

HACIA UN CIENTÍFICO DIGITAL

Q. Hernández^{1*}, A. Badías¹, D. González¹, F. Chinesta², E. Cueto¹¹ Instituto de Investigación en Ingeniería de Aragón (I3A), Universidad de Zaragoza² PIMM Lab, Arts et Metiers Institute of Technology*email: quercus@unizar.es

Instituto Universitario de Investigación
en Ingeniería de Aragón
Universidad Zaragoza



Universidad
Zaragoza

INTRODUCCIÓN

- La modelización de sistemas físicos es fundamental en una amplia variedad de disciplinas, tanto a nivel científico como empresarial, para predecir su futura evolución en el tiempo y poder tomar decisiones en base a esa información.
- Sin embargo, ciertos fenómenos son especialmente difíciles de modelar con fórmulas matemáticas exactas:
 - Materiales viscoelásticos
 - Fluidos no-Newtonianos
- Para resolver este problema, en las últimas décadas se han desarrollado técnicas basadas en datos (*data-driven*) que se aprovechan de los crecientes avances informáticos en gestión de datos para aprender los modelos directamente de observaciones y no depender de un modelo matemático cerrado.
- En concreto, las redes neuronales profundas (*deep neural networks*) han conseguido resultados excelentes en problemas tradicionalmente muy difíciles de resolver, entre ellos las simulaciones físicas.
- En el contexto de la predicción de física, la mayoría requieren de un conocimiento previo de las ecuaciones que gobiernan el sistema [1] o están restringidos a sistemas conservativos [2].

OBJETIVOS

- El objetivo de este trabajo es desarrollar un tipo de red neuronal capaz de predecir la evolución temporal de un sistema arbitrario (es decir, un integrador) sin saber a priori sus ecuaciones e incluyendo fenómenos de disipación.
- Las predicciones de esta red neuronal satisfacen las primeras leyes de la termodinámica:
 - Conservación de energía
 - Desigualdad de la entropía
- Esta nueva formulación se ha aplicado con dos ejemplos de validación en el ámbito de la mecánica de sólidos y fluidos, incluyendo tanto efectos conservativos como de disipación.

METODOLOGÍA

- Formulación GENERIC [3] de un sistema físico:

$$\mathbf{z}: \text{Vector de estados} \rightarrow \frac{d\mathbf{z}}{dt} = \mathbf{L} \frac{\partial E}{\partial \mathbf{z}} + \mathbf{M} \frac{\partial S}{\partial \mathbf{z}}$$

E : Energía
 L : Matrix de Poisson (Efectos conservativos)
 S : Entropía
 M : Matrix de fricción (Efectos disipativos)


- Red neuronal GENERIC (Structure-preserving neural network, SPNN [4]):

$$\mathcal{L}_{SPNN} = \underbrace{\lambda_d \|\mathbf{z}_{t+1}^{net} - \mathbf{z}_{t+1}^{GT}\|_2^2}_{\text{Error de integración}} + \underbrace{\left\| \mathbf{L} \frac{\partial S}{\partial \mathbf{z}} \right\|_2^2 + \left\| \mathbf{M} \frac{\partial E}{\partial \mathbf{z}} \right\|_2^2}_{\text{Condiciones de degeneración}} + \underbrace{\lambda_r \|\mathbf{w}\|_2^2}_{\text{Regularizador}}$$

- Reducción de dimensionalidad (Sparse Autoencoder, SAE [5]):


$$\mathcal{L}_{SAE} = \underbrace{\lambda_d \|\mathbf{x}_t^{net} - \mathbf{x}_t^{GT}\|_2^2}_{\text{Error de reconstrucción}} + \underbrace{\lambda_r \|\mathbf{z}_t\|_1}_{\text{Regularizador sparse}}$$

- Algoritmo de integración completo:




RESULTADOS

- Péndulo doble termoelástico:



- Flujo de Couette de fluido viscoelástico:



CONCLUSIONES

- La red neuronal GENERIC es capaz de aprender la dinámica de los ejemplos propuestos a partir de datos, sin necesidad de conocer previamente las ecuaciones que gobiernan el sistema.
- Las restricciones de la red aseguran que las estimaciones sean consistentes con las leyes de la termodinámica.
- El método es capaz de identificar los fenómenos conservativos y disipativos de un sistema físico.
- En caso de que el sistema tenga una alta dimensionalidad, el autoencoder es capaz de detectar la dimensionalidad efectiva del modelo reducido sin necesidad de conocerla de antemano,

[1] M. Raissi, P. Perdikaris, G.E. Karniadakis. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 2020

[2] S. Greydanus, M. Dzamba, J. Yosinski. Hamiltonian Neural Networks. *Advances in Neural Information Processing Systems*, 2019

[3] M. Grmela, H.C. Öttinger. Dynamics and thermodynamics of complex fluids. I. Development of a general formalism. *Physical Review E*, 1997.

[4] Q. Hernández, A. Badías, D. González, F. Chinesta, E. Cueto. Structure-preserving neural networks. *Journal of Computational Physics*, 2020.

[5] Q. Hernández, A. Badías, D. González, F. Chinesta, E. Cueto. Deep learning of thermodynamics-aware reduced-order models from data. *ArXiv*, 2020.