

PRISMA ODS
REVISTA MULTIDISCIPLINARIA
SOBRE DESARROLLO SOSTENIBLE
ISSN: 3072-8452

**EVALUACIÓN DE LA CARGA
COGNITIVA EN TELEOPERACIÓN
ROBÓTICA SIMULADA: MEDIDAS
SUBJETIVAS Y FISIOLÓGICAS**

*ASSESSING COGNITIVE LOAD IN SIMULATED
ROBOTIC TELEOPERATION: SUBJECTIVE AND
PHYSIOLOGICAL MEASURES*

AUTORES/A

**GUILEBALDO VARGAS
SOLIS**

UNIVERSIDAD AUTÓNOMA DE
GUERRERO
MÉXICO

RAÚL JUÁREZ MORALES

UNIVERSIDAD AUTÓNOMA DE
GUERRERO
MÉXICO

**PETRA BALDIVIA
NOYOLA**

UNIVERSIDAD AUTÓNOMA DE
GUERRERO
MÉXICO

**HUGO BALTAZAR
PALACIOS PÉREZ**

UNIVERSIDAD AUTÓNOMA DE
GUERRERO
MÉXICO

JUAN PARRA ABARCA

UNIVERSIDAD AUTÓNOMA DE
GUERRERO
MÉXICO

Evaluación de la Carga Cognitiva en Teleoperación Robótica Simulada: Medidas Subjetivas y Fisiológicas

Assessing Cognitive Load in Simulated Robotic Teleoperation: Subjective and
Physiological Measures

Guilebaldo Vargas Solis

16454819@uagro.mx

<https://orcid.org/0009-0007-1536-9862>

Universidad Autónoma de Guerrero
Guerrero – México

Raúl Juárez Morales

raul.juarezm@uagro.mx

<https://orcid.org/0000-0002-2409-7842>

Universidad Autónoma de Guerrero
Guerrero – México

Petra Baldivia Noyola

pbn29@uagro.mx

<https://orcid.org/0000-0001-7678-8867>

Universidad Autónoma de Guerrero
Guerrero – México

Hugo Baltazar Palacios Pérez

hugobaltazar@uagro.mx

<https://orcid.org/0000-0001-5004-9943>

Universidad Autónoma de Guerrero
Guerrero – México

Juan Parra Abarca¹

juanparra@uagro.mx

<https://orcid.org/0000-0002-4955-0244>

Universidad Autónoma de Guerrero
Guerrero – México

Artículo recibido: 17/09/2026

Aceptado para publicación: 17/10/2026

Conflictos de Intereses: Ninguno que declarar

¹ Autor de correspondencia.

RESUMEN

La teleoperación robótica se ha consolidado como una herramienta fundamental para operar en entornos donde la presencia humana representa un riesgo, lo que ha incrementado el interés por evaluar la carga cognitiva de los operadores. El objetivo de este trabajo fue describir cómo se ha evaluado la carga cognitiva en tareas de teleoperación robótica desarrolladas en entornos simulados mediante medidas subjetivas y fisiológicas. Se revisaron 14 estudios publicados entre 2014 y 2026, localizados en Scopus, Web of Science, IEEE Xplore, PubMed y Google Scholar, y se analizaron según las técnicas de evaluación, las características de los entornos simulados y el tipo de tarea. El NASA-TLX fue el instrumento subjetivo más empleado (6 de 14 estudios) y la electroencefalografía (EEG), la técnica fisiológica predominante (5 de 14), mientras que la actividad electrodérmica, la variabilidad de la frecuencia cardíaca y la pupilometría se utilizaron con menor frecuencia. Un número creciente de estudios combina medidas subjetivas y fisiológicas en simulaciones de mayor fidelidad, lo que permite detectar variaciones en la carga cognitiva que no siempre se reflejan en el desempeño del operador. No obstante, pocos estudios evalúan la carga cognitiva en escenarios simulados de emergencia y desastre, lo que representa una oportunidad de investigación particularmente en aplicaciones de búsqueda y rescate.

Palabras clave: carga cognitiva, carga mental de trabajo, teleoperación robótica, simulación, electroencefalografía, NASA-TLX

ABSTRACT

Robotic teleoperation has become a fundamental tool for operating in environments where human presence poses a risk, which has increased interest in assessing operators' cognitive load. This study aimed to describe how cognitive load has been assessed in robotic teleoperation tasks performed in simulated environments using subjective and physiological measures. Fourteen studies published between 2014 and 2026 were retrieved from Scopus, Web of Science, IEEE Xplore, PubMed, and Google Scholar and analyzed according to the assessment techniques, the characteristics of the simulated environments, and the type of task. The NASA Task Load Index (NASA-TLX) was the most frequently used subjective instrument (6 of 14 studies), and electroencephalography (EEG) was the predominant physiological technique (5 of 14), whereas electrodermal activity, heart rate variability, and pupillometry were used less frequently. A growing number of studies combine subjective and physiological measures in higher-fidelity simulations, which makes it possible to detect variations in cognitive load that are not always reflected in operator performance. However, few studies assess cognitive load in simulated emergency and disaster scenarios, which represents a research opportunity, particularly in search and rescue applications.

Keywords: cognitive load, mental workload, robotic teleoperation, simulation, electroencephalography, NASA-TLX

INTRODUCCIÓN

La teleoperación robótica ha adquirido una importancia creciente debido a su capacidad para ejecutar tareas en entornos donde la presencia humana representa un riesgo o resulta inviable, en ámbitos como la medicina, la industria, la exploración espacial y la respuesta ante desastres (Araya-Carvajal et al., 2025; Jain, 2024). Sin embargo, durante la operación remota, los usuarios deben procesar información proveniente de distintas fuentes, mantener la atención y tomar decisiones en tiempo real (Wang et al., 2024). Estas exigencias pueden incrementar la demanda mental y, cuando superan los recursos disponibles del operador, favorecer la aparición de errores, fatiga y disminución del desempeño (Dell’Agnola et al., 2022; Fernández-Rojas et al., 2020). Por ello, comprender y evaluar el estado cognitivo de los operadores resulta relevante para mejorar la seguridad, el desempeño y la toma de decisiones durante tareas complejas.

En la literatura este fenómeno se aborda con términos cercanos: carga cognitiva (cognitive load), originado en la psicología educativa, y carga mental de trabajo (mental workload), propio de la ergonomía y los factores humanos. Ambos describen la relación entre demandas de una tarea y los recursos mentales disponibles del individuo (Paas et al., 2003; Wickens, 2008). Dado que los estudios sobre teleoperación emplean ambos términos de forma indistinta, en esta revisión se utilizan como equivalentes.

Para estudiar este fenómeno se han utilizado diferentes estrategias. Las medidas subjetivas, como el NASA Task Load Index (NASA-TLX), permiten conocer la percepción del operador sobre las demandas de la tarea (Hart & Staveland, 1988), mientras que técnicas fisiológicas y neurofisiológicas, como la electroencefalografía (EEG), registran cambios asociados al esfuerzo mental durante su ejecución (Antonenko et al., 2010). Paralelamente, los entornos simulados ofrecen condiciones controladas, seguras y reproducibles para modificar factores como la dificultad de la tarea, las condiciones ambientales o el diseño de las interfaces (Kaonain et al., 2020). Sin embargo, estas medidas no siempre coinciden: en una tarea de teleoperación robótica, Odoh et al. (2024) encontraron que el desempeño en la tarea distinguía mejor los niveles de carga que la mayoría de los indicadores fisiológicos.

Existen revisiones previas sobre la medición de la carga mental mediante indicadores fisiológicos (Charles & Nixon, 2019) y sobre su evaluación en entornos laborales reales (Diarra et al., 2025); sin embargo, abarcan múltiples dominios y no se centran en teleoperación ni en

el papel de la simulación. Por ello, resulta necesario integrar la evidencia disponible sobre el uso conjunto de medidas subjetivas y fisiológicas en tareas de teleoperación simuladas.

En este contexto, resulta pertinente sintetizar los métodos empleados para estudiar las demandas cognitivas durante la operación remota e identificar las principales tendencias y oportunidades de investigación. Así, la presente revisión se orienta a responder la siguiente pregunta: ¿cómo se ha evaluado la carga cognitiva en tareas de teleoperación robótica desarrolladas en entornos simulados mediante medidas subjetivas y fisiológicas? En correspondencia con esta pregunta, el objetivo de este trabajo es describir cómo se ha evaluado la carga cognitiva en tareas de teleoperación robótica simulada e identificar las principales medidas utilizadas, las tendencias reportadas en la literatura y los vacíos de investigación existentes.

METODOLOGÍA

Se realizó una revisión narrativa de la literatura con el objetivo de identificar estudios que evaluaran la carga cognitiva en tareas de teleoperación robótica desarrolladas en entornos simulados. Se optó por este tipo de revisión debido a la heterogeneidad de las tareas, los simuladores y las medidas empleadas en los estudios, lo que dificulta una síntesis cuantitativa. La búsqueda bibliográfica se efectuó en las bases de datos Scopus, Web of Science, IEEE Xplore, PubMed y Google Scholar, considerando publicaciones disponibles hasta julio de 2026. Los estudios empíricos analizados se publicaron entre 2014 y 2026; también se incluyeron trabajos clásicos ampliamente reconocidos por su relevancia en el área, como el desarrollo original del NASA-TLX (Hart & Staveland, 1988), así como revisiones y trabajos teóricos que sirvieron para contextualizar los resultados.

Para la búsqueda se emplearon términos en inglés relacionados con carga cognitiva, teleoperación y simulación, entre ellos cognitive load, mental workload, teleoperation, remote operation, simulation, virtual reality, EEG, NASA-TLX, physiological measures y human-robot interaction. Estos términos se combinaron mediante operadores booleanos; entre las combinaciones utilizadas se encuentran ("cognitive load" OR "mental workload") AND ("teleoperation" OR "remote operation") AND ("simulation" OR "virtual reality"). Se consideraron artículos de revista y actas de congresos con revisión por pares, publicados en inglés o español.

Como criterios de inclusión, se consideraron estudios empíricos que evaluaran la carga cognitiva del operador en tareas de teleoperación robótica o en tareas simuladas de control remoto o interacción humano-robot con demandas cognitivas comparables, mediante medidas subjetivas, fisiológicas o neurofisiológicas. Se incluyeron investigaciones que emplearan instrumentos como NASA-TLX, EEG, actividad electrodérmica (EDA, por sus siglas en inglés), variabilidad de la frecuencia cardíaca (HRV), pupilometría y seguimiento ocular, así como estudios que analizaran el desempeño del operador en relación con la complejidad de la tarea, las características de la interfaz o las condiciones del entorno simulado. Se excluyeron trabajos centrados exclusivamente en aspectos técnicos de sistemas robóticos que no evaluaran al operador humano, estudios que no midieran la carga cognitiva y registros duplicados.

La selección de los estudios se realizó en dos etapas. En primer lugar, se revisaron los títulos y resúmenes para identificar trabajos potencialmente relacionados con el objetivo de la revisión. Posteriormente, los estudios considerados pertinentes fueron revisados a texto completo para verificar su correspondencia con los criterios establecidos, y 14 cumplieron los criterios de inclusión. La selección fue realizada por los autores y las discrepancias se resolvieron por consenso. De cada trabajo seleccionado se identificaron aspectos como el contexto o tarea de teleoperación, el tipo de entorno o simulador utilizado, las técnicas empleadas para evaluar la carga cognitiva y los principales resultados reportados. Finalmente, la información se organizó temáticamente en tres ejes (medidas subjetivas, indicadores fisiológicos y neurofisiológicos, y evaluación basada en simulación), que corresponden a los apartados de Resultados.

RESULTADOS Y DISCUSIÓN

De los 14 estudios incluidos, 8 abordaron tareas de teleoperación robótica y 6, tareas simuladas afines, como la conducción, el vuelo, la operación de montacargas o el uso de sillas de ruedas (Tabla 1). 12 de ellos se publicaron a partir de 2020, y solo uno, el de Dell'Agnola et al. (2022), se desarrolló en un escenario de búsqueda y rescate. En cuanto a las medidas, seis estudios emplearon el NASA-TLX, cinco el EEG, dos la HRV, uno la EDA y uno la pupilometría y el seguimiento ocular; cuatro combinaron medidas subjetivas y fisiológicas. Tras un apartado que contextualiza la relación entre teleoperación y carga cognitiva, los resultados se presentan en tres ejes: medidas subjetivas, indicadores fisiológicos y neurofisiológicos, y evaluación basada en simulación.

Tabla 1. Características de los estudios incluidos en la revisión

ESTUDIO	TIPO	TAREA O CONTEXTO	MEDIDAS DE CARGA	HALLAZGO PRINCIPAL
Woehrle & Kirchner (2014)	T	Teleoperación robótica demandante con detección de objetivos	EEG (P300)	El P300 puede detectarse en línea durante la teleoperación
Moya et al. (2017)	T	Teleoperación de robot móvil con distintos niveles de dificultad y retardo	EEG (potencia de bandas)	Propuesta de detección de la carga a partir de la potencia de bandas del EEG
Mohanavelu et al. (2020)	A	Vuelo con distintas condiciones de visibilidad	HRV + NASA-TLX + desempeño	Las medidas detectaron cambios en la carga aun con desempeño estable
Shao et al. (2020)a	T	Control de un robot de dos brazos mediante exoesqueleto en modo maestro-esclavo	HRV	Diferencias significativas en la HRV entre dos estados de carga mental
Glaros et al. (2021)	T	Teleoperación de rover en misión lunar	NASA-TLX	Diferencias en la carga percibida; posible influencia del momento del día
Dell'Agnola et al. (2022)	T	Operación de drones en misión de búsqueda y rescate	Respiración, ECG, fotopletimografía y temperatura de la piel + aprendizaje automático	Distinguió carga baja y alta con 87.3 % y 91.2 % de precisión, según el tipo de control
Jiang et al. (2023)	A	Conducción de vehículo	Carga percibida	A mayor realismo, evaluación más representativa de la carga
Nenna et al. (2023)	T	Guiado de un brazo robótico industrial con control por botones o por movimiento	Autorreportes, pupilometría y seguimiento ocular	El control por movimiento mejoró rapidez y precisión y redujo la carga; el tamaño pupilar fue el indicador más robusto
Zoric et al. (2023)	T	Control de brazos antropomórficos	NASA-TLX	Diferencias en la carga percibida entre interfaces

		con distintas interfaces		
Musicant et al. (2024)	T	Teleconducción con distintas perspectivas de cámara	NASA-TLX	La perspectiva elevada redujo la carga y mejoró la seguridad y la eficiencia
Lee & Lee (2025)	A	Colaboración humano-robot en construcción	EDA	Uso de la EDA como indicador de carga cognitiva
Verkennis et al. (2025)	A	Vuelo	EEG (espectral y conectividad) + aprendizaje automático	La conectividad mejoró la clasificación de los niveles de carga
Zahabi et al. (2025)	A	Entrenamiento de operadores de montacargas	NASA-TLX + EEG	Ambas medidas aumentaron con la dificultad de la tarea
Pereira Salgado et al. (2026)	A	Entrenamiento en silla de ruedas	NASA-TLX + parpadeo (EEG)	Las medidas fisiológicas complementan a las subjetivas

Nota: T: teleoperación robótica; A: tarea simulada afín. EEG: electroencefalografía; EDA: actividad electrodérmica; HRV: variabilidad de la frecuencia cardiaca; NASA-TLX: NASA Task Load Index. a Estudio realizado con un robot real; se incluyó por tratarse de teleoperación robótica, conforme a los criterios de inclusión.

Fuente: elaboración propia.

Teleoperación y carga cognitiva

La teleoperación robótica es una modalidad de interacción humano-máquina que permite a un operador controlar dispositivos o sistemas a distancia mediante interfaces de comunicación y control (Jain, 2024). Este tipo de tecnología ha adquirido una gran relevancia debido al avance de la robótica, los sistemas autónomos y las telecomunicaciones, que han hecho posible la ejecución de tareas remotas en entornos donde la presencia humana directa puede resultar complicada, costosa o peligrosa (Khedr et al., 2025). Sus aplicaciones abarcan múltiples áreas, incluyendo la medicina, la exploración espacial, las operaciones industriales, los vehículos submarinos, la defensa y la respuesta ante desastres naturales (Araya-Carvajal et al., 2025).

En el ámbito médico, la teleoperación ha permitido el desarrollo de sistemas de telecirugía asistida por robots capaces de mejorar la precisión de diversos procedimientos quirúrgicos y

facilitar intervenciones remotas especializadas (Yang et al., 2024). De manera similar, en la exploración espacial y submarina, los sistemas teleoperados se utilizan para controlar vehículos y manipuladores robóticos en entornos extremos caracterizados por altas presiones, temperaturas adversas o grandes distancias de comunicación. Asimismo, en contextos industriales y nucleares, la teleoperación resulta fundamental para la manipulación segura de materiales peligrosos y el mantenimiento de infraestructuras en ambientes hostiles (Lopez-Pulgarin et al., 2022).

La teleoperación también desempeña un papel importante en escenarios de emergencia y desastres naturales. Diversos estudios han reportado el uso de vehículos aéreos no tripulados y robots terrestres en tareas de búsqueda, rescate, inspección y evaluación de daños en zonas afectadas por incendios, terremotos e inundaciones (Wu, 2023; Verhagen et al., 2024). En este contexto, los sistemas teleoperados permiten recopilar información crítica en tiempo real y apoyar la toma de decisiones durante situaciones de alto riesgo, lo que reduce la exposición directa de los equipos de rescate.

A pesar de sus ventajas operativas, las tareas de teleoperación representan importantes desafíos cognitivos para los operadores humanos. Durante la operación remota, el usuario debe procesar información proveniente de múltiples fuentes, interpretar estímulos visuales y espaciales en tiempo real, mantener la atención sostenida y responder rápidamente ante cambios del entorno (Wang et al., 2024). Estas exigencias incrementan significativamente la demanda mental de la tarea, especialmente en escenarios dinámicos o complejos, y, cuando exceden los recursos disponibles, aumenta la probabilidad de errores, fatiga mental y disminución del desempeño operativo. Además, la carga mental en teleoperación depende de factores como la complejidad de la tarea, las habilidades individuales del operador y las condiciones del entorno de operación (Shao et al., 2019).

Asimismo, variables como la latencia en la transmisión, la perspectiva de cámara y la calidad visual de las interfaces pueden afectar directamente el desempeño y la carga cognitiva de los operadores (Zunjic, 2015). Los altos niveles de latencia incrementan el tiempo de ejecución de las tareas y aumentan la probabilidad de cometer errores, mientras que una baja frecuencia de actualización visual puede aumentar la dificultad percibida durante la operación remota.

Debido a estas implicaciones, la evaluación de la carga cognitiva en tareas de teleoperación se ha convertido en un área relevante de investigación. Para ello, distintos estudios han empleado

medidas subjetivas y fisiológicas con el objetivo de analizar el estado cognitivo de los operadores durante tareas remotas y simuladas. Asimismo, el uso de entornos virtuales y simuladores ha permitido estudiar estas variables bajo condiciones controladas y reproducibles.

Medidas subjetivas de carga cognitiva

La evaluación de la carga cognitiva puede realizarse mediante diferentes enfoques orientados a estimar el esfuerzo mental requerido durante la ejecución de una tarea. En términos generales, estos métodos pueden clasificarse en medidas subjetivas, medidas fisiológicas o neurofisiológicas y medidas de desempeño (Wang et al., 2024). Las medidas subjetivas se basan en la percepción personal del operador respecto a la dificultad y demanda de la actividad realizada, por lo que proporcionan información relacionada con la experiencia consciente del esfuerzo mental.

Entre las herramientas subjetivas más utilizadas para la evaluación de la carga cognitiva destaca el NASA Task Load Index (NASA-TLX), desarrollado por Hart y Staveland (1988) como una técnica multidimensional para medir la carga de trabajo percibida. Este instrumento parte de la idea de que la carga de trabajo no depende únicamente de la tarea en sí, sino también de la interacción entre el individuo, el entorno y las condiciones bajo las cuales se desarrolla la actividad.

El NASA-TLX evalúa seis dimensiones principales: demanda mental, demanda física, demanda temporal, desempeño, esfuerzo y nivel de frustración. El participante valora cada dimensión en una escala de 0 a 100 y, en la versión original, pondera su importancia relativa mediante 15 comparaciones por pares; a partir de ello se obtiene un índice global de carga percibida. Con frecuencia se emplea también una versión sin ponderación (Raw TLX), que promedia directamente las seis dimensiones (Hart, 2006). Debido a su facilidad de aplicación y flexibilidad, fue el instrumento subjetivo más empleado en los estudios revisados: seis de los 14 lo utilizaron, como medida única o combinado con indicadores fisiológicos (Tabla 1).

Diversas investigaciones han empleado el NASA-TLX para analizar la percepción de carga mental durante tareas de teleoperación. Zoric et al. (2023), por ejemplo, utilizaron esta herramienta para comparar distintas interfaces de teleoperación aplicadas al control de brazos robóticos antropomórficos, con el objetivo de determinar cuál ocasionaba una menor demanda cognitiva y resultaba más adecuada para tareas operativas complejas. Los resultados mostraron

diferencias en la carga cognitiva percibida entre las distintas configuraciones de control, lo que evidencia la influencia de la interfaz sobre el esfuerzo mental del operador.

De manera similar, Musicant et al. (2024) evaluaron la carga mental percibida por operadores durante la teleconducción simulada de un vehículo bajo diferentes perspectivas de cámara. Compararon una vista ubicada a la altura del conductor con una cámara colocada en la parte superior del vehículo. Después de cada sesión de conducción simulada se aplicó el NASA-TLX para estimar la carga cognitiva experimentada por los participantes. Los resultados indicaron que la perspectiva elevada reducía la carga mental percibida y mejoraba aspectos relacionados con la seguridad y la eficiencia operativa.

El NASA-TLX también se ha utilizado para evaluar el efecto de factores propios del operador. Glaros et al. (2021) lo aplicaron durante una misión lunar simulada para analizar la relación entre somnolencia, desempeño y carga de trabajo, mientras que Mohanavelu et al. (2020), Zahabi et al. (2025) y Pereira Salgado et al. (2026) lo combinaron con indicadores fisiológicos, como se describe en los apartados siguientes. En varios de estos estudios, el cuestionario sirvió como referencia para contrastar las medidas fisiológicas.

A pesar de su amplio uso, las medidas subjetivas presentan algunas limitaciones importantes. Al depender de la percepción individual del participante, los resultados pueden verse influenciados por factores como la experiencia previa, el estado emocional o la interpretación personal de la tarea. Asimismo, estas herramientas suelen aplicarse al finalizar la actividad, lo que impide el monitoreo continuo de cambios momentáneos en el estado cognitivo del operador y hace que la valoración dependa del recuerdo de la tarea; aplicarlas durante la ejecución, en cambio, puede interrumpirla. Además, su sensibilidad es limitada: Wang et al. (2024) observaron que la carga global autorreportada no permitía distinguir entre los niveles más bajos de carga. Estas limitaciones han motivado el uso de medidas fisiológicas que ofrezcan un registro continuo y complementario.

Indicadores fisiológicos y neurofisiológicos de carga cognitiva

Además de las medidas subjetivas, la carga cognitiva puede evaluarse mediante indicadores fisiológicos y neurofisiológicos asociados al esfuerzo mental durante la ejecución de una tarea. A diferencia de las herramientas basadas en percepción, estos métodos ofrecen registros continuos que no dependen del autorreporte del operador, por lo que han adquirido gran

relevancia en investigaciones relacionadas con teleoperación e interacción humano-robot. Entre las técnicas más utilizadas destacan la EEG, la actividad EDA, la variabilidad de la HRV, la pupilometría y el seguimiento ocular. Estas herramientas permiten registrar respuestas fisiológicas relacionadas con procesos de atención, memoria de trabajo y control cognitivo (Tabla 2).

Tabla 2. Técnicas para la medición objetiva de la carga cognitiva en teleoperación

TÉCNICA / MÉTODO	VARIABLE EVALUADA	APLICACIÓN EN TELEOPERACIÓN	REFERENCIA
Electroencefalografía (EEG)	Energía de bandas (Delta, Theta, Alpha, Beta)	Teleoperación de robot móvil con distintos niveles de dificultad y retardo	Moya et al., 2017
Actividad electrodermal (EDA)	Conductancia de la piel (activación simpática)	Evaluación de carga en tareas colaborativas con robots	Lee & Lee, 2025
Variabilidad de la frecuencia cardiaca (HRV)	Variación en el tiempo entre latidos del corazón	Carga cognitiva en operación de robot dual-arm	Shao et al., 2020
Pupilometría	Variación del diámetro pupilar	Carga cognitiva en teleoperación robótica en VR	Nenna et al., 2023
Medidas combinadas (Subjetivas + Fisiológicas)	NASA-TLX + EEG	Entrenamiento de operadores de montacargas en realidad virtual	Zahabi et al., 2025

Fuente: Elaboración propia a partir de la literatura revisada.

La electroencefalografía (EEG) es una de las técnicas más utilizadas para evaluar carga cognitiva debido a su capacidad para registrar actividad cerebral en tiempo real. Esta técnica no invasiva mide variaciones eléctricas generadas por la actividad neuronal mediante electrodos colocados sobre el cuero cabelludo, permitiendo detectar cambios asociados al esfuerzo mental durante tareas complejas (Antonenko et al., 2010). El EEG permite estimar la carga mental mediante el análisis de bandas de frecuencia cerebrales y potenciales relacionados con eventos (ERP), los cuales han demostrado utilidad para diferenciar distintos niveles de demanda cognitiva (Brouwer et al., 2012).

Las bandas de frecuencia más estudiadas son delta (0.5–4 Hz), theta (4–8 Hz), alpha (8–13 Hz) y beta (13–30 Hz). De forma consistente, el aumento de la carga cognitiva se asocia con un

incremento de la actividad theta en regiones frontales y una disminución de la actividad alpha en regiones parietales, que refleja la mayor asignación de recursos atencionales a la tarea (Antonenko et al., 2010; Roy et al., 2016); los cambios en las bandas delta y beta son menos consistentes entre estudios. En el contexto de la teleoperación, el análisis de estas bandas permite estimar el estado cognitivo de los operadores durante tareas remotas y dinámicas.

Los potenciales relacionados con eventos (ERP, por sus siglas en inglés) corresponden a pequeñas variaciones eléctricas generadas como respuesta a estímulos específicos. Algunos de estos componentes se relacionan con procesos de atención, evaluación y toma de decisiones, por lo que han sido ampliamente utilizados para estudiar carga cognitiva en interacción humano-máquina (Sur & Sinha, 2009). En la Tabla 3 se presentan los principales componentes ERP, sus latencias aproximadas y las funciones cognitivas con las que se relacionan.

Tabla 3. Principales componentes de los potenciales relacionados con eventos (ERP)

COMPONENTE ERP	LATENCIA APROXIMADA	QUÉ INDICA EN EL CEREBRO	FUNCIÓN / SIGNIFICADO
N100 (N1)	90–200 ms	Detección de estímulos	Aparece cuando el cerebro detecta un estímulo nuevo o inesperado.
P200 (P2)	100–250 ms	Procesamiento perceptivo	Relacionado con el análisis inicial del estímulo.
N200 (N2)	~200 ms	Detección de cambios	Asociado con discriminación de estímulos o conflicto cognitivo.
P300 (P3)	250–400 ms	Atención y evaluación	Indica que el cerebro reconoce y clasifica información relevante.
N400	300–600 ms	Comprensión del significado	Relacionado con el procesamiento semántico del lenguaje.
P600	~600 ms	Procesamiento del lenguaje	Asociado con la estructura sintáctica y comprensión de oraciones.

Fuente: Adaptado de Sur & Sinha (2009).

Entre los ERP, el P300 es uno de los marcadores más utilizados para evaluar carga cognitiva. Este potencial está asociado con procesos de atención y categorización de estímulos, y su amplitud tiende a disminuir conforme aumenta la demanda de la tarea principal, sobre todo cuando se evalúa mediante estímulos de una tarea secundaria, lo que refleja una reducción en

los recursos atencionales disponibles (Ghani et al., 2020). Woehrle y Kirchner (2014) demostraron que el P300 puede detectarse en línea durante tareas complejas de teleoperación robótica mediante EEG, incluso en entornos dinámicos y cognitivamente demandantes.

La variabilidad de la frecuencia cardiaca, obtenida a partir del electrocardiograma, refleja el equilibrio entre la actividad simpática y parasimpática del sistema nervioso autónomo; en general, el aumento de la carga se asocia con una menor variabilidad. Shao et al. (2020) encontraron diferencias significativas en la HRV entre dos niveles de carga mental durante el control de un robot de dos brazos, y Mohanavelu et al. (2020) observaron que índices como SDNN, SD2, VLF y la potencia total diferenciaban las condiciones de vuelo en un simulador de alta fidelidad, mientras que LFnu y HFnu distinguían el efecto de la baja visibilidad y de una tarea cognitiva secundaria.

La actividad electrodérmica mide cambios en la conductancia de la piel controlados por el sistema nervioso simpático, y tiende a aumentar con la demanda cognitiva. Lee y Lee (2025) la emplearon como indicador de carga cognitiva en tareas de colaboración humano-robot en construcción. Por su parte, el diámetro pupilar aumenta con el esfuerzo mental y puede registrarse de forma continua con dispositivos de seguimiento ocular. Nenna et al. (2023) observaron, durante el guiado de un brazo robótico industrial en realidad virtual, que el tamaño pupilar fue el indicador ocular más robusto: se correlacionó con la carga autorreportada y no se vio afectado por el movimiento físico del usuario.

Pese a estas ventajas, los indicadores fisiológicos presentan limitaciones relevantes. Ninguno es específico de la carga cognitiva: la EDA y la HRV también responden al estrés y a la activación emocional, el EEG y las señales cardiacas son sensibles a los artefactos de movimiento, y el diámetro pupilar varía con la iluminación (Charles & Nixon, 2019). Además, la variabilidad entre personas y entre sesiones obliga a normalizar las señales o a entrenar modelos individuales, como hicieron Dell'Agnola et al. (2022). Por ello, estos indicadores suelen interpretarse junto con medidas subjetivas y de desempeño, y no como sustitutos de ellas; de hecho, en una tarea de teleoperación robótica, el desempeño distinguió los niveles de carga mejor que la mayoría de los indicadores fisiológicos (Odoh et al., 2024).

Evaluación de la carga cognitiva basada en simulación en teleoperación

Las simulaciones se han consolidado como una de las principales herramientas para estudiar la carga cognitiva en tareas de teleoperación, ya que permiten recrear escenarios complejos bajo condiciones controladas, seguras y reproducibles. A diferencia de los entornos reales, donde existen limitaciones relacionadas con la seguridad, los costos y la dificultad para controlar las variables experimentales, los entornos virtuales permiten modificar sistemáticamente factores como la complejidad de la tarea, la presencia de obstáculos, las condiciones ambientales, la presión temporal o el diseño de las interfaces, lo que facilita el análisis del comportamiento y del esfuerzo cognitivo de los operadores (Kaonain et al., 2020). Su principal limitación es la validez ecológica: el grado en que la carga observada en un simulador se corresponde con la que se experimenta en una operación real depende del realismo del entorno.


En este sentido, Jiang et al. (2023) analizaron el efecto de la fidelidad del escenario sobre la carga mental percibida en simulaciones de conducción desarrolladas en Unreal Engine, y observaron que los escenarios más realistas favorecían una evaluación más representativa de la carga del conductor. El realismo también puede ampliarse mediante estímulos multisensoriales: Shaw et al. (2019) incorporaron calor y olor a humo a un entorno virtual de evacuación por incendio, aunque su objetivo fue estudiar la toma de decisiones y no la carga cognitiva.

Los entornos simulados también se han convertido en una plataforma adecuada para evaluar la carga cognitiva durante tareas de teleoperación. Glaros et al. (2021) emplearon una simulación en tiempo real para analizar la relación entre la somnolencia, el desempeño y la carga de trabajo de operadores encargados de teleoperar un rover en misiones de exploración lunar. Los resultados evidenciaron diferencias significativas en la percepción de la carga cognitiva medida mediante el cuestionario NASA-TLX, lo que sugiere que factores como el momento del día también pueden influir en el desempeño de los operadores.

En los últimos años también se ha observado una tendencia hacia la integración de medidas subjetivas y fisiológicas dentro de los entornos virtuales. Zahabi et al. (2025), por ejemplo, evaluaron operadores de montacargas en un simulador de realidad virtual utilizando simultáneamente el cuestionario NASA-TLX y señales de EEG, encontrando que ambas medidas aumentaban conforme se incrementaba la dificultad de la tarea. De forma similar, Pereira Salgado et al. (2026) combinaron el NASA-TLX con parámetros de parpadeo obtenidos

a partir de señales EEG durante el entrenamiento en un simulador de silla de ruedas, concluyendo que las medidas fisiológicas complementan la información proporcionada por los cuestionarios subjetivos y permiten una caracterización más completa de la carga cognitiva. En la Figura 1 se sintetiza el proceso general de evaluación de la carga cognitiva en entornos simulados de teleoperación, considerando las condiciones de la tarea y del entorno, así como la integración de medidas subjetivas, fisiológicas y neurofisiológicas.

Figura 1. Evaluación de la carga cognitiva en entornos simulados de teleoperación



Nota: EEG: electroencefalografía; EDA: actividad electrodérmica; HRV: variabilidad de la frecuencia cardiaca; NASA-TLX: NASA Task Load Index.

Fuente: elaboración propia.

El uso de simulaciones también ha favorecido el desarrollo de modelos capaces de estimar automáticamente la carga cognitiva. Verkennis et al. (2025) utilizaron simulaciones de vuelo para entrenar modelos de aprendizaje automático basados en características espectrales y de conectividad del EEG, y la incorporación de la conectividad cerebral mejoró la clasificación de los niveles de carga. En la misma línea, Mohanavelu et al. (2020), cuyo estudio se describió en el apartado anterior, mostraron en un simulador de alta fidelidad que la HRV y el NASA-TLX detectaban cambios en la carga aun cuando el desempeño de los pilotos se mantenía estable.

El único estudio de la muestra desarrollado en un escenario de búsqueda y rescate fue el de Dell'Agnola et al. (2022), quienes registraron la respiración, el electrocardiograma, el fotopletismograma y la temperatura de la piel de operadores que controlaban un dron en un simulador, y entrenaron un modelo de aprendizaje automático que distinguió entre carga baja

y alta con una precisión cercana al 90 %. Otros trabajos han empleado simulaciones de emergencia, como inundaciones (Arshaghi et al., 2026) o incendios (Shaw et al., 2019), pero para estudiar el comportamiento humano y no la carga del operador.

DISCUSIÓN

La literatura revisada evidencia un creciente interés por evaluar la carga cognitiva en tareas de teleoperación debido a su impacto sobre el desempeño y la toma de decisiones de los operadores. En este contexto, el NASA-TLX fue la herramienta subjetiva más utilizada (6 de 14), mientras que la electroencefalografía (EEG) fue la técnica fisiológica predominante (5 de 14). Sin embargo, más allá de su frecuencia de uso, los resultados muestran que estas medidas no siempre coinciden, y esa falta de coincidencia aporta información relevante para interpretar la carga cognitiva.

En varios estudios, las medidas subjetivas y fisiológicas variaron en la misma dirección. Zahabi et al. (2025) observaron que el NASA-TLX y el EEG aumentaban con la dificultad de la tarea, y Nenna et al. (2023) encontraron que el tamaño pupilar se correlacionaba con la carga autorreportada. En otros casos, las medidas se disociaron: Mohanavelu et al. (2020) detectaron cambios en la HRV y en el NASA-TLX mientras el desempeño de los pilotos se mantenía estable, y Wang et al. (2024) observaron que la carga autorreportada no distinguía los niveles bajos de carga que sí detectaban los indicadores fisiológicos. En sentido contrario, Odoh et al. (2024) encontraron que, en una tarea de teleoperación robótica, el desempeño diferenciaba la carga mejor que la mayoría de los indicadores fisiológicos.

Estas discrepancias sugieren que cada tipo de medida captura una faceta distinta de la carga: el autorreporte refleja la demanda percibida; los indicadores fisiológicos, la activación asociada al esfuerzo, y el desempeño, el resultado de la tarea. Un operador puede mantener su desempeño a costa de un mayor esfuerzo, lo que solo se detecta con medidas subjetivas o fisiológicas; a la inversa, la activación fisiológica puede aumentar por estrés sin que cambie la carga cognitiva. Por ello, la evaluación multimodal no es solo una forma de obtener una caracterización más completa, sino una condición para interpretar correctamente cada medida, idealmente incorporando también métricas de desempeño, que no siempre se analizan junto con las demás.

La comparación entre estudios se ve limitada por su heterogeneidad. Las tareas, los métodos para manipular la carga (dificultad, tarea secundaria, visibilidad o tipo de interfaz), las señales registradas y los análisis empleados, desde comparaciones de medias hasta clasificadores de aprendizaje automático, varían considerablemente, lo que coincide con la falta de estandarización señalada en revisiones previas (Charles & Nixon, 2019). Asimismo, solo poco más de la mitad de los estudios abordó tareas de teleoperación en sentido estricto; el resto correspondió a tareas simuladas afines, como el vuelo o la conducción, cuyas demandas son comparables, pero no idénticas. Además, los estudios revisados no contrastaron la carga observada en el simulador con la de operaciones reales, por lo que la transferencia de estos resultados a contextos operativos aún debe confirmarse.

A pesar de estos avances, persisten oportunidades de investigación en escenarios de emergencia y desastre. Dell'Agnola et al. (2022) fue el único estudio de la muestra centrado en búsqueda y rescate, y evaluó la carga solo mediante señales fisiológicas. Estas operaciones combinan presión temporal, incertidumbre, información incompleta y, con frecuencia, comunicaciones degradadas o con latencia, condiciones que pueden incrementar tanto la carga cognitiva como el estrés del operador. Dado que indicadores como la EDA y la HRV responden a ambos, los estudios futuros en estos escenarios deberán emplear diseños que permitan separarlos, por ejemplo, combinando medidas fisiológicas con el NASA-TLX y métricas de desempeño, y manipulando de forma independiente la dificultad de la tarea y las condiciones de riesgo. La simulación resulta especialmente valiosa en este contexto, porque permite reproducir condiciones de desastre que no pueden manipularse experimentalmente en operaciones reales.

Esta revisión presenta algunas limitaciones. Al tratarse de una revisión narrativa, no se evaluó la calidad metodológica de los estudios incluidos ni se documentó el proceso de selección con el detalle de una revisión sistemática, por lo que no puede descartarse un sesgo de selección. Además, la muestra es reducida, incluye estudios de tareas afines a la teleoperación y se limitó a publicaciones en inglés y español. Futuras revisiones sistemáticas o de alcance podrían ampliar la búsqueda y evaluar con mayor rigor la calidad y la consistencia de la evidencia.

CONCLUSIÓN

La presente revisión describió cómo se ha evaluado la carga cognitiva en tareas de teleoperación robótica desarrolladas en entornos simulados. El NASA-TLX y el EEG fueron

las medidas subjetiva y fisiológica más empleadas, y un número creciente de estudios las combina con otros indicadores, como la HRV, la EDA o la pupilometría.

La evidencia revisada indica que estas medidas no son intercambiables: el autorreporte, los indicadores fisiológicos y el desempeño capturan facetas distintas de la carga y pueden disociarse. Por ello, la combinación de medidas subjetivas, fisiológicas y de desempeño constituye el enfoque más sólido para caracterizar el esfuerzo cognitivo de los operadores e interpretar correctamente cada indicador.

Asimismo, aunque las simulaciones han demostrado ser una herramienta eficaz para estudiar la carga cognitiva, la heterogeneidad de las tareas y los métodos, así como la falta de contraste con operaciones reales, limitan la generalización de los resultados. Finalmente, se identificó una escasez de estudios en escenarios de emergencia y desastre, particularmente en operaciones de búsqueda y rescate, donde la carga cognitiva coexiste con niveles elevados de estrés. Investigar estos contextos con diseños que permitan distinguir ambos fenómenos puede contribuir al desarrollo de sistemas de teleoperación adaptativos y de estrategias de entrenamiento orientadas a mejorar el desempeño y la seguridad de los operadores.

REFERENCIAS

- Antonenko, P., Paas, F., Grabner, R., & van Gog, T. (2010). Using electroencephalography to measure cognitive load. *Educational Psychology Review*, 22, 425–438. <https://doi.org/10.1007/s10648-010-9130-y>
- Araya Carvajal, K., Ruiz Marin, M., & Ramos Marquez, Á. (2025). Robots teleoperados en la industria y los servicios: Una revisión bibliográfica sistematizada. *BIOTECH & ENGINEERING Untels*, 5(1), 183–184.
- Arshaghi, B., Lawson, G., Briganti, R., & Siebers, P.-O. (2026). Human decision-making in crowds in a virtual flood scenario. *Natural Hazards and Earth System Sciences*, 26, 981–1000. <https://doi.org/10.5194/nhess-26-981-2026>
- Brouwer, A.-M., Hogervorst, M. A., van Erp, J. B. F., Heffelaar, T., Zimmerman, P. H., & Oostenveld, R. (2012). Estimating workload using EEG spectral power and ERPs in the n-back task. *Journal of Neural Engineering*, 9(4), 045008. <https://doi.org/10.1088/1741-2560/9/4/045008>

- Charles, R. L., & Nixon, J. (2019). Measuring mental workload using physiological measures: A systematic review. *Applied Ergonomics*, 74, 221–232.
<https://doi.org/10.1016/j.apergo.2018.08.028>
- Dell'Agnola, F., Jao, P.-K., Arza, A., Chavarriaga, R., Millán, J. del R., Floreano, D., & Atienza, D. (2022). Machine-learning based monitoring of cognitive workload in rescue missions with drones. *IEEE Journal of Biomedical and Health Informatics*.
<https://doi.org/10.1109/JBHI.2022.3186625>
- Diarra, M., Theurel, J., & Paty, B. (2025). Systematic review of neurophysiological assessment techniques and metrics for mental workload evaluation in real-world settings. *Frontiers in neuroergonomics*, 6, 1584736.
<https://doi.org/10.3389/fnrgo.2025.1584736>
- Fernandez Rojas, R., Debie, E., Fidock, J., Barlow, M., Kasmarik, K., Anavatti, S., Garratt, M., & Abbass, H. (2020). Electroencephalographic workload indicators during teleoperation of an unmanned aerial vehicle shepherding a swarm of unmanned ground vehicles in contested environments. *Frontiers in Neuroscience*, 14, Article 40.
<https://doi.org/10.3389/fnins.2020.00040>
- Ghani, U., Signal, N., Niazi, I., & Taylor, D. (2020). ERP based measures of cognitive workload: A review. *Neuroscience & Biobehavioral Reviews*.
<https://doi.org/10.1016/j.neubiorev.2020.07.020>
- Glaros, Z., Carvalho, R. E., & Flynn-Evans, E. E. (2021). An evaluation of sleepiness, performance, and workload among operators during a real-time reactive telerobotic lunar mission simulation. *Human Factors*.
<https://doi.org/10.1177/00187208211056756>
- Hart, S. G. (2006). NASA-Task Load Index (NASA-TLX); 20 years later. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 50(9), 904–908.
<https://doi.org/10.1177/154193120605000909>
- Hart, S. G., & Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. In P. A. Hancock & N. Meshkati (Eds.), *Human mental workload* (pp. 139–183). Elsevier Science Publishers B.V.

- Jain, M. (2024). Teleoperated robots: Bridging the gap between human intelligence and remote operations. *International Journal of Innovative Research in Science, Engineering and Technology*, 13(9), 16314–16327. <https://doi.org/10.15680/IJIRSET.2024.1309049>
- Jiang, H., Mizobuchi, S., & Chignell, M. (2023). Scenario fidelity and perceived driver mental workload: Can workload assessment be crowdsourced? In *Proceedings of the 13th International Conference on Advances in Information Technology (IAIT 2023)*. Association for Computing Machinery. <https://doi.org/10.1145/3628454.3628458>
- Kaonain, T. E., Abdul Rahman, M. A., Mohammed Ariff, M. H., & Mondal, K. (2020). A simulated risk assessment of human-robot interaction in the domestic environment. *International Journal of Robotics and Automation*, 9(4), 300–310. <https://doi.org/10.11591/ijra.v9i4.pp300-310>
- Khedr, M., Le, Q. D., & Yang, E. (2025). Teleoperation control for robotic systems in hazardous environments: Overview and challenges. In *2025 30th International Conference on Automation and Computing (ICAC)*. IEEE. <https://doi.org/10.1109/ICAC65379.2025.11196301>
- Lee, S., & Lee, B. (2025). Electrodermal activity as an indicator of cognitive load for human-robot collaboration in construction. In *Advances in Information Technology in Civil and Building Engineering* (pp. 374–382). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-87364-5_31
- Lopez Pulgarin, E. J., Tokatli, O., Burroughes, G., & Herrmann, G. (2022). Assessing tele-manipulation systems using task performance for glovebox operations. *Frontiers in Robotics and AI*, 9, 932538. <https://doi.org/10.3389/frobt.2022.932538>
- Mohanavelu, K., Poonguzhali, S., Ravi, D., Singh, P. K., Mahajabin, M., Ramachandran, K., Singh, U. K., & Jayaraman, S. (2020). Cognitive workload analysis of fighter aircraft pilots in flight simulator environment. *Defence Science Journal*, 70(2), 131–139. <https://doi.org/10.14429/dsj.70.14539>
- Moya, V., Slawiński, E., Mut, V., & Couto, E. H. M. (2017). Workload detection based on EEG device for teleoperation of a mobile robot. In *2017 XVII Workshop on Information*

Processing and Control (RPIC) (pp. 1–6). IEEE.
<https://doi.org/10.23919/RPIC.2017.8211636>

Musicant, O., Botzer, A., & Richmond-Hacham, B. (2024). *Safety, efficiency, and mental workload in simulated teledriving of a vehicle as functions of camera viewpoint*. *Sensors*, 24(18), 6134. <https://doi.org/10.3390/s24186134>

Nenna, F., Zanardi, D., & Gamberini, L. (2023). *Enhanced interactivity in VR-based telerobotics: An eye-tracking investigation of human performance and workload*. *International Journal of Human-Computer Studies*, 177, 103079. <https://doi.org/10.1016/j.ijhcs.2023.103079>

Odoh, G., Landowska, A., Crowe, E. M., Benali, K., Cobb, S., Wilson, M. L., Maior, H. A., & Kucukyilmaz, A. (2024). *Performance metrics outperform physiological indicators in robotic teleoperation workload assessment*. *Scientific Reports*, 14. <https://doi.org/10.1038/s41598-024-82112-4>

Paas, F., Tuovinen, J. E., Tabbers, H., & Van Gerven, P. W. M. (2003). *Cognitive load measurement as a means to advance cognitive load theory*. *Educational Psychologist*, 38(1), 63–71.

Pereira Salgado, D., Roque Martins, F., Abreu Rosa de Sá, A., Flynnn, R., Murray, N., & Lázaro Martins Naves, E. (2026). *EEG-based cognitive load estimation during the use of a virtual wheelchair simulator*. *Frontiers in Signal Processing*, 6, 1691777. <https://doi.org/10.3389/frsip.2026.1691777>

Roy, R. N., Charbonnier, S., Campagne, A., & Bonnet, S. (2016). *Efficient mental workload estimation using task-independent EEG features*. *Journal of Neural Engineering*, 13(2), 026019. <https://doi.org/10.1088/1741-2560/13/2/026019>

Shao, S., Zhou, Q., & Liu, Z. (2019). *Mental workload characteristics of manipulator teleoperators with different spatial cognitive abilities*. *International Journal of Advanced Robotic Systems*, 16(6), 1–10. <https://doi.org/10.1177/1729881419888042>

- Shao, S., Wang, T., Wang, Y., Su, Y., Song, C., & Yao, C. (2020). Research of HRV as a measure of mental workload in human and dual-arm robot interaction. *Electronics*, 9(12), 2174. <https://doi.org/10.3390/electronics9122174>
- Shaw, E., Roper, T., Nilsson, T., Lawson, G., Cobb, S. V. G., & Miller, D. (2019). The heat is on: Exploring user behaviour in a multisensory virtual environment for fire evacuation. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems* (Article 626, pp. 1–13). Association for Computing Machinery. <https://doi.org/10.1145/3290605.3300856>
- Sur, S., & Sinha, V. K. (2009). Event-related potential: An overview. *Industrial Psychiatry Journal*, 18(1), 70–73. <https://doi.org/10.4103/0972-6748.57865>
- Verhagen, R. S., Neerincx, M. A., & Tielman, M. L. (2024). Meaningful human control and variable autonomy in human-robot teams for firefighting. *Frontiers in Robotics and AI*, 11, 1352601. <https://doi.org/10.3389/frobt.2024.1323980>
- Verkennis, B., van Weelden, E., Marogna, F. L., Alimardani, M., Wiltshire, T. J., & Louwerse, M. M. (2025). Predicting workload in virtual flight simulations using EEG spectral and connectivity features. In *2025 IEEE International Conference on Artificial Intelligence and eXtended and Virtual Reality (AIxVR)*. IEEE. <https://doi.org/10.1109/AIxVR63409.2025.00019>
- Wang, J., Stevens, C., Bennett, W., & Yu, D. (2024). Granular estimation of user cognitive workload using multi-modal physiological sensors. *Frontiers in Neuroergonomics*, 5, 1292627. <https://doi.org/10.3389/fnrgo.2024.1292627>
- Wickens, C. D. (2008). Multiple resources and mental workload. *Human Factors*, 50(3), 449–455. <https://doi.org/10.1518/001872008X288394>
- Woehrle, H., & Kirchner, E. A. (2014). Online detection of P300 related target recognition processes during a demanding teleoperation task: Classifier transfer for the detection of missed targets. In *Proceedings of the International Conference on Physiological Computing Systems (PhyCS-2014)* (pp. 13–19). SCITEPRESS. <https://doi.org/10.5220/0004724600130019>

- Wu, M. (2023). *Robotics applications in natural hazards. Highlights in Science, Engineering and Technology*, 43, 273–279.
- Yang, J., Barragan, J. A., Farrow, J. M., Sundaram, C. P., Wachs, J. P., & Yu, D. (2024). *An adaptive human-robotic interaction architecture for augmenting surgery performance using real-time workload sensing—Demonstration of a semi-autonomous suction tool. Human Factors*, 66(4), 1081–1102. <https://doi.org/10.1177/00187208221129940>
- Zahabi, S. J. N., Islam, M. S., Kim, S., Lau, N., Nussbaum, M. A., & Lim, S. (2025). *Task difficulty in virtual reality forklift training can be assessed using normalized EEG measurements. International Journal of Industrial Ergonomics*, 107, 103718. <https://doi.org/10.1016/j.ergon.2025.103718>
- Zoric, F., Suarez, A., Vasiljevic, G., Orsag, M., Kovacic, Z., & Ollero, A. (2023). *Performance comparison of teleoperation interfaces for ultra-lightweight anthropomorphic arms. In 2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE.*
- Zunjic, A. (2015). *Performance and workload of operators in a human-telerobot system. International Journal of Behavioral Research & Psychology*, 3(2e), 1–3. <https://doi.org/10.19070/2332-3000-150004e>

© Los autores. Este artículo se publica en Prisma ODS bajo la Licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0). Esto permite el uso, distribución y reproducción en cualquier medio, incluidos fines comerciales, siempre que se otorgue la atribución adecuada a los autores y a la fuente original.



 : <https://doi.org/10.65011/prismaods.v5.i5.375>

Cómo citar este artículo (APA 7ª edición):

Vargas Solis, G., Juárez Morales, R., Baldivia Noyola, P., Palacios Pérez, H. B., & Parra Abarca, J. (2026). Evaluación de la Carga Cognitiva en Teleoperación Robótica Simulada. *Prisma ODS: Revista Multidisciplinaria Sobre Desarrollo Sostenible*, 5(5), 651-675. <https://doi.org/10.65011/prismaods.v5.i5.375>