

Comparativa de los modelos Seed-Idriss y redes neuronales artificiales para la predicción de licuación de suelos

Comparison of Seed-Idriss models and artificial neural networks for soil liquefaction prediction

César Manuel Sánchez Oré^{a,*}, Juan Maldonado Pariona^b & Diana Lucia Calderón Cahuana^c

a Facultad de Ingeniería Civil, Universidad Nacional de Ingeniería, Lima, Perú. csanchezo@uni.edu.pe

b Facultad de Ingeniería Civil, Universidad Nacional de Ingeniería, Lima, Perú. jmaldonadop@uni.edu.pe

c Facultad de Ingeniería Civil, Universidad Nacional de Ingeniería, Lima, Perú. dcalderon@uni.edu.pe

* Autor de correspondencia

Recibido: 14 agosto 2021 / Recibido en formato revisado: 10 setiembre 2021 / Aceptado para publicación: 15 setiembre 2021 / Disponible en línea 18 de setiembre 2021

Resumen

El fenómeno de la licuación de suelos es uno de los grandes problemas en la rama de la ingeniería geotécnica, ello debido principalmente a la pérdida de resistencia al corte en suelos granulares y, en consecuencia, en su capacidad de carga. Por otro lado, se ha ido implementado en diversas ramas de la ingeniería geotécnica el uso de las redes neuronales, la cual aprovechando una gran cantidad de datos históricos puede llegar a generar predicciones de manera muy acertada. La presente investigación plantea una comparación entre ambas metodologías, para lo cual se realizó el entrenamiento de la red neuronal con 180 datos históricos de eventos de licuación, usando los parámetros de esfuerzo total vertical, esfuerzo efectivo vertical, aceleración sísmica, profundidad y número de golpes del ensayo SPT corregido. Los primeros resultados del modelo arrojaron una exactitud del 80.3%, frente al 79% de precisión para la metodología clásica de Seed-Idriss.

Palabras clave: licuación; redes neuronales artificiales; SPT; modelo predictivo.

Abstract

The phenomenon of soil liquefaction is one of the major problems in the field of geotechnical engineering, mainly due to the loss of shear strength in granular soils and, consequently, in their bearing capacity. On the other hand, the use of neural networks has been implemented in various branches of geotechnical engineering, which by taking advantage of a large amount of historical data can generate very accurate predictions. This research proposes a comparison between both methodologies, for which the neural network was trained with 180 historical data of liquefaction events, using the parameters of total vertical stress, vertical effective stress, seismic acceleration, depth, and number of blows of the corrected SPT test. The first results of the model yielded an accuracy of 80.3%, compared to 79% accuracy for the classical Seed-Idriss methodology.

Keywords: liquefaction; artificial neural networks; SPT; predictive model.

1 Introducción

A lo largo de la historia se han presentado eventos de licuación de suelos en diferentes lugares del Perú y del Mundo. Uno de los más importantes eventos fue lo ocurrido en el terremoto de 1964 en Niigata (Japón), que conllevó el vuelco de viviendas y colapso de puentes producto del fenómeno de licuación. En el Perú, el último evento grande fue lo ocurrido en el terremoto del 2007 con epicentro en Pisco, éste conllevó principalmente problemas de asentamiento en las edificaciones producto de la licuación de suelos. La información recabada de estos eventos nos ayuda para formular metodologías para su análisis y evaluación.

El estudio de fenómeno de licuación continúa siendo uno de los retos de la ingeniería geotécnica. El desafío de poder evaluar y predecir dicho fenómeno ha llevado a muchos investigadores a lo largo de la historia a proponer metodologías para su evaluación.

Uno de ellos y más utilizado mundialmente es el método simplificado de Seed-Idriss. Este método se basa en la demanda sísmica del estrato del suelo que está expresado por el CSR y por otra parte la capacidad de resistencia del suelo a la licuación expresado por el CRR.

La estimación confiable de los parámetros de licuación también es un problema común a la hora de evaluar la licuación de suelos. El empleo de las redes neuronales

puede hacer uso de los datos históricos para definir patrones que puedan predecir la licuación, en contraste del uso de fórmulas matemáticas.

El presente trabajo de investigación hace uso de las redes neuronales artificiales para estimar y predecir la licuación de suelos, y se contrasta con la metodología simplificada de Seed-Idriss para la comprobación de los resultados en la estimación del fenómeno de licuación. Para este fin, se realizó el procesamiento de los datos de eventos históricos de licuación de suelos.

1.1 Licuación de suelos

El fenómeno de licuación se presenta especialmente en suelos arenosos saturados, producto de un sismo. Debido a las vibraciones del sismo se generan esfuerzos cortantes en el suelo lo cual conlleva a un incremento de la presión de poros. De acuerdo con la mecánica de suelos, este incremento de las presiones de los poros hace que los esfuerzos efectivos reduzcan [1]. La licuación es un fenómeno donde la masa de suelo pierde un gran porcentaje de su resistencia al corte, al ser solicitado por cargas monotónicas, cíclicas o de impacto, y fluye de una manera semejante al de un líquido hasta que los esfuerzos de corte actuantes sobre la masa son lo suficientemente bajos como la resistencia a la corte reducida [2].

Para que se pueda desarrollar la presencia del fenómeno de licuefacción en un suelo, debe haber un sismo. Es por eso que este fenómeno, es considerado uno de los principales riesgos sísmicos urbanos, ya que implica grandes deformaciones en sus suelos, con alto grado de saturación y no cohesivos, dejando una gran susceptibilidad de las estructuras presentes [3].

1.2 Método simplificado Seed-Idriss

El método simplificado propuesto por Seed - Idriss en el año 1971, es uno de los métodos más aceptados a nivel mundial. Esto debido a que se basa de observaciones realizadas en campo y datos de ensayos SPT. Este método ha sido mejorado continuamente a lo largo del tiempo con nuevos aportes de investigaciones [4].

El método se basa en la comparación de los esfuerzos cortantes que son inducidos producto del sismo, contra los esfuerzos cortantes críticos donde pueda ocurrir licuación a un determinado número de ciclos. Para ello se analiza la magnitud, frecuencia y duración del sismo [5].

La estimación de dos variables es necesaria para la evaluación del factor de licuación de un terreno frente al fenómeno de la licuefacción. Primero, resistencia a la licuación requiere determinar la demanda sísmica del estrato de suelo que está expresada por la relación de esfuerzos cíclicos, por otra parte, también se requiere determinar la capacidad de resistencia del suelo a la licuación que está expresada por la relación de resistencia cíclica.

1.2.1 Relación de esfuerzo cíclico CSR

El CSR expresa la demanda sísmica que ocurre en un estrato de suelo. Seed e Idriss, proponen la siguiente expresión para evaluar la relación de esfuerzos cíclicos considerando un 65% del pico de tensiones cíclicas [6].

$$CSR = \frac{\tau_c}{\sigma_{vo}} = 0.65 \left(\frac{a_{max}}{g} \right) \left(\frac{\sigma_{vo}}{\sigma'_{vo}} \right) r_d \quad (1)$$

Donde:

τ_c : Esfuerzo cortante cíclico inducido por sismo

σ'_{vo} : Esfuerzo efectivo vertical

σ_{vo} : Esfuerzo total vertical

g : Aceleración de la gravedad

a_{max} : Aceleración horizontal pico en la superficie del terreno

r_d : Factor de reducción de esfuerzo por profundidad

1.2.2 Relación de resistencia cíclica CRR

El CRR expresa la capacidad de resistencia que ofrece el suelo al fenómeno de licuación. El método para evaluar la resistencia cíclica más común es a través de pruebas de campo basado en el ensayo de penetración estándar (SPT).

$$CRR_{7.5} = \frac{1}{34 - (N_1)_{60cs}} + \frac{(N_1)_{60cs}}{135} + \frac{1}{50 + \frac{(10 \cdot (N_1)_{60cs} + 45)^2}{200}} \quad (2)$$

Donde:

$(N_1)_{60cs}$: Número de golpes normalizado del SPT

$CRR_{7.5}$: Resistencia a la licuación para un sismo de 7.5 magnitud

El ensayo SPT consiste en medir la cantidad de golpes N para hincar una cuchara cilíndrica en tramos de 15 cm. Sin embargo, este ensayo no está estandarizado de forma global, por ello a los resultados obtenidos se les realiza correcciones por algunos factores como: porcentaje de finos, relación de energía del martillo (C_E), diámetro de perforación (C_B), longitud de caña (C_R) y método de muestro (C_S).

1.2.3 Factor de licuación

Para la evaluación de la predicción de licuación se requiere de la definición del factor de licuación. Definido como la relación entre la resistencia del suelo a la licuación y el esfuerzo cíclico generado debido al sismo [5].

$$FS = \frac{CRR}{CSR} \quad (3)$$

Si el FS es menor a 1 indica que ocurrirá el fenómeno de licuación. Sin embargo, este valor generalmente variable dependiendo cada país. La Norma Peruana considera la ocurrencia de licuación para valores de FS menores a 1 y 1.3 [7].

1.3 Normalización de datos

El proceso de normalización de datos de entrada para la red neuronal tiene un gran efecto para la preparación de los datos para el entrenamiento de la red, agilizando el algoritmo y regularizando los valores de entrada entre las características de la red neuronal [8].

Es por ello por lo que se implementó la normalización estadística, la cual a través de la media y desviación estándar de cada uno de los vectores de entrada transforma los datos según la siguiente ecuación:

Una de las ventajas del uso de la normalización estadística es que adicionalmente reduce el efecto de valores atípicos en los datos [8].

$$x' = \frac{x_i - \mu_i}{\sigma_i} \quad (4)$$

1.4 Redes neuronales artificiales

En este estudio se utiliza una red neural artificial definida como un perceptrón multicapa (MLP) de una capa este es un modelo no lineal basado en datos que aproxima las variables de salida en función del conjunto de variables de entrada.

Se tiene el siguiente esquema para el funcionamiento de una red neuronal:




Figura 1. Esquema de funcionamiento de una red neuronal
Fuente: [9]

A continuación, mostramos la formulación de la red neuronal, basado en [10] y [11], la red se basa en las siguientes ecuaciones:

$$net_{pj} = \sum_{i=1}^n W_{ji}x_{pi} + W_{jo} \quad (5)$$

$$h_{pj} = f(net_{pj}) \quad (6)$$

Donde net_{pj} son las entradas ponderadas en la j -ésima unidad oculta; n es el número de nodos de entrada; W_{ji} es el peso que conecta la unidad i en la unidad oculta j , x_{pi} es el valor de la i -ésima entrada para el patrón p ; W_{jo} es el sesgo para la neurona j y h_{pj} es la j -ésima función de

activación de la neurona j . Entonces la salida puede calcularse como:

$$net_{pk} = \sum_{j=1}^h W_{kj}h_{pj} + W_{ko} \quad (7)$$

$$y_{pk} = f(net_{pk}) \quad (8)$$

Donde h es el número de unidades ocultas, W_{kj} representa el peso que conecta el nodo oculto j con la salida k , W_{ko} es el sesgo para la neurona k , y y_{pk} es la k -ésima salida predicha. Para la función de activación se utilizó una función ReLu. El objetivo final del entrenamiento de la red es encontrar el conjunto de pesos que minimice el error medio error cuadrático medio. Para ello tendríamos la siguiente expresión:

$$E = \frac{1}{Nm} \sum_{p=1}^N \sum_{k=1}^m (t_{pk} - y_{pk})^2 \quad (9)$$

Donde N es el número de patrones (observaciones) y m es el total de unidades de salida, t_{pk} representa la salida que se desea y y_{pk} representa la salida predicha por el modelo.

El algoritmo de entrenamiento del modelo es el descenso de gradiente estocástico y el algoritmo de retro propagación con una tasa de aprendizaje adaptable.

$$dW_i = dW_{i-1} + l_r \frac{dE}{dW_t} \quad (10)$$

Donde t es el número de época, W_{t-1} es el cambio anterior del peso o sesgo, l_r es la tasa de aprendizaje. Con ello se itera hasta conseguir el objetivo esperado.

1.5 Indicadores de evaluación

1.5.1 Matriz de confusión

Una matriz de confusión de tamaño $n \times n$ muestra la clasificación predicha y la real, donde n es el número de clases diferentes [12], debido a que deseamos saber si hay o no licuación, la matriz de confusión será de tamaño 2×2 , ya que las posibles salidas serán 0 o 1. Como se observa en la siguiente tabla:

Tabla 1.
Matriz de confusión para un problema de 2 clases

	PREDICTED NEGATIVE	PREDICTED POSITIVE
ACTUAL NEGATIVE	a	b
ACTUAL POSITIVE	c	d

Fuente: [13]

Donde:

- a : número de predicciones negativas correctas
- b : número de predicciones positivas incorrectas
- c : número de predicciones negativas incorrectas
- d : número de predicciones positivas correctas

Según la referencia [12] se puede obtener la precisión del modelo de la siguiente forma:

$$Exactitud = \frac{a + d}{a + b + c + d} \quad (11)$$

$$Precisión = \frac{d}{d + b} \quad (12)$$

$$Error = \frac{b + c}{a + b + c + d} \quad (13)$$

1.5.2 Área debajo de la curva ROC (AUC)

Los resultados del índice de predicción son obtenidos mediante el método de las características operativas del receptor (ROC).

La curva de características operativas del receptor (ROC) para un problema de clasificación binaria representa la tasa de verdaderos positivos en función de la tasa de falsos positivos, como se muestra en la siguiente figura.




Figura 2. Curva ROC para evaluar el rendimiento de la prueba de diagnóstico
Fuente: [14]

Los puntos de la curva se obtienen barriendo el umbral de clasificación desde el valor de clasificación más posible hasta el más negativo. Para una clasificación totalmente aleatoria, la curva ROC es una línea recta que conecta el origen con (1,1). Cualquier mejora con respecto a la clasificación aleatoria se traduce en una curva ROC al menos parcialmente por encima de esta línea recta. El AUC se define como el área bajo la curva ROC [13].

2 Materiales y métodos

2.1. Recolección y análisis de datos

Los datos utilizados para el entrenamiento de la red neuronal fueron un total de 181 casos rescatados de un total de 210 datos obtenidos de la referencia [15].

Se tomo en cuenta esta muestra debido al limitante del número de golpes para lo cual es efectivo el método de Seed-Idriss.

Se utilizaron los parámetros de esfuerzo efectivo vertical, esfuerzo total vertical, profundidad del estrato, aceleración máxima y número de golpes modificado, algunos de los datos se muestran en la tabla 2.

2.2. Predicción por el método de Seed-Idriss

El método propuesto por Seed-Idriss está basado principalmente en datos de campo. Para ello hace uso de los datos de la prueba de penetración estándar (SPT). En base a los datos de campo correlaciona la demanda sísmica del estrato de suelo que está expresada por la relación de esfuerzos cíclicos (CSR) y la capacidad de resistencia del suelo a la licuación que está expresada por la relación de resistencia cíclica (CRR). El siguiente flujograma se utilizó para el análisis de los parámetros estudiados en los datos de eventos históricos.




Figura 3. Diagrama de Flujo para la metodología Seed-Idriss diagnóstico
Fuente: Los autores

2.3. Predicción por el método de redes neuronales artificiales

Para usar el método de redes neuronales se utilizó Orange Data Mining 3.23.1, el cual es una plataforma de análisis predictivo, minería y visualización de datos de libre acceso desarrollado en Python.

A continuación, mostramos el flujo de trabajo que se consideró:




Figura 4. Flujograma del modelo de redes neuronales artificiales en Orange
Fuente: Los autores

Entrada de datos y muestreo: Se insertó los datos de eventos de licuación de suelos a nivel internacional y con ello se realizó un muestreo aleatorio, escogiendo un 70% de los datos que servirán para el entrenamiento de la red neuronal.

Preprocesamiento de datos: Se realizó una normalización estadística de los datos de entrenamiento y se obtuvieron los datos estandarizados, los datos normalizados se muestran en la tabla 3. Se obtuvo al normalizar los datos, un mínimo de -1.843 y un máximo de 4.216.

Aplicación de redes neuronales artificiales: Se procedió a realizar varias arquitecturas de red neuronal,

obteniéndose así por prueba y error, la red neuronal de 5x25x1, es decir con un total de 25 neuronas dentro de la capa oculta, se utilizó además la función de activación ReLu, el algoritmo de retro propagación y el descenso de gradiente estocástico, finalmente se llegó a un resultado óptimo en la iteración 10000.

Test y resultados: Con esta herramienta de la plataforma se realizó la validación y el testeo, de forma aleatoria, repitiéndose 10 veces, y obteniendo así los resultados de nuestra red. Con ello se realizó la matriz de confusión y la curva ROC.

Tabla 2.

Datos de eventos históricos de licuación de suelos

Número de casos	Terremoto	Sitio	Esfuerzo Total (psf)	Esfuerzo Efectivo (psf)	Profundidad (m)	Aceleración máxima (g)	Número de golpes	¿Licuó?
1	Tohnankai M=8.0	Ienaga	1460	1085.6	4.3	0.2	5.4	SI
2	Tohnankai M=8.0	Komei	1214.8	904.6	3.5	0.2	9.9	SI
3	Tohnankai M=8.0	Meiko	703.2	397.3	2.0	0.2	5.5	SI
4	1948 Fukui M=7.3	Shonenji Temple	912.7	631.1	2.6	0.4	7.0	SI
5	1948 Fukui M=7.3	Takaya 45	3084.3	2220.0	8.0	0.4	21.2	SI
6	1964 Niigata M=7.5	Arayamotomachi	1177.0	716.4	3.3	0.1	8.4	SI

Fuente: [15]

Tabla 3.

Datos normalizados de eventos históricos de licuación de suelos

Número de casos	Terremoto	Sitio	Esfuerzo Total (psf)	Esfuerzo Efectivo (psf)	Profundidad (m)	Aceleración máxima (g)	Número de golpes	¿Licuó?
1	Tohnankai M=8.0	Ienaga	-0.525	-0.388	-0.351	-0.508	-1.456	SI
2	Tohnankai M=8.0	Komei	-0.799	-0.691	-0.702	-0.508	-0.741	SI
3	Tohnankai M=8.0	Meiko	-1.370	-1.541	-1.360	-0.508	-1.450	SI
4	1948 Fukui M=7.3	Shonenji Temple	-1.136	-1.149	-1.097	1.014	-1.197	SI
5	1948 Fukui M=7.3	Takaya 45	1.287	1.513	1.273	0.634	1.063	SI
6	1964 Niigata M=7.5	Arayamotomachi	-0.841	-1.006	-0.790	-1.346	-0.980	SI

Fuente: Los autores

3 Resultados y discusión

Se obtuvieron como resultados de la red neuronal la siguiente matriz de confusión en porcentaje con respecto a los datos reales para una de las iteraciones realizadas:

Artificiales

Resultados Reales	Predicción: Métodos Redes Neuronales	
	SI	NO
SI	87.2%	12.8%
NO	31.3%	68.7%

Fuente: Los autores

Tabla 4.

Matriz de confusión para el método Redes Neuronales

Se repitió 10 veces el muestreo aleatorio de los datos y se obtuvo como promedio, una exactitud de 80.3%, una precisión del 80.1% y un error de 19.7%.

Asimismo, mostramos la curva ROC obtenida del modelo:




Figura 5. Curva ROC del modelo de redes neuronales artificiales
Fuente: Los autores

Se obtuvo finalmente que el AUC de la curva ROC resulto de 0.879.

Para el modelo Seed-Idriss se obtuvo la siguiente matriz de confusión en porcentaje con respecto a los datos reales.

Tabla 5.
Matriz de confusión para el método Seed-Idriss

Resultados Reales	Predicción: Método Seed-Idriss	
	SI	NO
SI	72.6%	27.4%
NO	10.3%	89.7%

Fuente: Los autores

Al ser un procedimiento determinístico, solo se obtiene una única matriz de confusión con respecto al número de datos coincidentes y con ello obtuvimos una exactitud de 79%, una precisión del 92% y un error de 21%.

De la matriz de confusión se resalta que el modelo de redes neuronales artificiales tiene mejor desempeño para cuando el evento de licuación ocurriese, con un 14.6% más que con respecto al modelo de Seed-Idriss, mientras que la metodología Seed-Idriss tiene un mejor desempeño cuando el evento no ocurriese, en un 21 % más que con respecto a la metodología de redes neuronales artificiales.

4 Conclusiones

Del área debajo de la curva ROC, se obtuvo como resultado 0.879, mostrando una buena aproximación del testeo de los datos, ya que se encuentra dentro de los valores 0.7-0.9.

De la comparación de las matrices de confusión obtenemos que es mejor utilizar la metodología de redes neuronales artificiales ya que si ocurriese un evento de licuación de suelos por un movimiento sísmico podría acertar con mayor precisión

que ocurriese, y de este modo prevenir desastres relacionados a la licuación de suelos.

No se encontró una gran diferencia con respecto a la exactitud entre ambas metodologías, siendo la diferencia 1.3%, por lo cual, es posible usar la aplicación de la metodología de redes neuronales en la predicción de licuación de suelos.

Para futuros trabajos es necesario realizar un estudio más profundo del espacio de hipótesis óptimo para nuestra red neuronal artificial y realizar un análisis de sobreajuste.

Referencias bibliográficas

- [1] Brenes Quesada F. (2008). "Evaluación del potencial de licuefacción en suelos". Tesis de grado, Instituto Tecnológico de Costa Rica.
- [2] Sladen, J. A., D'hollander, R. D., & Krahn, J. (1985). "The liquefaction of sands, a collapse surface approach". Canadian geotechnical journal, 22(4), 564-578.
<https://doi.org/10.1139/t85-076>
- [3] L. Perucca, A. Pérez y C. Navarro, "Fenómenos de licuefacción asociados a terremotos históricos. Su análisis en la evaluación del peligro sísmico en la Argentina", Revista de la Asociación Geológica Argentina, 2006
- [4] Valera, J. E., & Donovan, N. C. (1977). "Soil liquefaction procedures". Journal of the Geotechnical Engineering Division, 103(6), 607-625.
<https://doi.org/10.1061/AJGEB6.0000439>
- [5] Coronado García L. A. (2005). "Evaluación del potencial de licuación en suelos". Tesis de grado, Universidad de los Andes. Bogotá.
- [6] Seed H.B. y I.M. Idriss (1982), "Ground motions and Soil Liquefaction during Earthquakes", Earthquake Engineering Research Institute, Berkeley.
- [7] E.050 Suelos y cimentaciones. Norma Técnica Peruana (2018).
- [8] Jayalakshmi, T., & Santhakumaran, A. (2011). Statistical normalization and back propagation for classification. International Journal of Computer Theory and Engineering, 3(1), 1793-8201.
- [9] Njock, P. G. A., Shen, S. L., Zhou, A., & Lyu, H. M. (2020). Evaluation of soil liquefaction using AI technology incorporating a coupled ENN/t-SNE model. Soil Dynamics and Earthquake Engineering, 130, 105988.
<https://doi.org/10.1016/j.soildyn.2019.105988>
- [10] Kang, F., Li, J. J., & Zhou, H. (2014). Artificial neural network model for evaluating gravelly soils liquefaction using shear wave velocity. In International Efforts in Lifeline Earthquake Engineering (pp. 608-615).
<https://doi.org/10.1061/9780784413234.078>
- [11] Bottou, L. (1991). Stochastic gradient learning in neural networks. Proceedings of Neuro-Nimes, 91(8), 12.
- [12] Caelen, O. (2017). A Bayesian interpretation of the confusion matrix. Annals of Mathematics and Artificial Intelligence, 81(3-4), 429-450.
<https://doi.org/10.1007/s10472-017-9564-8>
- [13] Cortes, C., & Mohri, M. (2005). Confidence intervals for the area under the ROC curve. Advances in neural information processing systems, 17, 305-312.
- [14] Jones, L., & Rushton, D. (2019). Optimising geotechnical correlations using Receiver Operating Characteristic (ROC) analysis.
- [15] Çetin, K. Ö., Seed, R. B., Kayen, R. E., Moss, R. E., Bilge, H. T., Ilgac, M., & Chowdhury, K. (2018). Dataset on SPT-based seismic soil liquefaction.
<https://doi.org/10.1016/j.dib.2018.08.043>