

INTERNATIONAL SOCIETY FOR SOIL MECHANICS AND GEOTECHNICAL ENGINEERING



This paper was downloaded from the Online Library of the International Society for Soil Mechanics and Geotechnical Engineering (ISSMGE). The library is available here:

<https://www.issmge.org/publications/online-library>

This is an open-access database that archives thousands of papers published under the Auspices of the ISSMGE and maintained by the Innovation and Development Committee of ISSMGE.

Árbol de regresión para determinar el potencial de licuación: ARELI

S. R. García, Miguel P. Romo O. & Efraín Ovando S.
Instituto de Ingeniería, UNAM, México



ABSTRACT

This paper presents a new method for assessing the liquefaction potential of soils based on geotechnical and seismic descriptions. Data from *in situ* and laboratory testing are used to develop a Cognitive Analysis and Computing environment for predicting the occurrence and non occurrence of liquefaction. No empirical equation is used to approximate the unknown limit state curve 2D, a Regression Tree is proposed to map the soil and seismic parameters (translated and transfigured by Fuzzy Logic) to nominal and numeric conclusions (calculated by Neural Networks) about liquefaction.

RÉSUMÉ

En este documento se presenta un nuevo método para determinar el potencial de licuación de los suelos basados en descripciones geotécnicas y sísmicas. Se explotan los datos de pruebas de campo y laboratorio para construir un ambiente de Cómputo y Análisis Cognitivo que permite predecir la ocurrencia o no ocurrencia de la licuación. Se eliminan las tradicionales ecuaciones empíricas para definir la curva de estado límite en un espacio 2D y se incluye un Árbol de Regresión que permite mapear las entradas del material y la carga cíclica (traducidas y transfiguradas con Lógica Difusa) hacia conclusiones nominales (calculadas con Redes Neuronales) y numéricas de la licuación.

1 INTRODUCCIÓN

El poder destructivo del fenómeno de licuación llamó la atención de la ingeniería mundial a partir de los dos grandes terremotos de 1964 (Alaska, 27 de marzo, $M_w = 9.2$ y Niigata, 16 de junio, $M_w = 7.5$) donde severos desplazamientos laterales y fallas de flujo ocasionaron enormes pérdidas económicas y humanas. La investigación derivada de estos eventos se dirigió hacia el esclarecimiento de los mecanismos que controlan la licuación, al pronóstico de su ocurrencia y la mitigación de sus efectos devastadores.

La experiencia en campo y laboratorio indica que la licuación y la deformación del terreno asociada a este fenómeno constituyen un problema complejo (difícil de modelar física y analíticamente) por lo que los procedimientos empíricos son la práctica estándar en la evaluación de la resistencia a la licuación, predicción de la deformación del suelo y el diseño de acciones de rehabilitación.

Numerosos son los procedimientos desarrollados para establecer el potencial de licuación de los suelos granulares saturados sin embargo, la elección de la ecuación empírica adecuada no es tarea fácil. La alta incertidumbre en la definición de los ambientes sísmicos y en la caracterización de los suelos obliga a la búsqueda de modelos simples constituidos por dos componentes esenciales: 1) un marco analítico basado en la experiencia (casos históricos), y 2) un índice que relacione parámetros de pruebas *in situ* y las características de licuación del suelo. Las aproximaciones derivadas de estas condiciones buscan vincular el mínimo número de parámetros de los suelos

y de los sismos con una interpretación simplista del fenómeno.

Las conexiones derivadas del comportamiento en la naturaleza, con un gran número de variables (conocidas y ocultas) moviéndose en rangos dinámicos (dependientes de la variable tiempo) difíciles de definir, hacen del fenómeno de licuación un candidato no apto para ser estudiado con reglas lineales o de baja dimensión.

El campo del cómputo cognitivo ha mostrado ser una alternativa poderosa y eficiente para modelar problemas no-lineales multidimensionales que se desarrollen en ambientes con incertidumbre y contaminación. En este trabajo se examina un nuevo procedimiento semi-empírico para evaluar el potencial de licuación de los suelos saturados sujetos a carga cíclica.

Esta propuesta combina la lógica difusa y las redes neuronales para alimentar e interpretar los resultados de un árbol de regresión, ARELI. Con ARELI se extraen las relaciones naturales detrás de las observaciones de campo y las condiciones conocidas del suelo. El aprendizaje neuronal y la expresión difusa se usan para la interpretación numérica y lingüística de los parámetros de entrada y las recomendaciones de salida con las que ARELI construye el discurso "potencial de licuación". Un aspecto esencial en este nuevo modelo es que, siendo extremadamente simple, genera estimaciones de gran exactitud. Adicional, pero no menos importante, es la ventaja de realizar una separación natural del efecto de las propiedades de suelo, de los métodos de prueba, de la carga sísmica y de otros aspectos que, debido a las fronteras y sesgos de los modelos tradicionales, no es posible cuantificar correctamente.

Con base en los resultados de esta investigación, se concluye que ARELI es una atractiva alternativa para describir el fenómeno de licuación a pesar de las observaciones limitadas, el conocimiento parcial de las condiciones geotécnicas y sísmicas, así como del razonamiento ambiguo con el que se infiere el universo de comportamientos de los suelos.

2 REVISIÓN DE LAS FORMULACIONES PARA EVALUAR EL POTENCIAL DE LICUACIÓN

Las variables con las que se expresa el potencial de licuación son 1) la demanda cíclica que afecta a un estrato de suelo, expresada en términos de la relación de esfuerzo cíclico CSR (por sus siglas en inglés *cyclic stress ratio*) y 2) la capacidad del suelo para resistir la licuación, expresada en términos de la relación de resistencia cíclica CRR (por sus siglas en inglés *cyclic resistance ratio*). El procedimiento original de Seed e Idriss (1971), para calcular el CSR, permanece como la guía básica para expresar la demanda sísmica. En lo que respecta al CRR, a pesar del gran número de refinamientos en los componentes del marco analítico, los mayores progresos se han generado en la estandarización e interpretación de las pruebas índice in situ (prueba de penetración estándar SPT, prueba de penetración del cono eléctrico CPT y medición de velocidades de ondas de corte Vs) y el almacenamiento y manejo de las bases de datos de casos históricos.

Las actualizaciones más recientes de los procedimientos semi-empíricos, en la evaluación del potencial de licuación, se dirigen hacia la inclusión de expresiones numéricas que minimicen la variación entre los patrones numéricos y permitan su estudio con herramientas básicas. Dichas expresiones pre-procesan una variable a la vez y no mejoran la interpretación física general; tratan de modificar el valor numérico de un parámetro pero no están integradas con el marco de comportamiento general y por ende, no lo alteran. Entre los ajustes más destacados se encuentran:

- Coeficiente de reducción de esfuerzos, r_d
- Factor de escala de magnitud, M_{SF}
- Factor de corrección por sobre-esfuerzo cíclico, R_s
- Factor de corrección por sobre estimación de la resistencia a la penetración, C_m

Los cambios en la expresión de estos coeficientes están basados en la re-evaluación de casos históricos y la re-interpretación de pruebas y correlaciones mejoradas (SPT, CPT y Vs $\rightarrow$ propiedades índice/clasificación de materiales) y algunas veces, en los avances computacionales disponibles.

2.1 Procedimientos Semi-empíricos: aspectos básicos

En el procedimiento de Seed e Idriss (1971) se define al CSR en función de los esfuerzos vertical total σ'_{v0} y efectivo σ'_{v0} (a una profundidad Z) y la aceleración máxima horizontal a_{max} en la superficie del terreno (en g's). El coeficiente de reducción de esfuerzo r_d se integra a esta formulación para tomar en cuenta la flexibilidad de la columna de suelo ($r_d = 1$, corresponde al comportamiento de cuerpo rígido). Además, un coeficiente (0.65) es incluido para convertir la relación de esfuerzo cortante cíclico máximo al nivel de esfuerzos correspondiente al número de ciclos equivalentes a la excitación sísmica particular. Los valores de CSR así calculados pertenecen al esfuerzo cortante uniforme equivalente inducido por un sismo de magnitud M. Para Seed e Idriss (1971) r_d decrece con la profundidad y es independiente de la configuración del perfil de suelo.

Debido a que la incertidumbre en el valor de r_d se incrementa con la profundidad, Idriss, (1999) en una extensión del trabajo de Goleorkhi (1989), desarrolló varios cientos de análisis paramétricos de respuesta de sitio y concluyó que para las condiciones de mayor interés práctico, el parámetro r_d podía ser expresado como una función de Z y M, aceptando que los esfuerzos de corte inducidos en cualquier punto del depósito de suelo se deben primordialmente a la propagación vertical de ondas de corte y pueden ser obtenidos a través del movimiento del terreno (intensidad y contenido de frecuencia), el perfil de velocidades de ondas de corte y las propiedades dinámicas de los suelos.

El M_{SF} permite ajustar el CSR inducido durante un sismo de magnitud M a uno equivalente al generado durante un sismo de $M=7.5$. El M_{SF} es una representación aproximada de los efectos de la duración de la sacudida o el número equivalente de ciclos de esfuerzo y sus valores se derivan de 1) correlaciones entre el número de ciclos uniformes equivalentes y la magnitud sísmica, y 2) pruebas de laboratorio donde se relacione el esfuerzo cíclico requerido para causar licuación y el número de ciclos de esfuerzo uniformes. A pesar de los intentos por depurar este parámetro, la incorporación de éste en la secuencia de cálculo sigue siendo una de las etapas más complejas e inciertas de los procedimientos semi-empíricos (Idriss y Boulanger, 2004).

Uno de los ajustes para tomar en cuenta el efecto de la densidad relativa y los esfuerzos de confinamiento efectivos sobre el nivel de resistencia de los suelos es el factor de corrección C_m . Su estimación impacta de manera importante el valor del CSR y dada la complejidad y dimensión de su universo, existe un gran número de alternativas de cálculo (Boulanger, 2003b y Boulanger e Idriss, (2004, 2003). Los métodos de análisis actuales están diseñados para trabajar con los resultados de una prueba in situ. Se elige la que represente ventajas para los intereses del analista (como posibilidad de recuperación de muestras, por ejemplo) o la mejor estandarizada (Boulanger et al. 1995, 1997). A pesar de que las conclusiones prácticas de estos estudios apuntan hacia la conveniencia de acoplar los perfiles de varias pruebas in situ para identificar y

caracterizar de mejor manera los estratos potencialmente licuables, sobre todo los de espesor reducido no existe un marco de análisis que permita tomar en cuenta esta recomendación (Moss, 2003). El uso del número de golpes N de la prueba SPT, de la resistencia a la penetración del cono q_c de la prueba CPT y el perfil de valores de velocidad de ondas de corte V_s como índices para caracterizar la licuación de los suelos, ha mostrado que su efectividad se incrementa conforme las pruebas y su interpretación se mejoran. Usando las ventajas de cada prueba (recuperación de muestras o perfiles continuos de resistencia y velocidad, por ejemplo) se puede minimizar el error en la identificación de los contactos entre suelos con grandes diferencias de resistencias y los suelos interestratificados muy finamente (Boulanger, 1999; Andrus y Stokoe 2000; Andrus et al. 2003).

3 CÓMPUTO COGNITIVO: REDES NEURONALES, LÓGICA DIFUSA Y ÁRBOLES DE DECISIÓN

En el horizonte de los descubrimientos relacionados con la informática surgen no sólo ideas nuevas para mejorar las técnicas existentes, sino también paradigmas radicalmente diferentes de los actuales procedimientos. Uno de ellos, actualmente aplicado en casi todas las ramas de la ciencia, es el Cómputo Cognitivo CC. En lugar de sostenerse únicamente en las habilidades del modelador, un programa de CC aprende de su experiencia por generalización y abstracción, adquiriendo la facultad de razonamiento y aprendizaje en un ambiente incompleto, incierto, impreciso y con verdad parcial, aspectos propios de la realidad. El CC, capaz de modelar y controlar una gran variedad de sistemas, se constituye como una herramienta efectiva en problemas de toma de decisiones, control, clasificación y compresión, reconocimiento y predicción.

En el CC se combinan diferentes técnicas de la Inteligencia Artificial como la Lógica Difusa LD, las Redes Neuronales RNs, la Minería de Datos MD, los Algoritmos Genéticos AGs y el Razonamiento Probabilístico; esta última comprende Algoritmos Evolutivos, Sistemas Caóticos, Redes de Opinión y, parcialmente, Teoría del Aprendizaje (Zadeh, 1997, Bonissone, 1997). Conviene aclarar que el CC no es una mezcla de ingredientes sino una disciplina en la que cada componente contribuye con una metodología específica para manejar problemas en su dominio de aplicación que, de otra forma, se tornarían irresolubles. En este apartado se enuncian algunos aspectos básicos de las herramientas del CC usados en esta investigación, para el lector interesado en profundizar sobre cada una de ellas y su aplicación en la Ingeniería Geotécnica se recomienda la revisión de García (2008).

La LD, en su más popular concepción, se liga a los cálculos numéricos basados en reglas difusas que tienen el propósito de modelar una función numérica para describir sistemas de ingeniería (Mendel, 1995). Sin embargo, en la literatura orientada hacia las

matemáticas modernas, se le califica como una lógica multi-valuada cuyo propósito es modelar valores de verdad parcial e incertidumbres (Hajek, 1995). El desarrollo de la LD está ligado con la investigación en IA (Inteligencia Artificial) pero sobre todo con los análisis de sistemas de ingeniería, por lo que las aplicaciones a problemas reales tratan en las primeras etapas de su desarrollo con la representación del conocimiento y una vez terminadas se convierten en una interfaz numérica/simbólica.

Las RNs se originaron en un intento por construir modelos matemáticos de unidades de procesamiento elementales anidadas en un cerebro que permitieran el flujo de señales a través de ellas. Después de un periodo de estancamiento, los modelos formales de RNs incrementaron su popularidad con el descubrimiento de eficientes algoritmos capaces de ajustarse a complicadas y masivas bases de datos. Las aplicaciones neuronales más exitosas se concentran en la construcción de arquitecturas computarizadas capaces de aproximar funciones no lineales con un gran número de variables y clasificar objetos inmersos en espacios multidimensionales. Básicamente, una red neuronal es una sofisticada función no lineal, tipo caja negra, que puede ser entrenada con datos numéricos para satisfacer tareas objetivo.

La MD es un conjunto de herramientas de análisis que sirven para descubrir patrones, validarlos y relacionarlos dentro de un conjunto de datos masivo (Adriaans y Zantinge, 1996). Entre estas herramientas se encuentran las del aprendizaje automático (algoritmos que mejoran su comportamiento automáticamente a través de la experiencia) entre los más exitosos se encuentran los árboles de decisión AD. Los AD, sean de clasificación (salida nominal) o de regresión (salida numérica), son especialmente atractivos por tres razones, su representación intuitiva (fácil de asimilar y comprender por los humanos), son modelos no paramétricos (no intervienen los sesgos del modelador) y son algoritmos escalables (Breimann et al. 1984; Gehrke et al., 1998; Murthy 1995; Lim et al., 1997).

En esta investigación se usan las RNs para encontrar las reglas que relacionan entradas y salidas (altamente no lineales), la LD para realizar la inducción y análisis de datos desde la experiencia expresada nominalmente y los AR (Árboles de Regresión) para establecer un ambiente de estado donde existan fronteras de múltiples dimensiones.

4 COMPORTAMIENTO DE LOS REGISTROS DE CAMPO: INTERPRETACIÓN CON CC

La principal ventaja de las aproximaciones semi-empíricas es el uso de las consideraciones teóricas y los hallazgos experimentales para establecer el marco de análisis y sus componentes. La teoría le da sentido a las observaciones de campo, validando la aproximación para interpolar o extrapolar hacia zonas con datos insuficientes y restringirla como única solución. Las interpretaciones empíricas de los casos históricos, sin un

marco de análisis basado en la física, llevaría a un oscurecimiento de las condiciones para las cuales estas relaciones son aplicables. En este trabajo se presenta al CC como la herramienta capaz de cumplir con esta necesidad de abstracción y modelación en ambientes de trabajo inciertos y contaminados.

Con base en una extensa revisión de la literatura en el tema, de las conclusiones y juicios ligados a las observaciones, y de las características de los estudios de campo y laboratorio que conforman las bases de datos, se eligieron los factores con más peso y mayor certidumbre para incluirlos en el modelo de CC. Estos modelos se desarrollaron procurando mantenerlos completos (amplia gama de comportamientos y condiciones iniciales), simples y fundamentados en interpretaciones físicas de las respuestas del material. De acuerdo con el proceso empírico de creación de modelos se plantea el siguiente esquema de solución al problema de obtener el potencial de licuación de un suelo:

- SISTEMA: depósito de suelo.
- PROCESO: Colapso estructural del esqueleto de suelo debido a esfuerzos de corte, con una coexistente pérdida de energía por mecanismos de fricción entre partículas.
- ENTRADAS: parámetros del suelo/ parámetros de la carga.
- MODELO: Técnica Híbrida (un Sistema LD, una RN y un AR).
- SALIDA: “licuación: si”/ “licuación: no” y CRR/CSR.

4.1 Sistema

Diversas condiciones de carga y estados iniciales en los materiales deben ser coincidentes para que la licuación ocurra. El sistema no tiene restricciones sobre dichas condiciones. La integración de los materiales que componen un depósito no requiere de caracterizaciones que dirijan la salida hacia alguna zona del espacio de respuestas. Por ejemplo, etiquetar al suelo como “cohesivo”/“no cohesivo”, dentro de un análisis tradicional dirige el razonamiento. Si el material es “no-cohesivo” entonces el término licuación se refiere al comportamiento asociado a las presiones de poro en exceso, deformaciones significativas y la posible pérdida de resistencia, en campo se identifica por deformaciones de terreno y volcanes de arena, mientras que en el laboratorio puede ser definida en términos de algún criterio de falla (alcanzar el 3% de deformación por corte, por ejemplo).

Si por otro lado, la etiqueta del material es “cohesivo”, el término licuación no es usado para describir el fenómeno, ya que se sabe que la carga cíclica en las arcillas puede producir exceso de la presión de poro, pero usualmente menor al 100%. (Zergoun y Vaid 1994, Boulanger et al. 1998, Idriss 1985, Idriss 1985). ¿Pero qué sucedería en el caso de materiales que exhiben comportamiento intermedio? La parametrización rígida no permite evaluar condiciones naturales e introduce sesgos en el patrón de respuesta estimado. En este trabajo de investigación el “sistema” es descrito a través de parámetros índice, mecánicos y geométricos (Figura 1), con fronteras de expresión aproximadas. La observación ligada con el arreglo natural permite una completa exploración y explotación de la experiencia en campo y laboratorio.




Figura 1. ARELI: entradas SUELO.

4.2 Proceso

El colapso estructural del esqueleto de suelo, como el término general para describir los fenómenos asociados con la licuación (falla de flujo y movilidad cíclica) no se modela en el esquema matemático expuesto en este trabajo de investigación, sino que se vincula la expresión nominal de una de sus manifestaciones evidentes (“este suelo licuó”/“este suelo no licuó”) con algunos parámetros que caracterizan al evento generador del Proceso. La solución CC es un planteamiento fenomenológico, es decir, el modelo es capaz de describir las manifestaciones del proceso y eventualmente relacionarlas con causas, pero no de explicar la estructura que las genera.

1.1 Entradas

Los parámetros de suelo que permiten construir el ambiente de análisis se detallan en la Figura 1. Un sistema de LD funge como traductor de los parámetros nominales a numéricos de acuerdo con la experiencia previa de casos históricos (entrenamiento neuronal de un sistema difuso) y como transfigurador de los parámetros continuos (perfiles de resistencias y

velocidades) para hacer evaluaciones discretas dentro del ambiente “depósito de suelo”. Una de las ventajas de usar LD en la expresión del sistema es que involucra duplas de variables nominales y numéricas para construir la imagen del medio. Los parámetros señalados como obligatorios cubren el mínimo de información geotécnica y geométrica con el que ARELI puede comenzar un análisis, sin embargo el sistema de LD podría completar al sistema de acuerdo con la experiencia y conocimiento del analista.

La introducción de la carga sísmica se puede realizar a través de: a) la magnitud y la aceleración máxima o b) un acelerograma (Figura 2). El uso combinado de ellas también es permitido. La entrada de carga dependerá del rigor necesario en el análisis y la disposición de información histórica y registros de aceleraciones pertinentes. Es motivo de investigación más profunda la definición del dominio en el que se expresen mejor las características de la carga que inciden sobre la generación de la licuación (series de tiempo, espectros en el dominio de la frecuencia o espectros temporofrecuenciales).




Figura 2. ARELI: entradas SISMO.

1.2 Modelo

En la primera etapa de este estudio se usa una RN con salidas “licuación: sí”/“licuación: no” que dependen de las entradas que caracterizan al suelo, al medio y a la demanda sísmica. A diferencia de otras aproximaciones neuronales (Goh, 1996; Aghda et al., 1998; Juang et al., 2003; Chern y Lee, 2009) ARELI no intenta completar la superficie de estado límite con datos artificiales que cumplan con $CRR=CSR$ para luego ser analizados con una limitada ecuación de estado. Sin duda mecanizar el proceso presentado hace más de 20 años no significa un

avance en el análisis ni en el conocimiento. Usar una red neuronal para reproducir patrones con variaciones mínimas en los valores de sus coeficientes (entradas) no explota la capacidad de aprendizaje de una técnica cognitiva.

Para poder otorgar al ingeniero de la práctica de una salida que contenga el sentido práctico que guarda la relación $CRR=CSR$, en esta investigación se construyó un tercer módulo de aprendizaje con minería de datos: un árbol de estado límite (árbol de regresión). Este elemento es el núcleo de ARELI porque toma la información del sistema difuso y la decisión de la red neuronal para generar un patrón de comportamiento

donde el analista puede estudiar el efecto que cada aspecto del sistema y de la carga tienen sobre la relación entre la capacidad de resistencia de un suelo y el esfuerzo cíclico que le afecta (Figura 3). Además, en su hoja final, el árbol concluye con un valor numérico, apto para la idea de la práctica de valorizar el riesgo con base en este número.

2 ARELI: EJEMPLO DE APLICACIÓN

Con base en los criterios y metodología establecidos en los capítulos anteriores, se presenta un ejemplo de

integración de patrón de entrada (Figura 4) para el sitio Borah Peak (EU), durante el sismo de Idaho en 1983 ($M_w = 6.9$) (Andrus y Stokoe, 1996). Por limitaciones de espacio se presenta el esquema de entrada más simple, pero ARELI contiene conceptos y funciones de membresía sobre otras condiciones de sitio (pruebas índice, descripciones geológicas, geomorfológicas y geotécnicas) y su relación lingüística con un aspecto de la licuación de los materiales (descripción detallada de las fuentes bibliográficas en García et al., 2010).




Figura 3. Módulo Neuronal y Árbol de Regresión: proceso de aprendizaje con retroalimentación.

Sitio	Prof. NAF (m)	Z* (m)	H (m)	Esf.Vert (kPa)	Esf.Vert Ef (kPa)	Tipo Suelo	Vs (m/s)	amax (g)	Licuación?	
									RN	Observada
Pence Ranch	1.7	1.8	1.9	57.2	46.2	Arena	107	0.36	0	0
	1.5	1.5	2.8	52.7	40.5	gravosa	94	0.36	0	0
	1.4	1.4	1.8	44.5	36	a	102	0.36	0	0
	1.8	1.8	2.8	62.1	49.4	Grava	109	0.36	0	0
	1.5	1.5	1.9	60.5	45.6	Arenosa	122	0.36	0	0
	2	2	1.7	57.5	46.3		134	0.36	0	0
	1.5	1.5	1.7	38.8	32.9		128	0.36	0	0
	1.5	1.5	1.9	38.4	32.4		107	0.36	0	0
	1.5	1.5	1.7	39.4	33.8		131	0.36	0	0
	1.7	1.7	1.5	43.3	38.3		122	0.36	0	0
Goddard Ranch	1.5	1.5	2.3	48.5	38.1		154	0.36	0	0
	1.2	1.2	2	47.3	36	Grava arenosa	122	0.3	1	0
Andersen Bar	1.2	1.2	2	41.1	32.7	Grava arenosa	105	0.3	0	0
	0.8	0.8	2.4	40.6	28.7	Grava arenosa	106	0.29	0	0
Larter Ranch	0.8	0.8	2.4	39	27.8		105	0.29	0	0
	0.8	2.2	1.3	59.9	39	Grava areno-limosa	176	0.5	0	0
Whiskey Springs	0.8	2.2	1.3	55.4	38.4		153	0.5	0	0
	0.8	2.2	1.3	59.9	40.5		183	0.5	0	0
North Gravel Bar	0.8	1.8	2.2	59.1	38.2	Grava limo-arenosa	181	0.5	0	0
	0.8	1.8	2.2	45.6	31.7	Grava limo-arenosa	210	0.5	0	0
Mackay Dam	1	1.8	1.2	51	36	Grava arenosa	206	0.46	1	1
	3	3	1.3	75.2	53.5	Grava arenosa	274	0.46	1	1
	2.3	2.3	2.7	66.6	57.4	Grava areno-limosa	271	0.23	0	1

Z* Profundidad a la frontera superior
 del estrato
 H Espesor del estrato
 Esf.Vert Esfuerzo vertical (Total)
 Esf.Vert Ef Esfuerzo vertical (Efectivo)
 0 – Licuación SÍ
 1 – Licuación NO

Figura 4. Ejemplo de Tabla de Entrada y Salidas calculada y observada.

Con ARELI se puede partir del juicio de los expertos, hacerlo empatar con los conceptos almacenados en la memoria difusa de ARELI (Youd y Perkins, 1987; Kramer, 1996, por mencionar algunos de los trabajos integrados) y deducir el valor numérico que más convenga al análisis. En este ejemplo la demanda sísmica se integra con a_{max} y M .

Cuando este patrón de entrada llega al módulo neuronal la salida binaria indica "licuación: sí". La clasificación acertada de ARELI está por encima del 88% de los casos usados en la prueba del modelo neuronal, siendo importante aclarar que un gran número de patrones que no pudieron ser evaluados

correctamente contaban con información contradictoria entre los niveles de resistencia a la penetración y el tipo de material.

ARELI finalmente bosqueja el patrón del comportamiento de este caso de análisis como se muestra en la Figura 5. La comparación de los resultados de simulación y los de ARELI revela la alta capacidad de predicción del modelo y sus remarcables ventajas en el estudio y aprendizaje de la licuación y los procesos relacionados.




Figura 5. Ejemplo del patrón de comportamiento y su interpretación con el esquema de análisis ARELI.

3 CONCLUSIONES

Existe un gran número de métodos que el ingeniero puede seleccionar cuando analiza, clasifica o resuelve problemas de regresión. Las técnicas cognitivas cuando “trabajan” y “producen” predicciones numéricas o clasificaciones acertadas basadas en un reducido número de condiciones lógicas, representan una gran ventaja sobre otras alternativas escasas y “oscuras”, de difícil acceso y con poca utilidad fuera de las bases de datos con las que fueron construidas.

Los resultados finales de ARELI se pueden resumir como una serie de condiciones lógicas si-entonces (nodos del árbol), siendo la RN la que ratifica y retroalimenta dichas condiciones y la LD la que traduce el conocimiento y la experiencia para completar el análisis. En ARELI no existen hipótesis implícitas sobre las relaciones entre las variables de entrada y las dependientes, por lo que esta herramienta es ideal para el estudio de fenómenos relacionados con los sismos y los suelos, dónde existe poco conocimiento a priori sobre las ligas paramétricas o el conjunto de teorías parece en algunos sentidos incongruente (importancia de variables y cómo están relacionadas).

La interpretación de los resultados de ARELI es muy simple. Esta simplicidad es útil no sólo cuando se requiere una rápida clasificación (o predicción) de nuevas observaciones, sino porque tener un modelo más simple para explicar las observaciones y los resultados

de clasificación (o predicción) permite elaborar conceptos, conclusiones y conocimientos “naturales”.

Se demuestra con los resultados presentados en este trabajo que, en el estudio del potencial de licuación, los métodos del CC pueden ayudar a revelar relaciones simples, explotando las variables de fácil y económica obtención en campo y laboratorio.

4 REFERENCIAS

- Adriaans P y Zantinge D, (1996). Data Mining , New York: Addison Wesley.
- Aghda S, Teshnehlav A, Suzuki T., Akiyoshi T y Kitazono, (1998), Liquefaction Potential Assessment Using Multilayer Artificial Neural Network, J. Sci. I.R. Iran, Vol.9, No.3.
- Andrus, R.D., y Stokoe, K.H.,(2000) II. "Liquefaction resistance of soils from shear-wave velocity," Journal of Geotechnical and Geoenvironmental Engrg., ASCE, 126(11), 1015-1025.
- Andrus, R.D., Stokoe, K.H., II, Chung, R.M., Juang, C.H. (2003), "Guidelines for evaluating liquefaction resistance using shear wave velocity measurements and simplified procedures." NIST GCR 03-854, National Institute of Standards and Technology, Gaithersburg, MD.
- Andrus, R.D.y Stokoe, K.H., (1996), "Liquefaction Resistance Based on Shear Wave Velocities", Proc. NCEER Workshop on Eval. Liquefaction Resistance of Soils, Eds. Youd and Idriss, NCEER-97-0022.

- Boulanger, R, Mejia L, e Idriss, (1999) I, Closure to "Liquefaction at Moss Landing during Loma Prieta earthquake." *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, 125(1): 92-96.
- Boulanger R, Meyers M, Mejia L e Idriss,I (1998), "Behavior of a fine-grained soil during Loma Prieta earthquake." *Canadian Geotechnical J.*, 35: 146-158.
- Boulanger R, Idriss I y Mejia,(1995), Investigation and evaluation of liquefaction related ground displacements at Moss Landing during the 1989 Loma Prieta earthquake. Report No. UCD/CGM-95/02, Center for Geotechnical Modeling, Department of Civil & Environmental Engineering, University of California, Davis, 231 pp.
- Boulanger R, Mejia L, e Idriss (1997),I, "Liquefaction at Moss Landing during Loma Prieta Earthquake." *Journal of Geotechnical and Geoenvironmental Engineering*, ASCE, 123(5): 453-467.
- Boulanger R, (2003) "Relating K_0 to relative state parameter index." *J. Geotechnical and Geoenvironmental Engineering*, ASCE, 129(8), 770-773.
- Boulanger R (2003b) "High overburden stress effects in liquefaction analyses." *J. Geotechnical and Geoenvironmental Engineering*, ASCE, 129(12), 1071-1082.
- Bonissone P.P. (1987). *Soft Computing: the Convergence of Emerging Reasoning Technologies. Soft Computing: A Fusion of Foundations, Methodologies and Applications*, 1(1) 6-18.
- Breiman L, Friedman J, Olshen R and Stone C, (1984). *Classification and Regression Trees*, Wadsworth, Belmont Eds..
- Chern S y Lee CH., (2009), CPT-Based Simplified Liquefaction Assessment by using Fuzzy-Neural Network, *Journal of Marine Science and Technology*, Vol. 17, No. 4, pp. 326-331.
- García S.R. (2008). *Métodos Conexionistas en la Solución de Problemas Geosísmicos*. Doctoral thesis, Facultad de Ingeniería, Universidad Nacional Autónoma de México, México.
- Gehrke J, Ramakrishnan R, and Ganti V, (1998). Rainforest – a framework for fast decision tree construction of large datasets. *Proceedings of the 24th International Conference on Very Large Databases*, Morgan Kaufmann, 416–427.
- Golesorkhi R, (1989), Factors influencing the computational determination of earthquake-induced shear stresses in sandy soils, Ph.D. thesis, University of California, Berkeley, 395 pp.
- Goh, A.T.C. (1996), "Neural network modeling of CPT seismic liquefaction data", *Journal of Geotechnical Engineering*, ASCE, Vol. 122, No. 1, pp: 70-73.
- Hájek P. (1995), Getting Belief Functions from Kripke Models. *Int. J. General Systems*, 23, No. 3, 00-00.
- Idriss I,(1999), "An update to the Seed-Idriss simplified procedure for evaluating liquefaction potential", *Proc., TRB Workshop on New Approaches to Liquefaction*, January, Publication No. FHWA-RD-99-165, Federal Highway Administration.
- Idriss I y Boulanger R., (2004),Semiempirical Procedures for evaluating Liquefaction Potential during Earthquakes, *Proc. of the 11th ICSDEE, USA*, pp 32-56.
- Idriss I, (1985), "Evaluating seismic risk in engineering practice," *Proc., 11th International Conference on Soil Mechanics and Foundation Engineering*, San Francisco, Balkema, Rotterdam, 265-320.
- Juang, C. H., Yuan, H. M., Lee, D. H., and Lin, P. S., (2003), "Simplified cone penetration test-based method for evaluating liquefaction resistance of soils," *Journal of Geotechnical and Geoenvironmental Engineering*, Vol. 129, No. 1, pp. 66-80.
- Kramer S. L., (1996). *Geotechnical earthquake engineering. Prentice-Hall International Series in Civil Engineering and Engineering Mechanics*, Prentice Hall, New Jersey, USA.
- Lim T, Loh W, y Shih Y, (1997). An empirical comparison of decision trees and other classification methods. *Technical Report 979, Department of Statistics, University of Wisconsin*, Madison, June.
- Mendel J.M. (1995), "Fuzzy Logic Systems for engineering: A Tutorial", *Proc. of the IEEE*, vol. 83,nº 3, pp. 345 - 377.
- Murthy S., (1995). On growing better decision trees from data. *PhD thesis, Department of Computer Science, Johns Hopkins University*, Baltimore, Maryland.
- Seed H, e Idriss I, (1971), "Simplified Procedure for Evaluating Soil Liquefaction Potential," *J. Soil Mechanics and Foundations Div.*, ASCE, 97:SM9, 1249-1273.
- Youd, T.L. and D. M. Perkins, (1987). Mapping of Liquefaction Severity Index, *Journal of the Geotechnical Engineering Division*, ASCE, pp.1374-1393.
- Zadeh L.A. (1994). *Fuzzy Logic and Soft Computing: Issues, Contentions and Perspectives*. *Proc. of IIZUKA'94: Third Int. Conf. on Fuzzy Logic, Neural Nets and Soft Computing*, Iizuka, Japan, 1-2.
- Zergoun M y Vaid Y,(1994), "Effective stress response of clay to undrained cyclic loading," *Canadian Geotechnical Journal*, 31: 714-727.