



Sistema automático de adquisición y análisis de datos con machine learning para el control de calidad en una máquina de inyección de plástico

Automatic data acquisition and analysis system with machine learning for quality control in a plastic injection machine

Sistema automático de aquisição e análise de dados com aprendizado de máquina para controle de qualidade em uma máquina de injeção plástica

Wilson Paul Rojas-Campuzano ^I
wrojasc1@est.ups.edu.ec
<https://orcid.org/0000-0002-8222-4678>

Juan Alejandro Palacios-Salazar ^{II}
jpalacios3@est.ups.edu.ec
<https://orcid.org/0000-0001-6662-9934>

Mónica María Miranda-Ramos ^{III}
mmiranda@ups.edu.ec
<https://orcid.org/0000-0002-7497-1593>

Correspondencia: wrojasc1@est.ups.edu.ec

Ciencias Técnicas y Aplicadas
Artículo de Investigación

***Recibido:** 02 de enero de 2022 ***Aceptado:** 22 de enero de 2022 * **Publicado:** 16 de febrero de 2022

- I. Ingeniería Electrónica. Universidad Politécnica Salesiana, Ecuador.
- II. Ingeniería Electrónica. Universidad Politécnica Salesiana, Ecuador.
- III. Magister en Automatización y Control Industrial, Ingeniera en Electricidad y Electrónica, Profesora de la Universidad Politécnica Salesiana, Ecuador.

Resumen

Uno de los procesos de manufactura más comunes para realizar productos de plástico es el moldeo por inyección. Muchos factores influyen en la eficiencia de este proceso, existen métodos modernos de adquisición de datos que combinados con algoritmos de Machine Learning podrían ayudar a mantener una eficiencia alta en toda la producción. En este artículo, se presenta un sistema que adquiere y almacena datos en una base de datos no relacional, usando un controlador industrial para posteriormente ser analizados aplicando la técnica de regresión lineal usando Machine Learning y finalmente generar alarmas que ayuden a prever defectos en los productos de plástico. Se utilizan sistemas integrados electrónicos como Raspberry PI, Arduino y un controlador industrial Logo, que se conecta a la máquina inyectora de plástico, alimentan la base de datos en tiempo real y generan las variables de entrada para el algoritmo de Machine Learning. Se generó una base de datos con más de doscientos veintidós mil registros de productos tomando en cuenta una sola máquina en la planta, y se agruparon los datos en filas de “horas” usando el lenguaje de programación Java, para así generar un archivo en formato JSON listo para analizarse con el lenguaje de programación R. La herramienta ayudó al departamento de calidad y producción de la planta a prevenir paradas de máquina y productos defectuosos, identificando las causas más comunes por las que su eficiencia baja.

Palabras clave: Aprendizaje automático; base de datos; arduino; fábrica; programación; adquisición de datos.

Abstract

One of the most common manufacturing processes to make plastic products is injection molding. Many factors influence the efficiency of this process, there are modern data acquisition methods, which combined with machine learning algorithms could help to maintain high efficiency in all production. In this article, a system is presented that acquires and stores data in a non-relational database, using an industrial controller to later be analyzed by applying the linear regression technique using Machine Learning and finally generating alarms that help predict product defects. Integrated electronic systems such as Raspberry PI, Arduino and a Logo industrial controller are used, which are connected to the plastic injection machine, which feed the database in real time and generate the input variables for the Machine Learning algorithm. A database was generated with more than two hundred twenty-two thousand product records taking into account a single

machine in the factory, and the data was grouped into rows of "hours" using the Java programming language, in order to generate a file in format JSON ready to be parsed with the R programming language. The tool helped the factory's quality and production department prevent machine stoppages and defective products, identifying the most common causes of low efficiency.

Keywords: Machine learning; database; arduino; factor; programming; data acquisition.

Resumo

Um dos processos de fabricação mais comuns para a fabricação de produtos plásticos é a moldagem por injeção. Muitos fatores influenciam na eficiência desse processo, existem métodos modernos de aquisição de dados que combinados com algoritmos de Machine Learning podem ajudar a manter a alta eficiência em toda a produção. En este artículo, se presenta un sistema que adquiere y almacena datos en una base de datos no relacional, usando un controlador industrial para posteriormente ser analizados aplicando la técnica de regresión lineal usando Machine Learning y finalmente generar alarmas que ayuden a prever defectos en los productos Plástico. São utilizados sistemas eletrônicos integrados como Raspberry PI, Arduino e um controlador industrial Logo, que são conectados à máquina de injeção plástica, alimentam o banco de dados em tempo real e geram as variáveis de entrada para o algoritmo de Machine Learning. Foi gerado um banco de dados com mais de duzentos e vinte e dois mil registros de produtos considerando uma única máquina da planta, e os dados foram agrupados em linhas de "horas" utilizando a linguagem de programação Java, a fim de gerar um arquivo no formato JSON pronto para ser analisado com a linguagem de programação R. A ferramenta auxiliou o departamento de qualidade e produção da planta a evitar paradas de máquinas e produtos defeituosos, identificando as causas mais comuns de baixa eficiência.

Palavras-chave: Aprendizado de máquina; base de dados; Arduino; fábrica; programação; Aquisição de dados.

Introducción

El sector de producción y manufactura es un punto clave en el desarrollo económico de un país. La tercera revolución industrial estuvo marcada por los procesos de automatización con controladores lógicos programables, mientras que la cuarta revolución industrial aún se encuentra en un proceso

de formación y se actualiza constantemente (Khosravani et al., 2022). Los nuevos métodos de optimización de procesos requieren una sincronización entre los sistemas de planificación, protocolos de calidad y los sistemas de monitorización de datos con sensores inteligentes (Larek et al., 2019).

Los procesos de adquisición de datos en una planta tienen como entrada datos de los equipos o del proceso, estos datos son analizados y mostrados en forma de KPIs para mejorar las operaciones (Cutting-Decelle et al., 2012).

Uno de los procesos de manufactura más comunes es el de moldeo por inyección (Fu et al., 2020). El moldeo por inyección consta de un proceso cíclico, en el que bajo presión y en alta velocidad, el molde es llenado con material plástico caliente sintético u orgánico, para después ser enfriado y expulsado (Ogorodnyk & Martinsen, 2018).

Los parámetros de proceso iniciales con los que se configuran las máquinas de inyección están directamente relacionados con la forma y peso del producto final, afectando desde la calidad del producto hasta el costo del material producido en masa (Zhao et al., 2020).

Una adecuada monitorización del proceso y los parámetros usados es un punto fundamental para proponer acciones de optimización en la línea de producción (Kozjek et al., 2019). La información recolectada podría ser uno de los recursos más importantes si se usa y se administra apropiadamente, incluso las empresas más modernas suelen tener inconvenientes adquiriendo datos de sus instrumentos de medición, para identificar las variables estratégicas en el proceso deben adoptarse las metodologías y herramientas correctas (Gosselin & Ruel, 2007).

La adquisición de datos y su posterior uso en las industrias actualmente es uno de los temas más investigados por ingenieros, y son aplicados en procesos como el mantenimiento preventivo de las máquinas y en la evaluación de confiabilidad y calidad del producto (Shi et al., 2007).

Existen varios tipos de sensores, pero en el ambiente industrial actualmente se utilizan los sensores de bajo costo y gran capacidad, son esenciales para empezar con el proceso de adquisición de datos (Kalsoom et al., 2020).

Los sensores por lo general necesitan un microcontrolador para enviar la información, éste consiste en el conjunto de hardware y software que según su programación podría enviar órdenes a actuadores o simplemente almacenar los datos, como es en este caso (Wu et al., 2020).

Empresas de software como Facebook, Google o Twitter han comenzado a usar bases de datos no relacionales para almacenar la gran cantidad de datos que administran. Teniendo sensores

conectados a las máquinas de una industria escribiendo datos muy frecuentemente y sin llevar una estructura determinada las bases de datos relacionales se vuelven obsoletas (Čerešňák & Kvet, 2019).

Las bases de datos relacionales se han limitado mucho con respecto a su rendimiento, ya que se centran más en que tengan organizados y relacionados sus datos, a diferencia de las bases de datos no relacionales que sus recursos se concentran más en el rápido almacenamiento, en su fácil crecimiento y en su facilidad para usar herramientas de big data (Mehmood et al., 2017).

En la era de la interconexión inteligente de la información el big data se está convirtiendo en una herramienta que baja notablemente la complejidad de los problemas de almacenamiento de datos en las industrias, y lo seguirá haciendo mientras el mundo siga subiendo a la ola de la industria 4.0 (Li et al., 2022).

Así como hay grandes ventajas en la capacidad para almacenar grandes cantidades de datos también existen retos que se tienen que resolver con mucha rapidez y facilidad, para realizar esas tareas desde hace algunos años se utiliza el machine learning, basándose en métodos estadísticos como los árboles de decisiones o los vectores de soporte (Nasiri & Khosravani, 2021). El campo de machine learning es muy amplio porque puede abarcar redes neuronales, aprendizaje automático, entre otras ramas muy útiles para las mejoras en la fabricación y nos facilitan la manipulación de datos en tiempo real (Dogan & Birant, 2021).

Los indicadores de producción que se generan en tiempo real en las industrias necesitan ser mostrados de una manera ordenada y de fácil entendimiento para las personas encargadas de interpretarlos, por eso han aparecido los dashboards, pantallas donde se muestran los KPIs necesarios para una buena toma de decisiones, ahora con la normalización de los smartphones, cada vez se están volviendo más comunes (Tokola et al., 2016).

Como un ejemplo de buen uso de los dashboards este artículo científico presenta cómo un dashboard con los cálculos producidos con machine learning que nos ayudarán a mejorar la producción de una industria.

Metodología

En este artículo se expone el diseño de un sistema que controla la producción y calidad de productos de una máquina inyectora de plástico, clasificando los lapsos de funcionamiento y paradas de la

máquina para su posterior análisis, toda esta información será almacenada en una base de datos y se podrá visualizar en una plataforma web de alarmas.

Descripción del sistema

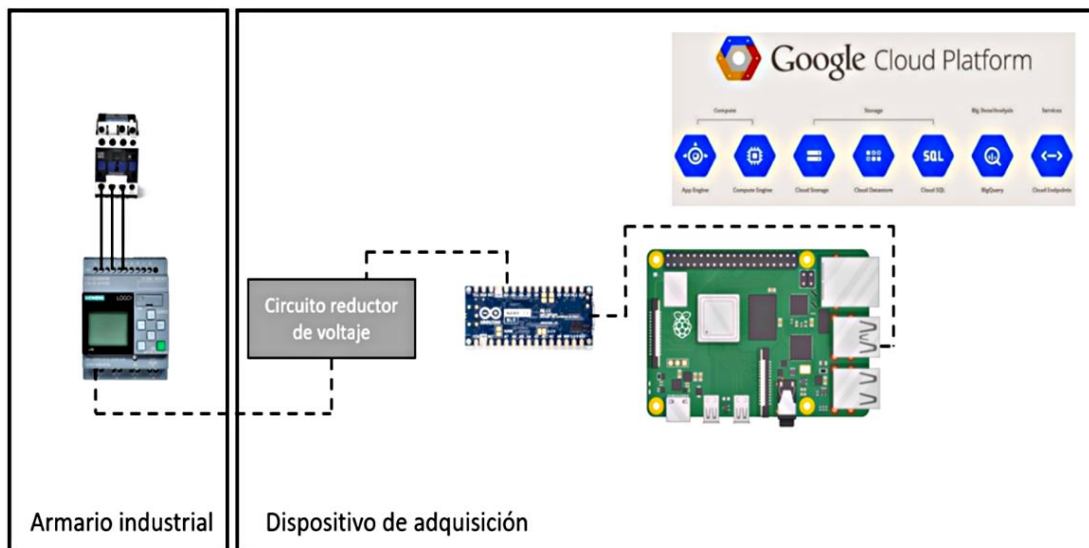
Este sistema se compone de 2 fases, la primera fase corresponde al hardware, consta de un dispositivo diseñado con un circuito electrónico constituido por un Arduino Nano, un Optoacoplador 4N25, un Raspberry Pi 4 y un controlador Logo marca Siemens.

En los contactores de la máquina inyectora debe estar conectado el logo, cuando la máquina inicia el proceso de inyección de la materia prima se energiza el primer contactor, luego, se abre el molde y se activa el segundo contactor, y una vez el producto pasa por la fotocélula de la máquina se activa el tercer contactor.

Todos estos pulsos de 24 voltios ingresan al controlador (logo) y por medio de un conjunto de condiciones generamos una salida de 24 voltios, esta salida debe ir conectada al arduino nano, para esto se diseña una tarjeta electrónica la cual va a convertir los 24 voltios a 5 voltios de corriente directa, esto se logra por intermedio del optoacoplador 4N25, ya que el voltaje final es el permitido por el arduino nano. Cuando se recibe el pulso, se escribe en la consola del puerto serial que se ha realizado un producto, los lenguajes de programación tienen la capacidad de leer este tipo de puerto que usa la conexión USB para comunicarse con la computadora. Siguiendo con el proceso, la raspberry pi tiene un código realizado en lenguaje de programación java para que detecte el puerto serial, este código de programación detecta la acción de que se creó un producto e inmediatamente se guarda la fecha de creación en una base de datos en la web.

La Figura 1 muestra el diseño general del proyecto, el esquema de conexión del logo siemens con la máquina inyectora de plástico que cumple con las condiciones de entrada para generar la salida deseada, la parte de la tarjeta electrónica que ayuda a regular el voltaje necesario para que trabajen el resto de componentes electrónicos, el arduino nano que envía el pulso por el puerto USB y que posteriormente es reconocido por la raspberry pi 4 para que cuando detecte el pulso rápidamente suba a internet la hora precisa en la que fue captado y que todas las horas que indujeron los pulsos queden guardados en la base de datos.

Figura 1. Diseño para la adquisición y control de una máquina inyectora de plástico.



Fuente: Los Autores.

En la fase 2, las horas de los pulsos registrados se suben al internet y quedan guardados en una base de datos no relacional, que es el tipo de base de datos recomendado para trabajar con big data, esta base de datos se llama Firebase Firestore que pertenece a Google.

Por último, para el análisis de la base de datos se usa una técnica paramétrica de machine learning denominada regresión lineal múltiple, este método clasifica las variables y encuentra una relación entre ellas, establecerá un modelo para ajustar la relación entre la variable dependiente x y el valor resultado correspondiente a la variable independiente y .

Para interpretar el modelo de regresión lineal múltiple existen los coeficientes predictores β , en donde β_0 se relaciona con la variable de respuesta y cuando las variables de respuesta son cero, β_j corresponde al cambio promedio esperado y que incrementa una unidad de la variable predictora x .

Todos estos resultados ayudan a encontrar una mejor eficiencia en el proceso implementado, además, por medio de una interfaz gráfica se puede visualizar la ecuación con sus respectivas variables y valores obtenidos por el algoritmo, y las alarmas que indican que es lo que hay que corregir o arreglar para que el proceso mejore y sea más eficiente para la fábrica.

Arduino nano: Es una placa electrónica de tamaño compacto, posee un microcontrolador Atmega328, está constituido por 14 pines de E/S digitales, de los cuales 8 pines son de entrada

analógica y 6 pines proveen salida PWM. Su voltaje de operación es de 5v con un voltaje de entrada que puede variar de 7v a 12v, posee una memoria de 32 KB (según su versión), además trabaja con una frecuencia de 16 MHz (Salem et al., 2019).

Raspberry Pi 4: El modelo B+ de 4GB, consta de 4 puertos USB, almacenamiento en MicroSD, memoria RAM de 512 MB con frecuencia de reloj de 1.4Ghz, voltaje de 5v con una corriente, conectividad Wifi, Bluetooth y Ethernet, puerto HDMI, posee una alimentación de 600mA a 1.8A con un voltaje de 5v, su sistema operativo principal es Raspbian el cual está basado en Linux. Se considera un ordenador capaz de trabajar con varios lenguajes de programación de alto nivel (Vujović & Maksimović, 2015).

Optoacoplador 4N25: Es un acoplador óptico que consta de 6 pines, este componente sirve para que la señal pase por dos circuitos diferentes, su corriente máxima de entrada es 50mA, produce un voltaje máximo de 30v y soporta un rango de temperatura entre -55 °c a +100°c (Codina, 2008).

Logo Siemens: Es un módulo inteligente que permite un control lógico de salida para varias entradas programadas, se lo puede controlar de manera interna por medio de instrucciones o comparaciones, para proyectos industriales Logo es más estable, tiene larga vida útil y es fácil de programar y operar (Zhang et al., 2021).

Machine Learning: Es un conjunto de algoritmos computaciones que son diseñados para emular la inteligencia humana (El Naqa & Murphy, 2015).

Regresión Lineal: La regresión lineal múltiple sincroniza los modelos lineales entre una variable dependiente y varias variables independientes, es uno de los modelos más sencillos de machine learning, usados para el análisis de grandes datos (Maulud & Abdulazeez, 2020).

Resultados

El proyecto fue realizado en la empresa Plásticos Panamericanos Plapasa S.A., de la ciudad de Guayaquil. Para analizar los resultados obtenidos de la investigación se los ha clasificado en tres secciones: (1) Sistema de adquisición de pulsos, (2) Interfaz gráfica para clasificar los datos y asignarles razones de paradas, (3) Análisis estadístico usando algoritmo de Machine Learning.

El dispositivo consta de un controlador logo que está conectado a los contactores de la máquina inyectora de plástico, con las condiciones establecidas, el controlador arroja 24 voltios en la salida para luego por medio de un circuito electrónico reducir a 5 voltios.

Sistema de adquisición de pulsos

Al conectar el controlador industrial con la tarjeta de adquisición se han recibido los pulsos de cada producto inyectado por la máquina y exitosamente se suben a la base de datos no relacional Firebase, no se observó pérdida de datos y su velocidad de subida es casi instantánea, cada vez que un producto es inyectado por la máquina, se crea el objeto tipo JSON y se envía con un método HTTP de tipo POST a un servidor que se ejecuta localmente en la raspberry pi, para que posteriormente el servicio de Google genere el documento con la información del JSON.

Interfaz gráfica para clasificar los datos y asignarles razones de paradas

Se desarrolló la interfaz gráfica para visualizar los indicadores de producción y clasificar las causas de las paradas, con ayuda del framework Angular se desarrolló el método para seleccionar un rango de tiempo y clasificar varias paradas al mismo tiempo, aparece una ventana emergente con varios menús en el que se selecciona la razón de parada y se puede escribir un comentario, si el operador así lo decide, esta acción llena los campos “Nombre de Paro”, “Descripción” y “Comentario” en Firebase para tener la base de datos lista para su análisis en el lenguaje de programación R.

Usando el servicio “Funciones” de Firebase con lenguaje de programación JavaScript, se desarrolló una función que lee la base de datos interna de Plapasa S.A y obtiene las órdenes de fabricación con información crítica para clasificar el proceso, como la media del peso por producto, peso mínimo, peso máximo, nombre de producto, su fecha de captura y su velocidad de producción.

Análisis estadístico usando algoritmo de Machine Learning

Para realizar el análisis estadístico se obtiene la base de datos en formato JSON , se la ordenó de tal manera que se puedan analizar las paradas por horas y se armó la tabla con las siguientes columnas: Producto, Peso mínimo, Peso medio, Peso máximo, Eficiencia por cantidad, Fecha de captura, Ciclo, Segundos totales, Segundos trabajados, Segundos no trabajados, Segundos de producción lenta, Eficiencia por tiempo, Cantidad de intermitencias, Cantidad de unidades producidas, Cantidad de unidades proyectadas, Tiempo de paro por subida de molde, Tiempo de paro por recalibración de máquina y molde, Tiempo de paro por artículo pegado en el molde, Tiempo de paro por mantenimiento hidráulico, Cantidad de unidades con rebabas, Cantidad de unidades con burbujas, Cantidad de unidades rechazadas por cambio de color, Cantidad de unidades rechazadas por llenado incompleto de molde, Cantidad de unidades rechazadas por deformación.

Usando el modelo de regresión lineal con machine learning se encontró que las variables más significativas para la predicción de la eficiencia por tiempo en las siguientes horas eran: segundos

totales, segundos no trabajados, tiempo de paro por artículo pegado en el molde, de intermitencias en la producción y tiempo de paro por recalibración de máquina y molde tal como se muestra en la Figura 2, donde las variables más relevantes están marcadas con asteriscos.

Figura 2. Datos de salida después de entrenar el modelo de machine learning.

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-2.244e-02	1.016e-01	-0.221	0.82597
productoSEPARADOR DE CUBIERTO VERDE FRESH	9.254e-02	3.768e-02	2.456	0.01713 *
pesoMedio	NA	NA	NA	NA
eficienciaPorCantidad	1.748e-01	9.819e-02	1.781	0.08028 .
segundosTotales	2.002e-04	3.192e-05	6.271	5.16e-08 ***
segundosNoTrabajados	-2.727e-04	3.406e-05	-8.005	6.73e-11 ***
cantidadUnidadesProducidas	NA	NA	NA	NA
tiempoParoSubidaDeMolde	7.758e-06	3.433e-05	0.226	0.82203
tiempoParoArtículoPegadoEnMolde	1.062e-04	3.429e-05	3.096	0.00304 **
cantidadUnidadesConRebabas	-8.766e-03	9.539e-03	-0.919	0.36201
cantidadUnidadesRechazadasPorCambioDeColor	NA	NA	NA	NA
cantidadUnidadesDeformadas	-5.013e-03	5.480e-03	-0.915	0.36416
pesoMínimo	NA	NA	NA	NA
pesoMáximo	NA	NA	NA	NA
ciclo	NA	NA	NA	NA
segundosTrabajados	NA	NA	NA	NA
segundosProduccionLenta	6.998e-05	3.629e-05	1.928	0.05882 .
cantidadIntermitencias	-7.336e-03	7.935e-03	-0.925	0.35910
cantidadUnidadesProyectadas	NA	NA	NA	NA
tiempoParoRecalibraciónMaquinaYMolde	1.498e-04	6.698e-05	2.236	0.02929 *
tiempoParoMantenimientoHidraulico	-1.811e-05	2.973e-05	-0.609	0.54480
cantidadUnidadesConBurbujas	NA	NA	NA	NA
cantidadUnidadesLlenadoIncompleto	-5.945e-03	5.503e-03	-1.080	0.28458


 Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.1008 on 57 degrees of freedom
 Multiple R-squared: 0.9441, Adjusted R-squared: 0.9314
 F-statistic: 74.08 on 13 and 57 DF, p-value: < 2.2e-16

Fuente: Los Autores.

Los siguientes gráficos en la Figura 3, indican el comportamiento de la regresión con los “betas” asignados automáticamente por el algoritmo.

Figura 3. Gráficas del comportamiento de la regresión.



Fuente: Los Autores.

Se comparó las predicciones del modelo con la eficiencia real y se puede observar diferencias muy pequeñas, lo que comprueba que el modelo tiene un alto nivel de confianza, esto se logra al separar el 70% de los datos para entrenar el modelo y el 30% para evaluar resultados.

La Tabla 1 refleja los valores reales y datos que ha predicho el algoritmo.

Tabla 1. Datos del algoritmo.

	Real	Pred
12	0.79361942	0.865941919
14	0.96697039	1.100385767
15	0.98512187	1.027001662
19	0.66522865	0.560770266
23	0.94808640	0.823137721
34	0.94368601	1.026295554
40	1.00000000	1.054272133
41	0.96948640	0.997821594
47	0.86523823	0.966353421
52	0.55222124	0.547500956
54	0.88536306	0.898551559
55	0.37998860	0.387445642
58	0.98180768	0.929686225

Fuente: Los Autores.

La función desarrollada en el lenguaje de programación R con la ayuda de la librería Shiny nos permite abrir una aplicación web, como se puede contemplar en la Figura 4, en la que podemos generar alarmas cuando la eficiencia que se predice supera algunos límites.

Figura 4. Alarma de eficiencia.



Fuente: Loa Autores.

Conclusiones

Por los resultados alcanzados se implementó un sistema de adquisición de datos utilizando un dispositivo electrónico que junto a un controlador logo van conectados a los contactores de la máquina inyectora de plástico, con toda la información adquirida y trabajando con una base de datos no relacional, los datos generados quedan guardados en la nube. Además, empleando un modelo de machine learning llamado regresión lineal múltiple, podemos hallar la cantidad de eficiencia de nuestro sistema a base de un algoritmo de predicción usando la información almacenada en la base de datos.

Con los índices de salida del algoritmo conseguimos generar alarmas visuales de prevención por defectos en una aplicación web que se usará en una computadora de la fábrica, la cual va a ayudar a hacer los respectivos correctivos en los procesos de la máquina y así conseguir que la eficiencia del equipo sea óptima. Este sistema contribuye a que el departamento de producción y calidad de la planta pueda analizar las diferentes paradas que tiene la máquina inyectora y así poder tomar decisiones para corregir estos fallos y que la industria no se vea afectada de manera económica por deficiencia.

Referencias

1. Khosravani, M. R., Nasiri, S., & Reinicke, T. (2022). Intelligent knowledge-based system to improve injection molding process. *Journal of Industrial Information Integration*, 25, 100275. <https://doi.org/10.1016/j.jii.2021.100275>
2. Larek, R., Grendel, H., Wagner, J. C., & Riedel, F. (2019). Industry 4.0 in manual assembly processes – a concept for real time production steering and decision making. *Procedia CIRP*, 79, 165–169. <https://doi.org/10.1016/j.procir.2019.02.038>
3. Cutting-Decelle, A. F., Barraud, J. L., Veenendaal, B., & Young, R. I. (2012). Production information interoperability over the Internet: A standardised data acquisition tool developed for industrial enterprises. *Computers in Industry*, 63(8), 824–834. <https://doi.org/10.1016/j.compind.2012.08.010>
4. Fu, H., Xu, H., Liu, Y., Yang, Z., Kormakov, S., Wu, D., & Sun, J. (2020). Overview of Injection Molding Technology for Processing Polymers and Their Composites. *ES Materials & Manufacturing*. <https://doi.org/10.30919/esmm5f713>

5. Ogorodnyk, O., & Martinsen, K. (2018). Monitoring and Control for Thermoplastics Injection Molding A Review. *Procedia CIRP*, 67, 380–385. <https://doi.org/10.1016/j.procir.2017.12.229>
6. Zhao, P., Dong, Z., Zhang, J., Zhang, Y., Cao, M., Zhu, Z., Zhou, H., & Fu, J. (2020). Optimization of Injection-Molding Process Parameters for Weight Control: Converting Optimization Problem to Classification Problem. *Advances in Polymer Technology*, 2020, 1–9. <https://doi.org/10.1155/2020/7654249>
7. Kozjek, D., Vrabič, R., Kralj, D., Butala, P., & Lavrač, N. (2019). Data mining for fault diagnostics: A case for plastic injection molding. *Procedia CIRP*, 81, 809–814. <https://doi.org/10.1016/j.procir.2019.03.204>
8. Gosselin, C., & Ruel, M. (2007). ADVANTAGES OF MONITORING THE PERFORMANCE OF INDUSTRIAL PROCESSES. *IFAC Proceedings Volumes*, 40(11), 33–38. <https://doi.org/10.3182/20070821-3-CA-2919.00006>
9. Shi, D., Axinte, D. A., & Gindy, N. N. (2007). Development of an online machining process monitoring system: A case study of the broaching process. *The International Journal of Advanced Manufacturing Technology*, 34(1–2), 34–46. <https://doi.org/10.1007/s00170-006-0588-1>
10. Kalsoom, T., Ramzan, N., Ahmed, S., & Ur-Rehman, M. (2020). Advances in Sensor Technologies in the Era of Smart Factory and Industry 4.0. *Sensors*, 20(23), 6783. <https://doi.org/10.3390/s20236783>
11. Wu, Z., Qiu, K., & Zhang, J. (2020). A Smart Microcontroller Architecture for the Internet of Things. *Sensors*, 20(7), 1821. <https://doi.org/10.3390/s20071821>
12. Čerešňák, R., & Kvet, M. (2019). Comparison of query performance in relational a non-relation databases. *Transportation Research Procedia*, 40, 170–177. <https://doi.org/10.1016/j.trpro.2019.07.027>
13. Mehmood, N. Q., Culmone, R., & Mostarda, L. (2017). Modeling temporal aspects of sensor data for MongoDB NoSQL database. *Journal of Big Data*, 4(1), 8. <https://doi.org/10.1186/s40537-017-0068-5>
14. Li, C., Chen, Y., & Shang, Y. (2022). A review of industrial big data for decision making in intelligent manufacturing. *Engineering Science and Technology, an International Journal*, 29, 101021. <https://doi.org/10.1016/j.jestch.2021.06.001>

15. Nasiri, S., & Khosravani, M. R. (2021). Machine learning in predicting mechanical behavior of additively manufactured parts. *Journal of Materials Research and Technology*, 14, 1137–1153. <https://doi.org/10.1016/j.jmrt.2021.07.004>
16. Dogan, A., & Birant, D. (2021). Machine learning and data mining in manufacturing. *Expert Systems with Applications*, 166, 114060. <https://doi.org/10.1016/j.eswa.2020.114060>
17. Tokola, H., Gröger, C., Järvenpää, E., & Niemi, E. (2016). Designing Manufacturing Dashboards on the Basis of a Key Performance Indicator Survey. *Procedia CIRP*, 57, 619–624. <https://doi.org/10.1016/j.procir.2016.11.107>
18. Salem, N., Alharbi, S., Khezendar, R., & Alshami, H. (2019). Real-time glove and android application for visual and audible Arabic sign language translation. *Procedia Computer Science*, 163, 450–459. <https://doi.org/10.1016/j.procs.2019.12.128>
19. Vujović, V., & Maksimović, M. (2015). Raspberry Pi as a Sensor Web node for home automation. *Computers & Electrical Engineering*, 44, 153–171. <https://doi.org/10.1016/j.compeleceng.2015.01.019>
20. Codina, E. G. (2008). Interfaz USB para controlar el monocromador Sciencetech 9010. <https://doi.org/10.13140/RG.2.2.35920.51209>
21. Zhang, C., Sun, Y., & Wang, Z. (2021). The Fuel Gas Odorizing Equipment Based on Siemens LOGO! 2021 7th Annual International Conference on Network and Information Systems for Computers (ICNISC), 158–167. <https://doi.org/10.1109/ICNISC54316.2021.00038>
22. El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? In I. El Naqa, R. Li, & M. J. Murphy (Eds.), *Machine Learning in Radiation Oncology* (pp. 3–11). Springer International Publishing. https://doi.org/10.1007/978-3-319-18305-3_1
23. Maulud, D., & Abdulazeez, A. M. (2020). A Review on Linear Regression Comprehensive in Machine Learning. *Journal of Applied Science and Technology Trends*, 1(4), 140–147. <https://doi.org/10.38094/jastt1457>