

GEMELOS DIGITALES DE TÚNELES DE CARRETERAS: IA Y SIMULACION AVANZADA PARA GESTION DE EMERGENCIAS

Benjamín Bentura¹, David Ciprés², José Ignacio Águila¹, David Díez²

¹NEXIO INGENIERIA 2024, Zaragoza, España, bbentura@nexioingenieria.com

²INSTITUTO TECNOLOGICO DE ARAGON, Zaragoza, España, dcipres@ita.es

Resumen

Los túneles de carretera constituyen infraestructuras complejas cuya gestión operacional exige garantizar condiciones de seguridad bajo escenarios altamente variables y, en ocasiones, extremos. Los sistemas convencionales de control se basan en algoritmos deterministas definidos en fase de diseño, lo que limita su capacidad de adaptación a condiciones reales.

Este trabajo presenta la arquitectura y fundamentos metodológicos de la capa de simulación y aprendizaje desarrollada en el marco del proyecto TWIN TUNNEL 5.0. Dicha capa integra modelos físico-numéricos de alta fidelidad basados en dinámica de fluidos computacional con modelos de orden reducido capaces de ser ejecutados en tiempo real.

Sobre esta base, se implementan algoritmos de inteligencia artificial, incluyendo aprendizaje supervisado, no supervisado y reforzado, orientados a la predicción de escenarios y la optimización adaptativa de sistemas críticos como la ventilación. La combinación de simulación multi-agente, fluidodinámica y aprendizaje automático permite la transición desde un enfoque reactivo hacia un modelo de gestión predictiva, incrementando la eficiencia energética y la resiliencia ante emergencias.

Palabras Clave: gemelo digital, CFD, simulación multi-agente, modelos de orden reducido, aprendizaje reforzado

1 Introducción

Los túneles de carretera presentan un comportamiento altamente no lineal y dependiente de múltiples variables exógenas e internas, incluyendo condiciones meteorológicas, características del tráfico y estado de los sistemas de explotación. En este contexto, los sistemas tradicionales de control basados en reglas predefinidas muestran limitaciones significativas para gestionar escenarios dinámicos, especialmente en situaciones de emergencia.

La adopción del paradigma de gemelo digital permite abordar esta problemática mediante la integración de modelos físicos, datos en tiempo real y capacidades de predicción. A diferencia de los modelos digitales estáticos, el gemelo digital incorpora un flujo continuo de datos que permite la actualización dinámica del estado del sistema y la simulación de escenarios futuros [1].

El presente trabajo se centra en la capa de simulación y aprendizaje, responsable de modelizar el comportamiento del túnel y extraer conocimiento a partir de los datos disponibles, constituyendo el núcleo funcional del sistema.

2 Arquitectura de la capa de simulación y aprendizaje

La arquitectura propuesta se estructura en torno a un enfoque modular que combina:

- Modelos simulación virtuales (multi-agente y fluido dinámicos)
- Modelos de Orden Reducido
- Algoritmos de inteligencia artificial
- Integración con plataformas IoT y data lake

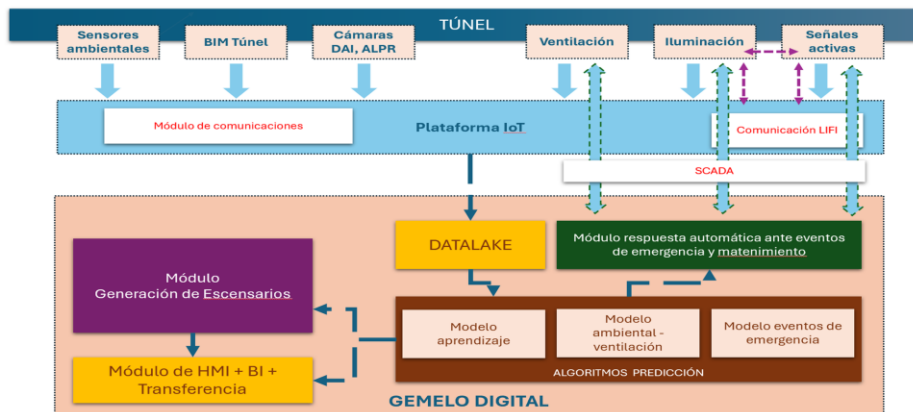


Figura 1. Arquitectura del Gemelo Digital

El flujo de información se basa en la adquisición de datos mediante sensores distribuidos, su almacenamiento en un repositorio estructurado y su explotación mediante modelos predictivos. Este enfoque permite tanto la simulación prospectiva como la adaptación continua del sistema [2].

Uno de los elementos clave es el módulo de generación de escenarios, que permite explorar el comportamiento del sistema bajo distintas configuraciones operativas y condiciones de contorno, habilitando análisis de sensibilidad y evaluación de riesgos.

3 Modelos de simulación del entorno del túnel

3.1 Modelización mediante dinámica de fluidos computacional

La modelización del comportamiento ambiental del túnel se realiza mediante técnicas de dinámica de fluidos computacional (CFD), basadas en la resolución numérica de las ecuaciones de Navier–Stokes y ecuaciones de transporte asociadas.

Estos modelos permiten caracterizar con elevado nivel de detalle:

- Campos de velocidad y presión del flujo

- Distribución de temperatura y humedad
- Transporte y dispersión de contaminantes
- Evolución del humo en escenarios de incendio

El uso de CFD ha sido ampliamente validado en el análisis de ventilación en túneles, especialmente en situaciones de incendio y dispersión de partículas [3].

No obstante, su elevado coste computacional limita su aplicabilidad en entornos operativos en tiempo real.

3.2 Modelos de orden reducido (ROM)

Para garantizar la viabilidad operativa, se implementan modelos de orden reducido (Reduced Order Models, ROM), que aproximan el comportamiento del modelo CFD mediante técnicas de reducción del espacio de estados.

El procedimiento metodológico se basa en:

1. Definición de un diseño de experimentos (DoE) para generar múltiples simulaciones CFD
2. Aplicación de técnicas de reducción (e.g., descomposición en modos propios, proyección de Galerkin)
3. Construcción de un modelo surrogate capaz de reproducir la dinámica relevante

Estos modelos permiten reducir significativamente el tiempo de cálculo, manteniendo una precisión adecuada para la toma de decisiones en tiempo real [4].

3.3 Sensor virtual ambiental

La combinación de CFD y ROM permite la creación de un sensor virtual capaz de inferir variables de estado no directamente medidas, tales como:

- Concentraciones locales de contaminantes
- Distribución espacial de temperatura
- Nivel de visibilidad en presencia de humo

Este enfoque reduce la necesidad de sensorización física intensiva y mejora la capacidad de observabilidad del sistema.

3.4 Modelo multi-agente para evacuación de emergencias

El proyecto incorpora un modelo multi-agente que reproduce virtualmente el comportamiento del túnel para simular los tiempos de evacuación en situaciones de emergencia. El modelo contempla diversos escenarios —desde un incendio en el túnel hasta una emisión masiva de contaminantes, entre otras intervenciones— y analiza las pautas de reacción de distintos tipos de vehículos según las características de sus ocupantes.

Estos modelos permiten cuantificar con precisión el impacto de las distintas medidas de seguridad y soluciones de diseño sobre los tiempos de evacuación, proporcionando criterios objetivos para optimizar los protocolos de respuesta ante emergencias.

4 Capa de aprendizaje e inteligencia artificial

4.1 Modelado mediante aprendizaje automático

La capa de aprendizaje incorpora distintos paradigmas de machine learning para capturar relaciones no lineales entre variables del sistema:

- Modelos supervisados para predicción de variables continuas
- Algoritmos no supervisados para detección de anomalías
- Redes neuronales profundas para modelado de dinámicas complejas

Estos modelos se entrenan con datos históricos y simulaciones generadas, permitiendo generalizar el comportamiento del túnel en condiciones no observadas previamente [5].

4.2 Aprendizaje reforzado para optimización operativa

El uso de aprendizaje reforzado (RL) permite formular el problema de control del túnel como un proceso de decisión secuencial, en el que el agente aprende una política óptima mediante interacción con el entorno simulado.

En este contexto:

- El estado incluye variables ambientales y operativas
- Las acciones corresponden a configuraciones de sistemas (ventilación, señalización)
- La función de recompensa integra criterios de seguridad, eficiencia energética y confort

Este enfoque permite optimizar estrategias de control adaptativas frente a entornos inciertos [6].

4.3 Aprendizaje continuo y adaptación del modelo

El gemelo digital incorpora un mecanismo de actualización continua basado en la comparación entre predicciones y datos reales, permitiendo:

- Calibración dinámica de modelos
- Reducción de incertidumbre
- Adaptación a cambios estructurales del sistema

Este proceso es crítico para garantizar la robustez del sistema a lo largo del tiempo.

5 Aplicación a la ventilación predictiva

5.1 Limitaciones del control convencional

Los sistemas de ventilación en túneles suelen diseñarse bajo condiciones conservadoras, con estrategias fijas basadas en escenarios tipo. Esto puede derivar en:

- Sobredimensionamiento del sistema
- Ineficiencias energéticas
- Respuestas subóptimas en situaciones reales

5.2 Estrategias de ventilación basadas en simulación e IA

La integración de modelos CFD/ROM con algoritmos de aprendizaje permite:

- Predecir la evolución temporal de contaminantes
- Determinar la activación óptima de ventiladores
- Ajustar dinámicamente el caudal de ventilación

En escenarios de incendio, se mejora la gestión del humo evitando fenómenos de desestratificación y optimizando las condiciones de evacuación.

6 Discusión

El enfoque propuesto representa un cambio significativo respecto a los sistemas convencionales, al integrar:

- Modelización física de alta fidelidad
- Reducción de complejidad computacional
- Capacidad de aprendizaje adaptativo

Esto permite trasladar herramientas propias del diseño a la operación del túnel, habilitando capacidades de simulación en tiempo real y toma de decisiones basada en datos.

7 Conclusiones

La capa de simulación y aprendizaje del sistema desarrollado constituye un avance relevante en la gestión inteligente de infraestructuras críticas.

Entre sus principales contribuciones destacan:

- Integración de modelos CFD y ROM para simulación en tiempo real
- Aplicación de modelos multi-agente e inteligencia artificial a la operación del túnel y gestión de emergencias
- Implementación de aprendizaje reforzado para optimización de control
- Desarrollo de sensores virtuales para estimación de variables críticas

Este enfoque proporciona una base sólida para el desarrollo de sistemas de gestión predictiva en túneles y otras infraestructuras complejas.

8 Referencias

- [1] Lu, Y., et al. (2020). Digital twin-driven smart manufacturing. *Journal of Manufacturing Systems*.
- [2] Smarsly, K., & Tauscher, E. (2015). BIM-based digital twins. *Automation in Construction*.
- [3] Liu, Y. (2018). Numerical simulation of tunnel ventilation. *Tunnelling and Underground Space Technology*.
- [4] Vermesi, I. (2017). Reduced-order modeling in tunnel fire simulation. *Fire Safety Journal*.
- [5] Schneider, R., et al. (2018). Machine learning in infrastructure systems. *Structural Health Monitoring*.
- [6] Sutton, R. S., & Barto, A. (2018). *Reinforcement Learning: An Introduction*. MIT Press.
- [7] PIARC (2019). *Road tunnels: vehicle emissions and air demand for ventilation*.