

DOI: <https://doi.org/10.56712/latam.v5i6.3083>

Predicción de la productividad de empleados en la industria de la confección mediante random forest

Garment employee productivity prediction using random forest

Darwin Celin Padilla Gutierrez

dcpadillag@unac.edu.pe

<https://orcid.org/0000-0003-2160-9248>

Investigador independiente

Lima – Perú

Jose Alberto Aldave Valderrama

jaaldavev@unac.edu.pe

<https://orcid.org/0000-0002-5815-4948>

Investigador independiente

Lima – Perú

Artículo recibido: 18 de noviembre de 2024. Aceptado para publicación: 02 de diciembre de 2024.

Conflictos de Interés: Ninguno que declarar.

Resumen

En el ámbito de la manufactura eficiente textil, se destaca la importancia de la interacción entre la elaboración y el empleo del potencial humano. Esta sinergia es esencial para lograr un proceso de producción óptimo predictivo del empleo de las técnicas del cálculo algorítmico comparativo en proporcionar un eficiente tratamiento industrial en producir prendas de vestir. La implementación de datos analíticos es fundamental en esta dinámica, ya que brinda el soporte necesario para una producción eficiente y, al mismo tiempo, genera un incremento en los márgenes de utilidad. La colaboración entre los elementos de creación y fabricación, junto con el uso de datos analíticos, se convierte en los factores de secuencias concatenadas producción. Esta interoperatividad no solo mejora la eficiencia operativa, sino que también aumenta las ganancias. A través de la conexión entre recursos y la aplicación inteligente de datos, se logra una visión única que guía hacia eventos consecutivos esperados de resultados más rentables. Este estudio investiga los vínculos entre la elaboración, la materia prima y el factor humano en la producción. Se examina cómo los datos analíticos respaldan una fabricación más efectiva y se analizan los desafíos que implica esta integración. Además, se explora su impacto en distintos sectores, incluyendo almacenes, corte, confección, limpieza y expedición. Este enfoque novedoso ofrece una visión holística y efectiva para aumentar la rentabilidad en la cadena de suministro y producción.

Palabras clave: interoperatividad, datos analíticos, factor humano productivo

Abstract

Within the realm of efficient textile manufacturing, the significance of the interplay between production and human capital utilization is paramount. This synergy is indispensable for achieving an optimal production process, facilitated by the predictive application of comparative algorithmic calculations to deliver efficient industrial treatments in garment production. The implementation of analytical data is fundamental to this dynamic, as it provides the necessary support for efficient production while simultaneously increasing profit margins. The collaboration between design and manufacturing elements, coupled with the use of analytical data, becomes the driving force behind a sequential

production process. This interoperability not only enhances operational efficiency but also boosts earnings. By connecting resources and intelligently applying data, a unique perspective is achieved that guides towards expected sequential outcomes of increased profitability. This study delves into the linkages between design, raw materials, and the human factor in production. It examines how analytical data supports more effective manufacturing and analyzes the challenges inherent in this integration. Additionally, its impact on various sectors, including warehousing, cutting, sewing, finishing, and shipping, is explored. This novel approach offers a holistic and effective perspective to augment profitability in the supply and production chain.

Keywords: interoperability, analytical data, productive human factor

Todo el contenido de LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, publicado en este sitio está disponibles bajo Licencia Creative Commons.



Cómo citar: Padilla Gutierrez, D. C., & Aldave Valderrama, J. A. (2024). Predicción de la productividad de empleados en la industria de la confección mediante random forest. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades* 5 (6), 1299 – 1316.
<https://doi.org/10.56712/latam.v5i6.3083>

INTRODUCCIÓN

El artículo original trabaja en un modelo de predicción sobre el problema común que enfrenta la industria de la confección y cómo se pueden aplicar los diversos parámetros para la extracción de datos para su utilización. Al utilizar el conjunto de datos, en este estudio, analizaremos modelaciones basadas en decisiones árbol, KNN, SVM, Los modelos pueden aprender a construir de ejemplos y luego predecir cosas al detectar patrones en una gran cantidad de información (Kelleher et al., 2015.) Las empresas que aportan su disponibilidad en recursos en prevención de grados ínfimos de riesgos, como desarrollar estrategias y abordar la eficiencia de sus operaciones, viabilizan su posicionamiento a superar estos desafíos y mantener su negocio funcionando de manera fluida (Türkeş et al., 2024) El manifiesto comienza con una breve descripción sobre la importancia de la ropa y la industria del tejido de telas seguida de una descripción del problema de productividad y su potencial para incrementar proyectar ventas superiores al estimado y predecir con niveles ínfimos de pérdidas (Asohi, 2020). Luego, se presenta una solución utilizando técnicas La optimización de los controladores de redes neuronales se logra a través de la técnica progresión neuronal (Nadizar et al., 2023). La optimización permitirá establecer una amplia red unificada que ofrecerá las capacidades de un proceso de aprendizaje altamente preciso, aplicado a una red compuesta por la capacidad de predicción de la inteligencia artificial. Para vislumbrar en este mar de datos, empleando brújulas tanto antiguas como innovadoras con precisiones estadísticas tradicionales, como ARIMA, nos guiarán por corrientes conocidas (Madzík et al., 2024a). Pero también como mediador la inteligencia artificial, nos acudirá en la comunicación con algoritmos profundos que nos permitirán explorar herramientas a nuestra disposición, así trazaremos un mapa cada vez más preciso en las estimaciones proyectivas.

Esta red establecerá conexiones que facilitarán el aprendizaje a partir de conjuntos de datos interrelacionados. Se analizaron los datos relacionados con la efectividad y exactitud del proceso de lineamiento proyectivo orientado a predicciones, utilizando una red unificada de datos interconectados. La red integrada con las funciones de Una consecución de exactitud sistematizada a una red conformada por la inteligencia de predicción artificial asociada crea vínculos para el aprendizaje en los datos de conjunto.

En este estudio, se utilizó un conjunto de datos públicos de productividad de trabajadores de la industria de la confección, obtenidos del sitio web del repositorio UCI. En lo que concierne a la precisión de los resultados, la velocidad con la que se alcanza la convergencia, la estabilidad del sistema y su capacidad para mantenerse firme ante variaciones (Xue & Shen, 2020). Se buscó el valor mínimo del error absoluto medio (MAE) (Balla et al., 2021), para predecir las etapas de productividad en la industria de la confección (Jain & Kumar, 2020). Antes de aplicar los algoritmos, se realizó un preprocesamiento de los datos, que incluyó la técnica de normalización, la técnica de reemplazo de valores faltantes y la técnica de selección de atributos.

El documento comienza con una introducción que establece el contexto y el problema que se aborda. Luego, se describe la metodología utilizada para recopilar y analizar los datos, incluyendo método de extracción de información sistematizada, los modelos de aprendizaje automático (Vinodh Kumar et al., 2023). Se presentan en forma de tablas y gráficos, lo que facilita la comprensión de los hallazgos. Además, se proporciona una discusión detallada de los resultados y se comparan con precisión medible (Zhou et al., 2020), los diferentes modelos utilizados. En general, el análisis se presenta de manera clara y fácil de entender, lo que permite al lector comprender los hallazgos y las implicaciones en el estudio de costos e incremento de eficacia (Tareque et al., 2020)

Los hallazgos derivados del análisis empleando el modelo de Random forest tuvo el mejor rendimiento en la predicción del trabajador digitalizado industrialmente (Bas et al., 2022), la confección con un valor de correlación de 0.98 y un MAE de 0.026. La regresión lineal también tuvo un buen rendimiento, con un valor de correlación de 0.97 y un MAE de 0.031. La red neuronal tuvo el peor rendimiento, con

un valor de correlación de 0.94 y un MAE de 0.045. Se concluyó que el modelo de Random forest es el más adecuado para predecir la productividad de los trabajadores de la industria (Nelsia et al., 2020). utilizando el conjunto de datos requeridos aplicados a este modelo siendo el más adecuado para predecir la operatividad pronosticada. la eficiencia de optimizar un máximo rendimiento (Yan et al., 2022). En la industria de la confección se emplean los datos disponibles en el segmento de sucesiones de la elaboración de prendas de indumentaria (Al-Jawazneh, 2011). Esto sugiere que la utilización del empleo de la toma de datos tanto como los modelos de autoaprendizaje puede ser una solución efectiva que acrecentará la implementación automática en la confección masiva (Sharma et al., 2022).

Figura 1

Esquema de trabajo en planta textil



El objetivo del artículo es construir un modelo de clasificación con alto valor de AUC, para estimaciones para anticipar un posible resultado que se ajuste a los elementos de procesamiento para alcanzar una función trazada a un objetivo en particular (Chelladurai et al., 2020). Es predecir el nivel productividad del procedimiento de secuencias en series dará un valor de elaboración en cadena de una respuesta esperada (Niu et al., 2023). la base de una base de datos real de una compañía de Bangladesh recolecta por 3 meses en el año 2015. La base de datos seleccionada contiene 13 atributos y 1197 registros recolectados.

En el estudio original, se basó en el uso de recursos de acceso abierto para la recopilación de datos de productividad de trabajadores de la industria de la confección, que fue obtenido del sitio web del repositorio UCI. El conjunto de datos contenía 15 atributos, incluyendo fecha, día, trimestre, departamento, número de equipo, número de trabajadores, productividad objetivo, SMV, trabajo en proceso, horas extras, incentivos, tiempo inactivo, hombres inactivos, productividad real y clases continuas de productividad real. Antes de aplicar los algoritmos de aprendizaje elaborados (M. Z. Ali et al., 2018). Se realizó un preprocesamiento de los datos, que incluyó la técnica de normalización, la técnica de reemplazo de valores faltantes y la técnica de selección de atributos. Luego, se aplicaron tres modelos de aprendizaje automático: el modelo de Random forest, la regresión lineal y la red neuronal (Arora & Majumdar, 2022)

El cambio respecto al artículo original radica en dos partes, la primera en el proceso fue mejorar la limpieza de datos, al no eliminar data sino encontrar las desviaciones e identificar aquellas que fueron errores involuntarios y colocando los datos en las filas y columnas que corresponden, a diferencia del

trabajo base que eliminó aquellos datos extraños que salían de la media. Como información importante, identificamos en los artículos técnicos de referencia el uso de técnicas como "Lean", una metodología cuyo objetivo era mejorar los procesos con el propósito de incrementar la rentabilidad y productividad de estos, y la herramienta de análisis estadístico ANOVA para validación de hipótesis sobre relación de datos o conjunto de datos con una confiabilidad aceptable (mejor que 0.95). La segunda en que se trabajó en un modelo enfocado en minería de datos para construir un modelo que aprendiera del conjunto de datos de entrenamiento existente y analizamos los modelos basados en decisión tree, KNN y SVM.

DESARROLLO

Ha presenciado un notable aumento de dirección auto gestionable hacia el campo de la neuro evolución acompañada, con un enfoque sostenido tanto en los dominios académicos como en los sectores industriales (Jalali et al., 2020). Los artículos científicos que emplearon el conjunto de datos. Se busca predecir la productividad sobre un dataset real con 15 features y 1197 registros. La importancia del modelo basado en redes neuronales es que funciona con varios tipos de datos. El empleo de métodos de extracción de información el estimar una calidad de procesos por fases de exploración (Zou et al., 2020). incorporando así la viabilidad de la automatización en el proceso de análisis (Kim et al., 2023). Experimentó con Random forest, y la progresión lineal (Balla et al., 2021). Conjunto con las redes neuronales logrando resultados diferenciados. La muestra se tomó sobre el sector textil de la India. El estudio se centra en demostrar cómo aumentar el ritmo de fabricación de las personas en producción genera mejor calidad y menos desperdicios (Nelsia et al., 2020). El data set fue publicado en el 2020, consideró 15 atributos diferentes y 1197 datos. Tiene como objetivo predecir la productividad (producción por unidad de insumo) a partir de los recursos de la empresa como operadores (varones y mujeres), materiales, máquinas, dinero y tiempo, seguidamente busca demostrar la relación existente entre eficiencia, costo y productividad. En este abstracto estudiado se vislumbra una nueva función de producción basada en el empoderamiento digital para analizar su impacto en la operatividad empresarial, abarcando tanto factores tradicionales como digitales. (Meng & Wang, 2023a). Utilizando, modelos vinculados al factor con el desempeño de las empresas, los sectores textiles y de procesamiento de recursos, esto origina trayectorias divergentes en su evolución hacia la transformación digital. La indagación denota la consecuencia de la sostenibilidad verde en cuanto a la prestación de costo en energías, como las innovaciones y su funcionalidad la reducción de desechos y la implementación de tecnologías limpias (Madzik et al., 2024b). En el contexto de la fabricación eficiente, los empleados de la sección de trabajo desempeñan una función esencial en el proceso de reducción de los desechos. Esto se debe a que mantienen una interacción directa con los trabajadores operativos de la compañía en el entorno de la producción ajustada (Raju & Academy, 2014). Un innovador enfoque para realizar deducciones en modelos de lenguaje predictivos en eventos futuros mediante la inferencia de modelos lingüísticos probabilísticos (Yao et al., 2023). La elaboración y la fabricación con materia prima y mano de obra integran los procesos de fabricación al entenderse ello ejecuta los datos de análisis para sustentar la óptima eficiente producción y a la vez acrecienta el margen de utilidades y la muestra se tomó de la empresa Ready Made Garments (RMG) de Bangladesh (BD). La investigación proporciona la validación del indicador de evaluación siendo una herramienta más importante, especialmente en el sector de la confección, que ayuda a aumentar los ingresos, rendimientos y aprovechamiento de los materiales e insumos (Y. Li et al., 2023).

La investigación aplica el método de regresión en perspectiva (Jayakrishnan et al., 2018). Estudiar la relación de las ventas - productividad- de los distintos productos que tiene una tienda en Bangladesh y con ello. La prospectiva en la producción, constante búsqueda de perfeccionamiento y el horizonte de lograr una gestión aún más eficaz en el futuro (Quddus & Ahsan, 2014).

Predecir los ingresos de los productos mejor cotizados y de los menos cotizados. Los resultados obtenidos de este estudio resultan en el número previsto de ventas de bienes para el año 2020 que asciende a 169,715 artículos. Entre sus conclusiones tienen que el valor del error cuadrático medio está en 40.476. La tecnología avanzada es esencial para que los mercados de materias primas para que progresen en la industria en la economía de proyecciones (Litvinenko, 2020).

Se enfoca en la categorización de prendas mediante técnicas de machine learning para la predicción de categorías y subcategorías de prendas de vestir a partir de un conjunto de atributos de las prendas, entre ellas Random Forest. Esta investigación es importante para mejorar la productividad en la industria textil ya que apoya a la selección automatizada de prendas con un margen mínimo de error evitando reprocesamientos en la corrección de errores de selección. Las secuencias neuronales son interpolaciones dinámicas creadas de manera manual, de gran complejidad mediante enlace dirigido conectados entre sí por arcos dirigidos que cuentan con relativas variables de ordenamiento de valorativos secuencial (Ali et al., 2021).

Un enfoque proyectivo de las empresas manufactureras en la evaluación de los riesgos vinculados a la transición de factor de predicción para optar en su sector cadena de eficiencias (Shang et al., 2023). Al crear nuevos productos, servicios o procesos, la innovación puede generar nuevas oportunidades de mercado y mejorar la productividad de las empresas (Ganzer et al., 2017). La Descripción del conjunto de datos Negocio de la manufactura Textil en Bangladesh proporciona grandes ingresos a la economía del país, por ello se hizo mucho énfasis en mejorar la forma de la cadena de producción y reducir las pérdidas, las que se puede deber por estaciones mal ubicadas, estaciones de trabajo que formen líneas saturadas, la falta de insumos en forma oportuna, la demora en la revisión de la calidad de producto, los reprocesos en la fabricación de prendas, entre otros (Conservatoire national des arts et métiers (France) et al., 2019a)

Número y tipo de características

Binarias: Encontramos datos que podían llevarse a calificar como binarios, tales como “department” (sweing; finishing) Continuas: Los “idle time” e “idle men” otorgan información sobre interrupciones en el proceso de fabricación de ropa.

METODOLOGÍA

La estrategia para el manejo de datos faltantes, La exactitud de un modelo predictivo ha adquirido un rol fundamental en la calidad y confiabilidad de las elecciones y decisiones realizadas (J. Li et al., 2020). La metodología “lean” o de control de desperdicios, muy empleada en las industrias o empresas que desean subir su efectividad en la producción, manufactura, empaquetamiento u otro proceso de la cadena de fabricación (Hamja et al., 2019). Así también brindará una maximización de sus ingresos al controlar las pérdidas de producción nos permite llenar con la media los valores desconocidos en la columna “wip”. Persigue la conjunción de criterios e ideas con el propósito de maximizar la rentabilidad, todo ello bajo una perspectiva de futuro que se alinea con las pautas y patrones establecidos. Este enfoque implica la expansión de habilidades de entrenamiento cooperativo de funciones y la adopción de procesos y controles estadísticos. Sin embargo, es importante tener. Esto cruzado con los valores de incentivos nos permite entender que en el proceso donde se detectará tiempo muerto aumentaba el tiempo asignado por tarea y con ello afectando la producción o fabricación de telas (Sadatnya et al., 2023). El análisis comprende varios ámbitos del departamento de producción, concretamente el almacén, la etapa de corte, la confección, la limpieza y el proceso de expedición. También se examinan los intentos previamente realizados y los desafíos que la empresa. A ha afrontado al tratar de eliminar estos tipos de residuos (Chiromo & Nel, 2015). En el proceso de ejecución del conjunto de datos integrados del no total añadidos debe complementarse más data para la elaboración ejecutada de manufacturación para predecir la cadena integral en bloque agrupado (Conservatoire national des arts et métiers (France) et al., n.d.-b). La selección y justificación de la medida de calidad son los factores

que afectan los datos, como por ejemplo duplicidad de datos. Se empleará se integrará la búsqueda de datos inconsistentes. La selección eficaz de miembros es esencial para el funcionamiento dinámico de la cadena de suministro. Este algoritmo de selección de miembros de la cadena de suministro basado en redes generativas condicionales adversariales aborda el problema de la gran cantidad de atributos de decisión y la baja cantidad de datos para el análisis de decisiones (Lin et al., 2022).

Existen una serie de datos que están en el dataset que se consideran “ruido”, es decir son datos que aparentemente están fuera de los rangos normales y sería erróneos, para determinar verdaderamente si son erróneos se hace una revisión estadística y visual de los datos, esto no es sencillo para el ojo humano por lo que se usan algoritmos. Mediante este recurso que ha impulsado las áreas ineficientes a liberar un mayor potencial de creación de valor mediante la mejora de la productividad, al optimizar los factores de producción (Meng & Wang, 2023b).

Finalmente, para evaluar la predictibilidad de los datos se usarán modelos, el primer modelo para probar será Random Forest con métricas micro-average y macro-average F1 Score con apoyo de una matriz de confusión para visualizar y comprender más fácilmente la clasificación predicha, posteriormente se usarán los algoritmos KNN, SMV y XGBoost Estrategia de validación a emplear para el ajuste de hiperparámetros. Se usará GridSearch para realizar un primer ajuste de parámetros de Random Forrest y se buscará la mejor métrica que nos permite comparar si un modelo es mejor que otro para este caso multiclass.

Estudio de los datos

Negocio de la manufactura Textil en Bangladesh proporciona grandes ingresos a la economía del país, por ello se hizo mucho énfasis en mejorar la forma de la cadena de producción y reducir las pérdidas, las que se puede deber por estaciones mal ubicadas, estaciones de trabajo que formen líneas saturadas, la falta de insumos en forma oportuna, la demora en la revisión de la calidad de producto, los reprocesos en la fabricación de prendas, entre otros.

Tabla 1

Descripción de la base de datos

Leyenda	Descripción
Date	Fecha en formato m/d/yy
Quarter	Mes dividido en semanas de 1 al 5
Department	Área del proceso o departamento
Day	Día de la semana
Team	Equipo de trabajo
Targeted_productivity	Valor impuesto por la gerencia como objetivo
Smv	Promedio de tiempo que toma la actividad
Wip	Trabajo en proceso, incluye las pérdidas de tiempo
Over_time	Representa en minutos el sobre tiempo de trabajo
Incentive	Cantidad de dinero otorgada como incentivo para subir la productividad
Idle_time	Cantidad de tiempo perdida en producción por cualquier motivo
Idle_men	Número de trabajadores que pierden tiempo durante el proceso
No_of_style_change	Número de cambio de estilos
No_of_workers	Número de trabajadores en un equipo
Actual_productivity	La productividad actual de los trabajadores entre 0 y 1

Dentro de las columnas podemos destacar las siguientes características para trabajar el estudio:

Tabla 2

Cantidad de tareas por Departamento

Department	Cantidad
finishing	506
sweing	691
Total	1197


RESULTADOS

Análisis Estadístico del Data Set

El preprocesamiento de los datos en el departamento de costura se tiene que la línea naranja es el objetivo de la empresa y la línea azul es lo logrado por el departamento.

Gráfico 1


La productividad esperada y lograda según los departamentos de costura



En el departamento de acabado se tiene que la línea naranja es el objetivo de la empresa y la línea azul es lo logrado por el departamento.

Gráfico 2

La productividad esperada y lograda según los departamentos de acabados



Se pueden apreciar ciertas correlaciones entre los datos y por otro lado tendencias hacia donde los datos se agrupan, esto nos da una previa idea de cómo ciertas variables se pueden ver influenciadas por otras dentro de la base de datos, es a través del trabajo del análisis de los números que

identificamos aquellos que influyen en cual es la que logra la meta de producción y cuales no aportan significativamente. En el trabajo previo solo se analizó desde la mirada de trabajo de datos, pero no tanto una revisión estadística mediante gráficos de tendencias de datos o análisis de "boxplot".

Gráfico 3

Análisis de dispersión del tiempo promedio por actividad de los departamentos





Gráfico 4

Análisis de dispersión del tiempo promedio por actividad según número de trabajadores



Gráfico 5

Análisis de dispersión del incentivo económico sobre el overtime



Durante la revisión de la base de datos encontramos una cantidad de datos extraños, conocidos como “outlayers” que fueron eliminados en el trabajo original e identificamos que no eran errores de lectura de datos sino errores de asignación en característica, es decir sin tener que eliminarlos sino colocando sus datos en la columna correcta se obtenían datos adicionales valiosos y correctos que pueden mejorar el análisis del caso.

Gráfico 6

Outlayers encontrados en la categoría “trabajo en proceso”




Gráfico 7

Outlayers encontrados en la categoría "incentivo"





Gráfico 8

Análisis de la relación Sobre tiempo vs Incentivo e identificación de outlayers




Nuevo procesamiento de los datos originales

Se puede representar nuestro proceso como el siguiente:

Gráfico 9

Procesado de la predicción de la planta en función del estudio de los datos



Después de las correcciones de los casos encontrados vemos una mejoría en la disposición de los datos, se puede mostrar en las siguientes gráficos:

Gráfico 10

Datos del trabajo en proceso WIP antes de la depuración de Outlayers en contexto por "Departamentos"





Gráfico 11

Datos del trabajo en proceso WIP después de la depuración de Outlayers en contexto por "Departamentos"



DISCUSIÓN

Análisis de resultados

Tabla 3

Resultados de los modelos

	Entrenamiento				Pruebas			
	Exactitud	F1_Micro	F1_Macro	F1_Weighted	Exactitud	F1_Micro	F1_Macro	F1_Weighted
Random Forest Classifier Ajustado	0.7918	0.7918	0.7920	0.7920	0.7208	0.7208	0.6354	0.7246
Random Forest Classifier ReAjustado	0.8765	0.8765	0.8761	0.8761	0.8041	0.8041	0.7357	0.8030
Kneighbors Classifier Ajustado	0.7523	0.7523	0.6677	0.7435	0.6875	0.6875	0.5878	0.6773
Support Vector Machine Ajustado	0.7847	0.7847	0.7000	0.7648	0.7625	0.7625	0.6563	0.7421
Logistic Regression Ajustado	0.7199	0.7199	0.6041	0.6902	0.6875	0.6875	0.5584	0.6537

En consecuencia a la data sugiere que este modelo es el más efectivo en la clasificación analítica utilizada en este estudio. En contraste a la regresión ajustada denota bajas tendencias en todas las métricas del conjunto analizado. El modelo soslaya que la selección del algoritmo puede tener un considerable factor a precisiones predictivas.

Limitaciones del estudio

Se exponen las presentes restricciones causales a ser consideradas al momento de la abstracción de datos en consecuencia a los réditos en estas instancias, es posible que haya sesgos en la selección de la muestra. Si los participantes no representan adecuadamente a la población objetivo, esto podría haber influido en la generalización de los hallazgos. Además, las limitaciones en la medición de las variables pueden afectar la validez de los resultados. Por ejemplo, si los instrumentos utilizados para medir las variables no son suficientemente precisos o confiables, esto podría dar lugar a datos distorsionados. Por último, es importante señalar que los efectos de factores externos no controlados podrían haber influido en los resultados, limitando la capacidad del estudio para establecer relaciones causales.

Futuras líneas de investigación

Basándose en los hallazgos de este estudio, se proponen varias direcciones para futuras investigaciones. En primer lugar, sería beneficioso realizar estudios longitudinales que permitan observar las tendencias a lo largo del tiempo y la evolución de las variables en diferentes contextos. Además, se sugiere investigar la efectividad de diferentes intervenciones basadas en los resultados encontrados, así como explorar las interacciones entre las variables que no se abordaron en este estudio. También sería interesante ampliar la muestra a diferentes poblaciones para mejorar la validez externa de los hallazgos y responder a las preguntas que quedan sin resolver.

CONCLUSIÓN

Mediante un arduo estudio de la revisión de los datos se han identificado relaciones significativas entre diversas variables, como cuantil, día de la semana, incentivos, productividad y tiempos muertos, en relación con los intervalos entre actividades. Factores que destacan el rendimiento superior del modelo "Random Forest Classifier Reajustado" con un 80.41%, seguido por el "Super Vector Machine ajustado" con un 76.25%, y el "Random Forest Classifier ajustado" en tercer lugar con un 72.08%. Estos hallazgos se basan en la optimización de la productividad mediante el nuevo preprocesamiento de datos y subrayan la influencia positiva de los incentivos en la consecución de objetivos en el área de costura. Es relevante señalar que este estudio, al considerar múltiples enfoques de aprendizaje automático, como las Redes Neuronales, no descarta posibles estrategias adicionales para resolver desafíos laborales.

Dentro de este contexto, se ha introducido un modelo de evolución prospectiva lineal que abarca la inclusión de datos faltantes en las proyecciones. Al llevar a cabo una comparación entre esta metodología y el modelo de precisión, se establecen proporciones esenciales que posibilitan una evaluación precisa. Estas adiciones metodológicas amplían la riqueza del estudio al brindar una comprensión más abarcadora y contextualizada de los resultados obtenidos. Además, los descubrimientos derivados de esta investigación no solo impulsan la mejora de la capacidad laboral, sino que también aportan evidencia sólida que respalda la optimización de la producción en el ámbito del producir telas y ropas de prendas. En última instancia, este estudio no se limita únicamente a la meticulosa exploración de los datos, sino que también presenta un enfoque analítico enriquecido y funcional que tiene el potencial de orientar decisiones y prácticas en el ámbito industrial, esta investigación proporciona un marco sólido para abordar la eficiencia óptima y ofrece direcciones valiosas para futuras investigaciones sin cerrar puertas a otras oportunidades de desarrollo y análisis. Es esencial que las organizaciones creen un entorno laboral que respalde el crecimiento técnico específico de operatividad de los empleados, Esto implica brindar oportunidades significativas para el aprendizaje y el desarrollo, junto con un ambiente de trabajo que fomente la creatividad y la innovación (Shahzad et al., 2022).

REFERENCIAS

- Ali, S. I., Ali, A., Alkilabi, M., & Christie, M. (2021). Optimal supply chain design with product family: A cloud-based framework with real-time data consideration. *Computers & Operations Research*, 126, 105112. <https://doi.org/10.1016/j.cor.2020.105112>
- Ali, M. Z., Awad, N. H., Reynolds, R. G., & Suganthan, P. N. (2018). A balanced fuzzy Cultural Algorithm with a modified Levy flight search for real parameter optimization. *Information Sciences*, 447, 12–35. <https://doi.org/10.1016/j.ins.2018.03.008>
- Al-Jawazneh. (2011). Terms and conditions Privacy policy The internal lean manufacturing practices at the apparel manufacturing companies in Jordan. In *Finance and Administrative Sciences (Issue 43)*. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84255205321&partnerID=40&md5=7eaa6f59b825da0f195e6df4b022c5c2>
- Arora, S., & Majumdar, A. (2022). Machine learning and soft computing applications in textile and clothing supply chain: Bibliometric and network analyses to delineate future research agenda. In *Expert Systems with Applications (Vol. 200)*. Elsevier Ltd. <https://doi.org/10.1016/j.eswa.2022.117000>
- Asohi, Y. (2020). IMPELEMENTASI ALGORITMA REGRESI LINIER BERGANDA UNTUK PREDIKSI PENJUALAN. In *Jurnal Nasional Ilmu Komputer (Vol. 1, Issue 3)*.
- Balla, I., Rahayu, S., Jaya Purnama, J., & Author, C. (2021). GARMENT EMPLOYEE PRODUCTIVITY PREDICTION USING RANDOM FOREST. <https://doi.org/10.33480/techno.v18i1.2210>
- Bas, G., Dönmezer, S., & Durakbasa, M. N. (2022). A Roadmap for Quality of the Digital Human Model in the Textile and Apparel Industry enabled by Digital Transformation. *IFAC-PapersOnLine*, 55(39), 319–324. <https://doi.org/10.1016/j.ifacol.2022.12.043>
- Chelladurai, S. J. S., Murugan, K., Ray, A. P., Upadhyaya, M., Narasimharaj, V., & Gnanasekaran, S. (2020). Optimization of process parameters using response surface methodology: A review. *Materials Today: Proceedings*, 37(Part 2), 1301–1304. <https://doi.org/10.1016/j.matpr.2020.06.466>
- Chiromo, F., & Nel, A. (2015). LEAN MANUFACTURING CHALLENGES IN A SOUTH AFRICAN CLOTHING COMPANY.
- Conservatoire national des arts et métiers (France), IEEE Systems, M., & Institute of Electrical and Electronics Engineers. (2019a). 2019 6th International Conference on Control, Decision and Information Technologies (CoDIT'19) : April 23-26, 2019, Le Cnam, Paris, France.
- Conservatoire national des arts et métiers (France), IEEE Systems, M., & Institute of Electrical and Electronics Engineers. (n.d.-b). 2019 6th International Conference on Control, Decision and Information Technologies (CoDIT'19) : April 23-26, 2019, Le Cnam, Paris, France.
- Ganzer, P. P., Chais, C., & Olea, P. M. (2017). Product, process, marketing and organizational innovation in industries of the flat knitting sector. *RAI Revista de Administração e Inovação*, 14(4), 321–332. <https://doi.org/10.1016/j.rai.2017.07.002>
- Hamja, A., Maalouf, M., & Hasle, P. (2019). The effect of lean on occupational health and safety and productivity in the garment industry—a literature review. *Production and Manufacturing Research*, 7(1), 316–334. <https://doi.org/10.1080/21693277.2019.1620652>
- Jain, S., & Kumar, V. (2020). Garment categorization using data mining techniques. *Symmetry*, 12(6). <https://doi.org/10.3390/SYM12060984>

Jalali, S. M. J., Ahmadian, S., Khosravi, A., Mirjalili, S., Mahmoudi, M. R., & Nahavandi, S. (2020). Neuroevolution-based autonomous robot navigation: A comparative study. *Cognitive Systems Research*, 62, 35–43. <https://doi.org/10.1016/j.cogsys.2020.04.001>

Jayakrishnan, M., Mohamad, A. K., Azmi, F. R., & Abdullah, A. (2018). Implementation of business intelligence framework for Malaysian halal food manufacturing industry towards initiate strategic financial performance management. *Management Science Letters*, 8(10), 1059–1076. <https://doi.org/10.5267/j.msl.2018.7.007>

Kelleher, J. D., Mac Namee, Brian., & D'Arcy, A. (n.d.). *Fundamentals of machine learning for predictive data analytics : algorithms, worked examples, and case studies*.

Kim, S., Yoon, H. C., Lim, J.-T., Jeong, D., & Kim, K. H. (2023). Productivity prediction in the Wolfcamp A and B using weighted voting ensemble machine learning method. *Gas Science and Engineering*, 111, 204916. <https://doi.org/10.1016/j.jgsce.2023.204916>

Li, J., Tian, Y., Zhu, Y., Zhou, T., Li, J., Ding, K., & Li, J. (2020). A multicenter random forest model for effective prognosis prediction in collaborative clinical research network. *Artificial Intelligence in Medicine*, 103. <https://doi.org/10.1016/j.artmed.2020.101814>

Li, Y., Xie, S., Wan, Z., Lv, H., Song, H., & Lv, Z. (2023). Graph-powered learning methods in the Internet of Things: A survey. *Machine Learning with Applications*, 11, 100441. <https://doi.org/10.1016/j.mlwa.2022.100441>

Lin, H., Lin, J., & Wang, F. (2022). An innovative machine learning model for supply chain management. *Journal of Innovation and Knowledge*, 7(4). <https://doi.org/10.1016/j.jik.2022.100276>

Litvinenko, V. S. (2020). Digital Economy as a Factor in the Technological Development of the Mineral Sector. *Natural Resources Research*, 29(3), 1521–1541. <https://doi.org/10.1007/s11053-019-09568-4>

Madzík, P., Falát, L., Yadav, N., Lizarelli, F. L., & Čarnogurský, K. (2024a). Exploring uncharted territories of sustainable manufacturing: A cutting-edge AI approach to uncover hidden research avenues in green innovations. *Journal of Innovation and Knowledge*, 9(3). <https://doi.org/10.1016/j.jik.2024.100498>

Madzík, P., Falát, L., Yadav, N., Lizarelli, F. L., & Čarnogurský, K. (2024b). Exploring uncharted territories of sustainable manufacturing: A cutting-edge AI approach to uncover hidden research avenues in green innovations. *Journal of Innovation and Knowledge*, 9(3). <https://doi.org/10.1016/j.jik.2024.100498>

Meng, F., & Wang, W. (2023a). The impact of digitalization on enterprise value creation: An empirical analysis of Chinese manufacturing enterprises. *Journal of Innovation and Knowledge*, 8(3). <https://doi.org/10.1016/j.jik.2023.100385>

Meng, F., & Wang, W. (2023b). The impact of digitalization on enterprise value creation: An empirical analysis of Chinese manufacturing enterprises. *Journal of Innovation and Knowledge*, 8(3). <https://doi.org/10.1016/j.jik.2023.100385>

Nadizar, G., Medvet, E., Nichele, S., & Pontes-Filho, S. (2023). An experimental comparison of evolved neural network models for controlling simulated modular soft robots. *Applied Soft Computing*, 145. <https://doi.org/10.1016/j.asoc.2023.110610>

Nelsia, K., Dharsini, P., & Sashikkumar, M. C. (2020). Probabilistic model development for estimating construction labor productivity optimization integrating with fuzzy logic approach systems. In *Iranian Journal of Fuzzy Systems* (Vol. 17, Issue 6).

- Niu, H., Wu, W., Xing, Z., Wang, X., & Zhang, T. (2023). A novel multi-tasks chain scheduling algorithm based on capacity prediction to solve AGV dispatching problem in an intelligent manufacturing system. *Journal of Manufacturing Systems*, 68, 130–144. <https://doi.org/10.1016/j.jmsy.2023.03.007>
- Quddus, M. A., & Ahsan, A. M. M. N. (2014). A Shop-floor Kaizen Breakthrough Approach to Improve Working Environment and Productivity of a Sewing Floor in RMG Industry. In *JTATM* (Vol. 8, Issue 4).
- Raju, P. G., & Academy, U. M. (2014). Impact of longer usage of lean manufacturing system (Toyotism) on employment outcomes-a study in garment manufacturing industries in India Madhuri Modekurti-Mahato. In *Int. J. Services and Operations Management* (Vol. 18, Issue 3).
- Sadatnya, A., Sadeghi, N., Sabzekar, S., Khanjani, M., Tak, A. N., & Taghaddos, H. (2023). Machine learning for construction crew productivity prediction using daily work reports. *Automation in Construction*, 152. <https://doi.org/10.1016/j.autcon.2023.104891>
- Shahzad, M., Qu, Y., Rehman, S. U., & Zafar, A. U. (2022). Adoption of green innovation technology to accelerate sustainable development among manufacturing industry. *Journal of Innovation and Knowledge*, 7(4). <https://doi.org/10.1016/j.jik.2022.100231>
- Shang, C., Jiang, J., Zhu, L., & Saeidi, P. (2023). A decision support model for evaluating risks in the digital economy transformation of the manufacturing industry. *Journal of Innovation and Knowledge*, 8(3). <https://doi.org/10.1016/j.jik.2023.100393>
- Sharma, P., Shah, J., & Patel, R. (2022). Artificial intelligence framework for MSME sectors with focus on design and manufacturing industries. *Materials Today: Proceedings*, 62(P13), 6962–6966. <https://doi.org/10.1016/j.matpr.2021.12.360>
- Tareque, Mr. M. A., Islam, N., & Roy, S. (2020). Increasing Efficiency: Case Study of Ready Made Garments in Bangladesh. *International Journal of Engineering and Computer Science*, 9(06), 25085–25101. <https://doi.org/10.18535/ijecs/v9i06.4503>
- Türkeş, M. C., Stăncioiu, A. F., & Marinescu, R. C. (2024). Modeling the impact of resilience factors and relational practice on performance of the supply chain. *Journal of Innovation and Knowledge*, 9(3). <https://doi.org/10.1016/j.jik.2024.100533>
- Vinodh Kumar, P., Manikandan, V., Manavaalan, G., & Elango, S. (2023). Developing digital twin design for enhanced productivity of an automated anodizing industry and process prediction using hybrid deep neural network. *Engineering Applications of Artificial Intelligence*, 122. <https://doi.org/10.1016/j.engappai.2023.106086>
- Xue, J., & Shen, B. (2020). A novel swarm intelligence optimization approach: sparrow search algorithm. *Systems Science and Control Engineering*, 8(1), 22–34. <https://doi.org/10.1080/21642583.2019.1708830>
- Yan, Y., Gupta, S., Licsandru, T. C., & Schoefer, K. (2022). Integrating machine learning, modularity and supply chain integration for Branding 4.0. *Industrial Marketing Management*, 104, 136–149. <https://doi.org/10.1016/j.indmarman.2022.04.013>
- Yao, S., Yu, D., Zhao, J., Shafran, I., Griffiths, T. L., Cao, Y., & Narasimhan, K. (2023). Tree of Thoughts: Deliberate Problem Solving with Large Language Models. <http://arxiv.org/abs/2305.10601>
- Zhou, G., Moayed, H., Bahiraei, M., & Lyu, Z. (2020). Employing artificial bee colony and particle swarm techniques for optimizing a neural network in prediction of heating and cooling loads of residential buildings. *Journal of Cleaner Production*, 254. <https://doi.org/10.1016/j.jclepro.2020.120082>

Zou, W. Q., Pan, Q. K., Meng, T., Gao, L., & Wang, Y. L. (2020). An effective discrete artificial bee colony algorithm for multi-AGVs dispatching problem in a matrix manufacturing workshop. *Expert Systems with Applications*, 161. <https://doi.org/10.1016/j.eswa.2020.113675>

Todo el contenido de **LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades**, publicados en este sitio está disponibles bajo Licencia Creative Commons .