

Análisis de aplicabilidad de la arquitectura cognitiva CLEAR en mejora de procesos industriales

Arévalo, J.^{a,*}, Bretón, J.^b, Pérez de la Parte, M.^b, Sáenz-Diez, J.C.^b, Flor, F.J.^c, Jiménez, E.^b

^a Departamento de Ingeniería, Universidad Pública de Navarra, Campus de Tudela, Av. Tarazona, s/n, 31500 Tudela, Navarra, España.

^b Escuela Técnica Superior de Ingeniería Industrial, Universidad de La Rioja, C/ S. José de Calasanz, nº31, 26004, Logroño, España.

^c Escuela Superior de Ingeniería y Tecnología, Universidad Internacional de La Rioja, Av. de la Paz, 137, 26006 Logroño, La Rioja, España.

To cite this article: Arévalo, J., Bretón, J., Pérez de la Parte, M., Sáenz-Diez, J.C., Flor, F.J., Jiménez, E., 2025. Análisis de aplicabilidad de la arquitectura cognitiva CLEAR en mejora de procesos industriales. XX Simposio CEA de Control Inteligente, Huelva (Spain), 2025.

Resumen

Este trabajo analiza la aplicabilidad de la arquitectura cognitiva CLEAR (*Cognitive Layered Engine for Advanced Reasoning*) a procesos industriales, con especial atención a su capacidad para implementar consciencia de acceso y consciencia de monitoreo computacional. CLEAR se presenta como un sistema híbrido, distribuido y metacognitivo que integra modelos de lenguaje, grafos de conocimiento y agentes supervisores para tareas de diagnóstico, mantenimiento predictivo y toma de decisiones autónoma. A través de una descripción detallada de su arquitectura en capas, su integración con ontologías industriales como IOF-Maint y un marco metodológico de validación funcional, se demuestra su potencial para actuar como núcleo cognitivo de sistemas industriales inteligentes. Se ofrece asimismo una comparativa con otras arquitecturas cognitivas y sistemas de control inteligente, destacando las ventajas de CLEAR en términos de adaptación, explicabilidad y cognición evolutiva aplicada. Como caso de estudio se presenta la metodología empleada en el mantenimiento industrial inteligente de un sistema de producción de acero.

Palabras clave: Sistemas de producción inteligentes, Arquitecturas cognitivas, Mantenimiento inteligente, Producción industrial inteligente, Consciencia computacional, Grafos de conocimiento, Metacognición artificial, Espacio de trabajo global.

Applicability Analysis of CLEAR Cognitive Architecture to Industrial Process Improvement

Abstract

This work analyzes the applicability of the CLEAR (Cognitive Layered Engine for Advanced Reasoning) cognitive architecture to industrial processes, with particular attention to its ability to implement access consciousness and computational monitoring consciousness. CLEAR is presented as a hybrid, distributed, and metacognitive system that integrates language models, knowledge graphs, and supervisory agents for tasks such as diagnosis, predictive maintenance, and autonomous decision-making. Through a detailed description of its layered architecture, its integration with industrial ontologies such as IOF-Maint, and a functional validation framework, the paper demonstrates its potential to act as the cognitive core of intelligent industrial systems. A comparison with other cognitive architectures and intelligent control systems is also provided, highlighting CLEAR's advantages in adaptability, explainability, and applied evolutionary cognition. As a case study, the methodology applied to intelligent industrial maintenance in a steel production system is presented.

Keywords: Intelligent production systems, Cognitive architectures, Smart maintenance, Smart industrial production, Computational consciousness, Knowledge graphs, Artificial metacognition, Global workspace.

1. Introducción

Desde la perspectiva de la ingeniería y las aplicaciones de la Inteligencia Artificial (IA), un sistema cognitivo puede definirse como una arquitectura artificial capaz de percibir su

entorno, representarlo internamente, razonar sobre dicha representación y actuar en consecuencia mediante procesos adaptativos, distribuidos y frecuentemente integrados con aprendizaje automático. Estos sistemas buscan emular ciertas propiedades de la cognición humana —como la percepción, la

memoria, la planificación y la toma de decisiones— con el fin de operar de manera autónoma en entornos complejos y no estructurados (Newell and Simon, 1976). Diferentes tipos de sistemas cognitivos, con un mayor o menor grado de emulación de diferentes aspectos de la cognición humana, han sido ampliamente utilizados con éxito durante décadas en toda clase de aplicaciones (Kotseruba and Tsotsos, 2016).

En el seminal artículo “On A Confusion About a Function of Consciousness”, Ned Block introdujo una distinción que ha adquirido estatus canónico en la teoría de sistemas cognitivos. Identificó dos modalidades de referencia:

1. Consciencia fenoménica (*phenomenal consciousness* o *P-consciousness*), que alude a la vivencia cualitativa de los estados mentales, como el “qué se siente” al experimentar un color, un sonido, un pensamiento al que aludía Nagel (1974), que enlaza con el problema difícil de la consciencia que enunció Chalmers (1995).

2. Consciencia de acceso (*access consciousness* o *A-consciousness*), entendida como la disponibilidad de representaciones mentales para procesos de razonamiento, control de la acción y articulación verbal. Un estado es *A-conscious* si cumple con los siguientes criterios funcionales:

a. Promiscuidad inferencial: El contenido del estado puede ser utilizado como premisa en múltiples procesos de razonamiento.

b. Disponibilidad para la acción racional: El contenido guía o modula conductas voluntarias y finalistas.

c. Disponibilidad para el lenguaje: El contenido puede ser verbalizado o reportado racionalmente.

A las dos mencionadas, se añade una que atañe el autorreconocimiento como entidad diferenciada (autoconsciencia), y otra que es categoría funcional denominada consciencia de monitoreo o metacognitiva, que consiste en la capacidad de un sistema para representar y supervisar sus propios estados internos. Esta última forma es a menudo subsumida bajo el concepto de *higher-order thought* o pensamiento de orden superior, central en los sistemas con capacidad de autovigilancia. La consciencia de monitoreo implica por lo tanto la existencia de estados cuyo contenido es otro estado del sistema.

En el contexto del diseño de arquitecturas cognitivas artificiales, sólo la consciencia de acceso y la consciencia de monitoreo son computacionalmente factibles, al poder ser formalizadas como procesos de disponibilidad informacional y de representación introspectiva, respectivamente. La consciencia fenoménica, en cambio, implica propiedades cualitativas que se estudia admitan una traducción computacional operativa (Goertzel *et al.*, 2023), mientras que la autoconsciencia, si bien puede ser parcialmente modelada, no tiene aún una implementación consensuada ni funcional en entornos artificiales complejos.

La arquitectura cognitiva CLEAR incorpora explícitamente ambos tipos de consciencia computable: de acceso y de monitoreo. La primera se implementa mediante la integración de Modelos de Lenguaje de Gran Tamaño con grafos de conocimiento dinámicos que actualizan el estado informativo del entorno operativo (espacio global de trabajo). La segunda, a través de agentes metacognitivos encargados de evaluar el rendimiento interno de los módulos de razonamiento, sus incertidumbres y su fiabilidad. Esta doble capacidad,

informacional y reflexiva, confiere a CLEAR una idoneidad singular para entornos industriales en los que se requiere diagnóstico autónomo, mantenimiento predictivo y reconfiguración adaptativa del sistema.

2. Arquitectura cognitiva CLEAR

2.1 Características principales de CLEAR

La arquitectura CLEAR constituye una propuesta híbrida que integra capacidades de representación semántica, inferencia basada en grafos y generación lingüística contextualizada, con el objetivo de implementar consciencia de acceso y monitoreo computacional en entornos industriales. Es un marco computacional diseñado para modelar el razonamiento adaptativo y contextual de agentes inteligentes, especialmente en entornos dinámicos, y ha sido utilizada principalmente en ámbitos como la robótica cognitiva y la inteligencia artificial aplicada a entornos complejos. Sus características principales son:

- Jerarquía por capas contextuales
- Razonamiento adaptativo
- Integración de módulos funcionales
- Aplicación en agentes autónomos
- Inspiración cognitiva

2.2 Modelo de capas

CLEAR constituye una propuesta híbrida que integra capacidades de representación semántica, inferencia basada en grafos y generación lingüística contextualizada, con el objetivo de implementar consciencia de acceso y monitoreo computacional en entornos industriales. Se estructura en cuatro capas o estratos funcionales que permiten transformar datos sensoriales brutos en conocimiento estructurado y decisiones verificables, conformando un sistema cognitivo artificial distribuido, reflexivo y adaptativo.

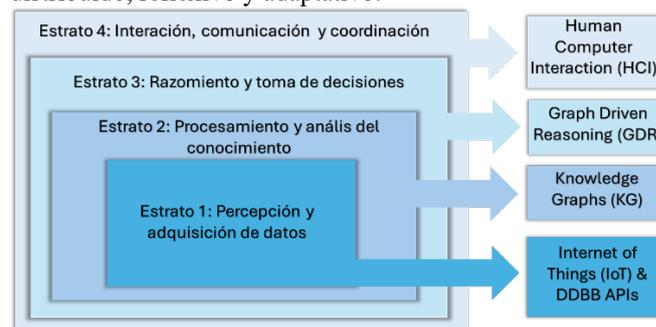


Figura 1: Modelo de capas de CLEAR

En la *Capa 1*, dedicada a la percepción, adquisición y coordinación, se integran sensores IoT de vibración, temperatura, gases y otros parámetros industriales, junto con mecanismos de consulta a bases de datos técnicas. El procesamiento de extracción e integración de datos se realiza mediante *bots* especializados que normalizan, filtran y contextualizan los *inputs*. En entornos industriales, esta capa permite una monitorización continua del estado operativo de equipos mediante la adquisición de datos en tiempo real.

La *Capa 2* está orientada al análisis y estructuración del conocimiento. Los datos preprocesados son enriquecidos y

analizados mediante técnicas estadísticas y patrones de detección, para posteriormente ser representados en Grafos de Conocimiento (KG, de *Knowledge Graphs*) dinámicos que actúan como memoria estructurada del sistema. Los *bots* de esta capa aseguran que el conocimiento incorporado sea verificable, coherente y accesible para el razonamiento ulterior. La capacidad de detectar anomalías o correlaciones operativas en datos históricos la hace muy útil en el mantenimiento predictivo.

En la *Capa 3*, dedicada al razonamiento y toma de decisiones, se integran modelos predictivos, simulaciones de escenarios y sistemas de Inferencia Guiada por Grafos (*IGG*). De esta forma el sistema es capaz de generar hipótesis operativas, anticipar fallos y evaluar el impacto de distintas estrategias de intervención, con base en información actualizada y validada. Esto permite seleccionar acciones correctivas o preventivas con base en simulaciones cognitivamente informadas, mejorando la fiabilidad y seguridad en entornos industriales complejos.

Finalmente, la *Capa 4* abarca la interacción y coordinación del sistema. A través de módulos de interacción en lenguaje natural y mecanismos de explicación inteligible (*XAI*, de *Explainable Artificial Intelligence*) (Gunning et al., 2019), se facilita una relación transparente entre operadores humanos y sistema cognitivo. Simultáneamente, agentes de meta-control supervisan el estado de los procesos internos, evalúan el rendimiento global y orquestan las funciones cognitivas de cada capa. Este mecanismo metacognitivo emula una forma de consciencia de monitoreo, permitiendo al sistema detectar inconsistencias, autodiagnosticarse y ajustar su estrategia de razonamiento.

2.3 Comparativa con otras arquitecturas cognitivas

Existen otras arquitecturas cognitivas ampliamente conocidas, como ACT-R, SOAR o CLARION, cuya comparativa con CLEAR se muestra en la Tabla 1.

Tabla 1: Comparación entre arquitecturas cognitivas

Característica	CLEAR	SOAR	ACT-R	CLARION
Inspiración cognitiva	Moderada (por capas y contexto)	Alta (símbolos, reglas, chunking)	Alta (módulos cerebrales simulados)	Alta (dualidad implícito/explicito)
Representación del conocimiento	Jerárquica y contextual	Basada en reglas de producción	Declarativo (chunks) y procedimental (producciones)	Implícita (red neuronal) y explícita (reglas)
Aprendizaje	Adaptativo, basado en contexto y experiencia	Mediante chunking y refuerzo	Mediante refuerzo y experiencia	Mediante refuerzo, imitación y reglas
Contexto y percepción	Fuerte (estructurado en capas contextuales)	Limitado (necesita integración externa)	Moderado (modelado del foco de atención)	Moderado, pero adaptable
Integración de módulos	Alta, modular por capas funcionales	Buena, pero centrada en toma de decisiones	Alta en tareas cognitivas puras	Muy buena, especialmente en tareas mixtas
Entornos dinámicos	Muy adecuada (fuerte en adaptación y contexto)	Razonable	Limitada, más centrada en experimentación controlada	Buena, aunque más difícil de configurar
Aplicación típica	Robótica cognitiva, IA adaptativa, sistemas en tiempo real	Simulación cognitiva, planificación y resolución de problemas	Psicología cognitiva experimental	Modelado de emociones, motivación, comportamiento humano

2.4 Comparativa de los sistemas cognitivos con los sistemas de control inteligente convencionales

Diversos trabajos tratan sobre la comparativa entre los sistemas cognitivos y los sistemas de control inteligente convencionales, tales como Faghihi et al. (2023), Jarrahi et al. (2022) o Kotseruba and Tsotsos (2018), de los que se puede extraer la información que resume la Tabla 2, si bien la comparativa está realizada desde el punto de vista de los sistemas cognitivos.

Tabla 2: Comparativa de los sistemas cognitivos con los sistemas de control inteligente convencionales

Característica	Sistema Cognitivo	Sistema de Control Inteligente Convencional
Capacidad de Aprendizaje	Sí, aprende y se adapta continuamente	Limitado, requiere reprogramación manual
Manejo de Incertidumbre	Alto, puede trabajar con datos ambiguos	Bajo, depende de datos estructurados
Interacción con Humanos	Natural, usa lenguaje y contexto	Limitada, interfaces tradicionales
Adaptabilidad al Entorno	Alta, ajusta estrategias según contexto	Baja, basado en reglas fijas
Procesamiento de Lenguaje Natural	Sí	No
Toma de Decisiones	Basada en razonamiento contextual	Basada en algoritmos predefinidos
Ejemplo de Aplicación	Asistentes virtuales, diagnóstico médico	Control de procesos industriales
Inspiración en Neurociencia	Sí, modelos internos similares al cerebro	No, modelos matemáticos clásicos
Evolución con la Experiencia	Sí, mejora con el uso	No, permanece estático
Requiere Programación Manual	No necesariamente	Sí, para ajustes y mejoras

3. Espacio de Trabajo Global y uso de Grafos de Conocimiento

Desde la perspectiva del mantenimiento industrial, CLEAR habilita un sistema capaz de detectar fallos inminentes, interpretando su posible causa contextualizada, y proponiendo rutas alternativas de mantenimiento con una comunicación de decisiones con trazabilidad completa. Esta arquitectura permite implementar sistemas con consciencia funcional aplicada, donde el flujo informativo se mantiene coherente desde la percepción sensorial hasta la decisión final, incluyendo reflexión sobre su propia validez y explicabilidad.

CLEAR implementa un ciclo operativo iterativo que modela el flujo completo de procesamiento cognitivo desde la adquisición de datos hasta la actualización del conocimiento. Este bucle está formalmente inspirado en teorías de la cognición distribuida y en el modelo del Espacio de Trabajo Global (GW, de *Global Workspace*), adaptado para su implementación computacional mediante KG y estructuras cognitivas multiagente.

El GW es un concepto central en neurociencia cognitiva y fue formalizado computacionalmente por Baars (1988) como una arquitectura de memoria funcional compartida. En términos computacionales, actúa como un espacio donde diferentes agentes cognitivos intercambian información significativa, acceden a conocimiento compartido y sincronizan procesos heterogéneos.

En CLEAR, esta función de espacio de trabajo global es implementada directamente mediante un KG dinámico, que actúa simultáneamente como:

- Memoria semántica de largo plazo.
- Entorno estructurado de representación situacional.
- Plataforma de interoperabilidad cognitiva entre agentes.

Este grafo permite que cada agente acceda a porciones del conocimiento global, modifique nodos y aristas, incorpore inferencias, detecte inconsistencias y construya narrativas explicativas.

3.1 Ventajas del uso de KG en el GW

La incorporación de KG en CLEAR refuerza la coherencia estructural del sistema cognitivo y optimiza la interoperabilidad entre agentes. Las propiedades que hacen de esta tecnología una base idónea para la representación y gestión de información industrial compleja son:

1. Representación estructurada y relacional.
2. Escalabilidad semántica.
3. Acceso distribuido y concurrencia.
4. Inferencia multimodal.
5. Trazabilidad y explicabilidad.

En el contexto del mantenimiento industrial, esta implementación del GW mediante un KG permite integrar múltiples fuentes y dominios de conocimiento, y dotar al sistema de una memoria operativa coherente, evolutiva y cognitivamente activa. Así, el bucle CLEAR se convierte en un ciclo de aprendizaje y acción que permite a la arquitectura mantener, revisar y optimizar su modelo del entorno de manera autónoma, reflexiva y transparente.

3.2 Bucle cognitivo CLEAR como base de cognición evolutiva

El esquema mostrado en la Figura 2 representa el bucle cognitivo de la arquitectura CLEAR, un ciclo operativo iterativo que modela el flujo completo de procesamiento cognitivo desde la adquisición de datos hasta la actualización del conocimiento. Este flujo cíclico constituye la base de la cognición evolutiva de CLEAR.

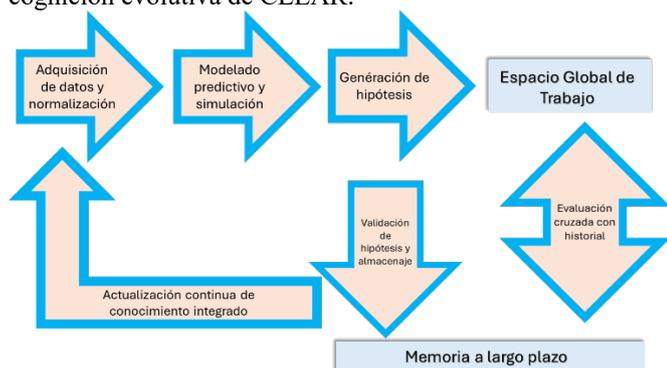


Figura 2. Bucle cognitivo CLEAR como base de cognición evolutiva

4. CLEAR aplicada al mantenimiento industrial

Aplicado al mantenimiento industrial, este marco permite que CLEAR acceda a la información crítica sobre el estado de los equipos en tiempo real, vigilando su propia interpretación de los datos, y evaluando si sus decisiones están fundamentadas o requieren intervención humana. La implementación de estas capacidades en un entorno cognitivo distribuido, por medio de agentes intercomunicados,

proporciona una plataforma avanzada para la gestión inteligente del ciclo de vida de activos industriales, tal y como a continuación veremos.

4.1 Análisis de aplicación de consciencia de acceso y monitoreo en mantenimiento industrial

En los sistemas industriales avanzados, el mantenimiento ya no puede ser entendido como un conjunto de intervenciones periódicas estáticas, sino como un proceso adaptativo, dinámico y cognoscente. Esta transformación requiere incorporar mecanismos que permitan tanto representar el estado de los activos industriales, como reflexionar sobre la calidad de dicha representación, evaluando de manera continua la fiabilidad de los diagnósticos y la pertinencia de las acciones derivadas. Es en este contexto donde las capacidades computacionales de consciencia de acceso y consciencia de monitoreo, implementadas por la arquitectura CLEAR, resultan fundamentales.

La consciencia de acceso puede definirse aquí como la capacidad del sistema para mantener disponible —de forma estructurada, coherente y contextualizada— la información que alimenta sus procesos de inferencia, planificación y acción de mantenimiento. En CLEAR, esta función se materializa a través del KG activo, que actúa como espacio de trabajo global y memoria dinámica compartida por los distintos agentes cognitivos. Este grafo no sólo almacena datos de sensores (vibración, temperatura, presión, etc.), sino que los relaciona con representaciones semánticas de componentes, históricos de fallos, protocolos técnicos y reglas de dependencia funcional.

Por ejemplo, ante la detección de una desviación en la frecuencia de vibración de un motor, CLEAR accede al grafo para identificar el subsistema afectado, los componentes relacionados, las fallas históricamente asociadas con esa señal, y los procedimientos de inspección disponibles. Esta disponibilidad transversal del conocimiento permite que los agentes razonadores generen hipótesis causales, evalúen la probabilidad de fallo y propongan intervenciones contextualizadas. Dicha operación implica tanto la consulta de datos, como una instancia de razonamiento situado, estructurado sobre una representación activa del entorno físico y lógico del sistema.

En paralelo, la consciencia de monitoreo dota al sistema de una segunda capa de procesamiento: la metacognición. CLEAR incorpora agentes supervisores que monitorizan constantemente el estado epistemológico del sistema en cuanto a tal: validez de las inferencias, consistencia de los datos, precisión de los modelos activos, fiabilidad de las fuentes, recursos disponibles y nivel de incertidumbre asociado a cada hipótesis generada. Este metanivel no genera en exclusiva contenido primario, dado que evalúa y regula el funcionamiento de los módulos cognitivos responsables del razonamiento, el aprendizaje y la acción.

Esta capacidad de autovigilancia permite detectar, por ejemplo, que una hipótesis diagnóstica presenta una confianza estadística inferior a un umbral definido; o que las fuentes de datos están generando ruido incoherente; o que dos rutas inferenciales conducen a conclusiones contradictorias. En cualquiera de estos casos, el sistema puede reconfigurar sus procesos, suspender la emisión de alertas, solicitar

confirmación externa o activar modelos de respaldo. En términos funcionales, el sistema actúa no sólo sobre el entorno físico que monitoriza, sino también sobre su propia cognición.

En el ámbito del mantenimiento predictivo, esta dualidad cognitiva se traduce en un comportamiento inteligente que permite anticipar fallos antes de que se manifiesten, reduciendo tiempos de inactividad y optimizando la vida útil de los componentes. A diferencia de los sistemas tradicionales que se basan en umbrales fijos o reglas predefinidas, CLEAR adapta continuamente sus modelos de predicción en función de la evidencia observada, actualiza su KG y evalúa su propia capacidad diagnóstica. El resultado es un sistema que aprende, razona y reflexiona sobre su desempeño operativo.

4.2 Marco metodológico

La validación funcional de una arquitectura cognitiva orientada al mantenimiento industrial debe superar la mera verificación de sus componentes individuales, para evaluar su comportamiento integrado en condiciones operativas realistas. En consecuencia, se propone un marco metodológico que combina simulación de entornos industriales, instrumentación digital, gemelos virtuales y medición sistemática de indicadores de desempeño, con el objetivo de demostrar que CLEAR es capaz de ejecutar procesos de diagnóstico, predicción y toma de decisiones con consciencia de acceso y monitoreo computacionalmente efectiva.

El planteamiento metodológico se articula en cinco módulos funcionales:

1. Modelado industrial y generación del entorno simulado.
2. Construcción de la base ontológica adaptada y despliegue inicial del grafo de conocimiento.
3. Integración de los agentes CLEAR y sincronización de capas cognitivas.
4. Diseño de experimentos de diagnóstico y predicción.
5. Métricas de evaluación y validación del comportamiento cognitivo.

La validación incluye un componente comparativo, enfrentando los resultados obtenidos por CLEAR con los de sistemas expertos tradicionales (basados en reglas), sistemas basados en aprendizaje automático sin semántica estructurada, y plataformas de mantenimiento predictivo de propósito general. Esta comparación permitirá determinar en qué medida las capacidades de consciencia de acceso y monitoreo implementadas por CLEAR aportan mejoras tangibles en precisión, adaptabilidad y explicabilidad frente a arquitecturas no cognitivas.

Además, se contempla la interacción con usuarios humanos: técnicos y operadores industriales realizarán consultas en lenguaje natural, solicitarán explicaciones sobre inferencias y evaluarán la transparencia del sistema. El grado de aceptación, comprensión y validación subjetiva por parte de los operadores se integra como indicador cualitativo de la eficacia comunicativa del sistema y de su idoneidad en entornos colaborativos humano-máquina, en base al estándar de Análisis de Modos de Fallo y Efectos (AMFE) (Bluvband and Grabov, 2009).

En conjunto, este marco metodológico busca demostrar empíricamente que la arquitectura CLEAR opera de forma autónoma y estructurada, incorporando además mecanismos internos de verificación y reflexión sobre su propio

funcionamiento, lo cual la distingue funcionalmente como una arquitectura cognitiva con consciencia funcional aplicada.

4.3 Implementación de CLEAR en entornos industriales: Integración de CLEAR con IOF-Maint

La implementación de CLEAR en entornos industriales exige una representación explícita, coherente y extensible del conocimiento técnico inherente al dominio. Este requerimiento epistemológico y funcional justifica el uso de una ontología formal (Gruber, 1995) del mantenimiento industrial, concebida como un artefacto de ingeniería que estructura y regula la interacción semántica entre agentes cognitivos, sensores, bases de datos, modelos predictivos y operadores humanos.

La ontología mínima en la que CLEAR se apoya a la hora de estructurar las tareas a acometer ha de incluir al menos los términos relacionados con el mantenimiento (Tabla 3) junto con los referidos a equipamiento, materiales, planes y otros requisitos del proceso de mantenimiento (Tabla 4):

Tabla 3: Ontología mínima de CLEAR empleada para mantenimiento industrial (resumida)

N.º	Término ontológico
1	Efecto de fallo
2	Proceso de fallo
...	
19	Actividad de mantenimiento
20	Actividad de mantenimiento de apoyo

Tabla 4: Términos ontológicos del proceso de mantenimiento (resumida)

N.º	Término ontológico
1	Elemento material mantenible
2	Artefacto material
...	
12	Expresión de valor medido

Con estas premisas, la ontología *IOF-Maintenance Reference Ontology* (IOF-Maint) (Hodkiewicz et al., 2024) se presenta como una solución idónea para su integración con la arquitectura CLEAR, al proporcionar una estructura formal, modular y reconocida internacionalmente para la representación semántica del dominio del mantenimiento industrial. Desarrollada por la *Industrial Ontologies Foundry*, IOF-Maint se encuentra alineada con la *Basic Formal Ontology* (BFO), y ha sido construida a partir de múltiples casos de uso industriales, garantizando su aplicabilidad práctica y su compatibilidad con sistemas de Gestión de Mantenimiento Asistido por Ordenador (GMAO), AMFE, procedimientos técnicos y registros de órdenes de trabajo,...

Además, la ontología IOF-Maint ha sido validada en múltiples escenarios industriales reales (manufactura, transporte, petroquímica), lo que proporciona garantías adicionales para su adopción como modelo semántico en arquitecturas cognitivas. Su integración en CLEAR permite representar con precisión los activos, procesos y fallos de una planta industrial, razonando sobre ellos con trazabilidad lógica, explicabilidad en lenguaje natural y capacidad de aprendizaje continuo.

En consecuencia, la fusión entre CLEAR e IOF-Maint constituye una convergencia estratégica entre cognición artificial y estandarización semántica, habilitando sistemas de mantenimiento inteligente que razonan sobre datos técnicos de forma reflexiva, interoperable y formalmente validada.

4.4 Límites actuales y proyecciones para sistemas con consciencia funcional

La implementación efectiva de sistemas artificiales dotados de consciencia funcional —esto es, capacidad computacional para acceder a representaciones internas estructuradas, y monitorear el estado de sus propios procesos cognitivos— plantea una serie de problemáticas que trascienden la disponibilidad de herramientas tecnológicas. En el caso de la arquitectura CLEAR, éstas se sitúan en la intersección entre la ingeniería cognitiva distribuida, la lógica semántica formal y las exigencias operativas del entorno industrial.

Uno de los límites principales reside en la complejidad computacional de la integración ontológica en tiempo real. Aunque CLEAR es compatible con ontologías expresadas en OWL DL (de *Ontology Web Language - Description Logic*) y razonadores basados en lógica descriptiva, el razonamiento completo sobre KG dinámicos puede incurrir en costes temporales significativos si no se implementan estrategias de particionado semántico, razonamiento incremental y cacheo de inferencias frecuentes. Esta restricción afecta directamente a la escalabilidad de la arquitectura en entornos donde se requiere latencia baja y respuesta inmediata ante eventos críticos (por ejemplo, detección de fallo súbito en un compresor rotativo).

No obstante, estas limitaciones no invalidan la viabilidad funcional del paradigma, sino que delimitan el espacio de desarrollo futuro.

Finalmente, debe mencionarse la proyección organizativa que implica la adopción de CLEAR en entornos industriales reales. Su despliegue requiere no sólo validación técnica, sino también cambios en la cultura operativa: desde la aceptación de decisiones generadas por sistemas explicables pero no deterministas, hasta la formación de operadores capaces de interpretar inferencias estructuradas, interactuar con agentes lingüísticos y co-gobernar la actualización semántica del sistema cognitivo. Esta transición hacia una industria cognitivamente aumentada exige una articulación entre tecnología, epistemología aplicada y pedagogía organizacional.

En definitiva, CLEAR inaugura una línea prometedora hacia la implementación de agentes técnicos que no sólo actúan con autonomía, sino que comprenden, evalúan y justifican su propia conducta, constituyéndose en una herramienta estratégica para la transición hacia una industria cognitivamente aumentada.

5. Conclusiones

La arquitectura cognitiva CLEAR representa un avance significativo en la aplicación de sistemas con consciencia funcional al ámbito del mantenimiento industrial inteligente. Al integrar consciencia de acceso y monitoreo, grafos de conocimiento dinámicos y agentes cognitivos distribuidos, CLEAR ofrece una solución adaptable, explicable y evolutiva para la toma de decisiones autónoma en entornos industriales complejos.

Los resultados del marco metodológico propuesto muestran que CLEAR no sólo detecta y diagnostica fallos con precisión, sino que también reflexiona sobre la validez de sus propios

procesos inferenciales. Su capacidad para integrar ontologías industriales formales, como IOF-Maint, refuerza la interoperabilidad semántica y la trazabilidad de sus decisiones, consolidando un entorno cognitivo industrial con altos estándares de transparencia y eficiencia.

En definitiva, CLEAR inaugura una línea prometedora hacia la implementación de agentes técnicos que no sólo actúan con autonomía, sino que comprenden, evalúan y justifican su propia conducta, constituyéndose en una herramienta estratégica para la transición hacia una industria cognitivamente aumentada.

Las metodologías propuestas en este trabajo están siendo aplicadas en el proyecto europeo iSteel sobre una importante siderurgia, con resultados hasta el momento muy satisfactorios.

Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo de la Comisión Europea por el proyecto iSteel (*Remote expert virtual system enhancing human management capabilities that favors preservation, transfer, and continuous evolution of knowledge for steelmaking operations*) <https://www.isteel-expert.eu/>.

Referencias

- Baars, B. J., 1988. *A cognitive theory of consciousness*. Cambridge University Press, Cambridge.
- Bluvband, Z., Grabov, P., 2009. Failure analysis of FMEA. *Proceedings - Annual Reliability and Maintainability Symposium 2009*, 344–347. DOI: 10.1109/RAMS.2009.4914700
- Chalmers, D., 1995. Facing up to the problem of consciousness. [En línea]. Disponible en: <https://philpapers.org/rec/CHAFUT> [Accedido: 3 mayo 2025]
- Faghihi, U., Hudson, J., Franklin, S., 2023. A cognitive architecture for artificial agents based on Global Workspace Theory. *Informatics* 14, 32. DOI: 10.3390/informatics14010032
- Goertzel, B., et al., 2023. OpenCog Hyperon: A framework for AGI at the human level and beyond. *arXiv preprint arXiv:2310.18318*. DOI: 10.48550/arXiv.2310.18318
- Gruber, T. R., 1995. Toward principles for the design of ontologies used for knowledge sharing. *International Journal of Human-Computer Studies* 43, 907–928. DOI: 10.1006/ijhc.1995.1081
- Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., Yang, G. Z., 2019. XAI—Explainable Artificial Intelligence. *Science Robotics* 4, art. no. eaay7120. DOI: 10.1126/scirobotics.aay7120
- Hodkiewicz, M., Woods, C., Selway, M., Stumptner, M., 2024. Iof-maint: Modular maintenance ontology. *Data Collection*, abril 2024. DOI: 10.26182/chzp-vs60
- Jarrahi, M. H., Sutherland, W., Nelson, S. B., Sawyer, S., 2022. Cognitive automation. *ACM Computing Surveys* (preprint), 1–28. DOI: 10.13140/RG.2.2.31772.08325 (DOI provisional en ResearchGate)
- Kotscheruba, I., Tsotsos, J. K., 2018. Comparative study of cognitive architectures. *Journal of Artificial General Intelligence* 9, 1–42. DOI: 10.2478/jagi-2018-0001
- Kotscheruba, I., Tsotsos, J. K., 2016. A review of 40 years of cognitive architecture research: Core cognitive abilities and practical applications. *arXiv preprint arXiv:1610.08602*. DOI: 10.48550/arXiv.1610.08602
- Nagel, T., 1974. What is it like to be a bat? *The Philosophical Review* 83, 435–450. DOI: 10.2307/2183914
- Newell, A., Simon, H. A., 1976. Computer science as empirical inquiry: Symbols and search. *Communications of the ACM* 19, 113–126. DOI: 10.1145/360018.360022