



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

Departamento de Obras Civiles

APLICACIÓN DE ALGORITMOS DE REDES NEURONALES PARA LA MODELACIÓN EFICIENTE DE PROBLEMAS DE INTERACCIÓN SUELO-ESTRUCTURA.

Memoria de Título presentada por

Ricardo Antonio Álvarez Valdés

como requisito parcial para optar al título de la carrera de

Ingeniería Civil

Profesor Guía
Claudio Sepúlveda

Mayo de 2026



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: APLICACIÓN DE ALGORITMOS DE REDES NEURONALES PARA LA MODELACIÓN EFICIENTE DE PROBLEMAS DE INTERACCIÓN SUELO-ESTRUCTURA

Nombre del candidato(a): Ricardo Antonio Álvarez Valdés

Carrera / Grado: Ingeniería Civil

Campus: San Joaquín

Departamento: Obras Civiles

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Claudio Sepúlveda Contreras, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 19-06-2026

Firma:

Estudiante o Candidato(a):

Fecha: 19-06-2026

Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



TITULO DE LA TESIS:

**APLICACIÓN DE ALGORITMOS DE REDES NEURONALES PARA LA
MODELACIÓN EFICIENTE DE PROBLEMAS DE INTERACCIÓN
SUELO-ESTRUCTURA.**

AUTOR:

RICARDO ANTONIO ÁLVAREZ VALDÉS

TRABAJO DE MEMORIA, presentado como requisito parcial para optar al título de la carrera de INGENIERIA CIVIL de la Universidad Técnica Federico Santa María.

	<u>Nombre</u>	<u>Firma</u>
Prof. Guía		
Miembro 1 Comisión		
Miembro 2 Comisión		

Santiago, Chile, Mayo de 2026

APLICACIÓN DE ALGORITMOS DE REDES NEURONALES PARA LA MODELACIÓN EFICIENTE DE PROBLEMAS DE INTERACCIÓN SUELO-ESTRUCTURA

Ricardo Alvarez Valdes¹, PhD Claudio Sepulveda²

¹ Universidad Técnica Federico Santa María

Abstract

Soil–structure interaction (SSI) is a complex and fundamental phenomenon in seismic structural analysis, whose accurate representation through numerical models requires significant computational resources. These limitations hinder its incorporation into routine simulations and large-scale parametric studies.

In response to this challenge, this research proposes the use of deep learning techniques, specifically Long Short-Term Memory (LSTM) neural networks, to develop a reduced-order model capable of replicating the dynamic behavior of soil in structures subjected to seismic loading.

The methodological approach consists of generating a dataset from high-fidelity numerical simulations performed in OpenSees, considering multiple seismic records to capture a wide range of dynamic responses. This dataset is used to train a Teacher–Student framework, where a high-capacity LSTM model (Teacher) learns the full soil–structure response, and a reduced model (Student) aims to approximate this behavior using a limited set of input variables.

The results demonstrate that the Teacher model achieves high accuracy across all response variables, while the Student model maintains acceptable performance for certain variables, particularly base acceleration. However, its performance degrades for variables that depend on intermediate states, highlighting the impact of error propagation in reduced-order models.

Overall, the proposed approach shows significant potential for reducing computational costs while preserving essential dynamic characteristics, enabling more efficient analyses in seismic engineering applications.

Keywords: Soil–structure interaction, LSTM neural networks, deep learning, reduced-order modeling, structural dynamics, OpenSees.

Resumen

La interacción suelo-estructura (SSI) representa un fenómeno complejo y fundamental en el análisis estructural sísmico, cuya representación precisa mediante modelos numéricos de alta fidelidad demanda elevados recursos computacionales. Estas limitaciones dificultan su incorporación en simulaciones rutinarias y en estudios paramétricos extensos.

En respuesta a esta problemática, la presente investigación propone el uso de redes neuronales profundas, específicamente arquitecturas Long Short-Term Memory (LSTM), para desarrollar un modelo de orden reducido capaz de aproximar el comportamiento dinámico del suelo en sistemas sometidos a excitación sísmica.

El enfoque metodológico se basa en la generación de un conjunto de datos a partir de simulaciones numéricas en OpenSees, considerando múltiples registros sísmicos. Sobre esta base, se implementa un esquema Teacher–Student, donde un modelo LSTM de alta capacidad (Teacher) aprende la respuesta completa del sistema, mientras que un modelo reducido (Student) busca replicar dicho comportamiento utilizando un conjunto limitado de variables de entrada.

Los resultados muestran que el modelo Teacher logra una alta fidelidad en la predicción de variables clave, mientras que el modelo Student mantiene un desempeño aceptable en ciertas variables, particularmente la aceleración basal, aunque presenta degradaciones en variables más dependientes de estados internos, evidenciando efectos de propagación de error.

En conjunto, el enfoque propuesto permite reducir significativamente el costo computacional del análisis, manteniendo una representación adecuada de la respuesta dinámica, lo que posiciona a los modelos basados en aprendizaje profundo como una alternativa prometedora para la simulación eficiente de problemas de interacción suelo-estructura.

Palabras clave: Interacción suelo-estructura, redes neuronales LSTM, aprendizaje profundo, modelos de orden reducido, dinámica estructural, OpenSees.

Índice

1	Introducción.....	8
1.1	Planteamiento del problema.....	8
2	Objetivos	9
2.1	Objetivo general.....	9
2.1.1	Objetivos específicos.....	9
2.2	Alcance	9
3	Marco Teórico	10
3.1	Interacción suelo-estructura	10
3.1.1	Limitaciones de modelos detallados.....	10
3.2	Reducción computacional.....	11
3.2.1	Comportamiento no lineal en estructuras	11
3.2.2	Enfoques basados en aprendizaje automático.....	12
3.3	Redes neuronales recurrentes (LSTM) aplicadas a problemas dinámicos	12
3.3.1	Aplicación de LSTM en dinámica estructural	14
3.3.2	Formulación del problema en este trabajo.....	14
3.3.3	Rol de LSTM en el esquema de reducción	14
3.4	Entrenamiento y regularización	15
3.4.1	Optimizadores: algoritmo Adam	15
3.4.2	Regularización L2.....	15
3.4.3	Dropout y prevención de sobreajuste	16
4	Modelo físico y generación de datos.....	16
4.1	Modelación numérica en OpenSees/STKO	16
4.2	Variables extraídas.....	18
4.3	Generación del dataset	19
4.4	Segmentación temporal del dataset y normalización de variables.....	20
4.5	Replicabilidad del flujo metodológico.....	22
5	Modelo LSTM.....	23
5.1	Arquitectura LSTM.....	24
5.2	Modelo LSTM_Teacher.....	24
5.3	Modelo LSTM_Student_AF (abase y FX).....	25
5.4	Modelo LSTM_Student_Mz (MZ)	26
5.5	Métricas	26
5.5.1	Métricas de entrenamiento.....	27
5.5.2	Evaluación gráfica y análisis del desempeño	27
6	Resultados	28
6.1	Desempeño del modelo LSTM_Teacher	28
6.2	Desempeño del modelo LSTM_Student (AF)	33

6.3	Desempeño del modelo LSTM_Student (Mz)	36
6.4	Comparación global del framework (OpenSees vs Teacher vs Student)	39
6.4.1	Comparación cuantitativa global	39
6.4.2	Comparación por variable <i>abase</i>	40
6.4.3	Comparación por variable <i>Fx</i>	42
6.4.4	Comparación por variable <i>Mz</i>	43
6.5	Costo computacional	45
7	Conclusiones y comentarios	46
7.1	Trabajo futuro	48
7.1.1	<i>Data Augmentation</i> para mejorar la robustez del modelo Teacher	48
7.1.2	Incorporación de comportamiento no lineal del suelo	48
7.1.3	Técnicas avanzadas de <i>Deep Learning (Knowledge distillation)</i>	48
8	Referencias	48
9	Anexos	49
9.1	Enlaces notebook Colab	50
9.2	Plots comparación metodológica entrenamiento secuencial ventanas (a) vs serie completa (b) vs combinación de ambas (c)	50
9.3	Plots predicción tiempo historia de validación de redes neuronales para LSTM_Teacher..	52
9.4	Plots predicción tiempo historia de validación de redes neuronales para LSTM_Student ..	68
9.5	Plots de comparación entre redes LSTM_Teacher vs LSTM_Student vs Valor True (OpenSees) en 4 eventos fuera del entrenamiento.	79

1 Introducción

En zonas de alta sismicidad, como Chile, la representación adecuada de la interacción suelo-estructura (SSI, por sus siglas en inglés *Soil Structure Interaction*) constituye un aspecto relevante en el análisis dinámico de estructuras. La flexibilidad del suelo modifica las condiciones de apoyo, altera las características dinámicas del sistema y puede afectar variables de respuesta tales como el período fundamental, la distribución modal de energía y las demandas en la base estructural (Kramer, 1996; Wolff, 1985). A pesar de ello, en la práctica profesional la SSI suele omitirse o simplificarse, principalmente debido a la complejidad de su modelación y al alto costo computacional asociado (Acuña Izquierdo et al., 2023).

La incorporación explícita de la SSI en análisis dinámicos no lineales exige modelar simultáneamente el suelo, la fundación y la estructura, lo que conduce a sistemas altamente acoplados y de elevado costo computacional. Esta dificultad se vuelve aún más crítica cuando se requieren análisis paso a paso frente a múltiples registros sísmicos, como ocurre en estudios paramétricos, calibraciones o validaciones probabilísticas. En consecuencia, el uso de modelos detallados suele quedar restringido a casos específicos (Noto et al., 2022), limitando su aplicación sistemática en problemas de ingeniería.

En este contexto, las técnicas de aprendizaje automático han surgido como una alternativa prometedora para construir modelos sustitutos capaces de aproximar el comportamiento dinámico de sistemas complejos con una fracción del costo computacional de los modelos numéricos tradicionales. En particular, las redes neuronales recurrentes del tipo Long Short-Term Memory (LSTM) resultan adecuadas para este tipo de problema, ya que permiten modelar relaciones temporales no lineales y capturar efectos de memoria asociados a la respuesta dinámica. Estudios recientes han mostrado el potencial de estas arquitecturas en problemas de simulación estructural, identificación dinámica y representación reducida de sistemas acoplados (Ricles et al., 2024).

La presente memoria se inserta en esa línea de investigación y propone el desarrollo de un modelo neuronal para aproximar la respuesta dinámica en la interfaz suelo-estructura a partir de datos generados mediante simulaciones en OpenSees (McKenna, 2011). El objetivo no es reemplazar completamente la formulación física del problema, sino construir un modelo reducido capaz de reproducir las variables dinámicas más relevantes en la base estructural, preservando la consistencia temporal de la respuesta y disminuyendo significativamente el costo computacional.

Para ello, se adopta un enfoque jerárquico basado en un modelo Teacher–Student. En una primera etapa, un modelo LSTM de mayor riqueza de entrada aprende a reproducir la respuesta dinámica completa del sistema suelo-estructura. En una segunda etapa, se exploran modelos reducidos capaces de aproximar dicha respuesta a partir de un conjunto más limitado de variables, con miras a una futura integración en esquemas de co-simulación paso a paso. De este modo, el trabajo busca aportar una metodología eficiente para la modelación de problemas SSI, combinando simulación numérica y aprendizaje profundo en un marco coherente con las exigencias de la ingeniería sísmica.

1.1 Planteamiento del problema

La modelación precisa de la interacción suelo-estructura constituye uno de los desafíos más complejos en ingeniería estructural/geotecnia moderna. Su adecuada consideración requiere representar simultáneamente el comportamiento dinámico del suelo y de la estructura, lo que conduce a sistemas de ecuaciones altamente acoplados y no lineales. Este nivel de detalle implica tiempos de simulación prolongados, la necesidad de recursos computacionales especializados y una limitada escalabilidad para realizar estudios paramétricos o probabilísticos.

En la práctica, esta complejidad obliga a simplificar el problema mediante supuestos restrictivos, tales como suelos rígidos, amortiguamientos equivalentes o interacciones unidireccionales, lo que puede introducir errores significativos en la estimación de las demandas sísmicas. La situación se agrava cuando se consideran no linealidades estructurales, ya que la solución numérica paso a paso requiere iteraciones internas y criterios de convergencia estrictos.

Por otro lado, las investigaciones recientes en modelos de aprendizaje automático han demostrado que las redes neuronales pueden emular el comportamiento dinámico de sistemas no lineales complejos a partir de datos generados por simulaciones detalladas o ensayos experimentales (Bas & Moustafa, 2020; Mucha, 2019). Estas aproximaciones permiten obtener modelos reducidos capaces de reproducir la respuesta del sistema con alta precisión y tiempos de cálculo considerablemente menores.

En este contexto, surge la necesidad de diseñar un modelo de red neuronal que capture los efectos de la interacción suelo-estructura de manera eficiente, integrando las principales no linealidades de la estructura sobre un suelo lineal equivalente. El desafío central radica en lograr un modelo que, una vez entrenado, sea capaz de predecir las señales de frontera —fuerzas, aceleraciones y momentos— que caracterizan la respuesta del sistema, sin requerir la resolución numérica explícita del dominio del suelo.

2 Objetivos

2.1 Objetivo general

Implementar un modelo basado en redes neuronales que permita reemplazar la modelación explícita del dominio de suelo mediante elementos finitos, incorporando los efectos de interacción suelo-estructura (SSI) en el análisis estructural, con el fin de reducir la complejidad y las limitaciones computacionales mediante técnicas de aprendizaje automático.

2.1.1 Objetivos específicos

- Modelar numéricamente la interacción suelo-estructura considerando un suelo lineal y una estructura con comportamiento no lineal, obteniendo las series temporales necesarias para el entrenamiento de la red neuronal.
- Implementar y entrenar una red neuronal de tipo LSTM que aprenda la relación entre desplazamientos, velocidades, aceleraciones y fuerzas de interfaz, para reproducir el acoplamiento suelo-estructura.
- Comparar y validar la respuesta del modelo neuronal frente a la simulación numérica tradicional, cuantificando su desempeño en términos de precisión y reducción del tiempo de cómputo.

2.2 Alcance

El estudio se centra en el desarrollo, entrenamiento y validación de una red neuronal LSTM aplicada a un modelo bidimensional suelo-estructura. El suelo se representa mediante un modelo lineal elástico equivalente, mientras que la estructura incorpora comportamiento no lineal concentrado.

El conjunto de datos utilizado para el entrenamiento se genera a partir de simulaciones numéricas en OpenSees/STKO, considerando registros sísmicos reales en roca y condiciones de frontera absorbentes. El modelo se calibra para un rango de intensidades sísmicas representativas, asegurando consistencia temporal entre las series de entrada y salida.

El trabajo no aborda explícitamente el modelado no lineal del suelo ni efectos tridimensionales complejos, sino que se enfoca en la fase de prueba y validación del marco metodológico. Asimismo, los resultados se limitan al análisis comparativo entre la red neuronal entrenada y el modelo numérico de referencia, tanto en precisión de respuesta como en eficiencia computacional.

3 Marco Teórico

3.1 Interacción suelo-estructura

La interacción suelo-estructura (SSI) corresponde al fenómeno mediante el cual la respuesta dinámica de una estructura y la del suelo que la soporta se modifican mutuamente. En contraste con la hipótesis simplificada de base fija, la SSI reconoce que el suelo posee rigidez, masa y amortiguamiento finitos, por lo que puede deformarse y alterar las condiciones de apoyo de la estructura durante un evento sísmico (Kramer, 1996; Wolff, 1985).

Desde el punto de vista ingenieril, la SSI puede modificar variables relevantes de la respuesta, tales como el periodo predominante, la disipación efectiva de energía y las demandas en la base estructural. En ciertos casos, estos efectos pueden reducir algunas solicitaciones; en otros, pueden amplificarlas. Por esta razón, su consideración resulta particularmente importante en estructuras apoyadas sobre suelos deformables o cuando se requiere una representación más realista del problema dinámico.

La modelación de la SSI puede abordarse mediante distintos niveles de complejidad. Entre los enfoques clásicos se encuentran los modelos de Winkler, los modelos basados en impedancias dinámicas y la modelación explícita del suelo mediante elementos finitos. Si bien estos últimos ofrecen una representación más completa del fenómeno, su uso implica un costo computacional elevado, especialmente cuando se consideran análisis no lineales paso a paso y múltiples registros sísmicos. Esta limitación constituye una de las principales motivaciones del presente trabajo (Mylonakis & Gazetas, 2000).




Ilustración 1. Comparación conceptual entre (a) un modelo completo de interacción suelo-estructura (SSI) y (b) un modelo de orden reducido donde el dominio del suelo se reemplaza por un macroelemento basado en LSTM que predice las fuerzas de interacción de la base.

3.1.1 Limitaciones de modelos detallados

Los modelos detallados de interacción suelo-estructura, tales como aquellos basados en elementos finitos tridimensionales con comportamiento no lineal, ofrecen una representación de alta fidelidad del sistema físico. Sin embargo, presentan importantes limitaciones desde el punto de vista práctico.

En primer lugar, el alto costo computacional constituye una barrera significativa. La simulación dinámica en el dominio del tiempo de modelos con un elevado número de grados de libertad —del

orden de decenas o cientos de miles— puede requerir tiempos de cómputo considerables, incluso utilizando hardware especializado (Hancock et al., 2008). Esta dificultad se acentúa cuando se requiere evaluar múltiples registros sísmicos, como ocurre en estudios paramétricos, análisis probabilísticos o procesos de calibración, donde el número total de simulaciones crece rápidamente hasta volverse prohibitivamente alto.

En segundo lugar, existe una incertidumbre inherente en la caracterización de las propiedades del suelo. Parámetros como el módulo de corte, las curvas de degradación de rigidez, el amortiguamiento y la estratigrafía presentan variabilidad espacial y limitaciones en su estimación experimental. En consecuencia, incluso modelos altamente detallados pueden no traducirse en una mejora proporcional en la precisión de los resultados, lo que reduce la eficiencia del esfuerzo computacional invertido.

Adicionalmente, los modelos de alta complejidad generan grandes volúmenes de información cuya interpretación puede resultar poco eficiente en aplicaciones de ingeniería. En la práctica, el interés suele centrarse en variables globales de respuesta, tales como fuerzas internas, desplazamientos o reacciones en la base, las cuales podrían obtenerse mediante modelos de menor complejidad debidamente calibrados (Amezquita-Sancheza et al., 2020).

Estas limitaciones han impulsado el desarrollo de estrategias de reducción computacional en problemas de interacción suelo-estructura. Dichas estrategias pueden clasificarse, de manera general, en dos categorías: (i) simplificación del modelo físico, mediante la representación equivalente del suelo o de la estructura con sistemas de menor orden; y (ii) utilización de modelos sustitutos (surrogate models) o técnicas de aprendizaje automático capaces de aproximar la respuesta del sistema a partir de datos, reduciendo significativamente el costo computacional asociado a la simulación directa (Malik et al., 2025).

3.2 Reducción computacional

3.2.1 Comportamiento no lineal en estructuras

Bajo solicitaciones sísmicas de intensidad moderada a severa, las estructuras civiles —tales como edificios y puentes— suelen exhibir comportamiento no lineal. Esto implica que la relación fuerza-deformación deja de ser proporcional, dando lugar a fenómenos como la formación de rótulas plásticas, la degradación de rigidez y la disipación de energía mediante mecanismos histéreticos (Bolisetti et al., 2018).

La presencia de comportamiento no lineal introduce una complejidad significativa en el análisis dinámico, ya que invalida el principio de superposición. En consecuencia, la respuesta estructural debe obtenerse mediante integración temporal paso a paso de las ecuaciones de movimiento, actualizando en cada incremento el estado interno del sistema en función de su historia de carga. Este tipo de análisis, conocido como análisis dinámico no lineal en el dominio del tiempo, requiere discretizaciones temporales finas y el seguimiento de múltiples variables internas, lo que incrementa considerablemente el costo computacional.

En el contexto de interacción suelo-estructura, la no linealidad puede manifestarse tanto en la estructura como en el suelo. Sin embargo, con el objetivo de aislar y analizar de manera controlada los efectos del acoplamiento dinámico, en este trabajo se considera una estructura con comportamiento no lineal apoyada sobre un suelo lineal equivalente. Esta simplificación permite capturar los mecanismos principales de la interacción sin introducir una complejidad excesiva en la modelación del suelo.

Los métodos para representar el comportamiento no lineal estructural abarcan desde modelos concentrados simplificados, como sistemas bilineales con degradación, hasta formulaciones avanzadas basadas en elementos finitos. No obstante, independientemente del nivel de detalle adoptado, el costo computacional asociado al análisis dinámico no lineal constituye una limitación relevante, lo que motiva el desarrollo de estrategias de reducción computacional (Simpson et al., 2022).

3.2.2 Enfoques basados en aprendizaje automático

En los últimos años, los enfoques basados en aprendizaje automático han emergido como una alternativa eficiente para abordar problemas complejos de dinámica estructural. En particular, las redes neuronales artificiales permiten aproximar relaciones no lineales entre variables de entrada y salida a partir de datos, sin necesidad de resolver explícitamente las ecuaciones físicas del sistema en cada evaluación (Janiesch et al., 2021).

En el contexto de interacción suelo-estructura, esta aproximación consiste en generar un conjunto de datos mediante simulaciones numéricas detalladas —por ejemplo, utilizando OpenSees (McKenna, 2011)— que relacionen variables de entrada, como registros sísmicos y estados en la interfaz, con variables de salida representativas de la respuesta estructural, tales como fuerzas, aceleraciones o momentos en la base. A partir de estos datos, se entrena un modelo neuronal capaz de aprender la relación entrada-salida del sistema.

Una vez entrenado, el modelo neuronal actúa como un modelo sustituto (surrogate model), permitiendo predecir la respuesta del sistema de manera significativamente más rápida que la simulación directa. Este enfoque resulta particularmente atractivo en aplicaciones que requieren evaluar múltiples escenarios, como análisis probabilísticos o estudios paramétricos, donde el costo computacional de los modelos tradicionales puede ser prohibitivo (Hancock et al., 2008).

Las redes neuronales profundas son especialmente adecuadas para este tipo de problemas debido a su capacidad para aproximar funciones altamente no lineales. En particular, las redes neuronales recurrentes del tipo Long Short-Term Memory (LSTM) (Hochreiter & Schmidhuber, 1997) permiten modelar dependencias temporales y efectos de memoria, lo que resulta fundamental en problemas de dinámica estructural donde la respuesta depende de la historia completa de excitación.

En este trabajo, el uso de redes LSTM se enmarca en una estrategia de reducción computacional basada en un esquema jerárquico tipo Teacher-Student. En una primera etapa, un modelo de mayor complejidad (Teacher) aprende a reproducir la respuesta dinámica del sistema suelo-estructura a partir de un conjunto amplio de variables de entrada. Posteriormente, un modelo reducido (Student) busca aproximar dicha respuesta utilizando un conjunto más limitado de entradas, con el objetivo de facilitar su integración en esquemas de co-simulación paso a paso.

Una ventaja fundamental de estos modelos es que, una vez entrenados, su evaluación requiere únicamente operaciones algebraicas, lo que permite tiempos de inferencia muy bajos en comparación con los modelos físicos tradicionales. Esto abre la posibilidad de realizar simulaciones en tiempo casi real o de incorporar estos modelos en herramientas de análisis estructural avanzadas.

No obstante, la aplicación de redes neuronales también presenta desafíos, tales como la necesidad de contar con datos de entrenamiento representativos y el control del sobreajuste. Para abordar estos aspectos, se emplean técnicas de regularización y optimización durante el entrenamiento, tales como dropout (Srivastava et al., 2014) y algoritmos de optimización adaptativos como Adam (Kingma & Ba, 2015), los cuales permiten mejorar la capacidad de generalización del modelo.

En conjunto, los enfoques basados en aprendizaje automático permiten reformular el problema de análisis dinámico desde una perspectiva basada en datos, en la cual el comportamiento del sistema se aproxima mediante modelos entrenados, reduciendo significativamente el costo computacional sin perder representatividad en la respuesta.

3.3 Redes neuronales recurrentes (LSTM) aplicadas a problemas dinámicos

Las redes neuronales recurrentes, particularmente las LSTM, han demostrado ser efectivas en la modelación de sistemas dinámicos con dependencia temporal, permitiendo capturar relaciones no lineales complejas entre entradas y salidas del sistema (Bolisetti et al., 2018).

Sin embargo, las RNN tradicionales presentan dificultades para capturar dependencias de largo plazo debido a problemas de desvanecimiento y explosión del gradiente durante el entrenamiento. Para abordar esta limitación, Hochreiter y Schmidhuber (1997) propusieron la arquitectura Long Short-Term

Memory (LSTM), la cual introduce un mecanismo de memoria interna controlada mediante compuertas, permitiendo preservar información relevante a lo largo del tiempo.

Una celda LSTM está compuesta por un estado interno c_t y un estado oculto h_t , los cuales se actualizan en cada instante de tiempo en función de la entrada actual x_t y del estado previo. El comportamiento de la celda se describe mediante el siguiente conjunto de ecuaciones:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \text{ (Compuerta de olvido)}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \text{ (Compuerta de entrada)}$$

$$\bar{c}_t = \tanh(W_c \cdot [h_t, x_t] + b_c) \text{ (Candidato de estado interno)}$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \bar{c}_t \text{ (Actualización de estado interno)}$$

$$o_t = \sigma(W_o \cdot [h_t, x_t] + b_o) \text{ (Compuerta de salida)}$$

$$h_t = o_t \odot \tanh(c_t) \text{ (Estado oculto / salida)}$$

, donde $\sigma(\cdot)$ corresponde a la función sigmoide, $\tanh(\cdot)$ es la tangente hiperbólica, y $\odot$ denota multiplicación elemento a elemento. Las matrices W y los vectores b representan los parámetros a entrenar del modelo.

El término f_t corresponde a la compuerta de olvido, que controla qué información del estado previo c_{t-1} se conserva; i_t es la compuerta de entrada, que regula la incorporación de nueva información; y o_t es la compuerta de salida, que determina qué parte del estado interno se expone como salida. Este mecanismo permite que la red mantenga información relevante durante largos períodos de tiempo, evitando su degradación progresiva (Ñanculef & Calvo, 2018).




Ilustración 2. Estructura interna de una celda Long Short-Term Memory (LSTM).

Fuente: MathWorks (2023).




Ilustración 3. Representación de una capa LSTM desplegada en el tiempo.

Fuente: MathWorks (2023).

3.3.1 Aplicación de LSTM en dinámica estructural

En problemas de dinámica estructural, la respuesta de un sistema depende inherentemente de la historia de excitación, especialmente en presencia de comportamiento no lineal. Variables como desplazamientos, velocidades, aceleraciones y fuerzas internas presentan dependencias temporales complejas, asociadas a fenómenos de histéresis y acumulación de daño.

En este contexto, las redes LSTM resultan particularmente adecuadas, ya que su estructura interna permite capturar de manera implícita estas dependencias históricas sin necesidad de definir explícitamente variables internas del modelo físico. Es decir, el estado interno c_t puede interpretarse como una representación latente del estado del sistema, que evoluciona en función de la historia de excitación.

En el caso específico de la interacción suelo-estructura, esta capacidad es especialmente relevante, ya que la respuesta en la base estructural depende no solo de la excitación sísmica actual, sino también de la evolución previa del sistema, incluyendo efectos de acoplamiento dinámico entre el suelo y la estructura.

3.3.2 Formulación del problema en este trabajo

En el presente trabajo, las redes LSTM se utilizan para aproximar la relación dinámica entre variables de entrada asociadas a la excitación sísmica y estados en la interfaz suelo-estructura, y variables de salida representativas de la respuesta en la base estructural.

De forma general, el problema se plantea como:

$$\{v_g(t), a_g(t), d_{mid}(t), v_{mid}(t), a_{mid}(t)\} \rightarrow \{a_{base}(t), F_x(t), M_z(t)\}$$

, donde:

- $v_g(t), a_g(t)$: velocidad y aceleración del registro sísmico.
- $d_{mid}(t), v_{mid}(t), a_{mid}(t)$: variables cinemáticas en la interfaz suelo-estructura.
- $a_{base}(t)$: aceleración basal.
- $F_x(t)$: fuerza horizontal en la base.
- $M_z(t)$: momento basal.

La red neuronal se entrena utilizando datos generados mediante simulaciones numéricas en OpenSees, de modo que aprende a reproducir la respuesta dinámica del sistema sin necesidad de resolver explícitamente el dominio del suelo en cada evaluación.

3.3.3 Rol de LSTM en el esquema de reducción

Dentro del enfoque propuesto, las redes LSTM cumplen un rol central como modelos sustitutos del comportamiento dinámico del sistema suelo-estructura. En particular, se emplea una estrategia jerárquica tipo Teacher-Student, en la cual:

- El modelo Teacher aprende la dinámica completa del sistema a partir de un conjunto amplio de variables de entrada, actuando como un macroelemento dinámico del suelo.
- El modelo Student busca aproximar esta respuesta utilizando un conjunto reducido de entradas, lo que permite simplificar la implementación y facilitar su integración.

Este enfoque permite desacoplar parcialmente la complejidad del problema físico, manteniendo la consistencia temporal de la respuesta y reduciendo significativamente el costo computacional asociado al análisis dinámico.

3.4 Entrenamiento y regularización

3.4.1 Optimizadores: algoritmo Adam

El entrenamiento de una red neuronal profunda consiste en ajustar sus parámetros θ de manera que se minimice una función de pérdida $J(\theta)$, la cual mide el error entre las predicciones del modelo y los datos de entrenamiento. Este proceso se realiza mediante métodos de optimización iterativos basados en gradiente.

Entre los algoritmos más utilizados se encuentra Adam (*Adaptive Moment Estimation*), el cual combina las ventajas de métodos como *AdaGrad* y *RMSProp* mediante el uso de estimaciones adaptativas de los momentos del gradiente (Kingma & Ba, 2017).

Para cada parámetro θ y su gradiente g_t en el paso t , Adam calcula:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

Posteriormente, se corrigen los sesgos iniciales:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad ; \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

, y se actualizan los parámetros mediante:

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}$$

, donde α es la tasa de aprendizaje, y β_1, β_2 son coeficientes de decaimiento típicamente definidos como 0.9 y 0.999.

Este esquema permite ajustar de forma adaptativa el tamaño del paso para cada parámetro, mejorando la estabilidad y velocidad de convergencia. En este trabajo, Adam se utiliza debido a su eficiencia en el entrenamiento de redes profundas y su buen desempeño en problemas de regresión no lineal asociados a series temporales.

3.4.2 Regularización L2

La regularización L2 se emplea para evitar el sobreajuste del modelo, penalizando valores elevados de los parámetros (Cortes et al., 2009). Esto se logra mediante la modificación de la función de pérdida original:

$$J_{\text{reg}}(\theta) = J(\theta) + \frac{\lambda}{2} \sum_i \theta_i^2,$$

, donde θ_i son los parámetros (pesos) de la red y λ es el hiperparámetro de regularización que controla la intensidad de la penalización.

Este término adicional induce un efecto de *weight decay*, reduciendo progresivamente la magnitud de los pesos durante el entrenamiento. Como resultado, el modelo tiende a aprender representaciones más suaves y generalizables, evitando depender excesivamente de patrones específicos del conjunto de entrenamiento.

3.4.3 Dropout y prevención de sobreajuste

El *dropout*, introducido por Srivastava et al. (2014), es una técnica de regularización que consiste en desactivar aleatoriamente un subconjunto de neuronas durante el entrenamiento con una probabilidad p . Esto implica que, en cada iteración, la red opera sobre una sub-arquitectura distinta.

Este mecanismo evita la co-adaptación excesiva entre neuronas, promoviendo la construcción de representaciones más robustas. Durante la fase de inferencia, todas las neuronas se activan, ajustando sus contribuciones de acuerdo con la probabilidad de retención utilizada en el entrenamiento (Srivastava et al., 2014).

En este trabajo, dropout se aplica en las capas densas posteriores a la LSTM, con el objetivo de mejorar la capacidad de generalización del modelo frente a distintos registros sísmicos.

4 Modelo físico y generación de datos

4.1 Modelación numérica en OpenSees/STKO

El modelo numérico utilizado como base para la generación del dataset fue desarrollado por Tommy Fernández en el marco de su tesis de magíster, actualmente en desarrollo (Fernández & Sepúlveda, 2025). Dicho modelo corresponde a un sistema suelo–estructura bidimensional implementado en STKO/OpenSees bajo condición de deformación plana (*plane strain*), compuesto por un muro rectangular de hormigón armado en voladizo, su sistema de fundación y un dominio de suelo circundante. El muro corresponde a la configuración P1-25 reportada por Grandón y Hube (2023), con una sección transversal de $7.0 \times 0.30 \text{ m}$, altura total de 62.5 m , equivalente a un edificio de 25 pisos, y un período fundamental objetivo de $T_1 = 1.56 \text{ s}$.

La estructura fue modelada mediante el macroelemento MVLEM (*Multiple Vertical Line Element Model*), apropiado para representar la respuesta dominada por flexión de muros esbeltos de hormigón armado. En este modelo, el hormigón fue representado mediante el material *Concrete02*, mientras que el acero de refuerzo se modeló con *SteelMPF*. La fundación profunda se representó mediante elementos *elasticBeamColumn*, con el objetivo de mantener esta región dentro del rango elástico durante los análisis. En la versión utilizada para esta memoria, la interfaz suelo–fundación fue considerada como un contacto perfecto, sin separación ni deslizamiento relativo entre ambos dominios.

El dominio de suelo fue discretizado mediante elementos finitos tipo *quad*, siguiendo criterios de discretización asociados a la propagación de ondas. El comportamiento del suelo fue representado mediante el modelo constitutivo *PressureDependentMultiYield02* (PDMY02), adecuado para suelos granulares cuyo comportamiento depende del confinamiento. Para reducir reflexiones artificiales en los límites del dominio, se incorporaron condiciones de borde absorbentes mediante elementos *ASDAbsorbingBoundary*, los cuales permiten representar de manera aproximada la propagación de ondas hacia un medio semi-infinito. Adicionalmente, se consideró amortiguamiento de Rayleigh tanto en la estructura como en el dominio de suelo. El dominio del suelo se considera lineal en esta etapa, con el fin de reducir la complejidad computacional y facilitar la generación de un conjunto amplio de datos sintéticos. La excitación sísmica se aplica en la base del modelo mediante registros de velocidad, obtenidos a partir de la base de datos del *PEER NGA-West*, procesado.

El modelo físico no fue el objetivo principal de desarrollo de esta memoria, sino la base numérica utilizada para generar las respuestas dinámicas con las que se entrenaron las redes LSTM. Por eso se describe su configuración general y las hipótesis relevantes, especialmente la modelación del muro, la fundación, el suelo y la interfaz suelo–fundación.

En particular, se registraron desplazamientos, velocidades y aceleraciones en un nodo ubicado en el centro de la interfaz suelo–estructura (nodo 11522), representativo del comportamiento en la zona de contacto entre el suelo y la fundación (ver figura 2). Adicionalmente, se registraron las fuerzas globales en un elemento estructural tipo MVLEM (elemento 34046), a partir de las cuales se extrajeron las componentes de fuerza horizontal F_x y momento M_z , asociadas a la respuesta en la base del sistema estructural. Del mismo modo, se consideró como variable de salida la aceleración en la base de la

estructura, obtenida a partir de registros en un nodo representativo ubicado en la zona superior del dominio de suelo, el cual permite capturar la respuesta dinámica transmitida hacia la estructura (ver figura 2).




Figura 1. Vista general del modelo numérico en STKO. Se observa el dominio de suelo discretizado mediante elementos finitos, la fundación (elementos en color morado) y el muro estructural representado mediante una línea de nodos verticales.




Figura 2. Detalle del nodo utilizado para la extracción de variables cinemáticas en la interfaz y el elemento estructural utilizado para obtener fuerzas globales.

4.2 Variables extraídas

Con el objetivo de construir un modelo reducido capaz de representar la interacción dinámica suelo–estructura, se definió un conjunto de variables de entrada y salida a partir de las simulaciones numéricas realizadas en OpenSees. Estas variables fueron seleccionadas de manera que capturen tanto el estado cinemático en la interfaz suelo–estructura como la respuesta global del sistema, permitiendo a la red neuronal aprender el comportamiento dinámico equivalente del dominio de suelo.

Como se muestra en la Figura 3, las variables se organizan en un esquema conceptual que relaciona el input sísmico, el modelo físico completo y el modelo reducido basado en redes neuronales.




Figura 3. Esquema conceptual del sistema suelo–estructura y definición de variables de entrada y salida utilizadas en el modelo.

Las variables de entrada corresponden a magnitudes asociadas al movimiento sísmico y al estado del sistema en la interfaz de contacto. En particular, se consideran:

- Velocidad y Aceleración sísmica en roca (v_g, a_g).
- Desplazamiento horizontal en el nodo de contacto suelo–estructura (u_c).
- Velocidad horizontal en el nodo de contacto suelo–estructura ($\dot{u}_c$).
- Aceleración horizontal en el nodo de contacto suelo–estructura ($\ddot{u}_c$).

Estas variables permiten describir el estado dinámico del sistema en cada instante de tiempo, incorporando información tanto del input externo como de la respuesta local en la interfaz, lo cual es fundamental para capturar efectos de memoria e histéresis en el comportamiento del suelo.

Las variables de salida fueron definidas con el objetivo de representar la acción equivalente del suelo sobre la estructura, permitiendo reemplazar explícitamente el dominio de suelo mediante un modelo reducido. En este contexto, se consideran:

- Aceleración en la base de la estructura (a_{base}).
- Fuerza horizontal basal (F_x).
- Momento flector basal (M_z).

Estas variables corresponden a las acciones transmitidas desde el suelo hacia la estructura, siendo coherentes con una formulación tipo macroelemento.

La selección de variables responde a una formulación entrada–salida en el dominio del tiempo, en la cual el modelo neuronal busca aproximar la relación funcional entre el estado cinemático en la interfaz y la respuesta estructural. En particular, la inclusión de desplazamiento, velocidad y aceleración en el nodo de contacto permite representar el comportamiento dinámico del suelo, dependientes de la historia de carga. Las variables de salida representan directamente las fuerzas generalizadas que el suelo ejerce sobre la estructura.

Este enfoque es consistente con modelos tipo macroelemento utilizados en interacción suelo–estructura, donde el dominio de suelo es reemplazado por una relación constitutiva equivalente en la interfaz.

4.3 Generación del dataset

El dataset utilizado para el entrenamiento de las redes neuronales fue generado a partir de simulaciones dinámicas realizadas en OpenSees, empleando el modelo numérico descrito en la Sección 4.1. El modelo numérico representa un sistema suelo–estructura bidimensional, consistente en un muro estructural apoyado sobre un dominio de suelo continuo. En este caso, la interfaz fundación–suelo se modela como completamente adherida, sin considerar elementos de contacto ni mecanismos de deslizamiento o fricción. Para cada registro sísmico considerado, se obtuvieron historias temporales de las variables relevantes mencionadas anteriormente, tanto en la interfaz como en la respuesta global del sistema.

Con el fin de caracterizar la variabilidad del conjunto de datos, se analizaron propiedades relevantes de los registros sísmicos utilizados, incluyendo velocidad de onda de corte promedio (V_{s30}), magnitud, distancia de ruptura, duración significativa e intensidad de Arias. La Figura 4 muestra el espectro mediano del conjunto de registros utilizados, junto con la dispersión asociada, evidenciando la variabilidad en el contenido frecuencial de las señales utilizadas. Por su parte, la Figura 5 presenta las distribuciones de parámetros relevantes. Estas distribuciones permiten verificar que el dataset cubre un rango amplio de condiciones de excitación sísmica, tanto en términos de intensidad como de contenido energético y duración, lo cual resulta fundamental para el adecuado entrenamiento y generalización de los modelos propuestos




Figura 4. Espectro de pseudo-aceleración del conjunto de registros sísmicos utilizados.




Figura 5. Histogramas de distribución de parámetros característicos de los registros sísmicos utilizados: (a) velocidad de onda de corte promedio V_{s30} , (b) magnitud, (c) distancia de ruptura R_{rup} , (d) duración significativa (5–75%) y (e) intensidad de Arias.

4.4 Segmentación temporal del dataset y normalización de variables

Con el objetivo de aumentar el número efectivo de muestras de entrenamiento y mejorar la estabilidad del proceso de optimización, se adoptó una estrategia de segmentación temporal basada en ventanas deslizantes (*sliding windows*). Cada registro sísmico fue dividido en ventanas de longitud fija $T = 2048$ pasos de tiempo, equivalentes aproximadamente a 10.24 segundos de historia dinámica considerando un paso de tiempo de referencia. El desplazamiento entre ventanas consecutivas se definió como $stride = 64$ pasos de tiempo, generando un alto grado de solapamiento entre muestras. Esta estrategia permite preservar la coherencia temporal dentro de cada secuencia, al mismo tiempo que incrementa significativamente el tamaño del dataset, lo que resulta particularmente relevante para el entrenamiento de modelos basados en redes neuronales recurrentes (*Recurrent Neural Networks*, RNN).

Adicionalmente, para comparar el desempeño de estas estrategias, se evaluaron tres enfoques de entrenamiento, consistentes con los casos mostrados en las figuras correspondientes: (A) segmentación mediante ventanas deslizantes (*sliding window segmentation*), (B) entrenamiento utilizando secuencias completas por evento (*full-sequence training*), y (C) una estrategia combinada basada en entrenamiento por ventanas y reconstrucción de la respuesta completa (*window-based training with full response reconstruction*). Cabe señalar que las métricas cuantitativas de desempeño utilizadas para evaluar estos enfoques se presentan y discuten en secciones posteriores.

Las Figuras 6, 7 y 8 muestran la comparación entre las respuestas predichas por cada estrategia y la respuesta real para un evento representativo, considerando variables clave como la aceleración en la base, la fuerza horizontal y el momento flector.

En términos generales, el entrenamiento basado en ventanas deslizantes (A) presenta una mejor capacidad para capturar la dinámica local y las variaciones de alta frecuencia, mientras que el enfoque basado en secuencias completas (B) tiende a suavizar la respuesta y perder precisión en amplitud. Por su parte, la estrategia combinada (C) permite reconstruir la respuesta completa manteniendo una

adecuada representación temporal, aunque con ciertas limitaciones en la estimación de amplitudes extremas. Estos resultados deben interpretarse como una comparación cualitativa inicial, la cual es complementada posteriormente mediante métricas cuantitativas de error.




Figura 6. Comparación de la aceleración en la base del sistema para un evento representativo.




Figura 7. Comparación de la fuerza horizontal basal F_x para un evento representativo.




Figura 8. Comparación de la fuerza horizontal basal F_x para un evento representativo.

Todas las variables de entrada y salida fueron normalizadas mediante una estrategia robusta basada en centrado en la media y escalamiento utilizando el percentil absoluto 99 (P_{99}) de cada variable. Esta

aproximación permite reducir la influencia de valores extremos, estabilizar el entrenamiento y evitar problemas asociados a saturación de gradientes, preservando al mismo tiempo la escala relativa entre variables físicas.

Con el fin de enfocar el entrenamiento y la evaluación en las regiones dinámicamente relevantes, se identificó la ventana temporal activa de cada registro sísmico mediante un criterio energético aplicado a la señal de entrada. Sobre esta base, se definió una subregión denominada `ACTIVE_CORE`, correspondiente al intervalo que concentra aproximadamente el 95% de la energía acumulada dentro de la ventana activa.

Esta definición permite reducir la influencia de segmentos de baja amplitud en las métricas de desempeño, enfocando el análisis en las porciones del registro donde la respuesta estructural es más significativa.

Posteriormente, los datos fueron procesados mediante un pipeline que incluyó re-muestreo temporal a un paso de tiempo uniforme, normalización robusta y segmentación en ventanas, permitiendo estructurar un dataset organizado por evento sísmico.

Para cada evento, se definieron las siguientes estructuras de datos:

- $X_{full} \in \mathbb{R}^{NT \times 5}$: matriz de variables de entrada, con columnas;
 - v_g : velocidad del registro sísmico
 - a_g : aceleración del registro sísmico
 - u_c : desplazamiento en el nodo de contacto
 - $\dot{u}_c$: velocidad en el nodo de contacto
 - $\ddot{u}_c$: aceleración en el nodo de contacto
- $Y_{full} \in \mathbb{R}^{NT \times 3}$: matriz de variables de salida, con columnas;
 - a_{base} : aceleración representativa en la base del sistema
 - F_x : fuerza horizontal en la base del muro
 - M_z : momento flector en la base del muro
- dt : paso de tiempo de la serie temporal
- NT : número total de pasos de tiempo del registro
- $record_id$: identificador del evento sísmico (por ejemplo, "EQ0##")

4.5 Replicabilidad del flujo metodológico

Con el objetivo de facilitar la continuidad del trabajo, el flujo metodológico desarrollado fue estructurado de manera modular y trazable, permitiendo no solo reproducir el caso de estudio analizado, sino también adaptar el procedimiento a nuevos modelos suelo–estructura. En este sentido, el framework propuesto debe entenderse como una secuencia de etapas replicables: selección de registros sísmicos, modelación numérica en STKO/OpenSees, extracción de variables, construcción del dataset, entrenamiento de redes LSTM y evaluación del desempeño.

La replicabilidad directa del estudio requiere mantener consistencia entre el modelo físico utilizado, las variables extraídas y la arquitectura neuronal entrenada. En este trabajo, el dataset se generó a partir de un modelo bidimensional suelo–estructura implementada en STKO/OpenSees, compuesto por un muro de hormigón armado, su sistema de fundación y un dominio de suelo circundante. Las variables utilizadas para el entrenamiento fueron definidas a partir de la excitación sísmica, el estado cinemático de la interfaz suelo–estructura y la respuesta estructural objetivo. Por lo tanto, cualquier intento de reproducción debe conservar la trazabilidad entre el registro sísmico aplicado, la simulación numérica correspondiente y las historias temporales extraídas desde el modelo.

No obstante, si el objetivo es adaptar el framework a un nuevo caso representativo de edificaciones chilenas, deben revisarse algunos aspectos fundamentales. En primer lugar, la selección de registros sísmicos debería responder al escenario sísmico de interés, considerando registros compatibles con la amenaza sísmica chilena, las condiciones de sitio y el nivel de intensidad objetivo. A diferencia de los registros utilizados en esta memoria, obtenidos desde una base internacional y seleccionados bajo criterios de disponibilidad y representatividad general, una aplicación nacional podría incorporar registros chilenos provenientes de estaciones del Centro Sismológico Nacional u otras bases locales, priorizando información confiable de aceleración, condición de sitio, distancia fuente–sitio, magnitud y contenido frecuencial. Además, debería verificarse que los registros seleccionados sean compatibles con el tipo de suelo y la zona sísmica considerada en el modelo.

En segundo lugar, el modelo numérico debe ser coherente con el sistema estructural que se desea estudiar. El presente trabajo utilizó un muro aislado como caso base; sin embargo, para extender el framework podrían considerarse muros con distintas alturas, relaciones de aspecto, cuantías de refuerzo, períodos fundamentales, configuraciones de fundación o niveles de acoplamiento con el suelo. Asimismo, debería evaluarse si el modelo debe representar una fundación superficial, profunda o mixta, ya que esta decisión modifica directamente la interacción suelo–estructura y, por lo tanto, las variables que la red debe aprender. En particular, si se incorporan efectos como separación, deslizamiento o fricción en la interfaz suelo–fundación, el dataset debería incluir variables capaces de representar dichos mecanismos.

En tercer lugar, la modelación del suelo debe ajustarse al perfil geotécnico del caso de estudio. Para una aplicación chilena, esto implica definir estratigrafías compatibles con la clasificación normativa y con información geotécnica local, por ejemplo, perfiles asociados a suelos tipo A, B, C, D o E, según corresponda. También debe revisarse la ley constitutiva utilizada para el suelo, sus parámetros de calibración, el amortiguamiento considerado y las condiciones de borde. Si se mantiene una formulación con elementos finitos tipo quad y bordes absorbentes, debe verificarse que la discretización sea adecuada para el contenido frecuencial de los registros utilizados, evitando reflexiones artificiales o filtrado numérico indeseado.

Finalmente, la arquitectura neuronal puede mantenerse como punto de partida, pero no necesariamente debe considerarse definitiva. Para un nuevo caso, el modelo LSTM_Teacher debería reentrenarse con las variables completas disponibles del nuevo sistema, mientras que los modelos LSTM_Student deberían redefinirse en función de las variables que se busque conservar como entrada reducida. En otras palabras, si el objetivo sigue siendo reemplazar el dominio de suelo mediante un modelo reducido, el Student debe entrenarse para aproximar la respuesta aprendida por el Teacher utilizando únicamente variables que sean accesibles o convenientes en una futura implementación. Por ello, la elección de entradas y salidas no debe copiarse de forma automática, sino adaptarse al objetivo físico y computacional del nuevo estudio.

En síntesis, la replicabilidad del framework se sustenta en conservar la lógica general del procedimiento, pero ajustando los componentes físicos y sísmicos al nuevo caso de análisis. Para replicar el estudio en un contexto chileno, un futuro trabajo debería revisar especialmente: la selección de registros sísmicos, el tipo de estructura, la configuración de fundación, el perfil de suelo, la modelación de la interfaz suelo–fundación, las variables extraídas y los criterios de entrenamiento. De esta manera, el aporte principal de esta memoria no se limita a los modelos entrenados en este caso particular, sino que corresponde a un flujo metodológico adaptable para el desarrollo de modelos neuronales reducidos aplicados a problemas de interacción suelo–estructura.

Como material complementario, los notebooks utilizados para el procesamiento de datos, entrenamiento de modelos y evaluación de resultados se encuentran disponibles en un repositorio público de GitHub. Estos se encuentran disponibles como material complementario en el Anexo 9.1, con el objetivo de facilitar la revisión, reproducción y continuidad del flujo computacional desarrollado.

5 Modelo LSTM

5.1 Arquitectura LSTM

Siguiendo enfoques recientes en la literatura, se emplea una arquitectura Long Short-Term Memory (LSTM) para modelar la relación entre la excitación sísmica y la respuesta estructural, utilizando secuencias temporales como entrada (Bolisetti et al., 2018). Esta formulación permite mapear secuencias temporales de entrada en secuencias de salida, capturando la evolución dinámica del sistema suelo–estructura en el tiempo.

La arquitectura propuesta emplea una red neuronal recurrente del tipo Long Short-Term Memory (LSTM) apilada, tamaño de estado oculto de 256 unidades, dropout de 0.2, con el objetivo de modelar la respuesta dinámica de sistemas con interacción suelo–estructura. En cada paso de tiempo discreto t , asociado a un intervalo de muestreo $\Delta t = 0.005$ s, la red recibe un vector de entrada x_t y actualiza sus estados internos, representados por el estado oculto h_t y el estado de memoria c_t . Estos estados permiten codificar la evolución temporal del sistema, incorporando efectos de memoria.

El funcionamiento interno de la celda LSTM se basa en un conjunto de compuertas que regulan el flujo de información. En particular, la actualización del estado de memoria y el estado oculto permite capturar dependencias de largo plazo y representar de manera eficiente la dinámica del sistema. Dentro de cada ventana, la red recorre secuencialmente cada paso temporal, propagando los estados internos entre instantes consecutivos, lo que permite construir una representación reducida del comportamiento dinámico del sistema.

Se consideran dos configuraciones principales de modelo. El modelo Teacher utiliza como entrada tanto la excitación sísmica como variables internas del sistema estructural, lo que le permite aproximar con alta fidelidad la respuesta completa. Por otro lado, los modelos Student operan con información reducida, basada principalmente en la excitación sísmica y, en algunos casos, variables derivadas.

5.2 Modelo LSTM_Teacher

Sobre el dataset generado se entrenó inicialmente un modelo LSTM denominado LSTM_Teacher, cuyo objetivo es aprender la relación completa entre el estado dinámico en la interfaz suelo–estructura y la respuesta estructural global. Con el objetivo de evaluar distintas estrategias de entrenamiento, se analizaron tres enfoques: entrenamiento basado en ventanas temporales, entrenamiento con secuencias, y un enfoque híbrido que combina ambos métodos.

El modelo Teacher se define mediante la siguiente relación entrada–salida:

Entradas:

$$x_t = [v_g(t), a_g(t), x_{mid}(t), \dot{x}_{mid}(t), \ddot{x}_{mid}(t)]$$

Salidas:

$$y_t = [a_{base}(t), F_x(t), M_z(t)]$$

La función de pérdida utilizada combina el error cuadrático medio (MSE) con un término de regularización orientado a preservar la escala global de las señales:

$$Loss_{Teacher} = MSE + \lambda_{scale} \cdot Loss_{Scale}$$

, donde:

$$Loss_{Scale} = \left(\frac{\sigma_{pred}}{\sigma_{true}} - 1 \right)^2$$

Este término adicional permite penalizar discrepancias en la amplitud global de las señales, evitando subestimaciones o sobreestimaciones sistemáticas.




Figura 9. Arquitectura general del modelo LSTM utilizado, incluyendo normalización de entrada, capas LSTM apiladas y capa densa de salida para la predicción de variables dinámicas.

5.3 Modelo LSTM_Student_AF (a_{base} y F_X)

El modelo LSTM_Student_AF tiene como objetivo aproximar la aceleración basal y la fuerza horizontal utilizando únicamente la excitación sísmica como entrada, lo que representa una reducción significativa del espacio de variables respecto al modelo Teacher. Los targets utilizados corresponden a predicciones generadas por el modelo Teacher. El modelo LSTM Student AF se entrena al igual que LSTM_Teacher como un modelo recurrente secuencia-a-secuencia que predice las respuestas $\{a_{base}, F_X\}$ a partir únicamente de la excitación sísmica.

Entradas:

$$\mathbf{x}_t = [v_g(t), a_g(t)]$$

Salidas:

$$\mathbf{y}_t = [a_{base}(t), F_X(t)]$$

Arquitectura de la red compuesta por una LSTM apilada de 2 capas con 128 unidades ocultas, seguida de una capa lineal fully-connected que entrega dos salidas por paso temporal. Se emplea dropout de 0.1 entre capas LSTM (solo si $L > 1$). Las entradas se normalizan mediante escalamiento robusto con clipping para estabilidad numérica.

$$x_n = \frac{x - x_m}{P_{99}(|x|) + \epsilon}$$

La función de pérdida utilizada combina el error cuadrático medio (MSE) con un término de regularización orientado a preservar la escala global de las señales:

$$Loss = \alpha \cdot Loss_{MSE(Peak_Weighted)} + \lambda_{Corr} \cdot Loss_{Corr} + \lambda_{Deriv} \cdot Loss_{Deriv}$$

$$Loss_{MSE} = w_1 \cdot MSE(a_{base,x}) + w_2 \cdot MSE(F_x)$$

$$Peak_Weighted(Loss_{MSE}) = w(t) = 1 + \beta |y(t)|^p$$

$$Loss_{Corr} = 1 - Corr(y_{pred}, y_{true})$$

$$Loss_{Deriv} = (y'_{pred} + y'_{true})^2$$

, donde $\alpha = 0.55$, $\lambda_{Corr} = 0.33$, $\lambda_{Deriv} = 0.20$. Pero además $MSE(Peak_Weighted)$ lo que hace es entregarle mayor peso e importancia en los picos de la señal (ACTIVE CORE), debido a que estos controlan mayoritariamente la respuesta estructural. $Loss_{Corr}$ fuerza a aprender la forma de la señal (dinámica temporal) y $Loss_{Deriv}$ busca mejorar pendientes y amplitud.

5.4 Modelo LSTM_Student_Mz (M_z)

El modelo LSTM_Student_Mz tiene como objetivo predecir el momento basal utilizando como entrada la excitación sísmica y las variables predichas previamente por el modelo Student_AF. Esta formulación corresponde a una estrategia tipo *cascade*, donde la predicción de variables intermedias permite mejorar la estimación de variables más complejas. Student (M_z) busca predecir el momento basal condicionado a las fuerzas basales predichas como input. También se entrena como una red secuencia-a-secuencia.

Entradas:

$$x_t = [v_g(t), a_g(t), a_{base}(t), F_X(t)]$$

Salidas:

$$y_t = [M_z(t)]$$

El entrenamiento se realiza utilizando validación cruzada por eventos sísmicos mediante un esquema Group K-Fold, donde cada grupo se compone de la misma cantidad de eventos. Luego para los K modelos entrenados se varía el grupo de validación, buscando que todos los eventos sean utilizados como validación al menos 1 vez. Este enfoque también evita que ventanas temporales del mismo evento aparezcan simultáneamente en entrenamiento y validación. Se utilizaron 5 folds (k), optimizador Adam, tasa de aprendizaje 0.0002 y regularización L_2 . La función de perdida utilizada fue el error cuadrático medio (MSE):

$$Loss_{Mz} = MSE$$




Figura 10. Esquema de la estrategia LSTM_Student. A la izquierda se muestra el modelo Student_AF para la predicción de aceleración y fuerza basal, y a la derecha el modelo Student_Mz para la predicción del momento.

5.5 Métricas

5.5.1 Métricas de entrenamiento

El desempeño de los modelos propuestos se evalúa mediante un conjunto de métricas que permiten cuantificar tanto la precisión como el comportamiento estadístico de las predicciones. Estas métricas se calculan durante el entrenamiento y la validación, permitiendo monitorear la convergencia del modelo y su capacidad de generalización (Nanculef & Calvo, 2018).

En primer lugar, se emplea el error cuadrático medio (MSE), definido como:

$$RMSE = \sqrt{\frac{1}{N} \sum (y_{pred,i} - y_{true,i})^2}$$

A partir de este se obtiene su raíz, el error cuadrático medio (RMSE):

$$RMSE = \sqrt{MSE}$$

El RMSE se expresa en las mismas unidades físicas de la variable de salida, lo que facilita su interpretación desde un punto de vista ingenieril. Valores bajos de RMSE indican una adecuada capacidad de ajuste del modelo.

Complementariamente, se utiliza el error absoluto medio (MAE):

$$MAE = \frac{1}{N} \sum |y_{pred,i} - y_{true,i}|$$

Esta métrica proporciona una medida robusta del error promedio, sin amplificar la influencia de valores extremos, a diferencia del RMSE. La comparación entre MAE y RMSE permite identificar la presencia de errores puntuales de gran magnitud (*outliers*): cuando el RMSE es significativamente mayor que el MAE, se sugiere la existencia de errores localizados de alta amplitud.

Adicionalmente, se evalúa el sesgo medio (Bias), definido como:

$$Bias = \frac{1}{N} \sum (y_{pred,i} - y_{true,i})$$

Esta métrica permite identificar tendencias sistemáticas del modelo a sobreestimar o subestimar la respuesta estructural.

Por otra parte, se incorpora el coeficiente de correlación lineal (Corr), definido como:

$$Corr = \frac{Cov(y_{pred}, y_{true})}{\sigma_{pred} \cdot \sigma_{true}}$$

Este indicador mide el grado de similitud entre las formas temporales de las señales predichas y reales. En problemas dinámicos, esta métrica resulta especialmente relevante, ya que permite evaluar la capacidad del modelo para reproducir la evolución temporal de la respuesta, independientemente de posibles diferencias en amplitud.

Las métricas anteriores se calculan principalmente sobre la región ACTIVE_CORE, definida como el intervalo que concentra el 95% de la energía de la señal dentro de la ventana activa. Esto permite enfocar la evaluación en los intervalos de mayor demanda dinámica, reduciendo la influencia de segmentos de baja amplitud.

Durante el entrenamiento, estas métricas se monitorean tanto en el conjunto de entrenamiento como en el de validación. Se espera que ambas curvas evolucionen de manera similar y converjan a valores estables; una divergencia significativa entre ellas es indicativa de sobreajuste (*overfitting*).

5.5.2 Evaluación gráfica y análisis del desempeño

En la etapa de evaluación final, se emplean herramientas gráficas que permiten analizar en mayor profundidad el desempeño predictivo de los modelos, considerando tanto aspectos globales como características locales de la respuesta dinámica.

En primer lugar, se utilizan gráficos de dispersión (*scatter plots*) entre valores predichos y valores reales. En estos gráficos, una predicción perfecta se representa mediante puntos alineados sobre la recta identidad $y = x$. La dispersión de los puntos respecto a dicha recta permite evaluar visualmente el nivel de error, mientras que patrones sistemáticos pueden evidenciar sesgos o limitaciones del modelo en determinados rangos de valores.

Asimismo, se analizan histogramas del error de predicción, definidos como la diferencia entre valores predichos y reales. Estos permiten caracterizar la distribución del error, evaluando si se encuentra centrado en cero (ausencia de sesgo) y su dispersión (precisión del modelo). Una distribución estrecha y aproximadamente simétrica en torno a cero es indicativa de un buen desempeño. La media del error refleja el sesgo global, mientras que la desviación estándar cuantifica la variabilidad del error.

Otra herramienta fundamental corresponde a la comparación directa de señales temporales, donde se contrastan las series predichas y reales en el dominio del tiempo. Este análisis permite evaluar la capacidad del modelo para reproducir características dinámicas específicas, tales como amplitudes máximas, fases y contenido frecuencial de la respuesta. En este contexto, el coeficiente de correlación adquiere especial relevancia, ya que permite cuantificar la similitud en la forma de las señales, incluso en presencia de discrepancias en amplitud.

6 Resultados

6.1 Desempeño del modelo LSTM_Teacher

El primer paso del análisis consiste en evaluar la capacidad del modelo LSTM_Teacher para reproducir la respuesta dinámica del sistema suelo–estructura obtenida mediante simulaciones directas en OpenSees. Este modelo tiene como objetivo actuar como un macroelemento dinámico equivalente del suelo, reproduciendo la interacción en la interfaz fundación–estructura sin necesidad de modelar explícitamente el dominio de suelo.

Las variables analizadas corresponden a:

$$\{a_{base}(t), F_X(t), M_Z(t)\}$$

, donde:

$a_{base}(t)$ corresponde a la aceleración en la base de la estructura.

$F_X(t)$ corresponde a la fuerza horizontal transmitida en la interfaz.

$M_Z(t)$ corresponde al momento flector basal.

Estas variables representan las magnitudes de mayor interés para la caracterización de la interacción suelo–estructura desde el punto de vista estructural.

Con el objetivo de evaluar la estabilidad del proceso de entrenamiento y la capacidad de generalización del modelo LSTM_Teacher, se analizaron las curvas de evolución de la función de pérdida (loss) y del coeficiente de correlación durante las etapas de entrenamiento y validación. La Figura 11 presenta la evolución del error cuadrático medio (MSE), mientras que la Figura 12 muestra la evolución del coeficiente de correlación.




Figura 11. Evolución de la función de pérdida (MSE) durante el entrenamiento y validación del modelo LSTM_Teacher.




Figura 12. Evolución del coeficiente de correlación durante el entrenamiento y validación del modelo LSTM_Teacher.

Se observa que la función de pérdida presenta una disminución progresiva durante las primeras épocas de entrenamiento, seguida de una fase de convergencia hacia valores estables. La cercanía entre las curvas de entrenamiento y validación indica que el modelo no presenta sobreajuste significativo, manteniendo un comportamiento consistente en datos no vistos.

En particular, la leve separación observada en algunas épocas intermedias sugiere pequeñas fluctuaciones propias del proceso de optimización, pero sin comprometer la estabilidad global del modelo.

Por otra parte, el coeficiente de correlación muestra un incremento sostenido desde las primeras épocas, alcanzando valores cercanos a 1 en el conjunto de entrenamiento y superiores a 0.9 en validación. Esto indica que el modelo logra capturar de manera efectiva la estructura temporal de las señales.

En conjunto, estos resultados evidencian que el proceso de entrenamiento es estable y que el modelo presenta una adecuada capacidad de generalización, lo cual es consistente con el buen desempeño observado en la evaluación sobre eventos sísmicos no utilizados durante el entrenamiento.

La ausencia de divergencia entre las curvas de entrenamiento y validación refuerza la validez del modelo como aproximación robusta del comportamiento dinámico del sistema suelo–estructura.

Las Figuras 13, 14, y 15 presentan la comparación temporal entre las respuestas obtenidas mediante OpenSees y las predicciones generadas por el modelo LSTM_Teacher para un evento sísmico representativo.




Figura 13. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ052).




Figura 14. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ052).




Figura 15. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ052).

En términos generales, se observa que el modelo reproduce de manera notable la respuesta dinámica del sistema, capturando adecuadamente tanto la fase como la amplitud de las señales.

En el caso de la aceleración basal, la red logra seguir con alta precisión la evolución temporal de la señal, incluyendo las fases de baja amplitud inicial, el incremento abrupto de energía y la posterior disipación. Se observa una muy buena coincidencia en frecuencia y fase, con pequeñas discrepancias en algunos picos máximos durante el tramo de mayor intensidad (aproximadamente entre 25 s y 35 s).

Para la fuerza horizontal basal, el modelo mantiene un nivel de precisión similar, reproduciendo adecuadamente los ciclos de carga y descarga, así como la modulación de amplitud asociada a la excitación sísmica. Se aprecia una leve subestimación en algunos máximos locales, particularmente en la zona de mayor demanda, lo que sugiere una ligera suavización de la respuesta por parte del modelo.

En el caso del momento flector basal, el modelo también presenta un ajuste satisfactorio, logrando capturar tanto la forma sinusoidal dominante en la fase post-transiente como la evolución de la amplitud. Sin embargo, se observan pequeñas diferencias en la amplitud de los ciclos, especialmente en los máximos y mínimos, lo que indica que esta variable —al depender de distribuciones internas de deformación— resulta más compleja de modelar que las variables directamente asociadas a la interfaz.

En conjunto, estos resultados evidencian que el modelo LSTM_Teacher es capaz de reproducir adecuadamente la dinámica global del sistema.

Para cuantificar el desempeño del modelo se utilizaron diversas métricas de error y correlación, incluyendo RMSE (Root Mean Square Error), MAE (Mean Absolute Error), sesgo medio (Bias), coeficiente de correlación (corr) y error relativo en los valores máximos.

Tabla 1. Métricas de desempeño del modelo LSTM_Teacher para eventos sísmicos de validación.

Variable	RMSE	MAE	Bias	corr	Error relativo en peak	Evento
$a_{base,X}$	0.161	0.103	0.052	0.918	0.008	EQ003
F_X	22.234	15.895	10.773	0.946	0.112	EQ003
M_Z	668.699	560.417	-498.420	0.958	0.069	EQ003
$a_{base,X}$	0.134	0.102	0.059	0.955	0.067	EQ024

F_X	20.417	15.724	11.787	0.976	0.160	EQ024
M_Z	769.972	631.147	-549.304	0.974	0.038	EQ024
$a_{base,X}$	1.129	0.622	0.089	0.846	0.102	EQ027
F_X	180.687	108.755	20.186	0.884	0.398	EQ027
M_Z	5511.277	3820.156	-882.114	0.893	0.086	EQ027
$a_{base,X}$	0.138	0.100	0.057	0.963	0.109	EQ029
F_X	22.946	17.435	14.026	0.968	0.078	EQ029
M_Z	745.464	638.211	-614.088	0.901	0.183	EQ029
$a_{base,X}$	0.063	0.057	0.054	0.965	0.020	EQ037
F_X	10.730	10.066	10.013	0.976	0.027	EQ037
M_Z	478.508	473.974	-473.974	0.944	0.769	EQ037
$a_{base,X}$	0.069	0.060	0.055	0.966	0.079	EQ038
F_X	11.722	10.285	10.112	0.980	0.033	EQ038
M_Z	515.488	479.298	-479.293	0.982	0.100	EQ038
$a_{base,X}$	0.107	0.084	0.070	0.979	0.157	EQ056
F_X	17.768	14.247	11.059	0.987	0.027	EQ056
M_Z	836.188	677.322	-555.583	0.986	0.098	EQ056
$a_{base,X}$	0.841	0.353	0.101	0.804	0.032	EQ058
F_X	136.595	59.034	9.845	0.879	0.287	EQ058
M_Z	4596.933	2383.274	-628.407	0.881	0.237	EQ058
$a_{base,X}$	0.088	0.071	0.054	0.877	0.163	EQ065
F_X	12.111	10.644	9.895	0.925	0.039	EQ065
M_Z	477.849	469.802	-469.802	0.759	1.566	EQ065
$a_{base,X}$	1.042	0.644	0.058	0.832	0.289	EQ066
F_X	173.185	117.104	5.532	0.891	0.191	EQ066
M_Z	7021.959	4961.586	-344.126	0.876	0.233	EQ066

Los resultados cuantitativos confirman el buen desempeño observado en la evaluación cualitativa. En la mayoría de los eventos, el modelo presenta coeficientes de correlación superiores a 0.9 para las tres variables, lo que indica una alta capacidad para reproducir la forma temporal de la respuesta.

En términos de error, la aceleración basal presenta los menores valores de RMSE y MAE, seguida por la fuerza horizontal, mientras que el momento flector muestra errores mayores, lo cual es consistente con su mayor complejidad física y de magnitud.

Se observa que en eventos de mayor intensidad (por ejemplo, EQ027, EQ058 y EQ066) los errores aumentan significativamente, particularmente en la predicción del momento flector. Esto sugiere que la precisión del modelo se ve afectada en condiciones extremas, donde los efectos no lineales y la interacción suelo–estructura adquieren mayor relevancia.

Adicionalmente, el sesgo negativo observado en el momento flector indica una tendencia del modelo a subestimar su magnitud, lo que es coherente con las discrepancias observadas en los picos de la señal.

A pesar de estas limitaciones, el modelo mantiene un desempeño robusto en una amplia variedad de eventos, lo que valida su capacidad de generalización.

6.2 Desempeño del modelo LSTM_Student (AF)

Con el objetivo de reducir la dimensionalidad del problema y evaluar la viabilidad de modelos simplificados, se desarrolló el modelo LSTM_Student (AF), orientado a predecir la aceleración basal y la fuerza horizontal en la interfaz a partir de un conjunto reducido de variables de entrada.

La selección del modelo final se realizó mediante un criterio de validación basado en el desempeño sobre múltiples eventos sísmicos, priorizando el peor caso (*worst-case validation*) con el fin de asegurar robustez. Se evaluaron distintas variantes de arquitectura, incluyendo modelos LSTM clásicos basados en ventanas superpuestas y modelos de tipo *stateful*.

Inicialmente, la evaluación basada en la ventana completa penalizaba fuertemente regiones de baja amplitud de la señal. Por esta razón, se introdujo el criterio ACTIVE_CORE, que considera únicamente el intervalo temporal que concentra el 95% de la energía del evento sísmico. Esta modificación permitió obtener una evaluación más representativa del comportamiento dinámico relevante.

Bajo este criterio, se observó una mejora significativa en el desempeño de los modelos, particularmente en configuraciones *stateful*. No obstante, el modelo LSTM clásico correspondiente al *fold* 1 presentó el mejor desempeño global, siendo seleccionado como modelo final.




Figura 16. Evolución de la función de pérdida (MSE) durante el entrenamiento y validación del modelo LSTM_Student (AF).




Figura 17. Evolución del coeficiente de correlación durante el entrenamiento y validación del modelo LSTM_Teacher (AF).

A diferencia del modelo Teacher, el proceso de entrenamiento del modelo Student (AF) evidencia una separación más marcada entre las curvas de entrenamiento y validación.

En particular, la función de pérdida en entrenamiento continúa disminuyendo de forma sostenida, mientras que la pérdida en validación se estabiliza e incluso presenta un aumento en etapas finales, lo que indica la presencia de sobreajuste (*overfitting*).

Este comportamiento se refleja también en la evolución del coeficiente de correlación, donde se observa una convergencia a valores significativamente menores que en el modelo Teacher, alcanzando niveles cercanos a 0.55–0.60 en validación.

Estos resultados confirman que la reducción de variables de entrada limita la capacidad del modelo para generalizar, obligándolo a ajustar en exceso las características presentes en los datos de entrenamiento.

En este contexto, el compromiso entre reducción de dimensionalidad y precisión del modelo se vuelve evidente, destacando la importancia de una adecuada selección de variables de entrada en modelos reducidos.

Las Figuras 18 y 19 presentan la comparación temporal entre las predicciones del modelo LSTM_Student (AF) y las respuestas obtenidas mediante OpenSees para un evento sísmico representativo.




Figura 18. Comparación temporal a_{base} (OpenSees vs Student) para Northridge-01 (EQ019).




Figura 19. Comparación temporal F_X (OpenSees vs Student) para Northridge-01 (EQ019).

En términos generales, el modelo logra capturar la forma global de la respuesta dinámica, incluyendo la localización temporal del evento principal y la evolución de la envolvente de amplitud.

En el caso de la aceleración basal, se observa un buen ajuste durante la fase de mayor energía del evento, reproduciendo adecuadamente la frecuencia dominante y la estructura de los ciclos. Sin embargo, el modelo tiende a suavizar los picos máximos, presentando una ligera subestimación en amplitud, particularmente en la zona de mayor intensidad (alrededor de 10–15 s).

Para la fuerza horizontal, el modelo reproduce de forma razonable la tendencia general de la señal, incluyendo la transición entre la fase transiente y la fase de oscilación libre. No obstante, se observan discrepancias más evidentes que en el caso de la aceleración, especialmente en la amplitud de los picos y en la dispersión de la señal posterior al peak. En particular, se aprecia que el modelo presenta una mayor dificultad para mantener la coherencia de fase en la respuesta de baja amplitud posterior al pulso principal, lo que sugiere limitaciones en la representación de efectos de memoria más sutiles.

Tabla 2. Métricas de desempeño del modelo LSTM_Student (AF).

Variable	RMSE	MAE	Bias	r	Error relativo en peak	Evento
$a_{base,X}$	0.191	0.145	-0.003	0.866	0.159	EQ003
F_X	36.052	29.640	-2.160	0.800	0.070	EQ003
$a_{base,X}$	0.092	0.056	-0.002	0.930	0.207	EQ008
F_X	9.751	6.807	-2.228	0.967	0.057	EQ008
$a_{base,X}$	0.154	0.112	-0.002	0.900	0.237	EQ013
F_X	32.110	24.966	-2.546	0.844	0.090	EQ013
$a_{base,X}$	0.946	0.623	-0.002	0.897	0.212	EQ019
F_X	160.194	125.473	-0.370	0.876	0.141	EQ019
$a_{base,X}$	0.304	0.206	-0.006	0.866	0.100	EQ025
F_X	67.174	46.247	-1.671	0.752	0.086	EQ025
$a_{base,X}$	0.656	0.468	-0.001	0.508	0.215	EQ030
F_X	160.266	114.048	-2.213	0.306	0.387	EQ030

$a_{base,X}$	0.106	0.043	-0.002	0.939	0.249	EQ035
F_X	11.619	6.344	-2.014	0.950	0.063	EQ035
$a_{base,X}$	0.035	0.027	0.001	0.916	0.047	EQ040
F_X	8.505	6.450	-2.174	0.822	0.099	EQ040
$a_{base,X}$	0.043	0.031	-0.002	0.984	0.040	EQ045
F_X	7.850	6.058	-2.407	0.988	0.096	EQ045
$a_{base,X}$	0.247	0.204	-0.001	0.668	0.122	EQ050
F_X	58.691	47.938	-2.447	0.490	0.039	EQ050
$a_{base,X}$	0.726	0.582	-0.003	0.300	0.222	EQ055
F_X	177.043	140.819	-3.491	0.175	0.353	EQ055
$a_{base,X}$	0.199	0.058	0.000	0.451	0.421	EQ060
F_X	25.118	10.430	-2.447	0.486	0.221	EQ060
$a_{base,X}$	0.072	0.041	-0.001	0.870	0.131	EQ065
F_X	7.391	4.768	-2.336	0.951	0.129	EQ065

Los resultados cuantitativos evidencian una degradación del desempeño respecto al modelo LSTM_Teacher, lo cual es esperable dada la reducción en la información de entrada.

En términos generales, la aceleración basal presenta un mejor desempeño relativo, con coeficientes de correlación que en varios casos superan 0.9 (por ejemplo, EQ008, EQ035, EQ045), mientras que la fuerza horizontal muestra una mayor dispersión en los resultados.

Se identifican eventos con desempeño significativamente inferior (por ejemplo, EQ030 y EQ055), donde los coeficientes de correlación disminuyen considerablemente y los errores aumentan de forma importante. Estos casos corresponden a registros donde la dinámica del sistema presenta características más complejas o mayor intensidad, lo que pone en evidencia las limitaciones del modelo reducido.

En particular, la caída de correlación en algunos eventos sugiere que el modelo no logra capturar completamente la relación entre la excitación sísmica y la respuesta estructural cuando se eliminan variables relevantes del sistema.

A pesar de estas limitaciones, el modelo mantiene una fidelidad global aceptable en la mayoría de los eventos, lo que demuestra su capacidad para aproximar la respuesta dinámica utilizando un conjunto reducido de variables.

6.3 Desempeño del modelo LSTM_Student (Mz)

A diferencia del modelo Student (AF), este modelo aborda una variable cuya dependencia está más directamente condicionada por el estado dinámico del sistema, particularmente por las fuerzas basales y la excitación sísmica. Esto permite analizar en qué medida un modelo reducido es capaz de capturar relaciones físicas más estructuradas.

El proceso de entrenamiento del modelo LSTM_Student (Mz) presenta un comportamiento significativamente más estable que el observado en el modelo Student (AF). La función de pérdida como muestra la figura 20, presenta una disminución sostenida tanto en entrenamiento como en validación durante las primeras épocas, alcanzando un mínimo en torno a la época 15. Posteriormente, se observa un leve aumento en la pérdida de validación, indicando un inicio de sobreajuste, aunque de forma mucho más controlada.

En cuanto al coeficiente de correlación (ver figura 21), se observa una rápida convergencia a valores cercanos a 1.0 tanto en entrenamiento como en validación, lo que refleja una alta capacidad del modelo para capturar la relación entre las variables de entrada y el momento basal.

Este comportamiento contrasta con el modelo Student (AF), evidenciando que la variable M_z presenta una relación funcional más simple e inferible a partir de las entradas disponibles. En consecuencia, el modelo logra generalizar de forma efectiva, manteniendo un alto desempeño incluso con un conjunto reducido de variables.




Figura 20. Evolución de la función de pérdida (MSE) durante el entrenamiento y validación del modelo LSTM_Student (M_z).




Figura 21. Evolución del coeficiente de correlación durante el entrenamiento y validación del modelo LSTM_Teacher (M_z).

La Figura 22 muestra que el modelo LSTM_Student (M_z) reproduce con cierta fidelidad la evolución temporal del momento basal durante la fase de mayor energía del evento sísmico, capturando de manera aceptable tanto la amplitud como la frecuencia dominante de la respuesta.




Figura 22. Comparación temporal M_z (OpenSees vs Student_ M_z) para Northridge-01 (EQ019).

En particular, se observa un excelente ajuste en la zona de excitación principal (aproximadamente entre 10 y 20 s), donde el modelo logra representar correctamente los ciclos de carga y descarga asociados a la respuesta dinámica.

Sin embargo, en la fase posterior al peak, caracterizada por oscilaciones libres de menor amplitud, el modelo tiende a amortiguar la respuesta, subestimando progresivamente la amplitud de las oscilaciones. Este comportamiento sugiere que, si bien el modelo captura correctamente la dinámica forzada, presenta limitaciones en la representación de efectos de memoria de largo plazo.

A pesar de esta discrepancia en la fase de baja amplitud, la forma global de la señal y la coherencia temporal se mantienen adecuadamente representadas.

En la tabla 3 los resultados cuantitativos evidencian un desempeño significativamente superior al observado en el modelo Student (AF).

Tabla 3. Métricas de desempeño Student (M_z)

Variable	RMSE	MAE	Bias	r	Error relativo en peak	Evento
M_z	246.864	163.261	77.913	0.969	0.045	EQ004
M_z	274.648	186.225	68.863	0.995	0.002	EQ009
M_z	273.589	206.965	66.886	0.997	0.064	EQ014
M_z	594.344	382.320	-11.826	0.991	0.093	EQ021
M_z	1036.276	813.587	-126.513	0.998	0.085	EQ027
M_z	305.101	242.523	61.216	0.997	0.032	EQ032
M_z	127.317	104.196	80.457	0.996	0.047	EQ038
M_z	121.239	99.551	81.783	0.986	0.016	EQ043
M_z	171.941	126.255	81.694	0.965	0.034	EQ048
M_z	147.025	116.609	78.811	0.997	0.019	EQ053
M_z	810.749	534.759	-18.156	0.999	0.124	EQ058
M_z	266.546	192.967	80.263	0.786	0.320	EQ064

En la mayoría de los eventos, el coeficiente de correlación supera valores de 0.99, lo que indica una alta capacidad del modelo para reproducir la dinámica del momento basal. Incluso en casos con mayor complejidad dinámica (por ejemplo, EQ027 y EQ058), el modelo mantiene valores cercanos a la unidad.

Los errores relativos en los picos se mantienen en niveles bajos, generalmente inferiores al 10%, lo que demuestra una adecuada capacidad para capturar las máximas demandas estructurales.

No obstante, se identifican algunos casos con desempeño inferior (por ejemplo, EQ064), donde el coeficiente de correlación disminuye y el error relativo en el peak aumenta considerablemente. Estos casos pueden estar asociados a condiciones particulares del registro sísmico o a comportamientos dinámicos no suficientemente representados en el conjunto de entrenamiento.

En términos generales, los resultados indican que el momento basal puede ser modelado de forma efectiva como una función condicionada a las variables disponibles, lo que sugiere que su dependencia respecto a las entradas es más directa y estructurada en comparación con otras variables del sistema.

A diferencia de los resultados observados en validación, la comparación temporal evidencia una degradación significativa en la capacidad del modelo para reproducir la respuesta dinámica. En particular, se observan discrepancias relevantes tanto en la amplitud como en la fase de la señal, así como una sobreestimación generalizada en ciertos intervalos. Este comportamiento contrasta con los altos valores de correlación obtenidos durante el entrenamiento y validación.

Esta inconsistencia se explica principalmente por la forma en que se construyen las variables de entrada del modelo Student (M_z). En efecto, el modelo utiliza como entradas las variables a_{base} y F_x , las cuales, durante el entrenamiento y validación, corresponden a valores obtenidos directamente desde las simulaciones en OpenSees.

Sin embargo, en un escenario de inferencia real, dichas variables deben ser provistas por el modelo Student (AF), introduciendo un error adicional asociado a la propagación de incertidumbre entre modelos.

En este contexto, la evaluación basada en métricas como MSE y correlación, calculadas sobre el conjunto de validación, no captura completamente este efecto, ya que no considera la dependencia entre modelos ni el error acumulado en la cadena de predicción.

Por lo tanto, los resultados obtenidos sugieren que, si bien el modelo LSTM_Student (M_z) es capaz de aprender la relación funcional bajo condiciones ideales de entrada, su desempeño en un esquema completamente desacoplado, y se ve afectado por la calidad de las variables de entrada.

6.4 Comparación global del framework (OpenSees vs Teacher vs Student)

6.4.1 Comparación cuantitativa global

Finalmente, se realizó una comparación global entre los tres modelos considerados; simulación directa en OpenSees, modelo LSTM_Teacher, modelo reducido LSTM_Student. El objetivo de esta comparación es evaluar la viabilidad de utilizar el modelo reducido como sustituto del dominio de suelo.

Los resultados mostrados en las Tablas 4 y 5, denotan que el modelo LSTM_Teacher presenta el mejor desempeño global, con altos niveles de correlación y bajos errores en todas las variables analizadas, incluso en eventos fuera del conjunto de entrenamiento.

Por su parte, el modelo LSTM_Student logra mantener una fidelidad razonable en la predicción de variables directamente asociadas a la excitación sísmica, como la aceleración basal y la fuerza horizontal, aunque con una degradación moderada respecto al modelo Teacher.

Sin embargo, para la variable momento basal M_z , el modelo Student presenta una degradación significativa en ciertos eventos, particularmente en escenarios de inferencia completamente desacoplada, donde las variables de entrada son generadas por otro modelo.

Tabla 4. Resumen de métricas Teacher en evaluación de eventos fuera de entrenamiento / validación.

Evento	Target	RMSE promedio	Bias/Sesgo	r	Error relativo en peak	Duración de predicción [s]
EQ007	$a_{base,X}$	0.078	0.001	0.993	0.127	38.210
EQ007	F_X	10.946	2.214	0.991	0.016	38.210
EQ007	M_Z	241.911	-98.959	0.896	0.479	38.210
EQ019	$a_{base,X}$	0.867	0.024	0.917	0.107	7.622
EQ019	F_X	114.324	2.651	0.944	0.212	7.622
EQ019	M_Z	3007.876	-210.528	0.849	0.281	7.622
EQ052	$a_{base,X}$	0.037	0.003	0.986	0.174	36.416
EQ052	F_X	6.786	1.324	0.987	0.071	36.416
EQ052	M_Z	218.452	-63.693	0.996	0.082	36.416

Tabla 5. Resumen de métricas Student en evaluación de eventos fuera de entrenamiento / validación.

Evento	Target	RMSE promedio	Bias/Sesgo	Corr promedio	Error relativo en peak	Duración de predicción [s]
EQ007	$a_{base,X}$	0.161	-0.008	0.953	0.233	0.752
EQ007	F_X	23.300	-2.114	0.947	0.163	0.752
EQ007	M_Z	440.187	189.238	0.822	0.467	0.752
EQ019	$a_{base,X}$	0.946	-0.002	0.897	0.171	3.874
EQ019	F_X	159.789	-0.400	0.876	0.059	3.874
EQ019	M_Z	5288.731	55.791	0.391	0.003	3.874
EQ052	$a_{base,X}$	0.131	0.001	0.718	0.087	3.881
EQ052	F_X	30.367	-2.339	0.547	0.129	3.881
EQ052	M_Z	1315.793	165.285	0.125	0.430	3.881

Los resultados muestran que el modelo Teacher presenta el mejor desempeño global, mientras que el modelo Student logra mantener una fidelidad razonable a pesar de la significativa reducción en la información de entrada.

6.4.2 Comparación por variable a_{base}

La aceleración basal es la variable mejor representada por ambos modelos. El modelo Teacher alcanza correlaciones superiores a 0.98 en la mayoría de los casos, mientras que el modelo Student mantiene valores elevados (en torno a 0.9), evidenciando que esta variable depende principalmente de la excitación sísmica directa.

No obstante, el aumento en RMSE y la dispersión observada en los gráficos *scatter* de las figuras 23 y 24 con eventos fuera del entrenamiento indican una pérdida de precisión menor en amplitudes extremas para LSTM_Student, lo cual se asocia a la reducción de variables de entrada.

Las distribuciones de error para la aceleración basal muestran un comportamiento consistente y bien centrado en torno a cero para ambos modelos.

En el caso del modelo LSTM_Teacher, el histograma muestra que la distribución presenta una alta concentración alrededor del valor medio, con una desviación estándar de aproximadamente 0.586 y un sesgo positivo leve (+0.0585). Esto indica una ligera sobreestimación sistemática, aunque de magnitud reducida. La forma de la distribución es aproximadamente gaussiana, con colas relativamente acotadas, lo que evidencia una predicción estable y robusta.

Por su parte, el modelo LSTM_Student presenta una distribución también centrada en cero, pero con una mayor dispersión (desviación estándar ≈ 0.667). A diferencia del Teacher, el sesgo es prácticamente nulo (-0.0014), lo que indica ausencia de tendencia sistemática en la predicción.

No obstante, la mayor amplitud de la distribución y la presencia de colas más extendidas reflejan una menor precisión en la estimación, particularmente en valores extremos. En términos generales, la variable a_{base} es bien capturada por ambos modelos, aunque el modelo Student presenta una leve degradación en precisión.




Figura 23. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Teacher para a_{base} .




Figura 24. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Student para a_{base} .

6.4.3 Comparación por variable F_x

Para la fuerza horizontal, se observa una mayor sensibilidad a la reducción de información. Si bien el modelo Teacher mantiene altos niveles de correlación (≈ 0.95), el modelo Student presenta una mayor dispersión en los resultados, con disminuciones en correlación y aumento en el error estándar.

Esto sugiere que F_x depende en mayor medida de variables internas del sistema (desplazamientos interfaz, entre otros), lo que limita la capacidad del modelo reducido para capturar completamente su comportamiento.

El modelo LSTM_Teacher presenta una distribución de error fuertemente concentrada en torno a cero, con una desviación estándar de aproximadamente 72.1 y un sesgo positivo moderado (+12.7). La distribución es relativamente simétrica y con colas acotadas, lo que indica un buen nivel de precisión global y una leve tendencia a sobreestimar la fuerza. En contraste, el modelo LSTM_Student muestra una distribución considerablemente más dispersa, con una desviación estándar significativamente mayor (≈ 113). Si bien el sesgo es bajo (-1.24), la mayor amplitud de la distribución y la presencia de colas más extendidas evidencian una mayor variabilidad en el error.

Esta diferencia indica que el modelo Student tiene dificultades para capturar completamente la dinámica de F_x , lo cual es consistente con la reducción de variables de entrada. La fuerza horizontal depende en mayor medida de estados internos del sistema, lo que limita la capacidad del modelo reducido para representarla con precisión.




Figura 25. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Teacher para F_X .




Figura 26. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Student para F_X .

6.4.4 Comparación por variable M_z

El caso del momento basal presenta el comportamiento más complejo. En condiciones de validación (con inputs provenientes de OpenSees), el modelo Student (M_z) muestra un desempeño sobresaliente, con correlaciones cercanas a 1.0. Sin embargo, al evaluar el modelo en condiciones de inferencia real (fuera del conjunto de entrenamiento y utilizando inputs provenientes del modelo Student (AF)), el desempeño se degrada significativamente, tal como se observa en los gráficos de dispersión y distribuciones de error.

En particular, se observa una alta dispersión respecto a la línea identidad y un aumento considerable en la desviación estándar del error, lo que evidencia la acumulación de errores en la cadena de predicción. Este comportamiento confirma que el momento basal es altamente sensible a la calidad de las variables de entrada, y que su modelación requiere una representación consistente de las variables intermedias.

El análisis de los histogramas de error en las figuras 27 y 28 para el momento basal revela el contraste más significativo entre ambos modelos. El modelo LSTM_Teacher presenta una distribución centrada en un sesgo negativo (-601), con una desviación estándar elevada ($\approx 1.87 \times 10^{-3}$). Si bien la dispersión

es considerable, la distribución mantiene una forma relativamente concentrada en torno a su media, lo que indica que el modelo logra capturar la tendencia general del momento basal, aunque con una subestimación sistemática. Por otro lado, el modelo LSTM_Student presenta una distribución mucho más dispersa, con una desviación estándar aproximadamente el doble ($\approx 3.74 \times 10^{-3}$) y un sesgo positivo (+94.7). La forma de la distribución muestra colas largas y una menor concentración en torno al valor medio, lo que evidencia la presencia de errores significativos en múltiples rangos de la señal.

Esta alta dispersión es consistente con los resultados observados en los gráficos de dispersión y comparaciones temporales, y se atribuye principalmente a la propagación de errores desde las variables de entrada (a_{base} y F_x), las cuales son estimadas por el modelo Student (AF). En consecuencia, el modelo Student (Mz) muestra una alta sensibilidad a la calidad de sus entradas, lo que limita su desempeño en condiciones de inferencia real.




Figura 27. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Teacher para M_z .




Figura 28. Diagrama de dispersión entre valores predichos - simulación; junto a histograma del error de predicción para LSTM_Student para M_z .

En conjunto, el análisis de las distribuciones de error confirma que la reducción del modelo impacta de manera diferenciada según la variable considerada. Mientras que la aceleración basal mantiene un

comportamiento robusto, la fuerza horizontal y, especialmente, el momento basal evidencian una degradación progresiva asociada a la pérdida de información y a la propagación de errores en el esquema desacoplado.

6.5 Costo computacional

Con el objetivo de evaluar la eficiencia computacional del framework propuesto, se compararon los tiempos de simulación asociados al modelo de elementos finitos en OpenSees y a los modelos basados en redes neuronales LSTM, tanto en su versión completa (Teacher) como reducida (Student).

Los tiempos de referencia para OpenSees corresponden al tiempo real de simulación de cada evento sísmico (denotado como t_{PC}), incluyendo el análisis completo (gravitacional y dinámico). Estas simulaciones fueron ejecutadas en un equipo con procesador AMD Ryzen 9 7900 (12 núcleos), 64 GB de memoria RAM y tarjeta gráfica NVIDIA GeForce RTX 3060, utilizando el entorno de STKO/OpenSees, el cual permite el uso de múltiples núcleos en paralelo. Por otra parte, los tiempos asociados a las redes neuronales (denotados como t_{NN}) corresponden al tiempo total de evaluación por evento, medido mediante el pipeline completo de predicción, incluyendo preprocesamiento, inferencia del modelo y reconstrucción de la señal de salida. Estas evaluaciones fueron realizadas utilizando una GPU ASUS Dual GeForce RTX™ 4060 OC Edition 8GB GDDR6, mediante un entorno de ejecución en contenedor.

La Tabla 6 presenta una comparación directa entre el tiempo de simulación en OpenSees (t_{PC}), el tiempo de inferencia de los modelos de redes neuronales (t_{NN}) y la duración real del registro sísmico (t_{sismo}) en el tiempo historia que se utiliza por evento. Adicionalmente, se incluyen razones adimensionales que permiten evaluar el desempeño relativo de cada enfoque en términos de simulación en tiempo real.

En particular, el cociente $\frac{t_{NN}}{t_{sismo}}$ permite determinar si el modelo es capaz de operar en condiciones compatibles con simulación en tiempo real, mientras que el cociente $\frac{t_{PC}}{t_{sismo}}$ cuantifica el costo computacional relativo de la simulación tradicional basada en elementos finitos.

Los resultados muestran que el modelo LSTM_Teacher presenta tiempos de inferencia significativamente menores que la simulación en OpenSees, con razones $\frac{t_{NN}}{t_{sismo}}$ del orden de 0.4 a 0.8, lo que indica que es capaz de reproducir la respuesta dinámica en tiempos comparables a la duración del evento sísmico.

Por su parte, el modelo LSTM_Student reduce aún más el costo computacional, alcanzando razones $\frac{t_{NN}}{t_{sismo}}$ inferiores a 0.2 en todos los casos analizados, lo que evidencia su potencial para aplicaciones que requieren alta eficiencia, como simulación en tiempo real o sistemas híbridos.

En contraste, la simulación en OpenSees presenta razones $\frac{t_{PC}}{t_{sismo}}$ considerablemente mayores, alcanzando valores entre 7.5 y 25.4, lo que confirma el alto costo computacional asociado a la modelación explícita del dominio de suelo.

Tabla 6. Comparación del costo computacional entre simulación en OpenSees y modelos LSTM (Teacher y Student).

Evento	t_{sismo} sec	t_{PC} min	$t_{NN}(\text{Teacher})$ sec	$\frac{t_{NN}(\text{Teacher})}{t_{sismo}}$	$t_{NN}(\text{Student})$ sec	$\frac{t_{NN}(\text{Student})}{t_{sismo}}$	$\frac{t_{PC}}{t_{sismo}}$
Whittier Narrows- 01	18.15	4	8.10	0.45	1.32	0.07	13.23

Northridg e-01	60.01	8	38.74	0.65	8.08	0.13	8.00
Chi-Chi_ Taiwan- 05	52.00	22	40.57	0.78	8.01	0.15	25.39
Lick Observato ry Mt. Hamilton CA USA- 07	200	25	141.79	0.71	30.64	0.15	7.50

En el caso del modelo Teacher, los tiempos de evaluación se reducen desde escalas del orden de minutos a segundos. Por ejemplo, para el evento *Lick Observatory Mt. Hamilton CA USA-07*, el tiempo de simulación en OpenSees es de aproximadamente 25 minutos (1500 segundos), mientras que la evaluación mediante la red neuronal toma aproximadamente 142 segundos, lo que representa una reducción de aproximadamente un orden de magnitud.

Por su parte, el modelo Student presenta una mejora adicional significativa en términos de eficiencia computacional, alcanzando tiempos de evaluación considerablemente menores. Para el mismo evento, el tiempo de evaluación se reduce a aproximadamente 31 segundos, lo que implica una reducción de casi dos órdenes de magnitud respecto al modelo numérico original.

Este comportamiento es consistente en todos los eventos analizados, evidenciando que el modelo Student no solo reduce la dimensionalidad del problema (al utilizar menos variables de entrada), sino que además mejora sustancialmente la eficiencia computacional del proceso de predicción.

En términos de simulación en tiempo real, los resultados muestran que el cociente $\frac{t_{NN}}{t_{sismo}}$ se encuentra en el rango aproximado de 0.4 a 0.8 para el modelo Teacher, mientras que para el modelo Student este valor disminuye significativamente, alcanzando valores entre 0.07 y 0.15, lo que evidencia su capacidad para operar en condiciones altamente eficientes desde el punto de vista computacional. En contraste, la simulación completa basada en elementos finitos presenta razones $\frac{t_{PC}}{t_{sismo}}$ considerablemente mayores, con valores que oscilan entre 7.5 y 25.4, lo que confirma el elevado costo computacional asociado a la modelación explícita del dominio de suelo en OpenSees.

7 Conclusiones y comentarios

El presente trabajo abordó la modelación eficiente del problema de interacción suelo-estructura mediante el uso de redes neuronales recurrentes tipo LSTM, con el objetivo de desarrollar un modelo reducido capaz de sustituir el dominio de suelo en análisis dinámicos.

Para ello, se implementó un enfoque basado en una arquitectura *Teacher-Student*, donde el modelo LSTM_Teacher aprende la relación completa entre la excitación sísmica y la respuesta estructural, mientras que el modelo LSTM_Student busca reproducir dicha respuesta utilizando un conjunto reducido de variables de entrada.

A partir del desarrollo del presente trabajo y del análisis de los resultados obtenidos, se pueden destacar las siguientes conclusiones principales:

1. Se logró desarrollar un modelo LSTM_Teacher capaz de reproducir con alta fidelidad la respuesta dinámica del sistema, alcanzando elevados niveles de correlación y bajos errores en variables clave como aceleración basal, fuerza horizontal y momento basal.

2. Se implementó un modelo reducido LSTM_Student que, a partir de una reducción significativa en las variables de entrada, mantiene un desempeño aceptable en la predicción de ciertas variables, particularmente la aceleración basal.
3. Se evaluó el desempeño de ambos modelos en escenarios de validación e inferencia fuera del conjunto de entrenamiento, permitiendo identificar limitaciones asociadas a la generalización y a la propagación de errores entre modelos.

A partir de los resultados obtenidos, se desprenden las siguientes conclusiones:

1. Viabilidad del enfoque basado en aprendizaje automático

El modelo LSTM_Teacher demuestra que es posible aproximar con alta precisión la respuesta dinámica de sistemas suelo-estructura mediante modelos de aprendizaje profundo, reduciendo la necesidad de simulaciones numéricas completas.

2. Impacto de la reducción de variables de entrada

La disminución de la información de entrada en el modelo Student genera una degradación en el desempeño, cuya magnitud depende de la variable analizada. Mientras que la aceleración basal presenta una relación más directa con la excitación sísmica, variables como la fuerza y el momento basal dependen de estados internos más complejos.

3. Sensibilidad a la propagación de errores

Se evidenció que el desempeño del modelo reducido se ve fuertemente afectado cuando las variables de entrada son generadas por otro modelo, lo que introduce un efecto de propagación de errores que no es capturado en la validación tradicional.

4. Diferencias en la complejidad de las variables objetivo

No todas las variables del sistema presentan el mismo nivel de dificultad de modelación. El momento basal, en particular, muestra una alta sensibilidad a la calidad de las entradas, lo que limita su predicción en esquemas desacoplados.

5. Reducción significativa del costo computacional

El uso de modelos basados en redes neuronales permite una reducción significativa del costo computacional en comparación con simulaciones numéricas tradicionales en OpenSees. En particular:

- El modelo LSTM_Teacher logra reducciones del orden de un orden de magnitud en los tiempos de evaluación.
- El modelo LSTM_Student alcanza reducciones de hasta dos órdenes de magnitud, permitiendo tiempos de evaluación considerablemente menores que la duración física del evento sísmico.

Este comportamiento habilita la aplicación de estos modelos en escenarios donde el costo computacional es una restricción crítica, tales como simulación en tiempo real o evaluación masiva de escenarios sísmicos.

En conjunto, los resultados obtenidos confirman el potencial de los modelos basados en redes neuronales para la reducción computacional de problemas de interacción suelo-estructura, permitiendo aproximar la respuesta dinámica del sistema sin necesidad de modelar explícitamente el dominio de suelo en cada simulación.

No obstante, también se evidencia la necesidad de abordar de manera explícita la consistencia entre modelos acoplados y la propagación de errores en arquitecturas de tipo Teacher-Student, lo cual constituye un desafío relevante para su aplicación práctica.

Por último, es importante enfatizar que los modelos LSTM desarrollados en este trabajo no constituyen aún una alternativa completamente validada para reemplazar de forma directa la modelación explícita del dominio de suelo en aplicaciones de ingeniería. Si bien los resultados obtenidos son prometedores,

el desempeño observado presenta limitaciones relevantes, particularmente en términos de generalización y propagación de errores en esquemas acoplados.

En este sentido, el presente trabajo debe entenderse como una etapa inicial en el desarrollo de modelos de orden reducido basados en aprendizaje automático para problemas de interacción suelo–estructura, cuyo perfeccionamiento requiere investigación adicional antes de su aplicación en contextos de diseño o análisis estructural real. Por lo tanto, se recomienda interpretar los resultados obtenidos como evidencia del potencial del enfoque propuesto, más que como una solución definitiva lista para su implementación práctica.

7.1 Trabajo futuro

A partir de los resultados obtenidos en este trabajo, se identifican diversas líneas de investigación que permitirían mejorar el desempeño y la robustez del modelo propuesto.

7.1.1 *Data Augmentation* para mejorar la robustez del modelo Teacher

Una línea de investigación relevante consiste en la generación de nuevos datos sintéticos mediante técnicas de *data augmentation*, con el objetivo de ampliar la diversidad del conjunto de entrenamiento.

Esto permitiría mejorar la capacidad de generalización del modelo LSTM_Teacher, particularmente frente a eventos sísmicos no considerados previamente. Entre las estrategias posibles se incluyen el escalamiento de amplitudes, modificaciones en la configuración del modelo para distintos tipos de suelo, y/o cambios en la amortiguación del sistema.

7.1.2 Incorporación de comportamiento no lineal del suelo

Otra línea de investigación consiste en incorporar modelos de suelo con comportamiento no lineal en la generación del dataset.

En el presente trabajo se utilizó una aproximación simplificada del suelo, lo que limita la complejidad de la respuesta dinámica. La inclusión de efectos no lineales permitiría capturar fenómenos como degradación de rigidez, histéresis y acumulación de deformaciones, generando un dataset más representativo de condiciones reales.

7.1.3 Técnicas avanzadas de *Deep Learning* (*Knowledge distillation*)

Finalmente, una línea de investigación clave corresponde a la aplicación de técnicas avanzadas de *knowledge distillation* para mejorar el modelo Student.

En este trabajo, la reducción de variables de entrada se realizó de forma directa, lo que implica una pérdida de información relevante. La implementación de técnicas de distillation permitiría transferir conocimiento del modelo Teacher al modelo Student de manera más eficiente, preservando información latente del sistema.

Esto podría lograrse mediante funciones de pérdida basadas en representaciones internas, esquemas multitarea o arquitecturas híbridas, mejorando el desempeño del modelo reducido y reduciendo la propagación de errores.

8 Referencias

- Acuña Izquierdo, F. L., Smith Castilla, J., Luna Villadiego, M., & Barrios Valverde, J. A. (2023). Interacción Suelo Estructura: una Revisión del Estado del Arte. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4). https://doi.org/10.37811/cl_rcm.v7i4.7427
- Amezquita-Sancheza, J. P., Valtierra-Rodriguez, M., & Adeli, H. (2020). Machine learning in structural engineering. *Scientia Iranica*, 27(6), 2645–2656. <https://doi.org/10.24200/sci.2020.22091>
- Bas, E. E., & Moustafa, M. A. (2020). Performance and Limitations of Real-Time Hybrid Simulation with Nonlinear Computational Substructures. *Experimental Techniques*, 44(6). <https://doi.org/10.1007/s40799-020-00385-6>

- Bolisetti, C., Whittaker, A. S., & Coleman, J. L. (2018). Linear and nonlinear soil-structure interaction analysis of buildings and safety-related nuclear structures. *Soil Dynamics and Earthquake Engineering*, 107, 218–233. <https://doi.org/10.1016/J.SOILDYN.2018.01.026>
- Cortes, C., Research, G., York, N., Mohri, M., & Rostamizadeh, A. (2009). *L 2 Regularization for Learning Kernels*.
- Fernández, T., & Sepúlveda, C. (2025). Efecto de la Interacción Suelo-Estructura en la Amplificación Dinámica del Corte en Muros. Artículo de conferencia en *XII Congreso Chileno de Geotecnia* (SOCHIGE), Santiago, Chile.
- Hancock, J., Bommer, J. J., & Stafford, P. J. (2008). Numbers of scaled and matched accelerograms required for inelastic dynamic analyses. *Earthquake Engineering and Structural Dynamics*, 37(14), 1585–1607. <https://doi.org/10.1002/eqe.827>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3). <https://doi.org/10.1007/s12525-021-00475-2>
- Kingma, D. P., & Ba, J. (2017). *Adam: A Method for Stochastic Optimization*. <http://arxiv.org/abs/1412.6980>
- Kramer, S. Lawrence. (1996). *Geotechnical earthquake engineering*. Prentice Hall.
- Malik, F. N., Gorini, D. N., Ricles, J., & Rahnemoonfar, M. (2025). Multi-physics framework for seismic Real-time Hybrid Simulation of soil–foundation–structural systems. *Engineering Structures*, 334. <https://doi.org/10.1016/j.engstruct.2025.120247>
- McKenna, F. (2011). OpenSees: A framework for earthquake engineering simulation. *Computing in Science and Engineering*, 13(4). <https://doi.org/10.1109/MCSE.2011.66>
- Mucha, W. (2019). Application of artificial neural networks in hybrid simulation. *Applied Sciences (Switzerland)*, 9(21). <https://doi.org/10.3390/app9214495>
- Mylonakis, G., & Gazetas, G. (2000). SEISMIC SOIL-STRUCTURE INTERACTION: BENEFICIAL OR DETRIMENTAL? *Journal of Earthquake Engineering*, 4(3), 277–301. <https://doi.org/10.1080/13632460009350372>
- Ñanculef, R., & Calvo, J. C. (2018). *EVALUACIÓN DE FRAMEWORKS DE SOFTWARE PARA LA IMPLEMENTACIÓN DE REDES NEURONALES ARTIFICIALES*.
- Noto, F., Iovino, M., Di Laora, R., de Sanctis, L., & Franchin, P. (2022). Non-linear dynamic analysis of buildings founded on piles: Simplified modelling strategies for soil-foundation-structure interaction. *Earthquake Engineering and Structural Dynamics*, 51(4). <https://doi.org/10.1002/eqe.3589>
- Ricles, J., Quiel, S., Marullo, T., & Malik, F. (2024). Real-time hybrid simulation of structural systems with soil-foundation interaction effects using neural networks. *Earthquake Engineering and Structural Dynamics*. <https://doi.org/10.1002/eqe.4236>
- Simpson, T., Dervilis, N., Couturier, P., Maljaars, N., & Chatzi, E. (2022). *Nonlinear Reduced Order Modelling of Soil Structure Interaction Effects via LSTM and Autoencoder Neural Networks*. <https://doi.org/10.48550/arXiv.2203.01842>
- Srivastava, N., Hinton, G., Krizhevsky, A., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. In *Journal of Machine Learning Research* (Vol. 15).
- Wolff, J. P. (1985). *Dynamic Soil Structure Interaction*.

9 Anexos

9.1 Enlaces notebook Colab

Con el objetivo de facilitar la revisión y replicabilidad del flujo computacional desarrollado, se dispone de un repositorio público en GitHub que contiene los notebooks utilizados durante la memoria. Estos notebooks corresponden al procesamiento inicial de datos, entrenamiento del modelo LSTM_Teacher, entrenamiento de los modelos LSTM_Student y consolidación de resultados.

Repositorio GitHub: [\[Memoria-LSTM-SSI\]](#)

El repositorio se publica con fines académicos y de revisión metodológica. Los datos pesados, registros originales, archivos completos de simulación y modelos entrenados pueden no encontrarse incluidos debido a restricciones de tamaño, por lo que la reproducción completa requiere disponer de la estructura de datos descrita en la metodología.

9.2 Plots comparación metodológica entrenamiento secuencial ventanas (a) vs serie completa (b) vs combinación de ambas (c)




Figura 29. Comparación temporal a_{base} (Ventanas vs Secuencia completa vs ambas) para Whittier Narrows-01 (EQ007).




Figura 30. Comparación temporal F_x (Ventanas vs Secuencia completa vs ambas) para Whittier Narrows-01 (EQ007).




Figura 31. Comparación temporal M_z (Ventanas vs Secuencia completa vs ambas) para Whittier Narrows-01 (EQ007).




Figura 32. Comparación temporal a_{base} (Ventanas vs Secuencia completa vs ambas) para Northridge-01 (EQ019).




Figura 33. Comparación temporal F_x (Ventanas vs Secuencia completa vs ambas) para Northridge-01 (EQ019).




Figura 34. Comparación temporal Mz (Ventanas vs Secuencia completa vs ambas) para Whittier Northridge-01 (EQ019).

9.3 Plots predicción tiempo historia de validación de redes neuronales para LSTM_Teacher




Figura 35. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Morgan Hill -84 (EQ004).




Figura 36. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Morgan Hill -84 (EQ004).




Figura 37. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Morgan Hill-84 (EQ012).




Figura 38. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ012).




Figura 39. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ012).




Figura 40. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ012).




Figura 41. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ014).




Figura 42. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ014).




Figura 43. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Loma Prieta-89 (EQ014).




Figura 44. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Northridge-01 (EQ021).




Figura 45. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Northridge-01 (EQ021).




Figura 46. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Northridge-01 (EQ021).




Figura 47. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Kocaeli_Turkey (EQ022).




Figura 48. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Kocaeli_Turkey (EQ022).




Figura 49. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Kocaeli_Turkey (EQ022).




Figura 50. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ027).




Figura 51. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ027).




Figura 52. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ027).




Figura 53. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ028).




Figura 54. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ028).




Figura 55. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ028).




Figura 56. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ030).




Figura 57. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ030).




Figura 58. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-99 (EQ030).




Figura 59. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-02 (EQ037).




Figura 60. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-02 (EQ037).




Figura 61. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-02 (EQ037).




Figura 62. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-04 (EQ045).




Figura 63. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-04 (EQ045).




Figura 64. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-04 (EQ045).




Figura 65. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ050).




Figura 66. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ050).




Figura 67. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Chi-Chi_Taiwan-05 (EQ050).




Figura 68. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para L'Aquila (aftershock 2)_Italy (EQ068).




Figura 69. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para L'Aquila (aftershock 2)_Italy (EQ068).




Figura 70. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para L'Aquila (aftershock 2) _Italy (EQ068).




Figura 71. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ070).




Figura 72. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ070).




Figura 73. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ070).




Figura 74. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ073).




Figura 75. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ073).




Figura 76. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ073).




Figura 77. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ075).




Figura 78. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ075).




Figura 79. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Iwate_Japan-08 (EQ075).




Figura 80. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher) para Mount Wilson Obsv-08 (EQ083).




Figura 81. Comparación temporal de F_x (OpenSees vs LSTM_Teacher) para Mount Wilson Obsv-08 (EQ083).




Figura 82. Comparación temporal de M_z (OpenSees vs LSTM_Teacher) para Mount Wilson Obsv-08 (EQ083).

9.4 Plots predicción tiempo historia de validación de redes neuronales para LSTM_Student




Figura 83. Comparación temporal de a_{base} (OpenSees vs LSTM_Sudent) para Coyote Lake -79 (EQ003).




Figura 84. Comparación temporal de F_x (OpenSees vs LSTM_Sudent) para Coyote Lake -79 (EQ003).




Figura 85. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Morgan Hill -84 (EQ009).




Figura 86. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Morgan Hill -84 (EQ009).




Figura 87. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Loma Prieta (EQ014).




Figura 88. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Loma Prieta (EQ014).




Figura 89. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Kocaeli_Turkey (EQ022).




Figura 90. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Kocaeli_Turkey (EQ022).




Figura 91. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan (EQ027).




Figura 92. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan (EQ027).




Figura 93. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan (EQ032).




Figura 94. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan (EQ032).




Figura 95. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan-02 (EQ037).




Figura 96. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_ Taiwan-02 (EQ037).




Figura 97. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-04 (EQ042).




Figura 98. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-04 (EQ042).




Figura 99. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-04 (EQ047).




Figura 100. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-04 (EQ047).




Figura 101. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-06 (EQ053).




Figura 102. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Chi-Chi_Taiwan-06 (EQ053).




Figura 103. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Loma Prieta (EQ058).




Figura 104. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Loma Prieta (EQ058).




Figura 105. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Niigata_Japan (EQ063).




Figura 106. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Niigata_Japan (EQ063).




Figura 107. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para L'Aquila (aftershock 2)_Italy (EQ068).




Figura 108. Comparación temporal de F_x (OpenSees vs LSTM_Student) para L'Aquila (aftershock 2)_Italy (EQ068).




Figura 109. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Iwate_Japan (EQ073).




Figura 110. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Iwate_Japan (EQ073).




Figura 111. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para San Francisco_Ca -07 (EQ078).




Figura 112. Comparación temporal de F_x (OpenSees vs LSTM_Student) para San Francisco_Ca -07 (EQ078).




Figura 113. Comparación temporal de a_{base} (OpenSees vs LSTM_Student) para Los Ángeles_Ca -08 (EQ084).




Figura 114. Comparación temporal de F_x (OpenSees vs LSTM_Student) para Los Ángeles_Ca -08 (EQ084).

9.5 Plots de comparación entre redes LSTM_Teacher vs LSTM_Student vs Valor True (OpenSees) en 4 eventos fuera del entrenamiento.




Figura 115. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher vs LSTM_Student) para Whittier Narrows-01_LA - Chalon Rd (EQ007).




Figura 116. Comparación temporal de F_x (OpenSees vs LSTM_Teacher vs LSTM_Student) para Whittier Narrows-01_LA - Chalon Rd (EQ007).




Figura 117. Comparación temporal de M_z (OpenSees vs LSTM_Teacher vs LSTM_Student) para Whittier Narrows-01_LA - Chalon Rd (EQ007).




Figura 118. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher vs LSTM_Student) para Northridge-01_LA 00 (EQ019).




Figura 119. Comparación temporal de F_x (OpenSees vs LSTM_Teacher vs LSTM_Student) para Northridge-01_LA 00 (EQ019).




Figura 120. Comparación temporal de M_z (OpenSees vs LSTM_Teacher vs LSTM_Student) para Northridge-01_LA 00 (EQ019).




Figura 121. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher vs LSTM_Student) para Chi-Chi_Taiwan-05_TTN040 (EQ052).




Figura 122. Comparación temporal de F_x (OpenSees vs LSTM_Teacher vs LSTM_Student) para Chi-Chi_Taiwan-05_TTN040 (EQ052).




Figura 123. Comparación temporal de M_z (OpenSees vs LSTM_Teacher vs LSTM_Student) para Chi-Chi_Taiwan-05_TTN040 (EQ052).




Figura 124. Comparación temporal de a_{base} (OpenSees vs LSTM_Teacher vs LSTM_Student) para San Francisco-07_ Lick Observatory_ Mt. Hamilton_ CA_ USA (EQ081).




Figura 125. Comparación temporal de F_x (OpenSees vs LSTM_Teacher vs LSTM_Student) para San Francisco-07_ Lick Observatory_ Mt. Hamilton_ CA_ USA (EQ081).




Figura 126. Comparación temporal de M_z (OpenSees vs LSTM_Teacher vs LSTM_Student) para San Francisco-07_ Lick Observatory_ Mt. Hamilton_ CA_ USA (EQ081).