquina  $m \in M$ , 0: *dlc*;  $LRf_{l,r}$  1: La letra  $l \in L$  debe realizar el proceso  $r \in R$ , 0: *dlc*;  $ILf_{i,l}$  1: La materia prima  $i \in I$  compone la letra  $l \in L$ , 0: *dlc*;  $NNf_{n,\tilde{n}}$  1: Nodo  $n \in N$  puede salir para el nodo  $\tilde{n} \in N$ , 0: *dlc*. *Nota: El detalle de la formulación del problema se encuentra en el anexo 4.*

De la misma forma, el sistema de manufactura emplea los siguientes supuestos para su ejecución:

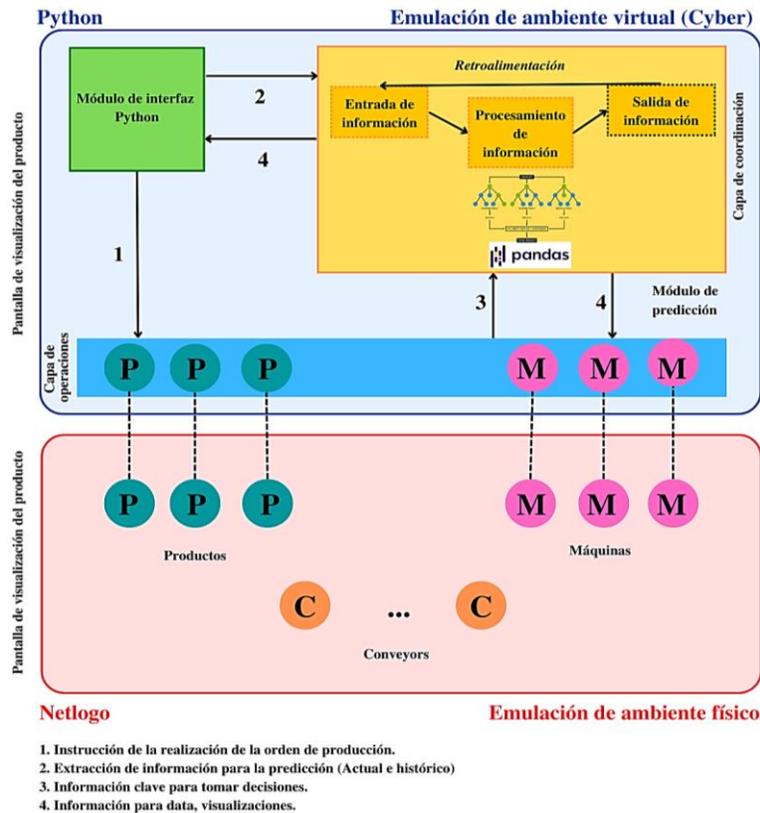
- Las órdenes de producción se generan asumiendo que el sistema dispone de las cantidades suficientes de componentes para satisfacer la producción.
- El “*setup time*” de cada máquina no es considerado en este sistema.
- Los productos se generan en el mismo nodo y salen del sistema en la máquina que registra la última operación requerida por el producto.
- El sistema de manufactura no cuenta con “*buffers*” para cada máquina. No obstante, los productos pueden esperar en los nodos anteriores antes de llegar a ser procesados, en caso tal que otra orden de producción se esté realizando delante de estos.
- En la ejecución de las órdenes de producción los productos se fabrican de manera aleatoria dependiendo de la disponibilidad de la máquina. y si en dicha máquina es posible realizar determinada operación.

#### 4.2.2. Arquitectura de control del sistema de manufactura de la plataforma simulada

La plataforma simulada se encarga del pilotaje de la producción del sistema de manufactura inteligente. Por ende, el modelo de previsión del comportamiento busca generar la predicción del pilotaje de la producción para la mejora en la toma de decisiones.

El desarrollo de la plataforma simulada requiere plantear una arquitectura de control para establecer el funcionamiento, conexión y componentes de la plataforma. Para ello, se emplea un diagrama de lenguaje unificado de modelo (UML). Según García, F. J *et al.*, (1998), los diagramas UML funcionan como una representación gráfica de la arquitectura física de un sistema informático. En este sentido, este diagrama permite evidenciar el orden, interacción e información que se transfiere dentro del sistema de la plataforma simulada (ver Figura 5).

Figura 5. Diagrama de la arquitectura de control del sistema. Autoría propia.



La arquitectura de control del sistema de la plataforma simulada está compuesta por dos subsistemas. El primer subsistema es la emulación de un ambiente virtual: este se encarga de recolectar la información del sistema de manufactura para generar predicciones que permitan mejorar el pilotaje de la producción. El segundo subsistema es la emulación de un ambiente físico: este se encarga de ejecutar las órdenes de producción del sistema de manufactura.

La emulación del ambiente virtual consta de una capa de operaciones y una capa de coordinación. Por un lado, la capa de operaciones se encuentra conectada con el sistema de manufactura, mientras que la capa de coordinación se encuentra conformada por un módulo de interfaz y un módulo de predicción. La descripción de la función de estos componentes de la capa de coordinación se presenta a continuación:

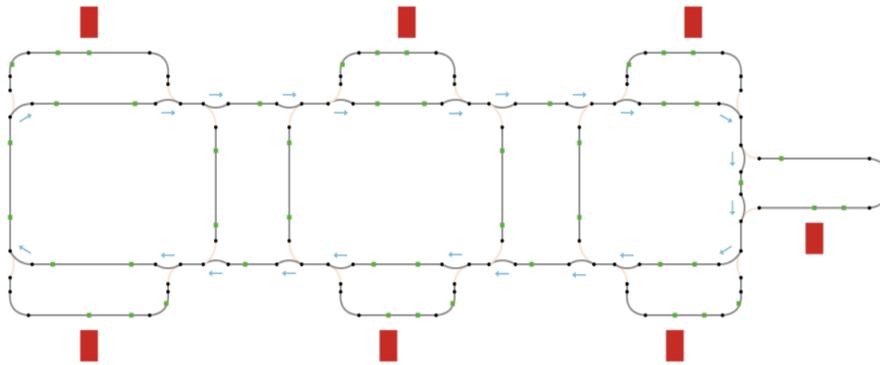
- **Módulo de interfaz de Python:** el módulo de interfaz se desarrolla en código de programación en Python. La codificación ejecuta las órdenes de producción para la capa de operaciones y suministra los datos históricos de las interacciones del sistema de manufactura al módulo de predicción.
- **Módulo de predicción:** el módulo de predicción se encarga de obtener la información del sistema de manufactura, procesa la información y genera predicciones para la toma de decisiones en el sistema. Por consiguiente, efectúa la interacción entre el módulo de interfaz y el ambiente físico (ver Anexo 5). En resumen, este módulo se encuentra conformado por tres secciones descritas a continuación:
  1. **Entrada de información:** en esta sección se suministra al modelo de previsión de comportamiento los datos de entrada de Netlogo.
  2. **Procesamiento de información:** en esta sección se desarrolla la codificación en Python por medio de librerías como Pandas y Sklearn. Estas librerías permiten administrar la información recibida y generar una predicción a partir de algoritmos de predicción.
  3. **Salida de la información:** en esta sección, el ambiente físico recibe la predicción del modelo para la

toma de decisiones.

La emulación de un ambiente físico está compuesta por productos (P), máquinas (M) y Conveyors (C). En este ambiente se implementa el sistema de manufactura en la plataforma de simulación en Netlogo. Para dicha implementación, es necesario definir los parámetros del modelo conforme a los cuatro tipos de agentes que define Zambrano (2014): *Tortugas*, *Parches*, *Enlaces* y *Observador*. Para el sistema se plantean tres agentes móviles y estáticos: *Productos*, *Nodos* y *Máquinas*. El detalle de esto se observa en el Anexo 6.

Luego de la descripción del sistema de manufactura inteligente y de la definición de la arquitectura de control del sistema de la plataforma simulada, se visualiza la distribución de planta de la plataforma en Netlogo (ver Figura 6)

**Figura 6.** Distribución de planta de la plataforma en Netlogo. Autoría propia.



Para este proyecto la plataforma de Netlogo se modifica con la finalidad de adaptarla a los requerimientos y necesidades de la plataforma de simulación, el modelo de predicción y la interfaz a desarrollar.

Finalmente, se crea un protocolo de prueba para la validación del correcto funcionamiento de la plataforma simulada (ver Anexo 7). Con base al protocolo de prueba, la plataforma simulada cumple con los requisitos planteados en el QFD del capítulo 4.1.

#### **4.3. Desarrollo de un mecanismo de previsión del comportamiento de sistemas de manufactura y KPI que contribuyen a la disminución de la miopía temporal.**

El tercer objetivo específico hace parte de la segunda fase “*Idear*” de la metodología *Design Thinking*. En esta sección, se desarrolla un mecanismo de previsión del comportamiento del sistema de manufactura de la plataforma simulada.

Para la realización del mecanismo de previsión se efectúan las siguientes pautas: en primer lugar, la identificación de los KPI para la previsión del comportamiento del sistema. En segundo lugar, la selección del modelo de predicción de los KPI. A continuación, se desarrollan dichas pautas:

##### **4.3.1. Identificación de KPI para la previsión del comportamiento del sistema de manufactura.**

El mecanismo de previsión del comportamiento busca reducir la miopía temporal en la producción del sistema de manufactura. Por tanto, se genera la predicción del comportamiento futuro a partir de la información recolectada de los KPI del sistema de producción. En consecuencia, se elabora una lista de priorización de KPI. Los KPI presentados en la lista de priorización deben permitir recolectar información puntual y de una ventana de tiempo del sistema de manufactura.

La lista de priorización se desarrolla con una lista compilada de KPI (ver Anexo 8) y con criterios de selección que permiten establecer los indicadores más oportunos para el mecanismo de previsión (ver Anexo 9). Para ello, se realiza la recolección de KPI como Ocupación, Eficiencia, Makespan, entre otros, a partir de diversas fuentes de información. De igual manera, se plantearon KPI para la extracción de la información en el sistema de producción como: efectividad de instrucción, camino más corto, entre otros. Asimismo, según Jiménez (2022) se determinan los criterios más relevantes para la selección de los KPI. A continuación, se presentan los nueve KPI seleccionados a partir de la lista de priorización para el mecanismo de previsión de comportamiento:

**Tabla 5.** KPI seleccionados para la previsión del comportamiento del sistema de manufactura. Autoría propia.

No.	Nombre	Descripción	Unidad	Tipo	Ecuación	Objetivo
1	Ocupación (Zona)	Calcula la cantidad de productos que circulan en cada zona en un instante de tiempo.	Unid.	Ventana	$\sum_{i \in \text{Productos}} P_{i,j} \forall i \in \text{Zonas}$ <i>P: Cantidad de productos</i>	Identificar las zonas con mayor congestión de productos para dirigir a los productos a zonas con poca ocupación.
2	Eficiencia (Máquina)	Calcula la eficiencia de cada máquina para realizar el tipo de operación de cada producto.	%	Puntual	$\frac{\sum_{i \in \text{Productos}} P_{i,m}}{\text{Tiempo producción}_m \cdot \text{Velocidad producción}_m} \forall m \in \text{Máquinas}$ <i>P: Cantidad de productos</i>	Identificar la máquina más eficiente-rápida para hacer la operación del producto.
3	Makespan (Producto)	Calcula el tiempo promedio en el que un producto ha estado en el sistema.	Min.	Ventana	$T_{i,j} \forall i \in \text{Productos}$ <i>T: Tiempo de producción promedio</i>	Identificar el tiempo de producción promedio del producto.
4	Cantidad de producción (Zona)	Calcula la cantidad de operaciones totales realizadas en cada zona.	Unid.	Puntual	$\sum_{i \in \text{Operaciones}} CP_{i,j} \forall i \in \text{Zonas}$ <i>CP: Cantidad de operaciones</i>	Identificar las zonas que más operaciones realizan en el sistema.
6	Rendimiento (Zona)	Calcula la cantidad de productos terminados en cada zona en un instante de tiempo.	Unid./Ticks de tiempo	Ventana	$\frac{\sum_{i \in \text{Productos}} P_{i,j}}{T_{p,i}}$ <i>Pt: cantidad de producto terminado, Tp: tiempo de producción de productos</i>	Identificar las zonas con mayor rendimiento del sistema.
7	Productos cerca (Producto)	Calcula la cantidad de productos que rodean a otro en una distancia menor, dependiendo del tipo de	Unid./Ticks de tiempo	Ventana	$\frac{\sum_{i \in \text{Productos cerca}} PC_{i,j}}{T_i} \forall i \in \text{Productos}$ <i>Pc: Cantidad de productos cerca, T: Tiempo promedio total</i>	Identificar el nivel de congestión del sistema según cada tipo de producto.
8	Velocidad del sistema	Calcula la velocidad promedio de todos los productos que se encuentran en procesamiento.	Unid. / Ticks de tiempo	Ventana	$\frac{Dis}{Temp}$ <i>Dis: Promedio de las distancias totales recorridas, Temp: Tiempo promedio total</i>	Identificar que la velocidad y fluidez de la producción del sistema.
9	Velocidad total de productos	Calcula la velocidad promedio de los productos que han estado dentro del sistema.	Unid. / Ticks de tiempo	Ventana	$\frac{Dis_i}{Temp_i} \forall i \in \text{Productos}$ <i>Dis: Promedio de las distancias totales recorridas, Temp: Tiempo promedio total</i>	Identificar la velocidad promedio de los productos en todo el tiempo de ejecución de la producción en el sistema.
10	Cantidad de productos en el sistema	Calcula la cantidad de productos que se encuentran circulación dentro del sistema en un instante de tiempo.	Unid.	Ventana	$\sum_{i \in \text{Productos}} P_i$ <i>P: Cantidad de productos en el sistema</i>	Identificar la cantidad de productos que se encuentran en circulación en un instante de tiempo.

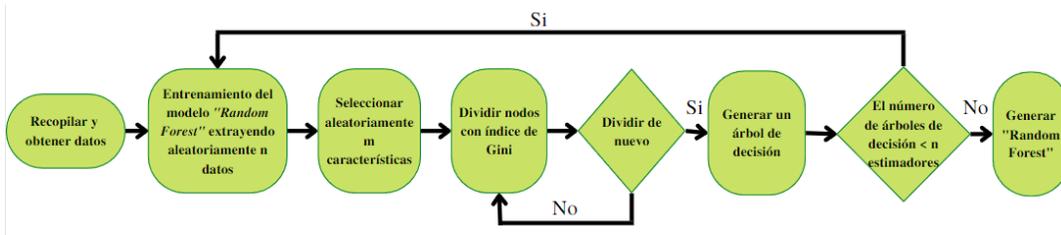
Los KPI seleccionados serán utilizados para la toma de decisiones futuras del sistema de manufactura. Para ello, se implementa un modelo que permita generar pronósticos de los datos recolectados de los KPI generados en la plataforma de Netlog.

### 4.3.2. Modelo de pronóstico de KPI

En los últimos años se han desarrollado un gran número de modelos de predicción (Hastie et al., 2009). Entre los modelos más utilizados se encuentran: neural networks (ANNs) (Brown et al., 2000; Porwal et al., 2003; Rigol-Sanchez et al., 2003; Rumelhart et al., 1986), decision trees (DTs) (Breiman et al., 1984), support vector machines (SVMs) (Abedi et al., 2012; Boser et al., 1992; Cortes and Vapnik, 1995; Zuo and Carranza, 2011) and ensembles of classification trees such as random forest (RF) (Breiman, 2001; Rodríguez-Galiano et al., 2014) (Rodríguez et al., 2015).

Dentro de los modelos de predicción mencionados anteriormente, el modelo seleccionado para la predicción de los KPI del sistema de producción es “Random Forest”. RF es una técnica de regresión para generar predicciones o clasificar una variable. Este modelo combina diversos algoritmos de DT. Cuando el modelo recibe el vector de entrada construye un número K de árboles y promedia el resultado de estos. Los árboles crecen a partir de diferentes datos de entrenamiento seleccionados aleatoriamente (Rodríguez et al., 2015). (Ver Figura 7)

Figura 7. Estructura lógica del modelo "Random Forest". Tomada de Zhou et al., (2020).

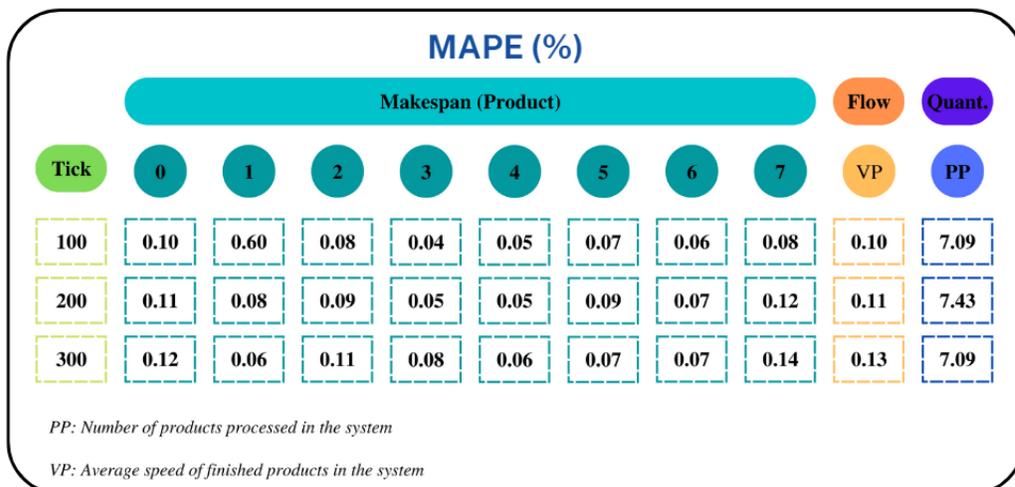


Para la aplicación del modelo RF en la predicción de KPI de la producción de la plataforma simulada se utiliza la librería Sklearn de Python. Asimismo, con la simulación de diferentes órdenes de producción en Netlogo se extraen dos bases de datos. La primera base contiene los datos de los KPI en el instante de tiempo 0. La segunda base de datos contiene los KPI en los instantes de tiempo futuros (100, 200 y 300). Para cada base de datos se selecciona el 80% de los datos para entrenar el modelo y el 20% de los datos para testear y determinar el error medio de porcentaje absoluto (MAPE) de cada modelo.

El entrenamiento del modelo se realiza para cada KPI, para cada producto, para cada máquina o zona, y para cada instante de tiempo futuro (100, 200 y 300). Por tanto, se obtienen 117 modelos de KPI entrenados (ver Anexo 10). Luego de entrenar los modelos se realiza el testeo para determinar el MAPE de cada modelo. Con base al MAPE obtenido se seleccionan los KPI con el menor error registrado de acuerdo a la Figura 8, en donde es posible observar que el menor MAPE es de 0.04. Como muestra de KPI fueron seleccionados los KPI 3, 9 y 10 de la tabla 4, los que a su vez se visualizan en la interfaz de la plataforma.

Cabe resaltar que en la figura 8 es posible identificar para el tick 100, 200 y 300 respectivamente los MAPE de los KPI seleccionados. En dicha figura el makespan 0 hace referencia al makespan promedio de todas las letras (A, I, P, B, E, L, T). De igual manera el makespan del 1 al 7 hace referencia al makespan de cada letra en su orden A, I, P, B, E, L y T. En adición se encuentra el "VP" que hace referencia a la velocidad promedio de productos terminados en el sistema". Por último, se encuentra el "PP" que indica el número de productos en proceso el sistema.

Figura 8. MAPE de los KPI seleccionados a partir del menor error registrado. Autoría propia.



#### 4.4. Realización del acoplamiento del mecanismo de previsión del comportamiento en la plataforma simulada de un sistema de manufactura.

El cuarto objetivo específico está alineado con la tercera fase “*Prototipar*” de la metodología *Design Thinking*. En esta sección se desarrolla el acoplamiento del modelo de previsión del comportamiento con la plataforma de simulación del sistema de producción.

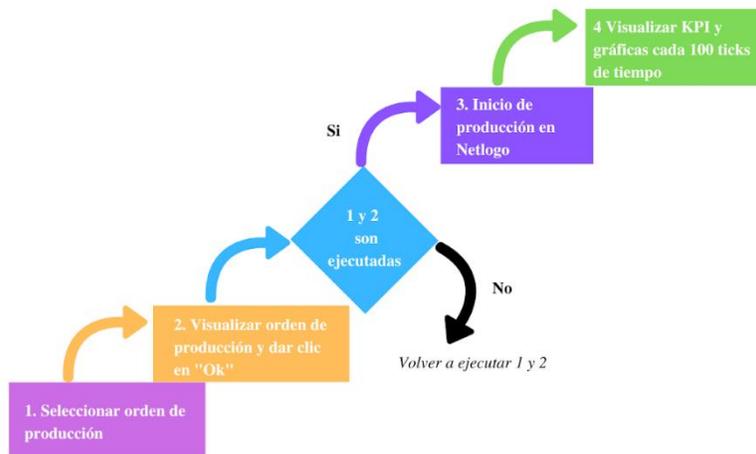
Para la realización del acoplamiento entre la plataforma simulada y el modelo de previsión de comportamiento se desenvuelven los siguientes pasos: en primer lugar, la incorporación del modelo de previsión con la plataforma simulada. En segundo lugar, la validación de la incorporación realizada entre el modelo y la plataforma simulada.

##### 4.4.1 Incorporación del modelo de previsión de comportamiento con la plataforma simulada.

La plataforma simulada se compone de un ambiente físico (Netlogo) y un ambiente virtual (Python). Para la conexión entre ambos ambientes se requiere una estructura lógica que permita conectar secuencialmente los componentes de la emulación del ambiente físico y virtual.

La estructura de la base lógica del mecanismo se plantea como se muestra en la Figura 9. La primera opción “Production Launch” permite ofrecer una variedad de 6 órdenes de producción al usuario, en la que es posible seleccionar una para ejecutar en Netlogo. Una vez seleccionada la orden de producción y pulsado el botón “OK”, se abre y ejecuta la producción en Netlogo. Asimismo, se “visualizan los KPI reales y predictivos junto con las gráficas que describen el comportamiento”. Además, se visualiza la gráfica del MAPE de los pronósticos de los KPI.

Figura 9. Diagrama de flujo de modelo predictivo. Autoría propia.



Con base a la estructura lógica planteada se realiza la programación en Python del acoplamiento del mecanismo de previsión del comportamiento con la plataforma simulada. La programación se desarrolla en un código principal en Python. En el código principal se integran tres estructuras de código. La primera estructura es la incorporación de la plataforma en Netlogo. La segunda estructura es el uso de los modelos predictivos de cada KPI. La tercera estructura es la interfaz en Qt Designer que permite visualizar la integración de todas las estructuras mencionadas.

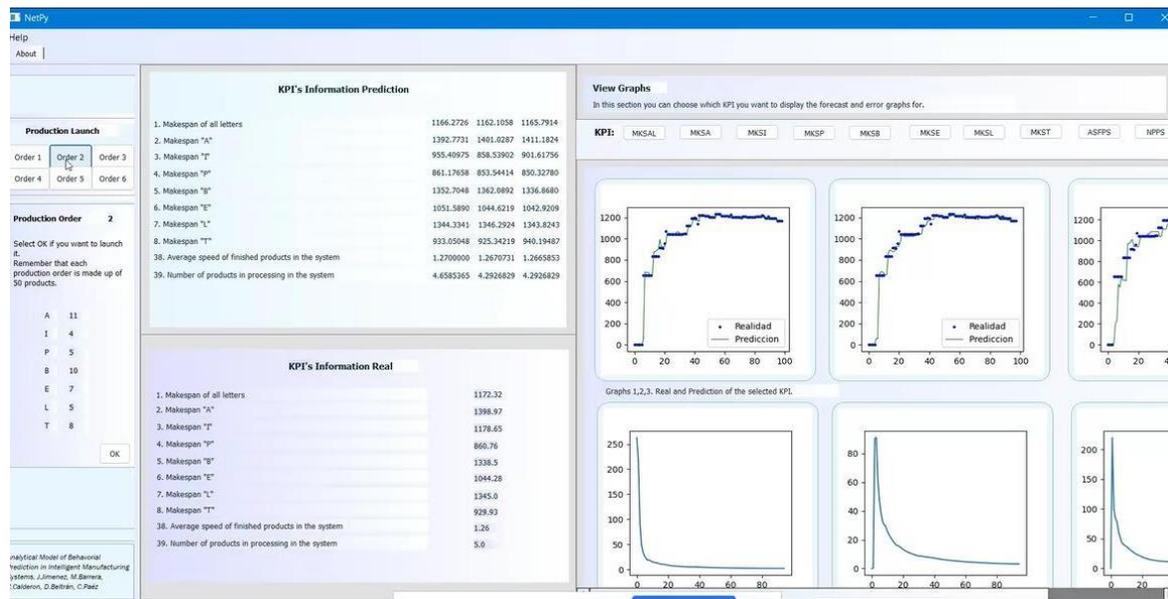
De esta forma, la interfaz denominada “NetPy” es la pantalla de visualización del modelo. Desde NetPy se lanza la orden de producción, se visualizan los KPI, los pronósticos y gráficas de cada KPI en 100, 200 y 300 ticks de tiempo. En adición, la plataforma en Netlogo se encarga de realizar las órdenes de producción y calcular los KPI de productos, máquinas y zonas. Los valores de los KPI son enviados a Python para calcular los

pronósticos de la producción. Así, los pronósticos son generados por los modelos entrenados de los KPI para ser visualizados en la interfaz. (Ver Anexo 11)

#### 4.4.2 Validación de la incorporación del modelo de previsión de comportamiento con la plataforma simulada

La validación de la incorporación del mecanismo de previsión y la plataforma simulada se desarrolla realizando la ejecución de diferentes órdenes de producción en la interfaz de la plataforma. Una vez ejecutadas las órdenes de producción se valida que cada función de la interfaz y las conexiones entre Python y Netlogo funcionan correctamente. Asimismo, que se generan y visualizan los KPI reales y predictivos junto con las gráficas correspondientes. (Ver Figura 10)

Figura 10. Interfaz de la plataforma simulada en funcionamiento. Autoría propia.



#### 4.5. Validación experimental de la efectividad y contribución en el pilotaje y toma de decisiones de producción del mecanismo de previsión propuesto.

El quinto objetivo específico se encuentra alineado con la cuarta fase “Evaluar” de la metodología Design Thinking. En esta sección se valida experimentalmente la efectividad del modelo de previsión del comportamiento. Asimismo, la contribución en el pilotaje y toma de decisiones en la producción de la plataforma simulada.

Tabla 6. Estudio de percepción. Autoría propia.

<b>Estudio de percepción del “Modelo analítico de predicción de comportamiento en sistemas de manufactura”</b>
<p><b>Introducción:</b> El estudio de percepción se desarrolla con la finalidad de realizar la validación del “Modelo analítico de predicción de comportamiento en sistemas de manufactura”. Para ello, se lleva a cabo una simulación con una muestra de 10 estudiantes de ingeniería industrial de la Pontificia Universidad Javeriana. La mitad de la muestra de estudio toma decisiones de producción con base a la información de las órdenes de producción (grupo A). La otra mitad de la muestra toma decisiones de producción con base a la información de la producción en y predicciones de los KPI y gráficas de la interfaz de la plataforma (grupo B).</p>

**Objetivo:** Validar el funcionamiento y el aporte a la reducción de la miopía temporal en un sistema de producción con aplicación del “Modelo analítico de predicción de comportamiento en sistemas de manufactura” con base a la percepción del usuario de la plataforma.

**Metodología:**

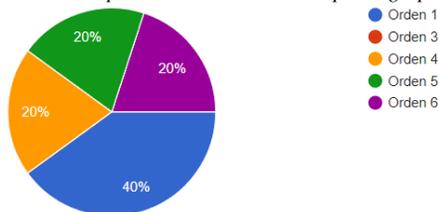
- Explicación del contexto de la problemática abordada y del modelo desarrollado a los participantes del estudio. Asimismo, se realiza la explicación de los pasos a seguir en el experimento observacional.
- Envío de formularios a las muestras del experimento. El formulario del grupo A es desarrollado por la muestra de ingenieros que toman decisiones a partir de la información de las órdenes de producción. El formulario del grupo B es desarrollado por la muestra de ingenieros que toman decisiones de producción a partir de la información en y predicciones de los KPI.
- Registro de formulario de las órdenes de producción que desea ejecutar el grupo A, a partir de la información de las características de las órdenes de producción.
- Sesión virtual con el grupo B. En la sesión se selecciona una orden de producción a ejecutar y los ingenieros pueden observar la información de los valores de los KPI y de sus predicciones. Al igual que las gráficas de los KPI y del MAPE de los pronósticos.
- Registro de formulario de las órdenes de producción que desea ejecutar el grupo B.
- Recolección de la información de los formularios de los grupos A y B.
- Comparación de los resultados obtenidos de los formularios de los grupos A y B.
- Ejecución de las órdenes de producción seleccionadas por los grupos de estudio A y B en la plataforma simulada.
- Recolección de los valores de los KPI de las ejecuciones de las órdenes de producción.
- Conclusiones de los resultados obtenidos a partir del estudio experimental de observación.

**Resultados de los formularios registrados por las muestras del estudio:**

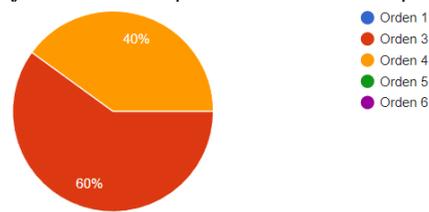
La muestra encuestada en el estudio experimental observacional comprende estudiantes de ingeniería industrial entre noveno y doceavo semestre de la Pontificia Universidad Javeriana.

Los resultados obtenidos de las órdenes de producción seleccionadas por cada grupo se muestran a continuación:

**Gráfica 1. Órdenes de producción seleccionadas por el grupo A**



**Gráfica 2. Órdenes de producción seleccionadas por el grupo B**



**Comparación de datos de las dos muestras de estudio:**

A partir de los resultados registrados en el formulario desarrollado por las muestras de estudio se obtiene lo siguiente:

- La muestra del grupo A presenta una selección más amplia de órdenes de producción con un total de 4. Mientras que la muestra del grupo B presenta una selección con un total de 2 órdenes de producción.
- La muestra del grupo A selecciona las órdenes 4,5 y 6 con un voto (20%) y la orden 1 con dos votos (40%).
- La muestra del grupo B selecciona la orden 4 con dos votos (40%) y la orden 3 con 3 votos (60%).

**Resultados de la ejecución de las órdenes de producción seleccionadas por las muestras del estudio:**

Luego de obtener los resultados de las órdenes seleccionadas por las muestras del estudio, se ejecutan dichas órdenes en la plataforma simulada. A continuación, se presentan los KPI en un instante de tiempo de la ejecución de cada orden:

*Tabla 6. KPI de las órdenes de producción seleccionadas por el grupo A y el grupo B. Autoría propia.*

KPI Real					
KPI	Orden 1	Orden 3	Orden 4	Orden 5	Orden 6
1	834.93	793.85	1145.63	1140.43	1203.22
2	0.00	0.00	1370.14	1571.49	1457.07
3	0.00	0.00	853.32	893.13	1056.80
4	532.60	495.80	995.54	702.91	894.97
5	1328.00	1108.10	1568.37	1322.92	1527.73
6	0.00	0.00	1067.77	1156.62	1222.80
7	0.00	0.00	1370.46	1299.09	1348.34
8	644.20	463.40	843.00	918.08	875.12
9	1.29	1.26	0.75	0.74	0.75
10	5.00	6.00	6.00	3.00	8.00

*Nota: Los valores de los KPI en color rojo representan los mínimos valores obtenidos en las órdenes de producción ejecutadas por cada KPI. Los valores mínimos de cada KPI son los valores óptimos o deseados en la producción.*

#### Conclusiones del estudio:

A partir de la percepción de las muestras de estudio sobre la plataforma simulada se concluye lo siguiente:

- Las órdenes de producción seleccionadas por la muestra de estudio que solo visualiza la información de las órdenes de producción (grupo A) presentan un rango de selección de las órdenes más amplio (el doble que el grupo B), con un total de 4 órdenes de producción. Mientras que la muestra de estudio que visualiza la información de los KPI en (grupo B) tiene un margen menor con 2 órdenes seleccionadas.
- La muestra del grupo A selecciona las órdenes 1,4,5 y 6 y la muestra del grupo B selecciona las órdenes 3 y 4.
- La orden de producción 3 presenta los valores mínimos de 8 KPI por lo que se determina como la orden de producción con los mejores valores para los KPI del sistema.
- El 60% de la muestra del grupo B acierta en la decisión de seleccionar la orden de producción 3 como la que contiene los mejores valores de los KPI para el sistema. Mientras que ningún integrante de la muestra del grupo A seleccionó la orden 3.

#### 5. Limitaciones, conclusiones y recomendaciones.

Netlogo es una herramienta esencial para el desarrollo de la emulación del ambiente físico de la plataforma simulada del proyecto. Sin embargo, la codificación de las órdenes de producción en Netlogo suponía una limitación en la cantidad de productos en el sistema de manufactura. En este sentido, para que la ejecución de las órdenes de producción se realice sin problemas de codificación, no se deben superar los 15 productos dentro del sistema.

Asimismo, la extracción de la información de los KPI de Netlogo se realiza cada 100 ticks de tiempo por facilidad en la codificación de Netlogo. Por ende, la visualización de esta información en NetPy se encuentra limitada a los datos de los KPI que Netlogo envía a la interfaz.

Las conclusiones de este trabajo de grado parten de la pregunta planteada: *¿Cómo un mecanismo de predicción e indicadores KPI puede contribuir a la miopía temporal en los sistemas de manufactura?* Esta pregunta se logra resolver con la realización de la plataforma simulada que integra un sistema de manufactura en Netlogo, del cual, se extrae información de los KPI y se generan predicciones de estos indicadores para la toma de decisiones de producción. Adicionalmente, la plataforma cuenta con una interfaz llamada NetPy, en la cual se selecciona la orden de producción a ejecutar, se visualiza la información numérica de los KPI y su pronóstico, así como sus correspondientes gráficas.

De igual forma, los resultados obtenidos en el estudio de percepción de la plataforma simulada permiten determinar una mejora en la toma de decisiones con base en la percepción de los participantes del estudio. Por consiguiente, a partir de la predicción de los KPI se evidencia una mejora en la toma de decisiones de producción debido al aumento de información de tiempo futuro del sistema. En consecuencia, la implementación del

modelo de previsión de comportamiento en el sistema de manufactura contribuye a la disminución de la miopía temporal para el usuario de plataforma encargado de la toma de decisiones en el pilotaje de la producción.

Igualmente, se concluye a partir de las sub preguntas planteadas: *¿Cómo se vería afectada la toma de decisiones, si se tiene una previsión del comportamiento futuro de un sistema de manufactura?* y, *¿Cuáles indicadores clave de rendimiento son los más acertados para predecir y determinar las acciones con mayor beneficio para el sistema de manufactura?* Por un lado, para la primera pregunta se realiza un estudio de percepción con estudiantes de ingeniería industrial de últimos semestres. Con base a este estudio se observa que las decisiones de producción mejoraron en un 60% para la muestra de ingenieros que visualizaban NetPy en la selección de las órdenes de producción más eficientes a ejecutar. Por otro lado, para la segunda pregunta se realiza una lista de priorización para la selección de KPI más acertados para la predicción y toma de decisiones de producción. Luego de esto, se evalúa el modelo de predicción de cada KPI y se seleccionan los KPI con el menor MAPE registrado para que sean visualizados en la interfaz NetPy.

Al mismo tiempo, para la realización del modelo de previsión de comportamiento se implementa “*Random Forest*”. RF es un modelo que permite generar predicciones a partir de un conjunto de datos. La aplicación de este modelo para el pronóstico de los KPI arrojó valores del MAPE entre el 0.04 y el 7.09, lo que hace que los pronósticos de los KPI sean muy acertados y la efectividad de la plataforma simulada aumente. Igualmente, el modelo RF permitió obtener pronósticos con un MAPE histórico que tiende a cero. Es decir, a medida que la plataforma obtiene más datos de la producción, el error en los pronósticos de los KPI disminuye con el tiempo.

En adición, cabe resaltar que teniendo en cuenta los análisis realizados se reduce la miopía temporal del sistema de manufactura propuesto, debido a los pronósticos de KPI por medio del modelo Random Forest. En este sentido, también considerando que el sistema de manufactura se encuentra simulado, es posible reducir costos, tiempos y de esta manera, incrementar constantemente el nivel de calidad del mismo.

Cabe resaltar que para el desarrollo lógico de este trabajo se tomó a consideración la norma ISO 15504 “*Determinación de la Capacidad de Mejora del Proceso de Software*”, también conocida por sus siglas “*SPICE*”. A partir de esta norma se realizó una evaluación de procesos con base en el nivel de capacidad, en donde se obtuvo como resultado un nivel 2. Lo anterior, teniendo en cuenta que el proceso “*está controlado, su implementación está planificada, monitoreada y ajustada. Sus resultados (productos de trabajo) son establecidos, controlados y debidamente registrados y mantenidos*”. (Normas Iso.,2022).

Con base a lo realizado en este proyecto, se realizan las siguientes recomendaciones a futuro. En primer lugar, realizar una ampliación de las órdenes de producción que se ejecutan desde la interfaz NetPy. La plataforma desarrollada se desenvuelve en un caso de estudio, por lo que la ordenes de producción se encuentran preestablecidas en la codificación de Netlogo. Sin embargo, una mejora a la plataforma simulada sería la flexibilidad en la creación de las órdenes de producción por parte del usuario. De esta forma, no solo se podrían ejecutar seis órdenes de producción si no todas las ordenes que el usuario decida ejecutar. En segundo lugar, realizar un estudio experimental con una muestra más amplia, de manera que permita identificar con mayor precisión la eficiencia del modelo de predicción y la plataforma simulada. Asimismo, identificar mejoras planteadas por el usuario para la mejora constante del proyecto.

## 6. Anexos.

Tabla 6. Lista de anexos.

Anexo	Nombre	Desarrollo	Tipo de archivo	Enlace de archivo	Relevancia para el proyecto
1	Matriz de priorización de plataforma	Propio	Excel	<a href="#">Anexo No.1</a>	2
2	QFD	Propio	Excel	<a href="#">Anexo No.2</a>	3
3	Distancia entre máquinas y secuencia de ensamble	Trentesaux et al., (2013)	PDF	<a href="#">Anexo No.3</a>	10
4	Formulación matemática de la plataforma de producción	Propio	PDF	<a href="#">Anexo No.4</a>	9
5	Diagrama módulo de predicción	Propio	PDF	<a href="#">Anexo No.5</a>	4
6	Diagrama de elementos Netlogo	Propio	PDF	<a href="#">Anexo No.6</a>	6
7	Protocolo de Prueba Plataforma de Simulación	Propio	PDF	<a href="#">Anexo No.7</a>	7
8	Lista de KPI	Propio	PDF	<a href="#">Anexo No.8</a>	8
9	Lista de priorización de KPI	Propio	Excel	<a href="#">Anexo No.9</a>	5
10	Modelos de KPI	Propio	.pkl	<a href="#">Anexo No.10</a>	2
11	Plataforma simulada	Propio	.py	<a href="#">Anexo No.11</a>	1

## 7. Referencias.

- Bú, R. C. (1994). Simulación: Un enfoque práctico. Editorial Limusa.
- Chabane, A. N., Sahnoun, M. H., & Bettayeb, B. (2021, May). Forecasting KPI of Production Systems Using LSTM Networks. In 2021 1st International Conference On Cyber Management And Engineering (CyMaEn) (pp. 1-6). IEEE
- De Jong, A. W., Rubrico, J. I., Adachi, M., Nakamura, T., & Ota, J. (2017, August). Big data in automation: towards generalized makespan estimation in shop scheduling problems. In 2017 13th IEEE Conference on Automation Science and Engineering (CASE) (pp. 1516-1521). IEEE.
- Ding-yi, Z., Peng, W., Yan-li, Q., & Lin-shen, F. (2019, November). Research on intelligent manufacturing systems of sustainable development. In 2019 2nd World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM) (pp. 657-660). IEEE.
- Duy, N. L. Q. (2020). Practicing design thinking for sustainability: a case study of a low-cost and flexible workstation in lean manufacturing (Doctoral dissertation).
- El Emam, K., & Jung, H. W. (2001). An empirical evaluation of the ISO/IEC 15504 assessment model. Journal of Systems and Software, 59(1), 23-41.
- Fúquene-Retamoso, C. E., Aguirre-Mayorga, H. S., & Córdoba-Pinzón, N. B. (2007). Evolución de un sistema de manufactura flexible (FMS) a un sistema de manufactura integrada por computador (CIM). Ingeniería y universidad, 11(1).
- Garrone, H., Pepe, C., Reineri, A., Monticone, E., Filippo, R., & Rajteri, M. (2022). Simulation software for transition-edge sensor performance prediction. IEEE Transactions on Applied Superconductivity.

- Göppert, A., Mohring, L., & Schmitt, R. H. (2021). Predicting performance indicators with ANNs for AI-based online scheduling in dynamically interconnected assembly systems. *Production Engineering*, 15(5), 619-633.
- Israel, L. V., Ismael, L. J., Jorge, C. C., Arquímedes, O. R., & Mario, P. C. (No tiene año). Hacia la Integración de un Sistema Inteligente de Manufactura: Consideraciones y Experimentos.
- Janikova, D., & Bezak, P. (2016, September). Prediction of production line performance using neural Networks. In 2016 Third International Conference on Artificial Intelligence and Pattern Recognition (AIPR) (pp. 1-5). IEEE.
- Jeeredy, S., Kennedy, K., Duffy, E., Walker, A., & Vorster, B. (2019, December). Machine learning use cases for smart manufacturing KPI. In 2019 IEEE International Conference on Big Data (Big Data) (pp. 4375-4380). IEEE.
- Kalpakjian, S., & Schmid, S. R. (2002). *Manufactura, ingeniería y tecnología*. Pearson Educación.
- Kang, N., Zhao, C., Li, J., & Horst, J. A. (2015, October). Analysis of key operation performance data in manufacturing systems. In 2015 IEEE International Conference on Big Data (Big Data) (pp. 2767-2770). IEEE.
- Kim, M., Jeong, J., & Bae, S. (2019, April). Demand forecasting based on machine learning for mass customization in smart manufacturing. In Proceedings of the 2019 International Conference on Data Mining and Machine Learning (pp. 6-11).
- Kuhnle, A., Schäfer, L., Stricker, N., & Lanza, G. (2019). Design, implementation and evaluation of reinforcement learning for an adaptive order dispatching in job shop manufacturing systems. *Procedia CIRP*, 81, 234-239
- Li, C., Wang, H., & Li, B. (2016, July). Performance prediction of a production line with variability based on grey model artificial neural network. In 2016 35th Chinese Control Conference (CCC) (pp. 9582-9587). IEEE
- Lin, C. Y., Hsieh, Y. M., Cheng, F. T., Huang, H. C., & Adnan, M. (2019). Time series prediction algorithm for intelligent predictive maintenance. *IEEE Robotics and Automation Letters*, 4(3), 2807-2814.
- Matzka, S. (2018, September). Using Process Quality Prediction to increase Resource Efficiency in Manufacturing Processes. In 2018 First International Conference on Artificial Intelligence for Industries (AI4I) (pp. 110-111). IEEE.
- Meza Villalba, S. (2020). Sistema de soporte de decisiones de producción en un entorno flexible job shop basado en un modelo predictivo-reactivo sujeto a perturbaciones. Escuela Colombiana de Ingeniería Julio Garavito.
- Murphy, R., Newell, A., Hargaden, V., & Papakostas, N. (2019). Machine learning technologies for order flowtime estimation in manufacturing systems. *Procedia CIRP*, 81, 701-706.
- Ni, Y. (2015, January). An agent-based real time scheduling system for mix-flow manufacturing. In 2015 International Conference on Computer and Computational Sciences (ICCCS) (pp. 83-86). IEEE.
- Paydas, S., Ergin, M., Seydaoglu, G., Erdogan, S., & Yavuz, S. (2009). Pronostic significance of angiogenic/lymphangiogenic, anti-apoptotic, inflammatory and viral factors in 88 cases.
- Pfeiffer, A., Gyulai, D., Kádár, B., & Monostori, L. (2016). Manufacturing lead time estimation with the combination of simulation and statistical learning methods. *Procedia CIRP*, 41, 75-80.
- Pires, F., Melo, V., Almeida, J., & Leitão, P. (2020, June). Digital twin experiments focusing virtualisation, connectivity and real-time monitoring. In 2020 IEEE Conference on Industrial Cyberphysical Systems (ICPS) (Vol. 1, pp. 309-314). IEEE.
- ISO 15504 Norma de desarrollo de software SPICE ISO/IEC 15504. (s/f). Normas ISO. Recuperado el 21 de noviembre de 2022, de <https://www.normas-iso.com/iso-iec-15504-spice/>
- Saxena, P., Sharma, K. y Easo, S. (2012). Pronóstico de inscripciones basado en series temporales difusas con mayor tasa de precisión de pronóstico. En t. J. Tecnología informática y aplicaciones , 3 (3), 957-961.
- Shahzad, A., & Mebarki, N. (2012). Data mining based job dispatching using hybrid simulation-optimization approach for shop scheduling problem. *Engineering Applications of Artificial Intelligence*, 25(6), 1173-1181.
- Shi, J., He, G., & Liu, X. (2018, August). Anomaly detection for key performance indicators through machine learning. In 2018 International Conference on Network Infrastructure and Digital Content (IC-NIDC) (pp. 1-5). IEEE.
- Sonthited, P., Koolpiruk, D., & Songkasiri, W. (2019, July). Prediction of Production Performance for Tapioca Industry using LSTM neural network. In 2019 16th International Conference on Electrical

- Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON) (pp. 147-150). IEEE.
- Sorjamaa, A., Hao, J., Reyhani, N., Ji, Y., & Lendasse, A. (2007). Methodology for long-term prediction of time series. *Neurocomputing*, 70(16-18), 2861-2869.
- Villa Buitrago, H. J. (2015). Un método para la definición de indicadores clave de rendimiento con base en objetivos de mejoramiento. *Escuela de Sistemas*.
- Wang, C., & Wei, K. (2019, November). Construction of Intelligent Manufacturing Digital Workshop Ability Assessment Model for CPS. In 2019 2nd World Conference on Mechanical Engineering and Intelligent Manufacturing (WCMEIM) (pp. 627-630). IEEE.
- Wang, J., Wang, K., Wang, Y., Huang, Z., & Xue, R. (2019). Deep Boltzmann machine based condition prediction for smart manufacturing. *Journal of Ambient Intelligence and Humanized Computing*, 10(3), 851-861.
- Wang, W., Zhang, Y., Gu, J., & Wang, J. (2021). A proactive manufacturing resources assignment method based on production performance prediction for the smart factory. *IEEE Transactions on Industrial Informatics*, 18(1), 46-55.
- Xu, X. L. (2011, November). Hull subsection production crisis early warning system design based on the KPI. In Proceedings of International Conference on Information Systems for Crisis Response and Management (ISCRAM) (pp. 118-122). IEEE.
- Yin, X., Zuo, J., Huang, X., Liu, Z., & Sang, G. (2020, October). A Smart Factory Prediction Method Combining Big Data Experience Feedback and Deep Learning. In 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE) (pp. 310-314). IEEE.
- Zambrano, G., Pach, C., Aissani, N., Berger, T., & Trentesaux, D. (2011, June). An approach for temporal myopia reduction in heterarchical control architectures. In 2011 IEEE international symposium on industrial electronics (pp. 1767-1772). IEEE.
- Zhang, Y., Liu, S., Si, S., & Yang, H. (2015, April). Production system performance prediction model based on manufacturing big data. In 2015 IEEE 12th International Conference on Networking, Sensing and Control (pp. 277-280). IEEE.
- FESTO. (n.d.). MES4 para CP Lab y CP Factory - CP Factory - La clasificación para la industria 4.0 - MPS® Sistema de Producción Modular - - Productos. Festo Didactic. Retrieved September 15, 2022, from <https://www.festo-didactic.com/es-es/productos/mps-sistema-de-produccion-modular/la-clasificacion-para-la-industria-4.0/cp-factory/mes4.htm?fbid=ZXMuZXMuNTQ3LjE0LjE4LjE2MDUuNTM3NjA>
- Morales Rodríguez, M., Calle Pérez, M., Cuéllar Quiñonez, J., & Tovar Vanegas, J. (2013, February 1). Biblioteca Digital - Universidad icesi: Elección de una herramienta de simulación. Biblioteca Digital Icesi. Retrieved September 15, 2022, from [https://repository.icesi.edu.co/biblioteca\\_digital/handle/10906/68447](https://repository.icesi.edu.co/biblioteca_digital/handle/10906/68447)
- Miranda, H. (2018, September). Que es NetLogo. Center for Connected Learning and Computer-Based Modeling. Retrieved September 23, 2022, from <https://ccl.northwestern.edu/netlogo/resources/NetLogo.pdf>
- Agencia de la Calidad de educación. (n.d.). Herramienta Matriz de priorización de problemas. archivos de www.agenciaeducacion.cl. Retrieved September 23, 2022, from [http://archivos.agenciaeducacion.cl/Matriz\\_de\\_priorizacion\\_de\\_problemas.pdf](http://archivos.agenciaeducacion.cl/Matriz_de_priorizacion_de_problemas.pdf)
- Yacuzzi, E. (n.d.). QFD: CONCEPTOS, APLICACIONES Y NUEVOS DESARROLLOS Enrique Yacuzzi (Universidad del CEMA) Fernando Martín (Aventis Pharma) RESUM. UCEMA. Retrieved September 23, 2022, from <https://ucema.edu.ar/publicaciones/download/documentos/234.pdf>
- Bú, R. C. (1994). Simulación: Un enfoque práctico. Editorial Limusa.
- Chabane, A. N., Sahnoun, M. H., & Bettayeb, B. (2021, May). Forecasting KPI of Production Systems Using LSTM Networks. In 2021 1st International Conference On Cyber Management And Engineering (CyMaEn) (pp. 1-6). IEEE.
- Wilensky, U. (2021, 13 diciembre). NetLogo 6.2.2 User Manual. NetLogo User Manual Version 6.2.2. <https://ccl.northwestern.edu/netlogo/docs/>
- Zambrano Rey, G. (2014). Réduction du comportement myope dans le contrôle des FMS: une approche semi-hétérarchique basée sur la simulation-optimisation (Doctoral dissertation, Valenciennes).
- Croatti, A., Gabellini, M., Montagna, S., & Ricci, A. (2020). On the integration of agents and digital twins in healthcare. *Journal of Medical Systems*, 44(9), 1-8.
- García-Peñalvo, F. J., & Pardo Aguilar, C. (1998). Diagramas de Clase en UML 1.1.

- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., & Chica-Rivas, MJOGR (2015). Modelos predictivos de aprendizaje automático para la prospección de minerales: una evaluación de redes neuronales, bosques aleatorios, árboles de regresión y máquinas de vectores de soporte. *Revisiones de geología de minerales*, 71 , 804-818.
- Zhou, Q., Lan, W., Zhou, Y. y Mo, G. (2020, noviembre). Evaluación de la efectividad de los dispositivos antipájaros basados en el algoritmo de bosque aleatorio. En *2020 7th International Conference on Information, Cybernetics, and Computational Social Systems (ICCSS)* (págs. 743-748). IEEE
- Khan, M. A. R., & Bilal, A. (2019, April). Literature survey about elements of manufacturing shop floor operation key performance indicators. In *2019 5th International Conference on Control, Automation and Robotics (ICCAR)* (pp. 586-592). IEEE.
- Muhammad, U., Ferrer, B. R., Mohammed, W. M., & Lastra, J. L. M. (2018, May). An approach for implementing key performance indicators of a discrete manufacturing simulator based on the ISO 22400 standard. In *2018 IEEE Industrial Cyber-Physical Systems (ICPS)* (pp. 629-636). IEEE.