

Simuladores físicos en realidad mixta mediante IA

Quercus Hernández¹, Alberto Badías², Francisco Chinesta³, Elías Cueto¹

¹ Applied Mechanics and Bioengineering (AMB)

ESI Group Chair. Aragon Institute of Engineering Research (I3A)

Universidad de Zaragoza, Mariano Esquillor s/n, 50018, Zaragoza, Spain.

Tel. +34-976762707, e-mail: quercus@unizar.es

² Universidad Politécnica de Madrid (UPM)

³ ENSAM (ParisTech)

Resumen

El objetivo de este trabajo es desarrollar herramientas de simulación en tiempo real en el contexto de la realidad aumentada. Para ello, se hace uso de los algoritmos de inteligencia artificial desarrollados en trabajos previos [1] que aseguran la consistencia física de los resultados.

Introducción

El avance de nuevas herramientas como la inteligencia artificial o las tecnologías inmersivas abren un mundo de posibilidades y oportunidades en la ingeniería tradicional. Hace décadas, el concepto de gemelo digital (*digital twin*) supuso un considerable ahorro de recursos económicos en ingeniería y pruebas experimentales gracias a las herramientas modernas de simulación. De la misma manera, el uso de inteligencia artificial puede ayudar a acelerar las técnicas clásicas hasta conseguir simulaciones en tiempo real, habilitando el uso de realidad mixta en cálculos de ingeniería, agilizando el diseño y permitiendo estudios de problemas inversos.

Con la reciente revolución de la inteligencia artificial, numerosos trabajos han demostrado que las redes neuronales profundas (*deep neural networks*) son capaces de resolver problemas extremadamente complejos en el ámbito del procesamiento de lenguaje natural (*ChatGPT*), gráficos por ordenador (*NeRF*) o visión por computador (*Superglue*).

Sin embargo, en el caso de los simuladores en ingeniería, la inteligencia artificial ha tenido un impacto limitado porque las soluciones requieren de una serie de condiciones físicas y matemáticas muy restrictivas (por ejemplo, conservación de energía, masa, momento, etc.) que no son garantizadas mediante la inteligencia artificial convencional. Dichas restricciones garantizan la consistencia y robustez de las predicciones, y son cruciales para que su uso sea apto para diseños serios de ingeniería. En

trabajos previos [1], se demostró cómo incorporando ciertos sesgos inductivos (*inductive biases*) en el aprendizaje, se pueden aprender simuladores basados en redes neuronales que no solo satisfacen las leyes físicas de forma consistente, sino que también son muy rápidas, logrando evaluación en tiempo real.

El objetivo de este trabajo es utilizar dichos algoritmos para desarrollar una herramienta de realidad aumentada para interacción en tiempo real de sólidos deformables no lineales.

Metodología

Las predicciones se basan en la imposición de un sesgo inductivo físico (metripléctico) y otro geométrico. Dicha arquitectura se utiliza en conjunto con un sistema de visión que permite interacción en tiempo real con sólidos virtuales.

Sesgo metripléctico

Las predicciones se realizan mediante el aprendizaje de la estructura GENERIC [2] del sistema dinámico. Dicha estructura divide al sistema en dos contribuciones distintas: una conservativa, descrita por la mecánica Hamiltoniana, y otra disipativa, de tal forma que la evolución del vector de estados de un sistema (\mathbf{z}) queda determinado por:

$$\frac{d\mathbf{z}}{dt} = \mathbf{L} \frac{\partial E}{\partial \mathbf{z}} + \mathbf{M} \frac{\partial S}{\partial \mathbf{z}}.$$

Las matrices \mathbf{L} y \mathbf{M} codifican la relación entre el vector de estados \mathbf{z} y la energía E y entropía S del sistema respectivamente. De esta forma se garantiza la consistencia termodinámica de los resultados, cumpliendo con la primera y segunda ley de la termodinámica.

Sesgo geométrico

La arquitectura de red utilizada para aprender el sistema dinámico está específicamente diseñada para

explotar las características geométricas del dominio discretizado. Utilizamos un tipo de red neuronal basada en grafos de tipo *message passing*, las cuales incluyen simetrías (invarianzas de permutación y traslación) que aumentan la capacidad de generalización y reducen el consumo de datos. Esta es la base del *geometric deep learning* [3], una generalización de las redes neuronales tradicionales a datos desestructurados.

Sistema de visión

Para la aplicación de realidad aumentada, se ha utilizado una cámara estéreo de la compañía *Stereolabs*, que permite calcular un mapa de profundidad además de la imagen RGB de la escena. La interacción se realiza con las manos del usuario, que son detectadas por un sistema de detección de manos también basado en inteligencia artificial de la compañía *MediaPipe*.

El renderizado de la solución se realiza en una pantalla de ordenador, pero podría implementarse de forma directa en unas gafas de realidad virtual o aumentada. La implementación de los *shaders* se ha realizado en OpenGL, incluyendo un modelo básico de iluminación Phong y efecto de z-buffer para distinguir profundidad entre el sólido virtual renderizado y los objetos reales de la escena.

Resultados

Se han realizado dos pruebas para demostrar la robustez de la aplicación final, ambos en el contexto de simulación de sólidos. El primero es la interacción de dos vigas prismáticas viscoelásticas y la segunda de una geometría más compleja (modelo *Stanford bunny*) con más puntos de carga.

En la Figura 1 se muestran dos capturas de pantalla de ambos casos. Como se puede observar, la simulación en tiempo real permite ver información

adicional en código de colores que de otra forma sería imposible de ver, como el tensor de tensiones o deformaciones.

El uso de simulaciones tan rápidas permite que ambas demos superen holgadamente los 30 *frames* por segundo requeridos para ser considerados en tiempo real. Los vídeos completos, junto con el código y bases de datos se pueden encontrar en la publicación [4].

Conclusiones

En este trabajo se demuestra cómo es posible desarrollar simulaciones en tiempo real y físicamente consistentes para aplicaciones inmersivas. El uso de los sesgos inductivos correctos permite la inclusión de principios físicos bien conocidos en las herramientas más potentes de aprendizaje automático, permitiendo simulaciones en tiempo real adecuadas para su uso en la ingeniería del futuro.

REFERENCIAS

- [1]. HERNANDEZ, Q., BADIAS, D., CHINESTA, F. and CUETO, E., 2022. Thermodynamics-informed graph neural networks. *IEEE Transactions on Artificial Intelligence*.
- [2]. GRMELA, M. and ÖTTINGER, H.C., 1997. Dynamics and thermodynamics of complex fluids. I. Development of a general formalism. *Physical Review E*, 56(6), p.6620.
- [3]. BRONSTEIN, M. M., BRUNA, J., LECUN, Y., SZLAM, A., and VANDERGHEYNST, P., 2017. Geometric deep learning: going beyond euclidean data. *IEEE Signal Processing Magazine*, 34(4), 18-42.
- [4]. HERNANDEZ, Q., BADIAS, D., CHINESTA, F. and CUETO, E., 2023. Thermodynamics-informed neural networks for physically realistic mixed reality. *Computer Methods in Applied Mechanics and Engineering*.




Figura 1. Modelos de realidad aumentada y simulación en tiempo real.