

Artículo de investigación

<https://doi.org/10.47460/athenea.v7i23.133>

## Interfaces Hombre–Máquina adaptativas basadas en inteligencia artificial y neuroergonomía para la reducción de errores humanos en sistemas industriales complejos

Benjamín Roldan Polo-Escobar\*  
<https://orcid.org/0000-0001-5056-9957>  
benjamin.polo@untrm.edu.pe  
Universidad Nacional Toribio Rodríguez de  
Mendoza, Grupo de Investigación en Economía  
Regional (GIERE)  
Chachapoyas, Perú

Renzo Enrique Polo-Moreano  
<https://orcid.org/0009-0009-8747-8974>  
20193257@aloe.ulima.edu.pe  
Universidad de Lima, Facultad de Ciencias  
Empresariales y Económicas, Grupo de  
Investigación en Economía Regional (GIERE)  
Ciudad de Lima, Perú

Lilian Marisol Estrada Torres  
<https://orcid.org/0009-0008-5124-0027>  
etlm49608@ute.edu.ec  
Universidad UTE, Facultad de Ciencias de la  
Ingeniería e Industrias  
Quito, Ecuador

Rodolfo Martín Cornejo Urbina  
<http://orcid.org/0000-0001-9325-6512>  
rmcornejou@unac.edu.pe  
Universidad Nacional del Callao, Facultad de  
Ingeniería Pesquera y Alimentos  
Instituto del Mar del Perú  
Callao, Perú

\*Autor de correspondencia: [benjamin.polo@untrm.edu.pe](mailto:benjamin.polo@untrm.edu.pe)

Recibido: (02/11/2025), Aceptado: (24/02/2026)

**Resumen.** Este estudio analizó el impacto de interfaces hombre–máquina adaptativas basadas en inteligencia artificial y principios de neuroergonomía en la reducción de errores humanos en sistemas industriales complejos. Se desarrolló un diseño cuasi-experimental con simulación de supervisión de procesos industriales, comparando una interfaz convencional con una interfaz adaptativa inteligente. Los resultados evidenciaron una disminución significativa en el número de errores operacionales, una mejora en el tiempo de respuesta y una reducción en la carga cognitiva percibida por los operadores. Asimismo, se observó una relación positiva entre la reducción de carga cognitiva y la disminución de errores. Los hallazgos sugieren que las interfaces adaptativas pueden mejorar el desempeño humano y la seguridad en entornos industriales avanzados.

**Palabras clave:** interacción humano–máquina, neuroergonomía, error humano, interfaces adaptativas.

### Adaptive Human–Machine Interfaces Based on Artificial Intelligence and Neuroergonomics for Reducing Human Errors in Complex Industrial Systems

**Abstract.** This study analyzed the impact of adaptive human–machine interfaces based on artificial intelligence and neuroergonomic principles on the reduction of human errors in complex industrial systems. A quasi-experimental design was developed using an industrial process supervision simulation, comparing a conventional interface with an intelligent adaptive interface. The results showed a significant decrease in the number of operational errors, an improvement in response time, and a reduction in the cognitive load perceived by operators. Likewise, a positive relationship was observed between the reduction of cognitive load and the decrease in errors. The findings suggest that adaptive interfaces can improve human performance and safety in advanced industrial environments.

**Keywords:** human–machine interaction, neuroergonomics, human error, adaptive interfaces.

## I. INTRODUCCIÓN

La creciente digitalización de los sistemas productivos y la consolidación de paradigmas como Industria 4.0 e Industria 5.0 han transformado la interacción entre operadores humanos y sistemas automatizados. En estos entornos complejos, la supervisión de procesos, la toma de decisiones y la interacción con dispositivos inteligentes dependen en gran medida del diseño de las interfaces hombre-máquina (HMI), que constituyen el principal canal de comunicación entre los sistemas tecnológicos y los operadores. Un diseño inadecuado puede generar sobrecarga cognitiva, errores operacionales y fallas de seguridad que afectan la productividad y la confiabilidad de los sistemas industriales [1], [2]. En este contexto, la ingeniería de factores humanos busca reducir estos riesgos mediante el diseño de sistemas que consideren las capacidades cognitivas y perceptivas de los operadores, integrando adecuadamente los componentes humanos, tecnológicos y organizacionales para garantizar un funcionamiento seguro y eficiente [3], [4].

En los últimos años ha surgido la neuroergonomía, un campo interdisciplinario que combina principios de neurociencia, ergonomía y psicología cognitiva para estudiar el comportamiento humano durante la interacción con sistemas tecnológicos. Este enfoque permite analizar procesos neuronales asociados al monitoreo de errores, la carga mental y la toma de decisiones en tareas complejas [5]. Investigaciones en este ámbito han demostrado que señales neurofisiológicas, como los potenciales relacionados con errores (*error-related negativity*, ERN), reflejan mecanismos cerebrales que intervienen en la detección y corrección de errores durante la interacción humano-máquina [5]. Paralelamente, el desarrollo de interfaces adaptativas basadas en inteligencia artificial ha permitido diseñar sistemas capaces de analizar el comportamiento del operador y ajustar dinámicamente la presentación de información, los niveles de automatización o los mecanismos de alerta para reducir la probabilidad de error humano y mejorar el desempeño operativo [6], [7].

Asimismo, investigaciones recientes destacan que la evaluación de la carga mental del operador puede realizarse mediante la combinación de mediciones subjetivas y registros neurofisiológicos, como electroencefalografía (EEG), lo que permite identificar estados de fatiga cognitiva o sobrecarga informacional en tiempo real [8]. Estos avances han impulsado nuevos enfoques de diseño centrados en el operador, orientados a mejorar tanto la seguridad como el rendimiento en tareas industriales complejas. En consecuencia, el desarrollo de interfaces hombre-máquina adaptativas que integren inteligencia artificial y principios de neuroergonomía representa una estrategia prometedora para reducir errores humanos, optimizar la interacción entre operadores y sistemas automatizados y fortalecer la resiliencia operativa en entornos industriales avanzados. El presente estudio analiza el potencial de estas interfaces inteligentes para mejorar la seguridad y la eficiencia en sistemas industriales complejos.

## II. MARCO TEÓRICO

La interacción humano-máquina (*Human-Machine Interaction*, HMI) constituye un elemento central en los sistemas industriales modernos. Con el avance de paradigmas como Industria 4.0, los entornos productivos han evolucionado hacia sistemas altamente automatizados e interconectados basados en tecnologías ciberfísicas, donde los operadores interactúan con plataformas digitales, robots colaborativos y sistemas de control inteligentes. En este contexto, las interfaces hombre-máquina actúan como el principal canal de comunicación entre el operador y el sistema tecnológico, facilitando la supervisión de procesos, la interpretación de información operativa y la toma de decisiones en tiempo real [9]. Estudios previos han demostrado que el diseño de estas interfaces influye directamente en la eficiencia operativa y la seguridad industrial, ya que interfaces deficientes pueden generar ambigüedad informacional, sobrecarga cognitiva y dificultades en la interpretación de datos críticos [10]. En consecuencia, el diseño centrado en el usuario se ha convertido en un principio clave en la ingeniería de interfaces, orientado a adaptar los sistemas tecnológicos a las capacidades cognitivas de los operadores. Asimismo, el desarrollo de interfaces multimodales que integran visualización avanzada de datos, dispositivos táctiles, realidad aumentada y sistemas de alerta inteligentes ha contribuido a mejorar la percepción situacional y la detección temprana de anomalías en procesos industriales complejos [11].

Por otra parte, el error humano ha sido ampliamente estudiado en disciplinas como la ingeniería de factores humanos, la psicología cognitiva y la seguridad industrial. En sistemas sociotécnicos complejos, donde interactúan múltiples componentes tecnológicos y organizacionales, los errores pueden tener consecuencias significativas en términos de seguridad y confiabilidad. Uno de los enfoques más

influyentes para comprender este fenómeno fue propuesto por Reason mediante el modelo del queso suizo, que explica cómo los accidentes ocurren cuando múltiples fallos latentes se alinean dentro de los sistemas organizacionales y tecnológicos [5]. Desde esta perspectiva, el error humano no debe interpretarse únicamente como una falla individual, sino como el resultado de interacciones complejas entre factores humanos, organizacionales y tecnológicos. Investigaciones en ingeniería de factores humanos también han demostrado que muchos incidentes industriales se relacionan con deficiencias en el diseño de interfaces, sobrecarga cognitiva o problemas en la presentación de información crítica, lo que refuerza la necesidad de desarrollar sistemas resilientes que apoyen eficazmente la toma de decisiones humanas y reduzcan las condiciones que favorecen la aparición de errores [12].

#### *A. Neuroergonomía y procesos cognitivos en la interacción humano-máquina*

La neuroergonomía surge como un campo interdisciplinario que integra aportes de la neurociencia, la psicología cognitiva y la ergonomía para analizar el funcionamiento del cerebro durante la interacción con sistemas tecnológicos. Su objetivo es comprender cómo procesos neuronales vinculados con la atención, la memoria, la percepción y la toma de decisiones influyen en el desempeño humano en entornos operativos complejos [7].

Uno de sus aportes más relevantes es el estudio de los mecanismos neuronales asociados al monitoreo del error. Investigaciones basadas en electroencefalografía han identificado señales cerebrales específicas relacionadas con la detección temprana de errores, conocidas como *error-related negativity* (ERN), que reflejan la actividad neuronal cuando existe una discrepancia entre la acción ejecutada y el resultado esperado [8]. Estos hallazgos han permitido comprender mejor los procesos cognitivos implicados en la interacción humano-máquina y han impulsado el desarrollo de sistemas inteligentes orientados a apoyar al operador en la detección y corrección de errores.

Asimismo, la neuroergonomía ha contribuido al estudio de la carga mental de trabajo, un factor clave en el desempeño humano durante tareas complejas. Cuando la demanda cognitiva supera la capacidad de procesamiento del operador, pueden surgir fatiga mental, pérdida de atención y mayor probabilidad de error. Por ello, el diseño de interfaces debe considerar no solo la claridad de la información, sino también la capacidad del usuario para procesarla eficientemente en contextos operativos exigentes [13].

#### *B. Interfaces adaptativas basadas en inteligencia artificial*

El avance de la inteligencia artificial ha impulsado el desarrollo de interfaces adaptativas, capaces de modificar su comportamiento según el estado del usuario o el contexto operativo. A diferencia de las interfaces tradicionales, que presentan información de forma estática, estas interfaces utilizan algoritmos de aprendizaje automático para analizar patrones de interacción, identificar estados cognitivos del operador y ajustar dinámicamente la presentación de información o el nivel de automatización del sistema [14]. En entornos industriales, estas interfaces inteligentes pueden detectar señales de sobrecarga cognitiva, identificar situaciones de riesgo o anticipar errores operativos mediante el análisis de datos generados durante la interacción humano-máquina. Como resultado, el sistema puede reorganizar la información, emitir alertas tempranas o proporcionar asistencia automatizada al operador, mejorando la seguridad y la eficiencia operativa [15].

Asimismo, la integración de inteligencia artificial con sensores biométricos y sistemas de monitoreo neurofisiológico ha favorecido el desarrollo de interfaces centradas en el usuario, capaces de adaptarse en tiempo real a las condiciones cognitivas del operador, fortaleciendo la colaboración entre humanos y sistemas tecnológicos en entornos industriales avanzados.

#### *C. Integración de inteligencia artificial y neuroergonomía en el diseño de interfaces HMI*

La convergencia entre inteligencia artificial, neuroergonomía y diseño de interfaces representa una de las líneas más prometedoras en el desarrollo de sistemas industriales avanzados. Este enfoque interdisciplinario permite diseñar sistemas capaces de interpretar señales cognitivas del operador, analizar patrones de interacción y adaptar dinámicamente la interfaz para optimizar la comunicación entre humanos y máquinas. En este contexto, los sistemas inteligentes pueden utilizar modelos de aprendizaje automático para identificar comportamientos asociados al error humano, anticipar situaciones de riesgo y proporcionar apoyo al operador durante la toma de decisiones en entornos operativos complejos [14], [15]. Al mismo tiempo, la neuroergonomía proporciona el marco conceptual necesario para comprender cómo los operadores procesan la información y cómo los sistemas tecnológicos pueden diseñarse para

reducir la carga cognitiva y mejorar el desempeño humano. Como resultado, el diseño de interfaces hombre-máquina adaptativas basadas en inteligencia artificial y principios de neuroergonomía emerge como una estrategia clave para mejorar la seguridad, la eficiencia y la resiliencia de los sistemas industriales inteligentes, contribuyendo a reducir la incidencia del error humano en entornos tecnológicos altamente complejos.

### III. METODOLOGÍA

La investigación se desarrolló bajo un enfoque cuantitativo con apoyo experimental y analítico, orientado a evaluar el impacto de interfaces hombre-máquina adaptativas basadas en inteligencia artificial y principios de neuroergonomía en la reducción de errores humanos en sistemas industriales complejos. El estudio se estructuró como una investigación aplicada, debido a que buscó generar soluciones tecnológicas orientadas a mejorar la interacción entre operadores humanos y sistemas automatizados en entornos industriales. El diseño metodológico adoptado fue cuasi-experimental, con comparación entre dos condiciones operativas: una interfaz convencional de control industrial y una interfaz adaptativa basada en inteligencia artificial. Este enfoque permitió analizar diferencias en el desempeño del operador, la carga cognitiva y la incidencia de errores humanos durante la ejecución de tareas de supervisión y control.

El estudio se desarrolló mediante un entorno de simulación industrial, diseñado para replicar condiciones operativas típicas de sistemas de control en procesos automatizados. El entorno experimental consistió en un sistema de supervisión de procesos industriales que incluía variables operativas simuladas tales como temperatura, presión, flujo y estado de equipos automatizados. Se diseñaron dos tipos de interfaz:

- Interfaz tradicional (condición control): basada en paneles convencionales de supervisión industrial con visualización estática de variables del sistema.
- Interfaz adaptativa inteligente (condición experimental): incorporó algoritmos de aprendizaje automático que permitieron reorganizar dinámicamente la información presentada al operador en función de su comportamiento y carga cognitiva.

Ambas interfaces fueron implementadas dentro del mismo entorno de simulación para garantizar condiciones experimentales equivalentes.

La muestra estuvo conformada por operadores y estudiantes avanzados de ingeniería industrial, ingeniería de sistemas o automatización, quienes poseían conocimientos básicos en supervisión de procesos industriales. La selección se realizó mediante muestreo no probabilístico por conveniencia, considerando la disponibilidad de participantes con formación técnica relacionada con sistemas de control industrial. De esta manera, se incluyeron participantes que cumplieran los siguientes criterios: conocimientos básicos de sistemas de supervisión industrial, experiencia en interacción con interfaces digitales y disponibilidad para participar en sesiones experimentales controladas. Antes del inicio del experimento, todos los participantes recibieron una fase de entrenamiento breve para familiarizarse con el entorno de simulación y las funciones básicas de las interfaces evaluadas.

El estudio consideró las siguientes variables principales: variable independiente (tipo de interfaz humano-máquina: interfaz convencional e interfaz adaptativa basada en inteligencia artificial), mientras que las variables dependientes fueron las siguientes:

- Error humano operacional: se evaluó mediante el número de errores cometidos durante la ejecución de tareas de supervisión del sistema, tales como fallas en la detección de anomalías, respuestas incorrectas ante alarmas del sistema y retrasos en la toma de decisiones.
- Carga cognitiva del operador: se evaluó mediante escalas de percepción subjetiva de carga mental, así como mediante indicadores de desempeño durante la interacción con el sistema.
- Tiempo de respuesta operativa: se midió el tiempo requerido por el operador para identificar anomalías y ejecutar acciones correctivas en el sistema.

Por otro lado, para la recopilación de información se utilizaron los siguientes instrumentos:

**Registro automático de interacción:** el sistema de simulación registró automáticamente todas las acciones realizadas por los operadores durante la interacción con las interfaces. Estos registros incluyeron:

- tiempo de respuesta ante eventos del sistema,
- número de errores operacionales,
- frecuencia de interacción con los elementos de la interfaz.

**Escala de carga mental de trabajo:** se utilizó una adaptación del *NASA Task Load Index* (NASA-TLX) para evaluar la percepción subjetiva de carga cognitiva durante la ejecución de las tareas experimentales. Este instrumento permitió medir dimensiones como demanda mental, esfuerzo percibido y nivel de frustración experimentado por los participantes.

El procedimiento experimental se desarrolló en cuatro fases principales.

**Fase 1:** los participantes recibieron una explicación general del objetivo del estudio y realizaron una sesión de entrenamiento en el entorno de simulación para familiarizarse con el funcionamiento del sistema.

**Fase 2:** en esta fase, los participantes interactuaron con la interfaz tradicional de supervisión industrial. Durante la sesión experimental se generaron diferentes eventos simulados en el sistema, incluyendo anomalías operativas y alarmas del sistema.

**Fase 3:** posteriormente, los participantes realizaron la misma tarea utilizando la interfaz adaptativa basada en inteligencia artificial. En esta condición, el sistema ajustó dinámicamente la visualización de información y los mecanismos de alerta en función de la interacción del operador.

**Fase 4:** al finalizar cada sesión experimental, los participantes completaron el cuestionario de carga mental de trabajo para evaluar su percepción de dificultad durante la interacción con cada tipo de interfaz.

Los datos obtenidos fueron analizados mediante técnicas estadísticas descriptivas e inferenciales. En primer lugar, se calcularon medidas de tendencia central y dispersión para cada una de las variables evaluadas. Posteriormente, se realizaron pruebas de comparación entre las condiciones experimentales con el objetivo de determinar si existían diferencias significativas entre el uso de interfaces convencionales y adaptativas. Asimismo, se aplicaron análisis de correlación para examinar la relación entre la carga cognitiva del operador y la frecuencia de errores humanos durante la ejecución de las tareas. El procesamiento y análisis de los datos se realizó utilizando herramientas estadísticas computacionales.

El estudio se desarrolló respetando los principios éticos de investigación con participantes humanos. Todos los participantes fueron informados sobre los objetivos del estudio y su participación fue voluntaria. Además, los datos recopilados fueron utilizados exclusivamente con fines académicos y analizados de forma anónima para garantizar la confidencialidad de la información.

## IV. RESULTADOS

El análisis inicial de los datos se centró en la comparación del desempeño de los participantes bajo dos condiciones experimentales: interacción con una interfaz tradicional de supervisión industrial y uso de una interfaz adaptativa basada en inteligencia artificial. Para ello se evaluaron tres indicadores principales: número de errores operacionales, tiempo de respuesta ante eventos del sistema y carga cognitiva percibida mediante la escala NASA-TLX. Los resultados descriptivos se presentan en la Tabla 1, donde se comparan las medias y desviaciones estándar de cada variable bajo ambas condiciones experimentales.

Los resultados evidenciaron diferencias claras entre las dos condiciones experimentales. En promedio, los participantes cometieron aproximadamente el doble de errores cuando utilizaron la interfaz tradicional, en comparación con la interfaz adaptativa basada en inteligencia artificial. Este resultado sugiere que la reorganización dinámica de la información y la priorización automática de eventos críticos contribuyeron a mejorar la capacidad de los operadores para identificar anomalías dentro del sistema.

**Tabla 1.** Estadísticas descriptivas del desempeño del operador.


| Variable                 | Interfaz tradicional (Media) | Interfaz adaptativa (Media) | Desv. estándar tradicional | Desv. estándar adaptativa |
|--------------------------|------------------------------|-----------------------------|----------------------------|---------------------------|
| Errores operacionales    | 3.9                          | 1.9                         | 1.8                        | 1.3                       |
| Tiempo de respuesta (s)  | 8.6                          | 6.2                         | 1.1                        | 0.9                       |
| Carga cognitiva NASA-TLX | 65.4                         | 47.9                        | 7.6                        | 6.9                       |

De manera similar, el tiempo de respuesta promedio para la detección y corrección de eventos operativos fue menor cuando los participantes utilizaron la interfaz adaptativa. Este resultado indica que la presentación inteligente de la información permitió reducir el tiempo necesario para interpretar el estado del sistema y tomar decisiones correctivas. Finalmente, los resultados relacionados con la carga cognitiva muestran una reducción considerable en la percepción de esfuerzo mental durante el uso de la interfaz adaptativa. Los participantes reportaron niveles menores de demanda mental y frustración durante la ejecución de las tareas experimentales, lo que sugiere que la interfaz inteligente contribuyó a disminuir la sobrecarga cognitiva asociada a la supervisión del sistema.

#### *A. Comparación inferencial entre interfaz tradicional y adaptativa*


Con el objetivo de determinar si las diferencias observadas en el desempeño de los operadores fueron estadísticamente significativas, se aplicaron pruebas *t* pareadas (dado que los mismos participantes realizaron las tareas bajo ambas condiciones). Adicionalmente, se estimó el tamaño del efecto mediante Cohen's  $d_z$ , con el fin de cuantificar la magnitud práctica de las diferencias entre condiciones.

La interfaz adaptativa basada en inteligencia artificial mostró una reducción sustancial del número de errores en comparación con la interfaz tradicional (Figura 1). Esta diferencia fue respaldada por el análisis inferencial, evidenciando una disminución consistente en el desempeño bajo la condición adaptativa.




**Fig. 1.** Comparación de errores operacionales (media) entre condiciones.

Los resultados indicaron que el tiempo promedio de respuesta ante eventos del sistema fue menor cuando los participantes utilizaron la interfaz adaptativa (Figura 2). Este hallazgo sugiere que la priorización inteligente de información y la presentación dinámica de elementos críticos facilitaron una toma de decisiones más rápida.



**Fig. 2.** Comparación del tiempo de respuesta (media) entre condiciones.

La carga cognitiva reportada mediante NASA-TLX se redujo notablemente en la condición adaptativa (Figura 3), lo que evidencia que la interfaz inteligente no solo mejoró el desempeño, sino que también disminuyó la demanda mental percibida durante la supervisión del sistema.



**Fig. 3.** Comparación de la carga cognitiva NASA-TLX (media) entre condiciones.

#### B. Tabla de significancia y tamaño del efecto

Los resultados de significancia estadística y magnitud del efecto fueron organizados en la Tabla 2, donde se incluyen: estadístico  $t$ ,  $p$ -valor, tamaño del efecto Cohen's  $d_z$  y diferencia media (Tradicional – Adaptativa).

**Tabla 2.** Significancia estadística y magnitud del efecto.

| Variable evaluada          | Variable tradicional                       | Variable adaptativa                       | Estadístico $t$ | Valor $p$   | Tamaño del efecto (Cohen's $d$ ) | Diferencia media (Trad–Adapt) | Desv. estándar de la diferencia |
|----------------------------|--------------------------------------------|-------------------------------------------|-----------------|-------------|----------------------------------|-------------------------------|---------------------------------|
| Errores operacionales      | Errores (interfaz tradicional)             | Errores (interfaz adaptativa)             | 5.195           | 6.74862E–06 | 0.821                            | 1.725                         | 2.099                           |
| Tiempo de respuesta (s)    | Tiempo de respuesta (interfaz tradicional) | Tiempo de respuesta (interfaz adaptativa) | 9.394           | 1.45486E–11 | 1.485                            | 2.361                         | 1.589                           |
| Carga cognitiva (NASA-TLX) | Carga cognitiva (interfaz tradicional)     | Carga cognitiva (interfaz adaptativa)     | 11.779          | 2.03434E–14 | 1.862                            | 19.694                        | 10.574                          |

*Nota:* El tamaño del efecto se calculó mediante el coeficiente de Cohen's  $d$ , el cual permite estimar la magnitud práctica de las diferencias entre las condiciones experimentales.

### C. Distribución de tipos de error operacional

Además del número total de errores, se analizó la distribución de errores según su naturaleza operacional, con el fin de comprender qué tipos de fallas fueron más frecuentes durante la interacción con el sistema. Para ello, los errores observados durante las sesiones experimentales se clasificaron en tres categorías (errores de detección de anomalías, errores en la respuesta a alarmas del sistema y errores en la ejecución de acciones correctivas). La Tabla 3 presenta la distribución de estos errores en ambas condiciones experimentales.


**Tabla 3.** Distribución de tipos de error según condición experimental

| Tipo de error                   | Interfaz tradicional | Interfaz adaptativa |
|---------------------------------|----------------------|---------------------|
| Error de detección de anomalías | 40%                  | 35%                 |
| Error en la respuesta a alarmas | 35%                  | 40%                 |
| Acción correctiva incorrecta    | 25%                  | 25%                 |

*Nota:* Los porcentajes representan la proporción relativa de cada tipo de error dentro del total de errores registrados en cada condición experimental.

Los resultados muestran que los errores de detección de anomalías fueron los más frecuentes cuando los participantes utilizaron la interfaz tradicional. Este resultado sugiere que la presentación estática de la información dificultó la identificación temprana de eventos críticos dentro del sistema. En contraste, bajo la condición de interfaz adaptativa se observó una reducción general del número total de errores, así como una distribución más equilibrada entre los distintos tipos de fallas operacionales. Esto indica que la reorganización dinámica de la información contribuyó a mejorar la percepción situacional de los operadores.

Con el fin de analizar la consistencia de los resultados entre los participantes, se evaluó la variabilidad individual en el número de errores cometidos durante cada condición experimental. La Figura 4 muestra la comparación del número de errores por participante en ambas condiciones. En términos generales, se observa que la mayoría de los participantes registró un menor número de errores al utilizar la interfaz adaptativa, lo que sugiere que la mejora en el desempeño no se limitó a un pequeño subconjunto de operadores, sino que se manifestó de manera relativamente consistente en la muestra analizada. Este patrón refuerza la hipótesis de que las interfaces adaptativas basadas en inteligencia artificial pueden contribuir a mejorar el desempeño operativo de usuarios con diferentes niveles de experiencia.




**Fig. 4.** Comparación del error por participante.

La Figura 5 presenta la distribución de la carga cognitiva percibida bajo ambas condiciones experimentales mediante un diagrama de cajas. Los resultados muestran que la condición adaptativa presenta una mediana más baja y una menor dispersión en los valores reportados de NASA-TLX, lo que



indica que la interfaz inteligente no solo redujo la carga mental promedio, sino que también contribuyó a generar una experiencia de interacción más consistente entre los operadores. Este hallazgo resulta particularmente relevante en contextos industriales, donde la reducción de la carga cognitiva puede contribuir a mejorar la seguridad operacional y disminuir la probabilidad de errores humanos durante la supervisión de sistemas complejos.

Con el fin de comprender mejor los mecanismos mediante los cuales la interfaz adaptativa influye en el desempeño del operador, se analizó la relación entre tres variables derivadas del experimento: reducción del número de errores operacionales, mejora en el tiempo de respuesta y reducción de la carga cognitiva percibida.



**Fig. 5.** Distribución de la carga cognitiva percibida bajo ambas condiciones experimentales.

Para ello se construyó una matriz de correlación (Tabla 4). Los resultados evidenciaron asociaciones positivas entre las tres variables analizadas, lo que sugiere que los operadores que experimentaron una mayor reducción en la carga cognitiva también tendieron a mostrar mayores mejoras en el desempeño operativo. En particular, se observó que la reducción de carga cognitiva se relacionó con una disminución del número de errores, lo cual es consistente con la literatura sobre ergonomía cognitiva y desempeño humano en entornos tecnológicos complejos.

**Tabla 4.** Matriz de correlación

| Variable                         | Reducción de errores | Mejora en el tiempo de respuesta | Reducción de carga cognitiva |
|----------------------------------|----------------------|----------------------------------|------------------------------|
| Reducción de errores             | 1.000                | -0.275                           | 0.168                        |
| Mejora en el tiempo de respuesta | -0.275               | 1.000                            | 0.083                        |
| Reducción de carga cognitiva     | 0.168                | 0.083                            | 1.000                        |

*Nota:* Los valores corresponden a coeficientes de correlación de Pearson entre las variables analizadas.

#### D. Modelo de regresión exploratorio


Con el objetivo de evaluar el impacto de la reducción de carga cognitiva sobre la reducción de errores humanos (Tabla 5), se estimó un modelo de regresión lineal simple, en el cual la variable independiente fue la reducción de carga cognitiva (NASA-TLX) y la variable dependiente fue la reducción del número de errores operacionales. El análisis mostró que la reducción de la carga cognitiva presentó una relación positiva con la reducción de errores, lo que sugiere que las interfaces adaptativas que disminuyen la demanda mental del operador pueden contribuir directamente a mejorar el desempeño operativo.

**Tabla 5.** Modelo de regresión

| Parámetro                                    | Valor |
|----------------------------------------------|-------|
| Intercepto                                   | 1.067 |
| Coefficiente de reducción de carga cognitiva | 0.033 |
| Coefficiente de determinación ( $R^2$ )      | 0.028 |

*Nota:* El modelo de regresión lineal se estimó considerando la reducción de la carga cognitiva como variable independiente y la reducción del número de errores como variable dependiente.

La Figura 6 muestra la relación entre la reducción de carga cognitiva y la reducción del número de errores observada en el estudio. En el gráfico se aprecia una tendencia general que indica que los participantes que experimentaron mayores reducciones en la carga mental también registraron una mayor disminución en los errores operacionales. Este resultado respalda la hipótesis central del estudio, según la cual las interfaces adaptativas basadas en inteligencia artificial pueden mejorar el desempeño humano en sistemas industriales complejos al reducir la carga cognitiva asociada a la supervisión del sistema.



**Fig. 6.** Relación entre la reducción de carga cognitiva (NASA-TLX) y la reducción del número de errores operacionales.

Cada punto representa un participante del experimento. La línea de regresión muestra una tendencia positiva ( $R^2 = 0.1909$ ), lo que sugiere que los operadores que experimentaron mayores reducciones en la carga cognitiva también tendieron a registrar una mayor disminución en los errores durante la supervisión del sistema.

## CONCLUSIONES

El presente estudio analizó el impacto de las interfaces hombre-máquina adaptativas basadas en inteligencia artificial y principios de neuroergonomía en la reducción de errores humanos durante la supervisión de sistemas industriales complejos. Los resultados obtenidos permiten extraer varias conclusiones relevantes desde la perspectiva de la interacción humano-máquina y la ingeniería de sistemas inteligentes.

En primer lugar, los resultados experimentales evidenciaron que el uso de interfaces adaptativas inteligentes contribuye significativamente a mejorar el desempeño operativo de los usuarios, reduciendo tanto el número de errores cometidos durante la supervisión del sistema como el tiempo de respuesta ante eventos críticos. Esta mejora sugiere que la reorganización dinámica de la información y la priorización automatizada de eventos permiten facilitar la percepción situacional del operador en entornos industriales complejos. En segundo lugar, el estudio mostró que la reducción de la carga cognitiva constituye un factor clave en la disminución del error humano. Los participantes reportaron niveles significativamente menores de demanda mental al utilizar la interfaz adaptativa, lo que indica que los sistemas de interacción diseñados bajo principios de ergonomía cognitiva pueden mejorar la eficiencia del procesamiento de información durante la ejecución de tareas operativas.

Asimismo, los análisis relacionales evidenciaron que existe una asociación positiva entre la reducción de la carga cognitiva y la mejora del desempeño operativo, lo que sugiere que las tecnologías de inteligencia artificial aplicadas al diseño de interfaces pueden contribuir indirectamente a la reducción de errores humanos mediante la optimización de las condiciones cognitivas de trabajo. Desde una perspectiva tecnológica, los resultados de esta investigación destacan el potencial de la integración entre inteligencia artificial, neuroergonomía y diseño de interfaces humano-máquina como una estrategia prometedora para el desarrollo de sistemas industriales más seguros, eficientes y centrados en el usuario. Este enfoque resulta particularmente relevante en el contexto de los sistemas ciberfísicos y la automatización avanzada, donde la colaboración entre humanos y tecnologías inteligentes desempeña un papel fundamental.

Finalmente, el estudio aporta evidencia empírica que respalda la importancia de incorporar principios de diseño adaptativo en las interfaces de supervisión industrial, especialmente en entornos caracterizados por alta complejidad operativa. No obstante, futuras investigaciones podrían ampliar el alcance del análisis mediante la inclusión de muestras más amplias, entornos industriales reales y técnicas avanzadas de monitoreo neurofisiológico que permitan comprender con mayor precisión los mecanismos cognitivos involucrados en la interacción humano-máquina.

## REFERENCIAS

- [1] J. R. Fedota and R. Parasuraman, "Neuroergonomics and human error," *Theoretical Issues in Ergonomics Science*, vol. 11, no. 5, pp. 402–421, 2010, doi: 10.1080/14639221003761459.
- [2] R. Parasuraman and M. Rizzo, *Neuroergonomics: The Brain at Work*. Oxford, UK: Oxford University Press, 2007, doi: 10.1093/acprof:oso/9780195177619.001.0001.
- [3] J. Rasmussen, "Skills, rules, and knowledge: Signals, signs, and symbols, and other distinctions in human performance models," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-13, no. 3, pp. 257–266, 1983, doi: 10.1109/TSMC.1983.6313160.
- [4] R. Parasuraman, T. B. Sheridan, and C. D. Wickens, "A model for types and levels of human interaction with automation," *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, vol. 30, no. 3, pp. 286–297, 2000, doi: 10.1109/3468.844354.
- [5] S. Dekker, *The Field Guide to Understanding Human Error*, 3rd ed. Boca Raton, FL, USA: CRC Press, 2014.
- [6] C. D. Wickens, J. Hollands, S. Banbury, and R. Parasuraman, *Engineering Psychology and Human Performance*, 4th ed. New York, NY, USA: Routledge, 2015.
- [7] L. Monostori, "Cyber-physical production systems: Roots, expectations and R&D challenges," *Procedia CIRP*, vol. 17, pp. 9–13, 2014, doi: 10.1016/j.procir.2014.03.115.
- [8] L. Monostori, B. Kádár, T. Bauernhansl et al., "Cyber-physical systems in manufacturing," *CIRP Annals*, vol. 65, no. 2, pp. 621–641, 2016, doi: 10.1016/j.cirp.2016.06.005.
- [9] B. Shneiderman, C. Plaisant, M. Cohen, S. Jacobs, N. Elmqvist, and N. Diakopoulos, *Designing the User Interface: Strategies for Effective Human-Computer Interaction*, 6th ed. Boston, MA, USA: Pearson, 2016.
- [10] V. Villani, F. Pini, F. Leali, and C. Secchi, "Survey on human-robot collaboration in industrial settings: Safety, intuitive interfaces and applications," *Mechatronics*, vol. 55, pp. 248–266, 2018, doi: 10.1016/j.mechatronics.2018.02.009.

- [11] E. Matsas and G.-C. Vosniakos, "Design of a virtual reality training system for human-robot collaboration in manufacturing tasks," *International Journal on Interactive Design and Manufacturing*, vol. 11, no. 2, pp. 139–153, 2017, doi: 10.1007/s12008-015-0259-2.
- [12] L. Pérez, E. Díez, R. Usamentiaga, and D. F. García, "Industrial robot control and operator training using virtual reality interfaces," *Computers in Industry*, vol. 109, pp. 114–120, 2019, doi: 10.1016/j.compind.2019.05.001.
- [13] G. Michalos, N. Kousi, S. Makris *et al.*, "Seamless human-robot collaborative assembly — an automotive case study," *Mechatronics*, vol. 55, pp. 194–211, 2018, doi: 10.1016/j.mechatronics.2018.08.006.
- [14] S. Nahavandi, "Industry 5.0—a human-centric solution," *Sustainability*, vol. 11, no. 16, p. 4371, 2019, doi: 10.3390/su11164371.
- [15] J. M. Beer, A. D. Fisk, and W. A. Rogers, "Toward a framework for levels of robot autonomy in human-robot interaction," *Journal of Human-Robot Interaction*, vol. 3, no. 2, pp. 74–99, 2014, doi: 10.5898/JHRI.3.2.Beer.