



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA CIVIL – GEOTECNIA

ESTIMACIÓN DE LA VARIACIÓN ESPACIAL DE LA RESISTENCIA AL CORTE EN
SUELOS MARINOS USANDO REDES NEURONALES

TESIS
QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN INGENIERÍA

PRESENTA:
CÉSAR BONETTI MARTÍNEZ

TUTOR
DRA. SILVIA RAQUEL GARCÍA BENÍTEZ

MÉXICO, D. F. AGOSTO 2013

JURADO ASIGNADO:

Presidente: Dr. Eduardo Botero Jaramillo
Secretario: Dr. Neftalí Sarmiento Solano
Vocal: Dra. Silvia Raquel García Benítez
1^{er} · Suplente: Dr. Sergio Antonio Martínez Galván
2^{do} · Suplente: Dr. Celestino Valle Molina

Lugar donde se realizó la tesis: CIUDAD UNIVERSITARIA, México, D.F.

TUTOR DE TESIS:

DRA. SILVIA RAQUEL GARCÍA BENÍTEZ

FIRMA

*A la **UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO (UNAM)***

por ofrecerme la oportunidad de estudiar dentro de sus aulas y brindarme

las herramientas que me permitieron cumplir con uno de

mis objetivos profesionales

*Al **CONSEJO NACIONAL DE CIENCIA Y TECNOLOGÍA (CONACYT)***

por haberme becado para realizar mis estudios de

Maestría en Ingeniería

*Al **INSTITUTO DE INGENIERÍA DE LA UNAM***

por haberme apoyado para realizar mis tesis de

Maestría en Ingeniería

*A mi tutora de tesis **DRA. SILVIA RAQUEL GARCÍA BENÍTEZ,***

por su valiosa dirección, disposición, paciencia y dedicación

a fin de lograr la realización del presente trabajo

*Al **DR. CELESTINO VALLE MOLINA,***

por haber proporcionado la base de datos trabajada en esta tesis y

por sus valiosos comentarios como sinodal para mi examen de grado

Gracias a los sinodales por el tiempo dedicado a la revisión

de este trabajo y por sus valiosos comentarios:

DR. EDUARDO BOTERO JARAMILLO

DR. NEFTALÍ SARMIENTO SOLANO

DR. SERGIO ANTONIO MARTÍNEZ GALVÁN

RESUMEN

Para estimar la variación espacial de la resistencia al corte no drenada del suelo marino en un área de 1,092 km² y hasta una profundidad de 14 m en la denominada Sonda de Campeche, se modelaron Variadores Espaciales Neuronales a partir de información geotécnica de sondeos exploratorios. En estos pozos se realizaron ensayos de veleta de campo, veleta miniatura, torcómetro, prueba de compresión triaxial tipo no consolidada–no drenada UU y se determinó el peso volumétrico sumergido.

Con la información espacial de propiedades se construyó un aproximador neuronal que usa estos datos para calcular, de manera indirecta, los valores de resistencia al corte no drenada asociados a una prueba de compresión triaxial UU.

El desequilibrio entre el número de pozos, el número de muestras ensayadas y las dimensiones del área en estudio hacen de estas tareas (variaciones espaciales y aproximaciones de funciones) problemas extremadamente complejos por resolver. Para desarrollar redes eficaces se generó una población de pozos “virtuales” cuya función es alimentar a los modelos con patrones de entrenamiento adicionales. Esta original propuesta metodológica permite la expansión “inteligente” de bases de datos escasas o muestreo parcial.

Los resultados presentados en esta tesis permiten concluir sobre la pertinencia del uso de las redes neuronales en la solución de problemas que involucran el estudio minucioso de grandes volúmenes de suelo.

ABSTRACT

To estimate the spatial variation of the undrained shear strength of marine soil, in an area of 1,092 km² and 14m depth located at the Sonda de Campeche, the Neural Spatial Variators were modeled based on geotechnical information obtained from boreholes. Vane, miniature vane, torvane, and unconsolidated-undrained triaxial compression tests were developed.

With the spatial information obtained, a neural approximator was constructed. This tool uses geo-information to calculate the shear strength associated to an unconsolidated-undreined triaxial compression test in an indirect way.

The umbalance among the number of boreholes, the number of samples and the dimensions of the study area makes these works (spatial variations and approximations of functions) an extremely hard problem to solve. A virtual boreholes population which work is to feedback the models with additional

training patterns was developed to get efficient networks. This original methodological proposal allows intelligent growth in poor database and partial sampling.

The results showed in this thesis allow to conclude that the use of this neural networks are appropriate in solving the problems involved in the study of large volumes of soil.

ÍNDICE

1	INTRODUCCIÓN	1
2	ALGUNAS CARACTERÍSTICAS DE LOS SUELOS MARINOS.....	3
3	EXPLORACIÓN DE SUELOS MARINOS: ASPECTOS BÁSICOS	11
3.1.	PRUEBAS DE CAMPO.	11
3.2.	PRUEBAS DE LABORATORIO.....	14
4	MÉTODOS DE INTERPOLACIÓN NUMÉRICA	19
5	REDES NEURONALES.....	29
5.1.	LA NEURONA ARTIFICIAL.....	30
5.2.	TOPOLOGÍA NEURONAL.....	33
5.3.	REGLAS DE APRENDIZAJE	34
6	APROXIMADOR NEURONAL DE LA RESISTENCIA AL CORTE EN SUELOS MARINOS.	37
6.1.	DESCRIPCIÓN DE LA BASE DE DATOS.....	37
6.2.	GEO-VARIABLES PARA EL MODELADO 3D Y LA ESTIMACIÓN INDIRECTA DE PROPIEDADES.	42
6.3.	CONSTRUCCIÓN DE LOS MODELOS	49
6.3.1.	Variadores espaciales neuronales, VEN.....	50
6.3.2.	Aproximador neuronal indirecto de la resistencia al corte Su_{uu} en suelos marinos, ANIRC.....	70
7	RESULTADOS.....	83
7.1.	VISUALIZACIÓN DEL MEDIO CON ANIRC.....	83
8	CONCLUSIONES.....	93
9	REFERENCIAS	95

A diferencia de la ingeniería estructural o mecánica, la ingeniería geotécnica trata con materiales naturales de estructura compleja, cuyas condiciones de trabajo y respuesta pueden ser complejas para analizar y/o diseñar y comúnmente se infieren a partir de limitadas y costosas observaciones. Esta característica le adhiere importantes niveles de incertidumbre a las actividades en obras civiles que se relacionan con las propiedades del suelo.

Las exploraciones geotécnicas aportan información necesaria para la determinación de las propiedades de los materiales que conforman el medio sin embargo, su estricta validez necesita en algunos de los casos, mayores niveles de confianza a lo largo de los sondeos y entre los mismos. Entonces el ingeniero geotecnista, de manera intuitiva o analítica inductiva debe estimar propiedades en muchos puntos más que los ensayados (García, *et al.*, 2005). Esto es particularmente importante cuando se trata de suelos marinos en los que la exploración, el muestreo y los ensayos de laboratorio requieren de equipo y personal de alta especialización, lo que provoca costos mucho mayores que los de exploraciones en tierra firme. Los estudios en suelos marinos suelen dirigirse en áreas extensas, así que el reto es lograr el equilibrio entre una confiable caracterización geotécnica y costos aceptables de sondeos bajo los criterios de obra rentable.

Por lo tanto, es necesario que el estado del arte sea actualizado y mejorado. Los modeladores y diseñadores que necesitan propiedades específicas de la masa de suelo en coordenadas no ensayadas demandan herramientas que permitan inferir o deducir la modificación de una propiedad del suelo debido a su posición en el espacio. El comportamiento geo-mecánico de las arcillas es complejo y la caracterización de sus propiedades *in-situ* en el ambiente marino no es trivial, debido a los grandes retos que adhieren a la exploración en este medio (DeGroot, Lunne, & Tjelta, 2011). Ante tales retos, el ingeniero geotecnista tiene que decidir ante la disyuntiva entre el número de puntos de medición necesarios para caracterizar lo mejor posible el medio y su costo, para proponer, con base en la experiencia, la mejor ubicación posible de los mismos.

En esta tesis se presenta una metodología para interpretar puntos escasos de observación en el medio marino y llegar así a una conclusión inteligente que genere mayor seguridad en los trabajos de exploración y otorgue una idea preliminar de la configuración de la resistencia al corte no drenada del suelo. Por lo tanto, explotando la capacidad de aproximador no lineal de las Redes Neuronales RN, en esta tesis se construyen modelos espaciales, de geopropiedades de suelos marinos para obtener indirectamente la resistencia al corte del medio.

Se elige la resistencia al corte no drenada del suelo, ya que es una propiedad de gran importancia dentro para el análisis y diseño de obras civiles y se relaciona directamente con la estabilidad del suelo ante las sollicitaciones de dichas obras, tales como como excavaciones, perforaciones, estructuras, etc. Según Peck, *et al.*, (1953), la resistencia al corte del suelo es un parámetro fundamental en el diseño, análisis y construcción de tales obras. Análogamente, conocer la variación de la resistencia al corte es de vital importancia en la toma de decisiones en las etapas de estudio y ejecución de las obras civiles desplantadas en el fondo marino.

Objetivo

Estimar la variación espacial de la resistencia al cote no drenada en suelos marinos que se obtendría mediante pruebas de compresión triaxial tipo no consolidada – no drenada a partir de otras pruebas de resistencia al corte más sencillas y económicas.

Alcance

Las estimaciones neuronales de la variación espacial de la resistencia al corte realizadas en esta tesis se obtuvieron a partir de una base de datos escasa, obtenida de la medición de dicha propiedad en 5 pozos de menos de 15 m de profundidad que se distribuidos en un área de 2,578.70 km², por lo que los modelos construidos solamente aplican para la zona en cuestión.

Esta tesis no se centra en definir cuál es la mejor o mejores geo-propiedades para definir la resistencia al corte del suelo marino.

Las geo-propiedades presentadas en este documento son las únicas con las que se cuenta para realizar los análisis correspondientes.

2 ALGUNAS CARACTERÍSTICAS DE LOS SUELOS MARINOS

Esta sección no intenta ser exhaustiva describiendo a los suelos marinos, sólo se presentan algunas de sus propiedades que resultan fundamentales en el desarrollo e interpretación de los modelos neuronales contruidos en esta tesis.

Debido a la gran importancia económica que el hidrocarburo ha ganado en todo el mundo y al creciente desarrollo de tecnología enfocada en su explotación, gran cantidad de las recientes construcciones marinas se enfocan en la fabricación de infraestructura para satisfacer las necesidades de la industria petrolera.

Condicionantes físicas del ambiente marino para fines de exploración, análisis, diseño y construcción de obras civiles costa afuera

Los métodos de análisis y diseño de obras civiles costa afuera, los equipos y procedimientos para la exploración de suelos y construcción de dichas obras son condicionadas por el ambiente físico característico de los océanos. Algunos factores que caracterizan a este ambiente según Gerwich (2000) son: las grandes distancias, las altas presiones hidrostáticas, la composición química del medio, las corrientes, el oleaje y la marea. A continuación se describen brevemente cada uno de estos factores.

- a) Las grandes distancias deben considerar incluso la curvatura de la Tierra.
- b) Las altas presiones hidrostáticas actúan de manera isotrópica e incrementan linealmente con la profundidad. La presión hidrostática está ligada directamente con el principio de boyancia o flotación definido por Arquímedes, donde el peso neto de un objeto sumergido es igual a su peso no sumergido menos el peso del agua que desaloja.
- c) Las características químicas del medio marino cuyo contenido de sodio, magnesio, cloruro, aceleran el proceso de corrosión del acero y concreto.
- d) Las corrientes marinas influyen en la estabilidad de las embarcaciones y estructuras marinas, creando vórtices en pilas, tensores y tuberías que pueden socavar al suelo de cimentación.
- e) El oleaje y la marea provocan que las estructuras y las embarcaciones respondan en 6 grados de libertad (desplazamientos horizontales en dirección x y y , desplazamiento vertical en dirección z y giro respecto a cada uno de los ejes x , y y z). Se considera que estos factores junto con el viento y las tormentas constituyen la principal causa de reducción de la eficiencia en la ejecución de exploración de suelos y construcción de obras civiles costa afuera.

Dificultades en la exploración de suelos marinos

Muchas obras de ingeniería en el océano se extienden en grandes áreas, por lo que existe mayor probabilidad de encontrar variaciones importantes de propiedades en los suelos. Debido a la relación costo *versus* tiempo requerido, no es posible realizar sondeos suficientes para mostrar la variación real de las geo-propiedades requeridas. Por esta razón se debe poner suficiente interés en el desarrollo de variadores espaciales que generalicen correctamente a partir de los pocos sondeos realizados.

La exploración en arcillas representa serios problemas para el ingeniero geotecnista. La susceptibilidad al remoldeo puede provocar pérdida temporal de la resistencia, por lo que es común que se midan menores resistencias en la muestras que la existente en campo (Bruun, 1989). Algunas de las pruebas para medir dicha resistencia en campo son: prueba de penetración estándar (SPT), veleta de campo, prueba de penetración de cono (CPT), phicómetro, etc. Todas estas pruebas requieren factores de corrección por profundidad, rango de resistencia y anisotropía de la arcilla.

Características geotécnicas

La mayoría de los suelos marinos están formados principalmente por arcillas, limos y arenas. Los sedimentos más someros son por lo general más sueltos y débiles y su espesor suele ser variable. En taludes marinos, suelen producirse deslizamientos debido a las corrientes producidas durante procesos de construcción y/o perforación a causa del exceso de presión de poro que se acumula a los costados de las estructuras o de las herramientas de perforación al momento de ser colocadas en el lecho marino.

Para fines de los alcances de esta tesis y debido a la heterogeneidad de los suelos marinos de todo el mundo, las características geotécnicas de los suelos del Golfo de México y en particular, en la denominada Sonda de Campeche serán abordadas. Los depósitos de la Sonda de Campeche están formados principalmente por partículas de sílice que se derivan principalmente de rocas meteorizadas y ceniza volcánica transportados por los ríos y el viento. Estos depósitos son fácilmente identificables por su alto contenido de arcilla, alta plasticidad, bajo contenido de limos y baja resistencia al corte, se les denominan coloquialmente como "lodos", término que denota alta plasticidad, y consistencia suave.

El último nivel del intemperismo de la roca resulta en la formación de arcillas, las cuales constituyen un gran volumen de los suelos marinos del mundo. Estos suelos se consolidan bajo la carga de los nuevos depósitos. Algunas de sus propiedades como la resistencia al corte y la permeabilidad son anisotrópicas. Regularmente estos depósitos contienen lentes de limo y arena, así como cierta cantidad

de materia orgánica. Estas arcillas suelen tener resistencias al corte entre 35 y 14 kPa, aunque en algunos más superficiales se pueden presentar resistencias de hasta 2 kPa.

Por otro lado, el proceso de consolidación en arcillas juega un papel importante en su comportamiento mecánico. La reducción de la relación de vacíos provoca dicha consolidación ganando resistencia. En suelos sumergidos se requiere, a parte de permitir el drenaje del suelo, una sobrecarga que expulse el agua para reducir la relación de vacíos. El incremento de la resistencia al corte debido a este proceso en suelos marinos es alrededor de 2 a 5 veces que la de los no consolidados (Quinn, 1975).

Según Poulos (1988), existe evidencia de que el comportamiento fundamental de las arcillas del lecho marino (costa afuera) y las arcillas en tierra firme (costa adentro) es similar, por lo que bajo ciertos aspectos prácticos en el desarrollo de obras civiles en el fondo marino, algunas de las relaciones hasta el momento publicadas en ciertas arcillas costa adentro (arcillas azules de Boston, de Bangkok o las arcillas barbadadas de Connecticut) pueden ser aplicadas a los depósitos marinos.

La baja consistencia de las arcillas tan plásticas del fondo del suelo marino que se analiza en esta tesis, hace imperioso el uso de ciertos índices o parámetros que expresan el valor de esta propiedad. Entre los parámetros más notables se encuentran i) la resistencia al corte no drenada, ya que si el esfuerzo cortante provocado por la ejecución de obras excede cierto valor crítico, el suelo falla, y ii) el peso volumétrico del suelo sumergido, valor necesario para la estimación de los esfuerzos verticales efectivos en la profundidad analizada.

Resistencia al corte no drenada S_u .

Uno de los objetivos principales de la investigación geotécnica costa afuera es la obtención de geoinformación del suelo marino, tal como la resistencia al corte no drenada necesaria para el análisis, diseño y construcción de obras civiles.

Según la ley fenomenológica de resistencia al esfuerzo cortante en materiales térreos formulada por C. A. Coulomb (1773), esta propiedad se define como la oposición del suelo a ser cortado o fallado. En suelos cohesivos-friccionantes, la resistencia al corte depende de la cohesión, del ángulo de fricción interna y del esfuerzo normal al plano de falla. Coulomb propone que un material falla cuando el esfuerzo cortante actuante en un elemento plano a través de un suelo alcanza el valor

$$\tau = c + \sigma \tan\phi \qquad 2.1$$

donde τ es el esfuerzo cortante actuante final o de falla, c es la cohesión del suelo supuesta constante por Coulomb (resulta ser la resistencia del suelo bajo presión normal exterior nula), σ es el esfuerzo normal actuante en el plano de falla y ϕ es el ángulo de fricción interna del suelo supuesto constante por Coulomb. La mecánica de suelos actual suele utilizar como criterio de falla lo que se acostumbra llamar criterio de Mohr-Coulomb, en el cual se emplea la ecuación 2.1.

Analógicamente, Coulomb estableció históricamente el concepto de cohesión, al observar que algunos materiales presentaban resistencia bajo presión normal exterior nula. De esta manera postuló como la ley de resistencia posible para tales materiales la expresión 2.2.

$$S = \tau = c \quad 2.2$$

Estos materiales fueron llamados “puramente cohesivos”, por lo que en ellos se consideró que ϕ era igual a cero. En la actualidad se sabe que la resistencia al corte, también depende de las condiciones de drenaje del suelo, tal es el caso de la resistencia al corte en condiciones no drenadas (S_u) donde la permeabilidad del material, si bien no es nula, es tan baja que puede considerarse nula con respecto a la velocidad de aplicación del esfuerzo que provoca la falla (esfuerzo desviador). La expresión que define a S_u es:

$$S_u = c \quad 2.3$$

Se aprecia que la expresión 2.3 es prácticamente igual a la 2.2, sin embargo ésta reconoce que el ángulo de fricción del material es aparente y depende de la condición de drenaje al que se somete (cuando no hay drenaje durante la aplicación del esfuerzo desviador el ángulo de fricción interna es cero).

En suelos marinos la condición de drenaje es muy lenta debido a la baja permeabilidad de las arcillas ($k = 10^{-6} 2.718^m$, donde k es la permeabilidad en cm/s, $m = 14.3 n - 26.3$ y n es la porosidad del material que puede ir de 0 a 1) (Bryant, *et al.*, 1976) y a la velocidad con la que se desplantan las obras civiles. Por apegarse a las condiciones de drenaje del medio, S_u resulta ser empleada para el análisis y diseño de obras costa afuera.

S_u se puede determinar de varias maneras, realizando pruebas de torcómetro, penetrómetro de mano (o de bolsillo) y de veleta miniatura aplicadas en muestras de arcilla que son adecuadas si la información de las características esfuerzo-deformación del suelo no son necesarias. Comúnmente los ensayos de

compresión sin confinar, compresión triaxial o procedimientos de corte directo y simple son los utilizados para modelar el estado de esfuerzo *in situ* empleando pruebas convencionales de laboratorio. Debido a los diferentes procedimientos característicos de cada una de estas pruebas, las mediciones de S_u pueden ser susceptibles a inexactitudes y a una considerable dispersión. Un ejemplo de ésta en ensayos de S_u en el Golfo de México se grafican en la figura 2.1. A pesar de la dispersión de los puntos medidos de S_u , se muestra un claro incremento de esta propiedad con la profundidad.

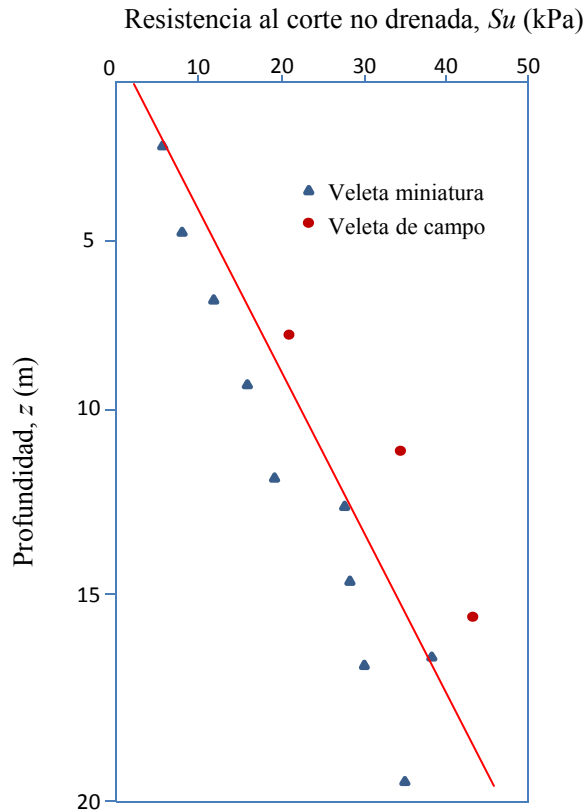


Figura 2.1. Perfil típico de S_u en el Golfo de México (modificada de Quiros, et al. 1983)

La resistencia al esfuerzo cortante del suelo se puede comprender de mejor manera en términos de su consistencia. La consistencia de los suelos varía de muy suave a muy rígida y es directamente proporcional a la S_u que presentan, sin embargo para el caso del lecho marino formado a base de arcillas, como es el caso del Golfo de México, los valores de consistencia van de muy suave a firme. Estudios realizados en diferentes suelos del mundo coinciden en la relación consistencia- S_u (Head, 1994, Gerwich, 2000, National Engineering Handbook, 2007, Day, 2010, entre otros). En esta tesis se tomó en cuenta la relación publicada en el National Engineering Handbook, ya que clasifica a la consistencia del suelo por rangos en el dominio de S_u (ver tabla 2.1).

Tabla 2.1. Consistencia versus Resistencia al corte S_u (National Engineering Handbook, 2007).

Consistencia	Resistencia al corte, S_u (kPa)
Muy suave	< 12
Suave	12 – 25
Firme	25 – 50
Muy firme	50 – 100
Dura	100 – 200

Peso volumétrico sumergido γ' .

Con el fin de comprender la variación de esfuerzos verticales efectivos en condición geo-estática con respecto a la profundidad es necesario conocer el peso volumétrico sumergido γ' . El cálculo de los pesos volumétricos situados bajo el agua debe tratarse con especial atención.

El peso volumétrico sumergido suele variar entre 4 y 9 kN/m³. Exploraciones realizadas en suelos marinos muestran que este parámetro no suele incrementar o disminuir con respecto a la profundidad (Thales Geosolutions, 2002), por lo que conocer dicha propiedad permite tener una idea del estado de esfuerzos efectivos al que se somete el medio del suelo marino. Dichos esfuerzos suelen incrementar de manera proporcional con la profundidad provocando la consolidación de los suelos más profundos. A su vez, el grado de consolidación al que está sometido el suelo responde de manera proporcional con la resistencia al corte. Bajo tal condición la resistencia al corte del suelo suele variar considerablemente con la profundidad (Fukue, *et al.*, 2000).

Desde el enfoque del SHANSEP (Historia de Esfuerzos y Propiedades Ingenieriles en Suelos Normalizados) propuesto por Ladd y Foott (1974), en el que la resistencia al corte medida se normaliza con respecto al esfuerzo efectivo (S_u/σ'_v) y que se relaciona contra la relación de sobreconsolidación OCR (σ'_p/σ'_v), se observa que la resistencia de los suelos, y en particular los del fondo marino del Golfo de México, es proporcional con el OCR (figura 2.2), es decir, mientras más consolidado se encuentre el suelo, mayor es su resistencia.

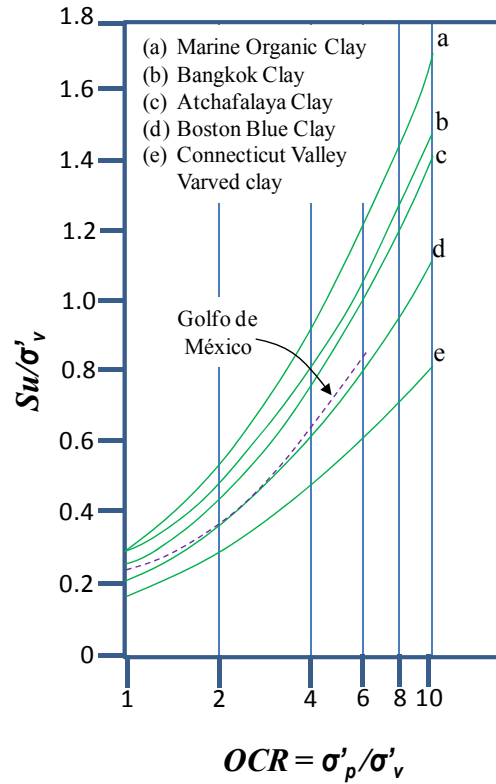


Figura 2.2. Resistencia al corte normalizada versus OCR (modificada de Quiros, et al. 1983)

donde S_u es la resistencia al corte sin drenaje del suelo, σ'_v es el esfuerzo vertical efectivo y σ'_p es el esfuerzo de preconsolidación.

3 EXPLORACIÓN DE SUELOS MARINOS: ASPECTOS BÁSICOS

En las últimas décadas la exploración de los océanos se ha incrementado intensamente debido principalmente a la necesidad de explotación de recursos de origen marino, entre los más demandados se encuentran hidrocarburos, minerales, depósitos sedimentarios, y energía térmica y cinética. Son los hidrocarburos los más importantes y los que representan alrededor del 90% del valor económico de estos recursos (Geer, 1982); debido a su impacto económico los esfuerzos en tecnología e ingeniería se enfocan principalmente en su explotación. La ingeniería geotécnica marina es solamente una entre un extenso número de disciplinas involucradas en la explotación de tan preciado recurso.

Las estructuras para fines de extracción de hidrocarburo se instalan en el suelo marino. Conocer las propiedades del suelo en las etapas de diseño y análisis de factibilidad de las obras marinas. La exploración del fondo marino consta de pruebas *in situ* y ensayos en laboratorio. Las pruebas *in situ* llevadas a cabo en condiciones controladas y el muestreo mediante perforación, se mantienen como actividades principales para la identificación y caracterización de los materiales.

Las pruebas de campo permiten medir directamente la resistencia al corte del suelo en condiciones *in situ*. Las pruebas de laboratorio que también miden la resistencia al corte, se realizan en muestras extraídas del medio y se desarrollan bajo un ambiente controlado, sin embargo los efectos de extracción, transporte, almacenamiento, manipulación, preparación, pérdida de confinamiento natural y montaje de la muestra, provocan alteraciones. En la práctica se prefieren los resultados de ensayos de laboratorio (Santoyo, 2010), sobre los obtenidos en campo cuando la dimensión e impacto de la obra son mayúsculos. Los valores de S_u medidos en pruebas en cámaras triaxiales son los solicitados en dichas condiciones y se requiere una delicada observación de las condiciones de esfuerzo, de drenaje y de aplicación de la carga para asegurar su pertinencia.

A continuación se describen las pruebas de campo y laboratorio que están involucradas en la información recopilada para el desarrollo del presente trabajo de investigación.

3.1. PRUEBAS DE CAMPO.

Veleta de campo.

Desde 1968, debido a la dificultad para obtener muestras inalteradas de buena calidad en suelos marinos a medida que el tirante de agua aumenta, se empezaron a desarrollar pruebas *in situ* que

permitieran la interpretación cualitativa y cuantitativa de los perfiles de suelo y de sus propiedades mecánicas (Mejía, 2009).

La medición de la resistencia al corte *in situ* de los suelos cohesivos empleando la veleta manual fue desarrollada en Suecia por John Olsson en 1919. Esta prueba consiste en hincar en el suelo una cruceta de lámina de acero y después, al hacerla girar, movilizar la resistencia al corte del cilindro de revolución que se genera en la masa de suelo (Santoyo, 2010). Según la norma ASTM D-2573, en la prueba de veleta de campo se debe hincar una veleta de cuatro aspas, sólo en suelos cohesivos y debería ser a la profundidad donde se requiere estimar la resistencia. El torque se aplica a carga constante hasta que el suelo falla en la superficie cilíndrica. El torque medido al momento de la falla está relacionado directamente con la resistencia al corte del suelo. En una segunda etapa se realiza otra prueba, pero esta vez en el material remoldeado del extraído a la misma profundidad, obteniendo la resistencia al corte remoldeada y con ello la sensibilidad del suelo (relación entre la resistencia entre la muestra inalterada y la remoldeada).

A la par del desarrollo tecnológico, las veletas han experimentado mejoras en el mecanismo de ejecución de torque y de medición (bandas extensométricas ó *strain gages*). La figura 3.1 muestra las piezas que conforman generalmente a una veleta de campo.



Figura 3.1 Veleta eléctrica de campo.

La veleta es útil únicamente para medir la resistencia al corte no drenada en arcillas suaves y depósitos orgánicos, no debe ser usada en arcillas rígidas (Head, 1994). Los resultados de esta prueba se pueden ver afectados por la presencia de gravas, conchas, raíces y lentes de arena. En ocasiones, debido a la

velocidad de aplicación del torque y la fricción que aporta el vástago, puede sobrestimarse la resistencia al corte por lo que es conveniente usar factores de corrección (Santoyo, 2010). Sin embargo, según Kolk, *et al.* (1988) y Radolph, (2004) indican que los resultados de la prueba se pueden usar directamente, ya que justifican que una parte de la reducción de la resistencia por remoldeo es parcialmente compensada por la velocidad de aplicación del esfuerzo cortante al momento de la prueba. Cabe mencionar que en esta tesis no se usaron factores de corrección. La justificación a este hecho se expresa en posteriores capítulos.

La principal ventaja técnica de este método para la obtención de la variable $Su\text{-}vcampo$ (resistencia al corte con veleta de campo) es que la alteración por muestreo del suelo es mínima durante el hincado de las espas, aunque la manipulación del operador podría afectar significativamente los resultados. Sin embargo si no nos interesa el estado de esfuerzos del suelo antes de la falla, esta prueba sigue siendo una buena herramienta para estimar la resistencia al corte no drenada Su (DeGroot, *et al.*, 2011).

Torcómetro.

Otro aparato sencillo, práctico y rápido, para obtener una primera aproximación de la resistencia al corte no drenada es el torcómetro (figura 3.2). La resistencia en cierta zona del suelo muestreado se mide al indentar las pequeñas espas y haciendo girar la perilla hasta que el suelo falle.




Figura 3.2 Torcómetro.

Este aparato opera prácticamente con los mismos principios que la veleta miniatura. La diferencia está en que el torque se aplica de manera manual. El torcómetro es de fácil transporte y manejabilidad y se usa tanto en campo como en laboratorio sin importar que la superficie donde se requiera conocer la

resistencia sea o no horizontal. Este aparato tiene claras limitaciones prácticas: las mediciones dependen grandemente del operador y las aspas del torcómetro sólo se indentan superficialmente en la muestra (mediciones sometidas a condiciones de frontera).

Las aspas de mayor diámetro otorgan más sensibilidad para las mediciones menores a 20 kPa, mientras que las aspas de menor diámetro pueden hacer mediciones por arriba de los 250 kPa. El torcómetro se debe usar para complementar la clasificación visual y al tacto del suelo y no sustituye los métodos de medición de la resistencia con fines de diseño. Según Bartetzko y Kopf (2006), el torcómetro está cayendo en desuso por su poca precisión y su baja exactitud. Sin embargo, esta sencilla herramienta permite identificar zonas de mayor o menor resistencia de forma muy inmediata aunque general. Esta herramienta también se puede usar en laboratorio en muestras dentro de tubos Shelby o en cubos labrados de suelo.

3.2. PRUEBAS DE LABORATORIO.

Veleta miniatura

La prueba con veleta miniatura sigue las bases de funcionamiento de la veleta de campo. La diferencia entre ambas radica en la escala. La veleta miniatura es un aparato simple utilizado para medir la resistencia al corte del suelo y fue diseñado para hacer mediciones en laboratorio (figura 3.3) incluso por debajo de los 20 kPa (Head, 1994). Algunas muestras de suelo pueden ser ensayadas directamente desde el tubo de pared delgada (Shelby) para provocar menos perturbaciones en la misma. Se asume que la zona remodelada alrededor de las aspas de la veleta, como consecuencia del proceso de hincado es mucho menor que la que tiene la veleta de campo, y tiene un efecto despreciable en la resistencia medida. Sin embargo el muestreo, transporte, almacenaje y manipulación del tubo Shelby puede influir en los resultados, siendo los suelos marinos particularmente sensibles al efecto de estas perturbaciones (Young, *et al.*, 1983).

Al igual que en la prueba de veleta de campo, el torque aplicado se relaciona con valores de resistencia al corte. Este torque debe ser motorizado y rotar al resorte de torsión a razón constante de 60 a 90° por minuto.

Por otra parte, según estudios realizados en suelos marinos del Golfo de México (Head, 1994) y (Quiros, *et al.*, 1983) los resultados de la veleta miniatura pueden ser comparados directamente con los

obtenidos mediante pruebas de compresión axial no confinada. La norma ASTM D-4648 recomienda que esta prueba se realice en suelos finos, predominantemente en arcillas con S_u menor a 100 kPa.



Figura 3.3 Veleta miniatura.

El mecanismo de falla del suelo provocado por las pruebas que usan espas está definido por la geometría de las mismas y no reproduce ninguna condición natural de falla. Esta es una razón por la que esta prueba suele ser cuestionada, sin embargo debido a su sencillez, practicidad, rapidez y relación con los niveles de S_u obtenidos en cámara triaxial, la veleta miniatura ha ganado gran aceptación. Se recomienda al lector interesado en la interpretación de las pruebas de veleta consultar las publicaciones de Richards (1988) y Schnaid (2009).

Prueba de compresión triaxial no consolidada - no drenada UU.

La prueba triaxial constituye el método más versátil en el estudio de las propiedades esfuerzo-deformación del suelo. En este ensaye es posible reproducir una gran variedad de estados de esfuerzo y presión dentro de la muestra de suelo. El método consiste prácticamente en someter una muestra cilíndrica de suelo a presiones de confinamiento en una cámara triaxial y posteriormente se incrementa la carga axial hasta que la muestra falla por corte (ver figura 3.4). Las presiones a las que se somete el

suelo son en tres direcciones perpendiculares entre sí (de ahí, el nombre de triaxial), una componente vertical y las otras dos horizontales.

Los distintos tipos de prueba triaxial están constituidas por dos etapas generales, la primera, en la que se aplica presión de confinamiento a la muestra y puede permitirse o no el drenaje (que exista o no consolidación previa) y la segunda, también llamada etapa de carga, en la que la muestra es sometida a un esfuerzo axial vertical que provoca esfuerzos cortantes en su interior. Durante esta etapa puede también permitirse o no el drenaje de la muestra ya sea para medir la presión de poro o el cambio volumétrico de la muestra, antes, durante y después de la falla. En el caso de la prueba UU la válvula de drenaje de la muestra permanece cerrada durante las dos etapas mencionadas ya que el propósito de esta prueba es medir la resistencia al corte no drenada del suelo.




Figura 3.4 Cámara triaxial.

En la prueba UU se producen esfuerzos cortantes en toda la muestra de suelo, así la superficie de falla generada es el plano donde actúan los mayores esfuerzos de corte. A diferencia de los métodos de veleta y torcómetro, donde el plano de falla es inducido por el giro de las espas, en la prueba UU dicho plano se genera en la muestra a partir de la aplicación de una diferencia de esfuerzos horizontales contra el vertical (esfuerzo desviador), lo que permite la orientación natural del plano de falla. Su principal desventaja se debe a la alteración durante el muestreo, el transporte, el almacenaje y la manipulación del material al momento de ser montada la probeta en la cámara triaxial. No obstante,

debido a que permite observar el comportamiento del estado de esfuerzos, no sólo en la falla sino durante todo de la prueba, es uno de los métodos más usados y mejor sustentados para conocer la relación esfuerzo - deformación y los parámetros de resistencia al corte del suelo.

4 MÉTODOS DE INTERPOLACIÓN NUMÉRICA

La interpolación numérica permite encontrar datos desconocidos entre o en medio de otros datos conocidos. La interpolación numérica es un problema complejo que permea muchas áreas del cálculo numérico. El objetivo de la interpolación consiste en obtener la expresión matemática en el espacio que verifique una serie de condicionamientos impuestos y que se adecue a un conjunto de puntos definidos (Aymerich y Navarrina, 1985).

Método de interpolación lineal

Uno de los métodos de interpolación más sencillos es el lineal. La interpolación lineal solamente es válida cuando existe una variación proporcional entre los datos. En este tipo de interpolación se utilizan dos puntos (x_a, y_a) y (x_b, y_b) para obtener un tercer punto interpolado (x, y) a partir de la siguiente expresión

$$y = y_a + (x - x_a) \frac{(y_b - y_a)}{(x_b - x_a)} \quad 4.1$$

La interpolación lineal es rápida y sencilla pero poco precisa. La figura 4.1 muestra una gráfica cuyos puntos evaluados son los interpolados linealmente (línea continua).




Figura 4.1 Interpolación lineal

La variación de valores entre un punto y otro es la constante m de la función lineal. Esta función se puede utilizar para interpolar datos desconocidos a partir de otros conocidos (siempre y cuando se relacionen linealmente).

Método de vecinos cercanos

Este tipo de aproximación se caracteriza por la construcción de polígonos (llamados polígonos de Thiessen), los cuales definen áreas de influencia individual por cada punto de un conjunto de puntos. Este interpolador calcula las distancias euclidianas entre un punto de la malla y los demás puntos asignando al punto el valor que exhibe aquel con la menor distancia al punto estudiado. En la figura 4.2 se muestra un ejemplo ilustrativo de este tipo de interpolador.




Figura 4.2 Polígonos de Thiessen, a) Conjunto de datos en el plano, b) Polígonos de interpolación de vecino más cercano.

Este método de interpolación se limita a generar polígonos para determinar áreas de influencia y no genera una superficie continua de variación espacial, por lo que la extrapolación se define únicamente por las líneas rectas que se proyectan hacia afuera del conjunto de datos y con longitud infinita.

El objetivo principal de este método es extender la información puntual asumiendo que la mejor información para ubicaciones sin observaciones es el valor del punto más cercano (Aronoff, 1989).

Método de superficie de tendencia.

Una forma relativamente sencilla para describir variaciones graduales en grandes distancias es por medio de una regresión polinomial. La idea es ajustar una superficie polinomial por mínimos cuadrados sobre puntos conocidos obteniendo la menor dispersión. Las funciones que se pueden usar varían desde la más sencilla o lineal (para áreas de poca variación) hasta muy complejas (dependiendo del grado de orden polinomial) para superficies con marcadas e intrincadas relaciones. La superficie que resulta es la que mejor se ajusta a la máxima cantidad de puntos (Burrough P. , 1985).

Esta técnica únicamente se desarrolla con mapas de puntos en el dominio del atributo numérico. Ejemplos de superficie con una tendencia lineal, se muestran en la figura 4.3a mientras la en la figura 4.3b se observa una polinomial.




Figura 4.3 Interpolación de tendencia de superficie, a) Regresión lineal, b) Regresión polinomial.

Geoestadística

En un sentido amplio se define a la geoestadística como la aplicación del formalismo matemático de las funciones aleatorias al reconocimiento y estimación de fenómenos naturales (Matheron, 1965). En la geoestadística, como en cualquier método de inter-extrapolación, se busca siempre minimizar la varianza del error de estimación, es decir, la diferencia entre el valor estimado y el valor real (Galván, 2009).

A diferencia de la estadística y del enfoque de la variable aleatoria simple, la geoestadística permite analizar datos de fenómenos distribuidos en el espacio tomando en cuenta la posición relativa que guardan los datos de la muestra. En la geotecnia se puede emplear la geoestadística para resolver en forma racional problemas tales como la estimación de espesores y profundidad de estratos y la variación espacial de propiedades geotécnicas en el medio (suelo) a partir de información medida en la zona, principalmente usando técnicas de estimación como el *Kriging*, que se enfoca básicamente en la obtención de estimadores lineales, sin sesgo y de mínima varianza, que toman en cuenta la estructura del medio.

El método geoestadístico y su aplicación en geotecnia han sido presentados en forma detallada por varios autores (Auvinet, 1984, Auvinet, 1997, Juárez y Auvinet, 2000, Auvinet, 2002, Auvinet, 2009 y

Galván, 2009, entre otros). A continuación se describen, de manera general, algunos conceptos expuestos en estos tabajos.

- Campos aleatorios.

Sea V una *variable aleatoria* también conocida como *variable regionalizada* (por ejemplo, contenido de agua ó ángulo de fricción interna, ó resistencia al corte), definida en el espacio V (“ X ”, “ Y ” y “ Z ”) del dominio estudiado R^p ($p = 1, 2, \text{ ó } 3$). En cada punto del dominio, esta variable puede considerarse como aleatoria debido a que se desconoce su valor. El conjunto de estas variables aleatorias constituye un campo aleatorio, (figura 4.4).




Figura 4.4 Representación de un campo aleatorio (Medina, 2001).

Para poder analizar el campo aleatorio se emplean principalmente los siguientes parámetros: esperanza, varianza, desviación estándar, coeficiente de variación y función de autocovarianza. La autocovarianza $C_V(X_1, X_2)$ representa el grado de dependencia lineal entre los valores de la variable aleatoria en dos puntos diferentes X_1 y X_2 . Esta dependencia se escribe bajo la forma de un coeficiente de autocorrelación (ecuación 4.2), la cual describe la correlación espacial existente entre los valores de V_1 y V_2 de la propiedad en estudio en puntos distintos X_1 y X_2 del medio.

$$\rho_V(X_1, X_2) = \frac{C_V(X_1, X_2)}{\sigma_{V_1} \sigma_{V_2}} \quad 4.2$$

Una herramienta equivalente a la función de autocovarianza es el modelo estadístico de segundo orden del incremento $V(X) - V(X + h)$, mostrado en la ecuación 4.3.

$$2\gamma(h) = E\{[V(X) - V(X + h)]^2\} \quad 4.3$$

Las funciones de correlación de las ecuaciones 4.2 y 4.3 no son propiedades intrínsecas de los dos puntos X_1 y X_2 , ya que dependen también de la población, es decir, del dominio en el que el campo se encuentra definido. Si la esperanza, la varianza y los demás parámetros son constantes en el medio, se dice que éste es estadísticamente homogéneo. Si la esperanza y la varianza del campo no son constantes, se dice entonces que presentan alguna *tendencia* o *deriva*.

- Análisis estructural.

Las ecuaciones 4.2 y 4.3 son obtenidas estadísticamente a partir de resultados discretos (muestras aisladas) o continuos (sondeos) de las campañas de exploración. Estos últimos se evalúan con la (ecuación 4.4), donde se considera que el campo es estadísticamente homogéneo, estacionario y ergódico.

$$\mu_V \cong \mu^* = \frac{1}{L} \int_0^L V(X) dX \quad 4.4$$

donde L es la longitud del sondeo.

En la misma forma se estima la autocovarianza a lo largo de la dirección u como:

$$C_V(\lambda u) \cong \frac{1}{L} \int_0^L V(X)V(X + hu)dX - \mu^{*2} \quad 4.5$$

donde u es el vector unitario en la dirección en la que se evalúa la covarianza y h es un escalar.

Para el caso de un análisis tridimensional es importante determinar el grado de anisotropía de cualquier propiedad del suelo $V(X)$ dentro del medio. Para estimar la anisotropía se estima la función de autocovarianza en varias direcciones del vector u obteniéndose así los llamados *correlogramas*

direccionales. A partir de estas funciones se estima la distancia de correlación, definida convencionalmente como:

$$\delta = 2a \quad 4.6$$

donde a es el área bajo la curva representativa de la función ρ_V .

Con base en las distancias de correlación, se obtienen los modelos teóricos de las funciones de autocorrelación ajustándolos a la siguiente función exponencial (VanMarcke, 1983) donde la correlación decrece al incrementar la distancia de separación.

$$\rho = e^{-2h/\delta} \quad 4.7$$

Si el valor de la distancia de correlación permanece constante en todas las direcciones estimadas, entonces se dice que el campo es isótropo; en cambio, si esta distancia es variable para las diferentes direcciones, se dice que es anisótropo. La anisotropía de un campo aleatorio puede representarse en forma geométrica a través de una elipse, llamada elipse de anisotropía.

- Estimación.

La técnica de Kriging, desarrollada por Matheron, (1965) con base en los trabajos de Daniel G. Krige (Krige, 1962), permite encontrar el mejor (en función de la mínima varianza) estimador lineal sin sesgo (en inglés: *Best Linear Unbiased Estimation, BLUE*), tomando en cuenta la correlación espacial supuesta.

La aplicabilidad del Kriging se determina con la aceptación de que la distribución espacial de cualquier propiedad geológica, hidrológica o geotécnica (*variable regionalizada*) es demasiado irregular para ser modelada usando una función matemática polinomial, y que además puede ser representada con mejores resultados con una superficie empíricamente determinada.

Según Goovaerts, 1997, el kriging y sus variantes (kriging simple y ordinario y co-kriging) son una variante de la regresión lineal básica. En el kriging simple se asume que existe una tendencia constante de los valores en todo el medio, para el kriging ordinario, se considera que la tendencia sólo existe en el vecindario cercano al punto medido mientras que para el co-kriging, que se basa en las consideraciones de ambos, puede incorporar información de una o más variables correlacionadas entre

sí (covariables), entregando una tendencia no lineal de los valores del medio. Este último requiere de la información obtenida de modelos de covarianza entre dos variables diferentes.

Considérese una función $V(X): R_p \rightarrow R$ que representa una propiedad aleatoria del medio. Se suponen conocidos los valores de $V(X): V_1, V_2, \dots, V_n$ en n puntos X_1, X_2, \dots, X_n .

El problema consiste en estimar:

- a) El valor $V(X)$ en cualquier punto X (estimación puntual);
- b) O bien, el valor medio de V sobre un dominio de R_p (estimación global)

El estimador $V^*(X)$ de $V(X)$ en un punto X será un campo aleatorio, función de X y de la información disponible, es decir de los valores $V_i = V(X_i), i = 1$ a n .

Kriging recurre a estimadores que sean combinaciones lineales de los datos:

$$V^*(X) = \sum_{i=1}^n \lambda_i V_i \quad 4.8$$

donde los λ_i son reales.

El problema consiste en estimar los parámetros λ_i que den un estimador satisfactorio de $V(X)$. El Kriging usa al "*mejor estimador sin sesgo*"; es decir, a un estimador que tenga las dos propiedades siguientes:

1. Ausencia de sesgo: $E\{V(X) - V^*(X)\} = 0$
2. Mínimo valor de la varianza de estimación definida como:

$$\sigma_E^2(X) = \text{Var}[V(X) - V^*(X)] = E\{(V(X) - V^*(X))^2\} \quad 4.9$$

Considerando la hipótesis de estacionaridad en el sentido amplio de un campo aleatorio, la función de autocovarianza puede expresarse en la forma:

$$C_V(X_1, X_2) = C_0 \rho_V(X_2 - X_1) \quad 4.10$$

donde ρ_v es el coeficiente de autocorrelación, y C_0 es $\text{Var}[V(X)]$ en cualquier punto X .

Aceptando esta hipótesis y dividiendo la última ecuación entre C_0 , se obtiene:

$$\sum_{i=1}^n \lambda_i \rho_V(X - X_i) - \mu F(X_i) = \rho_V(X - X_i) \quad 4.11$$

para $i = 1$ a n , con $\mu = \nu / C_0$

Con estas n ecuaciones adicionales se cuenta en total con $n+1$ ecuaciones que pueden escribirse en forma matricial:

$$[K][\lambda] = [\rho(X)] \quad 4.12$$

En este caso, la varianza de estimación tiene la expresión:

$$\sigma_E^2(X) = Var[V(X)] + \mu F(X_i) - \sum_{i=1}^n \lambda_i C_V(X, X_i) \quad 4.13$$

Se tiene que resolver este sistema lineal de orden $n+1$, donde $[\lambda]$ es el vector de las incógnitas. Por lo tanto, si se acepta la hipótesis de estacionariedad que propone que la esperanza de la población sea constante, la condición de ingreso se escribe:

$$\sum_{i=1}^{n+1} \lambda_i = 1 \quad 4.14$$

El método geoestadístico tiene la posibilidad de dar mejores resultados en medios estructurados homogéneos como los lacustres, o terraplenes de suelo compactado, no así en medios caóticos como los conglomerados, brechas y depósitos coluviales.

Algunas características importantes de la geoestadística relacionadas con este trabajo son las siguientes (García y Romo, 2004):

- La geoestadística es conceptualmente compleja y su correcto uso requiere de bases matemáticas sólidas.

- En muchos de los análisis de sistemas naturales se obtienen parámetros sin sentido físico y los resultados dependen en gran medida de las hipótesis de estacionareidad y normalidad de la variable estudiada.
- La evaluación de la incertidumbre que ocasiona la propia variabilidad espacial, los errores introducidos durante la compilación de datos, y las inexactitudes causadas por el propio modelo, varía de acuerdo al método de interpolación geoestadístico considerado en cada análisis
- El método es altamente sensible al error adherido a los datos de entrada (ruido).
- Se requiere de un muestreo denso para lograr la confiabilidad en los resultados.

La correcta estimación de propiedades geotécnicas del fondo marino es esencial para el diseño de cimentaciones, pero el alto costo de la exploración y muestreo presenta un área de oportunidad para el desarrollo de herramientas de interpolación numérica capaces estimar inteligentemente la variación espacial de dichas propiedades con la información de un muestreo moderado. En esta tesis se hace uso de las Redes Neuronales para estimar la variación espacial de la resistencia al corte en suelos marinos.

El primer modelo neuronal, el más simple y básico, fue propuesto por McCulloch y Pitts (1943) en términos de un sistema computacional de “actividad nerviosa”, que sirvió de ejemplo para los modelos posteriores de Jhon Von Neumann, Marvin Minsky (Minsky y Papert, 1969), Frank Rosenblatt (Rosenblatt, 1959), entre otros. En 1969, una seria crítica por parte de Minsky a los modelos neuronales de aquel entonces cuya naturaleza era lineal, provocó una caída en las investigaciones y una época gris para las redes neuronales.

No fue sino hasta los años 80s en los que Rumelhart, y McClelland construyeron la primer Red Neuronal RN bajo el concepto de Procesamiento Distribuido en Paralelo PDP, cuya naturaleza era no-lineal (Rumelhart y McClelland, 1986). A partir de entonces, las RN se usan con mayor interés en tareas de predicción y clasificación en un gran número de campos de la ciencia. Una RN es un sistema informático reticular de procesamiento en paralelo que aprende de la experiencia mediante la auto-modificación de sus conexiones (Wasserman, 1989; Hecht-Nielsen, 1990; Hertz, *et al.*, 1991; Hilera y Martínez, 1995 y García, 2009), y tiene la capacidad de generar conocimiento a partir del entrenamiento ante patrones típicos del comportamiento del sistema (fenómeno). Imita al cerebro humano en dos aspectos (Haykin, 1994):

1. El conocimiento es adquirido mediante un proceso de entrenamiento (aprendizaje).
2. Las conexiones entre neuronas conocidas como pesos sinápticos son usadas para almacenar el conocimiento.

El proceso de aprendizaje dirige a las RN hacia la generalización, que no es más que la producción de resultados correctos para nuevos casos o condiciones de entrada no empleadas durante la creación del modelo. En la actualidad las RN constituyen una alternativa al cómputo clásico para abordar problemas y generar resultados convincentes en los que los métodos tradicionales no son capaces de lograr a través de modelaciones algorítmicas simplistas.

Una característica importante de las RN es su capacidad de establecer relaciones entrada-salida de manera que, ante entradas desconocidas, la red es capaz de dar una respuesta “aproximada” a la salida deseada, y su desempeño no depende de hipótesis ni simplificaciones referidas a modelos o funcionales previamente establecidos.

5.1. LA NEURONA ARTIFICIAL

Las RN están conformadas por unidades básicas llamadas nodos o neuronas que funcionan como elementos de procesamiento. Una neurona está compuesta por una capa de entradas, conexiones (o pesos), una función de entrada, una función de transferencia y una capa de salida (ver figura 5.1). Cada neurona recibe una o varias entradas, las procesa y entrega una salida que bien podría ser la entrada para otra neurona subsecuente. Se dice que las entradas corresponden a un valor numérico presentado a la neurona. Por ejemplo, si el problema trata de determinar si una cimentación puede fallar o no, las entradas podrían ser la carga, el ancho, el largo de la cimentación, la profundidad de desplante, el ángulo de fricción del suelo, la cohesión, etc. La salida (solución del problema), para el mismo problema, sería la decisión/conclusión “la cimentación falla” o “la cimentación no falla”.

Generalmente a cada entrada se le asigna un peso (conexión) que bien puede ser establecido (propuesto por el modelador) o aleatorio. Los pesos expresan la fuerza relativa de conexión por medio de un valor numérico inicial de entrada o de varias conexiones que transfieren datos de capa en capa. Los pesos muestran la importancia de la señal de entrada al elemento de procesamiento (neurona). Las entradas son procesadas dentro del cuerpo o soma de la neurona por medio de una función de transferencia para producir un valor de salida. Este proceso es mostrado en la figura 5.1 donde las barras verticales representan las magnitudes de señal de entrada $X_1, X_2 \dots X_n$. Estas señales son afectadas por los pesos $W_{1j}, W_{2j} \dots W_{nj}$ de cada conexión, después mediante una función de entrada en el cuerpo de la neurona (soma), se obtiene el valor y_j que posteriormente es afectado por una función de transferencia otorgando así la señal de salida Y_j .

Función de entrada.

En esta investigación se usa la sumatoria. Esta función suma los productos entre el valor de entrada y su peso para obtener un total de entradas ponderadas. Por ejemplo, para las entradas y pesos mostrados en la figura 5.1, para un número n de entradas i en la neurona j se tiene:

$$y_j = \sum_{i=1}^n X_i W_{ij} \quad 5.1$$




Figura 5.1 Esquema del funcionamiento de una neurona artificial

Función de transferencia

Esta función también conocida como función de activación se encarga de atribuir las características no lineales al procesamiento en los nodos. La función de transferencia actúa sobre el valor arrojado por la función de entrada limitando su crecimiento numérico. Existen diferentes tipos de funciones de activación, las más usadas son: lineal, umbral, umbral-lineal, sigmoide, hiperbólica-tangente, gaussiana y senoidal entre otras. La tabla 5.1 muestra para cada una de estas funciones sus características principales y su representación gráfica.

El propósito de esta transformación es modificar la salida a un valor razonable que depende de la función de transferencia (ver la columna Intervalo de la tabla 5.1). Sin esta transformación, el valor de la salida podría ser muy grande, especialmente cuando se involucran varias capas de neuronas. En ocasiones se usa una condición de umbral o polarización que se expresa como un peso sináptico más. A este valor de umbral se le llama *Bias* o sesgo en la señal de salida. El *Bias* es un valor numérico constante que opera directamente en la función de entrada de cada neurona y permite que los valores de salida estén siempre por debajo o por arriba del valor umbral.

Tabla 5.1. Funciones de transferencia

Tipo	Función	Intervalo	Gráfico
Lineal	$g(y_j) = y_j$	$\{-\infty, +\infty\}$	
Escalón (step)	$g(y_j) = \begin{cases} 0, & \text{si } y_j < 0 \\ 1, & \text{si } y_j \geq 0 \end{cases}$	$\{0, +1\}$ $\{-1, +1\}$ bipolar	
Lineal acotada	$g(y_j) = \begin{cases} 0, & \text{si } y_j < 0 \\ y_j, & \text{si } 0 \leq y_j \leq 1 \\ 1, & \text{si } y_j \geq 1 \end{cases}$	$\{0, +1\}$ $\{-1, +1\}$ bipolar	
Sigmoide	$g(y_j) = \frac{1}{1 + e^{-y_j}}$	$\{0, +1\}$ $\{-1, +1\}$ bipolar	
Hiperbólica-tangente	$g(y_j) = \arctan\left(\frac{y_j}{\pi}\right) + 0.5$	$\{0, +1\}$ $\{-1, +1\}$ bipolar	
Gaussiana	$g(y_j) = e^{-y_j^2}$	$\{0, +1\}$	
Senoidal	$g(y_j) = \begin{cases} 0, & \text{si } y_j < -5 \times \pi \\ \frac{\sin\left(\frac{y_j}{10}\right)}{2} + 0.5, & \text{si } 0 \leq y_j \leq 1 \\ 1, & \text{si } y_j \geq 5 \times \pi \end{cases}$	$\{0, +1\}$ $\{-1, +1\}$ bipolar	

donde $g(y_j)$ es el valor transformado de y_j y π es 3.141516

5.2. TOPOLOGÍA NEURONAL

La topología de la RN es el ordenamiento y disposición de sus unidades básicas (neuronas). La estructura de una red se define a través del número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. La topología depende de la complejidad del problema estudiado, tomando en cuenta que mientras más grande sea la red, el tiempo de procesamiento aumenta considerablemente y su eficiencia y eficacia podría no variar tanto. Cabe mencionar que aún no existe una metodología clara para determinar la mejor topología, la elección hasta el momento se basa en la experiencia del diseñador de la RN.

En una RN se pueden distinguir tres tipos de capas (figura 5.2):




Figura 5.2 Capas de una RN multicapa de propagación hacia adelante (feedforward)

- Capa de entrada: neuronas que reciben datos o señales procedentes del entorno.
- Capa de salida: son las neuronas que proporcionan la respuesta de la RN.
- Capa oculta: no tiene conexión directa con el entorno, es decir es precedido por otras capas ocultas o por la capa de entrada y sucedida por otras capas ocultas o por la capa de salida.

En términos del número de capas las RN se pueden clasificar en dos:

- Redes monocapa: Establecen conexiones laterales cruzadas o autorrecurrentes entre las neuronas que pertenecen a la única capa que constituye la red. Este tipo de redes es útil en tareas relacionadas con la autoasociación, es decir, regenera la información incompleta o

distorsionada de patrones que se presentan a la red. Las neuronas de esta red funcionan como nodos de entrada y salida simultáneamente y no existen capas ocultas.

- Redes multicapa: Como su nombre lo indica, la disposición de las neuronas de esta red es en dos o más capas (figura 5.2).

Las unidades entre capas están ligadas de cierta forma y ésta responde a la tarea por resolver. Estas conexiones determinan la manera en la que se organizan las neuronas (nodos) para procesar la información. A esto también se le llama arquitectura de red.

Cuando las redes reciben la señal desde la entrada y la propagan hasta la salida mediante procesamiento distribuido en paralelo se habla de la arquitectura de propagación al frente o *feedforward*. Este tipo de arquitectura es probablemente la más conocida y ampliamente usada en la actualidad. Existen también redes en las que algunas capas están conectadas desde la salida hasta la entrada en el orden inverso al que viajan las señales de información. La arquitectura de este tipo se denomina como arquitectura de retroalimentación o *feedback*. La arquitectura donde una neurona puede estar conectada a las neuronas de otra capa y/o a neuronas de la misma capa se denomina como arquitectura recurrente. Una arquitectura recurrente completamente conectada es potencialmente una arquitectura de procesamiento temporal; sin embargo, requiere de algoritmos muy poderosos para lograr un verdadero aprendizaje (Hopfield, 1982).

5.3. REGLAS DE APRENDIZAJE

El aprendizaje es el proceso por el cual una RN modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el aprendizaje implican la construcción, destrucción y modificación de las conexiones entre neuronas. Una conexión se construye cuando el peso tiene un valor distinto de cero y se destruye cuando su peso es cero. Existen dos tipos de aprendizaje: 1) aprendizaje supervisado y 2) aprendizaje no supervisado. La diferencia principal entre ambos estriba en que en el aprendizaje supervisado la variable de salida es conocida y en el no supervisado no es conocida.

Aprendizaje no supervisado

Las redes con aprendizaje no supervisado (también conocido como autosupervisado) no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada

entrada es o no correcta. A estas redes se les proporcionan únicamente los estímulos y ellas ajustan sus interconexiones basándose en sus propias salidas.

Aprendizaje supervisado

En el aprendizaje supervisado las salidas deben ser valores conocidos para compararlos con los valores evaluados, medir el error y controlar la salida del sistema.

En el aprendizaje supervisado, el usado en esta investigación, se comienza colocando pesos aleatorios dentro de la estructura inicial. La diferencia entre la salida Y_j obtenida por la RN y la salida deseada d es llamada error de predicción e . El objetivo del aprendizaje es minimizar e .

El entrenamiento hace que la red sea capaz de extraer, a partir de ejemplos, normas generales que le permitan en el futuro responder adecuadamente a patrones no vistos. Una vez que ésta resulte operativa (buena generalización entre valores evaluados y deseados, mínimos errores), la arquitectura, neuronas, conexiones y pesos quedan fijos y la red está lista para funcionar.

Cuando se está entrenando una red y se ha minimizado el error, es imprescindible establecer una condición de paro óptima que evite, en todo momento, el sobreajuste (*overfitting*) que se produce cuando una red es incapaz de generalizar para casos nuevos. Para evitar que esto ocurra se recomienda dividir el conjunto de patrones disponibles en conjunto de entrenamiento (usado para ajustar el valor de los pesos de la red) y conjunto de prueba (usado para medir la eficacia de la red). Este último debe ser significativo (debe contener ejemplos pertenecientes a todas las clases) y representativo (debe guardar la relación existente entre los ejemplos del conjunto de entrenamiento).

Propagación del error hacia atrás

La regla de aprendizaje empleada en esta investigación es conocida como Propagación del error hacia atrás o *Back Propagation*. Después de alimentar y propagar hacia adelante los valores de entrada en la RN, el error es calculado y propagado hacia atrás mientras los pesos son ajustados para hacer el error más pequeño. El valor de entrada es propagado hacia adelante a través de la RN hasta obtener el valor de salida. Después, el error e_j en una neurona j se calcula:

$$e_j = d_j - y_j \quad 5.2$$

donde y_j es la salida calculada y d_j es la salida deseada de la neurona j . El error e_j es usado para calcular un valor δ_j , el cual es usado para ajustar los pesos:

$$\delta_j = e_j g(y_j) \quad 5.3$$

donde $g(y_j)$, como se mencionó antes, es la función de activación.

Una vez obtenido el valor de δ_j se calcula el valor δ_k de las capas anteriores con la siguiente ecuación.

$$\delta_k = \eta g(y_k) \sum_{j=0}^{\eta} \delta_j W_{jk} \quad 5.4$$

donde J es el número de neuronas en esta capa y η es la tasa de aprendizaje propuesto heurísticamente, el cual determina que tanto debe ser ajustado el peso. Por lo tanto, los valores de Δw con el que los pesos deben ser ajustados se calcula:

$$\Delta W_{jk} = \delta_k y_j \quad 5.5$$

Este valor es usado para ajustar el valor de los pesos w_{jk} :

$$W_{1k} = W_{1j} + \Delta W_{jk} \quad 5.6$$

El algoritmo de *Back propagation* opera rápidamente debido a su sencillez, ya que el cálculo en cada conexión no es más que una multiplicación y una suma. De igual manera para ajustar los pesos de la conexión también realiza una multiplicación y una suma. Este proceso continua hasta que se alcanza cierto valor o criterio de salida deseado. Para una explicación más detallada sobre el algoritmo *Back Propagation* el lector puede consultar Hassoun, (1995) y Hertz, *et al.*, (1991).

6 APROXIMADOR NEURONAL DE LA RESISTENCIA AL CORTE EN SUELOS MARINOS.

Esta sección se centra en el desarrollo de un modelo neuronal para analizar e interpretar bases de datos de información geotécnica para estimar la resistencia al corte en condiciones no drenadas de suelos marinos. Se presentan metodologías espaciales eficientes para decidir sobre estratigrafías, posibles comportamientos geomecánicos y caracterización de la resistencia al corte en un ambiente 3D. El aproximador, en su conceptualización, contiene:

- 1) Variadores espaciales neuronales VEN para determinar la variación espacial del peso volumétrico sumergido y los valores de S_u obtenidos con pruebas de torcómetro, veleta de campo, y veleta miniatura en muestras inalteradas, así como pruebas de veleta de campo y veleta miniatura en muestras remoldeadas.
- 2) Un modelo 3D neuronal para estimar en el espacio de manera indirecta las resistencias al corte en condiciones no consolidadas-no drenadas. Este aproximador ofrece valores de S_u preliminares y relacionables con los que se obtendrían en una prueba de compresión triaxial UU en laboratorio.

6.1. DESCRIPCIÓN DE LA BASE DE DATOS.

La región estudiada se localiza en el Golfo de México en la bahía de Campeche, hacia el sur de la zona en estudio se observa el borde marginal externo de la llanura costera continental del norte de los estados de Tabasco y Campeche, al occidente se encuentra el Cañón de Veracruz y al Oriente el Cañón de Campeche y la franja litoral de los estados de Campeche y del noroccidente del Estado de Yucatán.

Geología de la región.

Para comprender mejor la geología de la Bahía de Campeche, es necesario conocer los antecedentes geológicos del Golfo de México. El Golfo de México es un mar de estilo mediterráneo ubicado en la esquina del sureste de Norteamérica. El Golfo limita al norte con Estados Unidos (Florida, Alabama, Mississippi, Louisiana y Texas), con cinco estados mexicanos al oeste y al sureste (Tamaulipas, Veracruz, Tabasco, Campeche y Yucatán) y la isla de Cuba el sureste.

Se sabe poco sobre la historia geológica de la Cuenca del Golfo de México antes del periodo Triásico Superior. Debido a que las rocas pre-Triásicas se conocen sólo por algunas áreas de afloramientos y pozos separados. Gran parte de la historia geológica de la cuenca durante la era Paleozoica debe ser

inferida con el estudio de las áreas vecinas. La cuenca actual del Golfo de México se cree que tuvo su origen en la era del Triásico Superior como resultado de su distanciamiento de la Placa Norteamericana al momento en que empezó a fracturarse y distanciarse de las placas Africana y Sudamericana. El desplazamiento probablemente continuó a lo largo de la era Jurásica Inferior y Media con la formación de una corteza continental "estrecha" o "transicional" a lo largo de la parte central de la cuenca. Un avance intermitente del mar hacia el área continental desde el oeste durante la era Jurásica Media tuvo como resultado la formación de los depósitos extensos de sal conocidos hoy en día en la cuenca del Golfo de México. Parece ser que el episodio principal de distanciamiento, durante el cual el bloque de Yucatán se movió hacia el sur, se separó de la Placa Norteamericana y se formó la corteza oceánica real en la parte central de la cuenca, sucedió durante la era Jurásica Superior temprana, después de la formación de los depósitos de sal. Información más profunda al respecto se publicó por (Aguayo, Neotectónica de facies sedimentarias cuaternarias en el suroeste del Golfo de México, dentro del marco tectónico-estratigráfico regional evolutivo del Sur de México, 2005).

Hoy en día, el Golfo de México es una pequeña cuenca oceánica rodeada por masas de tierra continental. Debido a su estructura física, el Golfo y el Mar Caribe a veces se combinan y son llamados el "Mediterráneo Americano". Según Antonie (1972), el Golfo se divide en siete provincias geológicas: La Cuenca, El Noreste, El Norte, La Plataforma y pendiente continental del sur de Florida, La Plataforma y pendiente continental del este de México, El Talud de Campeche y La Bahía de Campeche. Siendo esta última la que nos atañe.

La Bahía de Campeche es un bahía del istmo que se extiende desde la orilla occidental del Talud de Campeche hacia las regiones costeras al este de Veracruz. La Sierra Madre Oriental forma un borde al suroeste, y la planicie costera relacionada es similar a la costa de Texas y Louisiana en el norte del Golfo. La topografía del fondo se caracteriza por cadenas largas paralelas al exterior de la cuenca. Los domos de sal son frecuentes en la región y se piensa que la migración de la sal hacia arriba es una causa de los perfiles complejos del fondo (Worzel, *et al.*, 1968). Similar al Golfo del norte, las grandes cantidades de petróleo se producen aquí y predominan los gruesos depósitos de sedimentos marinos.

Campaña de exploración.

Se realizaron cinco pozos de exploración denominados A, B, C, D y E situados tal como se muestra en la figura 6.1.




Figura 6.1. Ubicación de los pozos de exploración en planta

En estos pozos se ensayaron pruebas de campo y laboratorio para definir las siguientes propiedades.

- *Peso volumétrico sumergido γ'* → 111 mediciones en los 5 pozos.
- *Resistencia al corte no drenado medida con veleta miniatura $Su-vmini$* → 30 mediciones en los 5 pozos.
- *Resistencia al corte no drenado medida con veleta de campo $Su-vcampo$* → 24 mediciones en los 5 pozos.
- *Resistencia al corte no drenado medida con torcómetro $Su-torc$* → 85 mediciones en los 5 pozos.
- *Resistencia al corte en muestra remoldeada medida con veleta miniatura $Su-vmr$* → 13 mediciones entre los pozos A y C.
- *Resistencia al corte en muestra remoldeada medida con veleta de campo $Su-vcr$* → 10 mediciones entre los pozos A y C.
- *Resistencia al corte no drenado medida con cámara triaxial en prueba no consolidada- no drenada $Su-uu$* → 11 mediciones entre los pozos B y D

Las tablas 6.1 a 6.7 muestran estas propiedades geotécnicas obtenidas a diferentes profundidades.

Tabla 6.1. Peso Volumétrico Sumergido γ' .

Pozo									
A		B		C		D		E	
z	γ'	z	γ'	z	γ'	z	γ'	z	γ'
m	kN/m ³	m	kN/m ³	m	kN/m ³	m	kN/m ³	m	kN/m ³
0.46	4.85	0.36	5.64	0.26	6.67	0.92	6.44	0.20	4.95
1.22	4.18	1.03	5.79	0.56	5.82	1.33	6.29	0.56	4.57
1.93	6.34	1.18	6.18	1.07	5.71	1.79	6.51	1.12	4.65
3.05	5.63	1.28	5.87	1.33	5.56	2.09	6.31	1.17	4.40
3.97	5.56	2.00	5.77	2.10	5.75	2.55	6.44	1.78	4.53
4.89	6.11	2.31	5.59	2.25	4.88	3.11	6.60	2.39	4.48
5.95	6.35	3.13	5.75	2.86	6.02	3.21	6.78	2.60	5.27
6.92	5.92	3.18	6.00	3.12	6.18	3.47	6.07	3.21	4.33
7.94	6.29	3.44	6.12	4.09	5.46	4.49	6.34	3.51	4.79
8.19	5.94	4.15	5.46	4.30	6.08	5.15	7.03	4.27	4.92
8.96	5.71	4.36	5.64	4.60	5.91	5.31	6.78	4.73	5.08
9.21	6.20	4.56	5.89	5.32	5.73	5.61	6.28		
9.97	5.92	5.13	5.46	6.09	6.16	6.28	6.91		
10.13	6.85	5.28	6.08	6.55	6.26	6.28	6.66		
10.33	6.68	5.44	5.70	7.16	5.79	6.58	6.13		
10.89	6.00	6.15	5.33	7.31	6.28	7.04	6.77		
11.15	6.49	6.31	5.11	9.21	6.88	7.45	6.01		
11.35	5.89	6.72	5.26	10.08	7.39	8.16	6.77		
11.91	6.28	7.13	5.68	11.05	6.78	8.16	5.91		
12.06	7.20	7.59	5.42	11.92	6.19	9.08	5.90		
12.32	6.74	8.05	5.42	12.02	6.67	9.13	5.74		
		8.46	5.99	13.45	7.78	9.44	6.19		
		9.03	5.52	13.91	6.58	10.05	6.86		
		9.18	6.00						
		9.54	5.70						
		9.54	5.88						
		10.15	6.09						
		10.46	6.20						
		10.51	6.69						
		10.62	5.98						
		11.03	6.98						
		11.38	7.37						
		11.44	5.93						

10kN/m³ \approx 1 t/m³**Tabla 6.2. Resistencia al corte medida con veleta miniatura Su-vmini.**

Pozo									
A		B		C		D		E	
z	Su-vmini	z	Su-vmini	z	Su-vmini	z	Su-vmini	z	Su-vmini
m	kPA	m	kPA	m	kPA	m	kPA	m	kPA
0.56	6.13	5.78	16.11	0.64	3.97	0.66	5.83	0.73	2.83
2.47	10.00	6.69	22.95	1.40	9.96	1.57	13.75	1.75	5.00
3.58	9.91	7.76	16.11	2.46	7.00	2.39	31.46	2.65	8.01
4.54	13.87	8.68	22.00	4.59	15.02	3.62	23.54	4.75	13.98
5.58	15.95			5.38	18.14	4.60	23.96		
6.52	19.91			6.55	18.90	5.63	28.54		
				7.55	12.74	6.56	31.67		
				8.10	27.09	7.62	38.13		

100 kPA \approx 1 kg/cm²

Tabla 6.3. Resistencia al corte medida con veleta de campo Su-vcampo.

Pozo									
A		B		C		D		E	
z	Su-vcampo	z	Su-vcampo	z	Su-vcampo	z	Su-vcampo	z	Su-vcampo
m	kPa	m	kPa	m	kPa	m	kPa	m	kPa
1.04	5.05	1.05	0.95	1.04	5.91	1.23	8.13	5.00	2.53
2.53	5.95	2.53	2.00	2.51	10.13	2.51	14.79	5.06	1.02
4.03	9.10	3.01	7.16	4.01	9.87	4.01	17.29	8.07	4.02
5.55	9.82	4.01	8.42	5.55	14.01	5.51	18.13		
		5.53	10.00	7.05	23.12	6.99	20.00		
		7.02	9.89						
		8.52	13.79						

100 kPa \approx 1 kg/cm²

Tabla 6.4. Resistencia al corte medida con torcómetro Su-torc.

Pozo									
A		B		C		D		E	
z	Su-torc	z	Su-torc	z	Su-torc	z	Su-torc	z	Su-torc
m	kPa	m	kPa	m	kPa	m	kPa	m	kPa
0.21	3.87	0.10	10.00	0.03	9.96	1.20	15.21	0.40	5.00
0.40	4.95	0.39	13.05	0.35	14.94	1.40	24.17	0.75	5.00
1.19	3.96	0.60	13.16	0.64	15.11	1.60	32.71	1.34	5.00
2.11	9.01	1.09	16.00	1.18	14.85	2.03	27.71	1.60	5.00
2.13	9.82	1.25	20.11	1.36	14.94	2.29	30.00	2.30	9.94
2.31	13.78	1.45	20.00	2.24	14.94	2.40	29.79	2.60	10.00
3.11	10.90	2.09	22.95	2.45	15.02	3.05	29.79	4.63	15.00
3.22	14.86	2.20	24.95	3.14	11.98	3.41	26.88	4.40	15.06
3.42	16.13	2.30	26.00	3.41	20.08	3.57	26.25		
4.02	12.97	3.11	22.21	4.21	17.97	5.13	29.79		
4.18	15.05	3.29	29.89	4.51	19.07	5.52	27.92		
4.37	14.95	3.61	30.11	5.11	22.95	5.63	30.00		
5.03	18.02	4.09	25.05	5.31	21.94	6.24	25.83		
5.23	16.04	4.40	25.16	6.06	24.05	6.44	27.92		
5.44	16.13	4.72	28.95	6.30	24.98	6.54	25.83		
6.04	26.94	5.11	25.89	6.53	9.96	7.22	31.04		
6.25	20.09	5.38	26.00	7.10	14.94	7.43	31.25		
6.38	20.00	5.68	26.00	7.32	30.04	7.53	33.13		
		6.12	24.95	7.51	22.03				
		6.42	24.00						
		6.59	25.05						
		7.08	30.00						

100 kPa \approx 1 kg/cm²

Tabla 6.5. Resistencia al corte en muestra remoldeada con veleta miniatura Su-vmr.

Pozo									
A		B		C		D		E	
z	Su-vmr	z	Su-vmr	z	Su-vmr	z	Su-vmr	z	Su-vmr
m	kPa	m	kPa	m	kPa	m	kPa	m	kPa
0.52	3.85	-	-	0.65	2.00	-	-	-	-
2.42	3.00			1.37	2.00				
3.48	3.76			2.45	3.89				
4.44	4.88			5.32	4.21				
5.47	7.04			6.53	5.16				
6.42	7.89			7.53	2.95				
				8.07	7.89				

100 kPa ≈ 1 kg/cm²

Tabla 6.6. Resistencia al corte en muestra remoldeada con veleta de campo Su-vmc.

Pozo									
A		B		C		D		E	
z	Su-vcr	z	Su-vcr	z	Su-vcr	z	Su-vcr	z	Su-vcr
m	kPa	m	kPa	m	kPa	m	kPa	m	kPa
1.04	0.85	-	-	1.04	1.05	-	-	-	-
2.51	2.91			2.56	3.89				
3.97	1.97			3.96	7.05				
5.47	3.00			5.51	10.95				
6.95	6.10			6.98	8.95				

100 kPa ≈ 1 kg/cm²

Tabla 6.7. Resistencia al corte con cámara triaxial en prueba UU.

Pozo									
A		B		C		D		E	
z	Su-uu	z	Su-uu	z	Su-uu	z	Su-uu	z	Su-uu
m	kPa	m	kPa	m	kPa	m	kPa	m	kPa
-	-	5.32	12.42	-	-	2.11	19.17	-	-
		8.30	22.21			3.10	21.25		
		9.32	19.16			3.29	20.00		
						5.20	25.21		
						6.08	19.79		
						6.28	27.08		
						7.08	28.96		
						7.28	26.04		

100 kPa ≈ 1 kg/cm²

6.2. GEO-VARIABLES PARA EL MODELADO 3D Y LA ESTIMACIÓN INDIRECTA DE PROPIEDADES.

El punto clave en los modelos desarrollados en esta investigación es la elección de las variables que definen el fenómeno en estudio. Las características de los ejemplos que se usen para alimentar a la red fundamentan las cualidades y las ventajas que se pretende tenga esta propuesta sobre las convencionales.

Variables geométricas.

A partir de las distancias entre pozos, su ubicación en el medio y su profundidad se definieron las fronteras del medio tridimensional (figura 6.2).

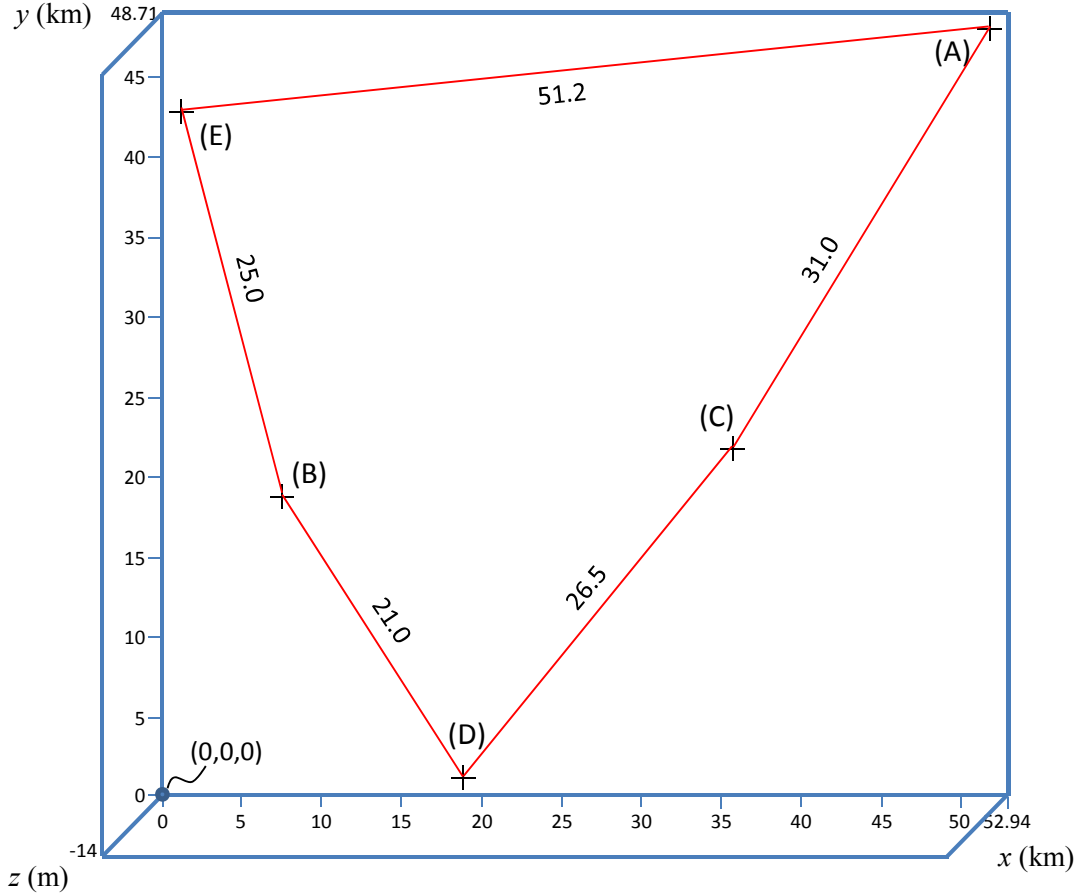


Figura 6.2 Arreglo geométrico de los pozos A, B, C, D y E.

Con el volumen de estudio definido, se ubican las coordenadas de los pozos a partir de la coordenada que marca (0,0,0) (tabla 6.8).

Tabla 6.8. Coordenadas de los pozos A, B, C, D y E.

Pozo	Coordenada x (km)	Coordenada y (km)
A	51.94	47.71
B	7.30	18.59
C	35.76	21.55
D	18.72	1.00
E	1.00	43.54

Variables geotécnicas.

En la campaña de exploración realizada en la zona fueron medidas las propiedades geotécnicas enunciadas en la sección 6.1. A continuación se describen los aspectos que dirigieron su inclusión en el modelo neuronal.

- Peso unitario sumergido γ' . Propiedad sencilla de interpretar y de bajo costo en términos de su medición, γ' es la variable con mayor cantidad de mediciones realizadas en toda la base de datos (111 mediciones). Por ello y por su relación directa con la propiedad objetivo se incluye como variable de entrada. Es importante señalar que se tienen datos suficientes para separar casos de entrenamiento y de prueba (equilibrio en los conjuntos). La figura 6.3 muestra un esquema tridimensional del medio, pozos y ubicación de las mediciones realizadas para esta variable.




Figura 6.3 Ubicación de los puntos de evaluación de γ'

Cabe mencionar que los datos de la variable γ' recibieron un tratamiento especial, porque su rango dinámico es muy pequeño (de 4.18 a 7.78 kN/m³). Esto provoca un problema de representatividad numérica para la RN, es decir que ante variables de entrada con un amplio rango dinámico (como lo es x , y y z) la RN podría obviar valores demasiado cercanos.

Para solventar este problema, se incrementó el rango dinámico de la variable cambiando por valores raíz a porcentajes, es decir, se propusieron dos casos frontera (γ' entre 3 y 9 kN/m³) que representan el valor mínimo y máximo del medio. A estos valores se les asignó el valor 0.0 y 100%, con base en estos

porcentajes y mediante interpolación lineal, se pueden conocer los porcentajes correspondientes a cada valor medido en la

tabla 6.1. De esta manera se amplía el rango dinámico y se mantiene la proporción de valores de γ' . Mediciones de esta propiedad en diferentes suelos marinos se presentan en la tabla 6.9.

Tabla 6.9. Pesos volumétricos sumergidos de suelos marinos de diferentes partes del mundo (modificada de Bennett, et al., 1980 y Keller y Benett, 1970).

Sitio	γ' (kN/m ³)			Profundidad (m)
	Máx	Mín	Promedio	
Atlantic slope	9.27	2.80	4.86	< 50
Upper rise	6.52	3.58	4.56	< 50
Outer Hudson Canyon	9.47	3.58	5.64	< 50
Western Atlantic mega-corridor	8.98	3.58	5.84	< 50
Chesapeake Bay	9.56	1.23	4.07	< 50
Tokyo Bay	9.37	1.62	5.15	< 50
Lake Pend Oreille	3.68	1.52	2.50	< 50
Pacific	9.86	1.23	4.17	< 50
San Diego Trough	3.19	1.81	2.40	< 50
Gulf of Maine	4.66	2.11	2.99	< 50
Estudio 1 (Carpa)	10.74	6.03	9.10	< 100
Estudio 2 (Amoca)	10.15	5.25	7.73	< 100

Según los autores, los valores presentados son resúmenes de sus investigaciones y presentan únicamente los valores máximos, mínimos y promedio medidos en sus exploraciones. Los denominados Estudio 1 y Estudio 2 son exploraciones realizadas en suelos marinos de la región de Carpa y Amoca en la denominada Sonda de Campeche (Thales Geosolutions, 2002). Los valores de γ' contenidos en la tabla 6.9 se pueden graficar con fines de visualización. La figura 6.4 muestra tales valores y la asignación de rangos (Alto, Medio y Bajo). Nótese que la muestra de suelos en el área de estudio contienen los tres niveles de pesos volumétricos obtenidos.




Figura 6.4. Pesos volumétricos sumergidos de suelos marinos de diferentes partes del mundo.

Esta gráfica se sintetiza en la tabla 6.10 que indica el rango de γ' al cual se adhiere alguna etiqueta.

Tabla 6.10. Etiquetas adheridas a diferentes rangos de γ' .

Etiqueta	γ' (kN/m ³)
Bajo	< 3.5
Medio	3.5 – 6.5
Alto	> 6.5

- Resistencia al corte medida con veleta miniatura *Su-vmini*. Esta variable fue medida en cada uno de los pozos y se tienen 30 mediciones para construir una RN. El 20% de las mediciones se separan para prueba. La figura 6.5 muestra un esquema con la ubicación de las mediciones realizadas para *Su-vmini*.




Figura 6.5 Ubicación de los puntos de evaluación de *Su-vmini*

- Resistencia al corte medida con veleta de campo *Su-vcampo*. La obtención de esta propiedad es relativamente sencilla y rápida, sin embargo debe tomarse con precaución por el alto nivel de ruido que posee. El valor de la resistencia fue obtenida en todos los pozos y cuenta con 24 mediciones lo que permitió generar una red con 5 casos de prueba y 19 de entrenamiento. La figura 6.6 muestra un esquema con la ubicación de las mediciones realizadas para *Su-vcampo*.




Figura 6.6 Ubicación de los puntos de evaluación de *Su-vcampo*

La resistencia al corte en esta prueba se mide en un plano cilíndrico de corte, así como en la superficie superior e inferior de dicho cilindro. Para definir la aportación de la resistencia en la parte superior e inferior de dicho cilindro se requieren hipótesis simplificadoras para definir la distribución de esfuerzos en la veleta durante el corte (Santoyo, 2010). No obstante, debido a que la tolerancia ante datos imperfectos como la ausencia o problemas de calidad en estos, las RN no requieren de hipótesis que supongan o modifiquen los datos medidos.

- Resistencia al corte medida con torcómetro *Su-torc*. La prueba de torcómetro se realizó en los cinco pozos registrando una cantidad considerable de mediciones, siendo el parámetro con mayor cantidad de puntos de evaluación después de γ' . Los casos de prueba para evaluar el comportamiento de esta RN son 17. La figura 6.7 muestra un esquema con la ubicación de las mediciones realizadas para *Su-torc*.




Figura 6.7 Ubicación de los puntos de evaluación de *Su-torc*

- Resistencia al corte en muestra remoldeada medida con veleta miniatura *Su-vmr*. La medición de la resistencia al corte no drenada en muestras remoldeadas sirve como indicador de la sensibilidad del material, y se incluye en esta investigación por su forma indirecta de relacionarse con *Su*. Estimar la resistencia al corte *Su-vmr* sin duda representa condiciones propias del material y podría servir de clasificador. Esta variable sólo fue medida en los pozos A y C, con 11 registros entre ambos pozos, lo que no permite que la RN sea evaluada con casos de prueba. La figura 6.8 muestra un esquema con la ubicación de las mediciones realizadas para *Su-vmr*.




Figura 6.8 Ubicación de los puntos de evaluación de Su_{vmr}

- Resistencia al corte en muestra remoldeada medida con veleta de campo Su_{vcr} . Al igual que Su_{vmr} , esta variable sólo fue registrada en los pozos A y C. Su inclusión sigue las mismas premisas declaradas para Su_{vmr} . La figura 6.9 muestra un esquema con la ubicación de las mediciones realizadas para Su_{vcr} .




Figura 6.9 Ubicación de los puntos de evaluación de Su_{vcr}

6.3. CONSTRUCCIÓN DE LOS MODELOS

La metodología que aquí se presenta se divide en dos 2 etapas i) la evaluación espacial de las propiedades geotécnicas y ii) la estimación indirecta de la resistencia al corte (valores relacionables

con los que se obtendrían en una prueba triaxial UU en laboratorio). En los variadores espaciales neuronales VEN la variable dependiente es la propiedad geotécnica (tablas 6.1 a 6.6), mientras que en el Aproximador neuronal indirecto de la resistencia al corte ANIRC es la $Su-uu$ el parámetro de salida. Se explica en orden estricto por ser acciones consecutivas: i) la definición de todos los VEN de las variables geotécnicas, ii) el análisis de resultados VEN y la definición de las variables convenientes para la estimación indirecta de $Su-uu$ y iii) la generación de los productos de visualización 3D de las propiedades en estudio.

6.3.1. Variadores espaciales neuronales, VEN

De acuerdo con lo mencionado en el capítulo 5 de esta tesis un variador espacial de propiedades permite estimar el valor de dicha propiedad en cualquier punto de coordenadas (x, y, z) de un dominio definido. El modelo 3D VEN de cualquiera de las variables analizadas, se desarrolla siguiendo los siguientes pasos:

1. Se completan las tablas (x, y, z) y la variable geotécnica adherida para cada caso.
2. Se elige un arreglo de capas y neuronas para entrenarlo hasta que se obtenga una RN exitosa que sea capaz de predecir valores de salida en casos de prueba con suficiente aproximación.
3. Se evalúa la congruencia de los resultados en los ambientes de visualización 3D y se generan los perfiles, y/o mapas de contornos.

Tablas de información geotécnica

En un análisis tridimensional, la variable dependiente $Vm = (\gamma', Su-vmini, Su-vcampo, Su-torc, Su-vmr, y Su-vcr)$ es función de las variables independientes (coordenadas x, y y z).

Los VEN para la predicción espacial se alimentan de tablas 6.1 a 6.6. Es importante señalar que en estos modelos no se permiten vacíos de información. La arquitectura utilizada en las RN fue multicapa de alimentación al frente (*Multilayer feed forward*), y la regla de aprendizaje fue propagación del error hacia atrás (*Back-propagation*). Esta combinación es una de las más eficientes y mejor documentadas (Rumelhart *et al.*, 1986a,b) y han mostrado buenos resultados en la predicción espacial de propiedades (García y Romo, 2004). En la figura 6.10 se muestra la topología general de los VEN (un variador espacial para cada variable Vm estudiada).

El número de capas ocultas y el de sus nodos se prueban y se descartan las distintas configuraciones de acuerdo con su actuación en predicción (diferencia entre valores medidos *versus* los evaluados con la RN), considerando como exitosa a la topología que presenta menor error de estimación en la prueba.




Figura 6.10. Red de alimentación al frente para la variación espacial de V_m

El inconveniente en cuanto al entrenamiento e incluso en la prueba de los modelos comienza al estimar valores en puntos del medio que están “lejos” de los pozos. La escasez de información provoca importantes errores en las zonas no ensayadas. En esta investigación se propone usar la metodología de “Generación de población virtual” propuesta por Chávez y García (2012) para “multiplicar” la información en zonas mal definidas o de conocimiento geotécnico parcial, la cual se explica a continuación.

Generación de población virtual

En el método de Chávez y García (2012) se multiplican las líneas de entrenamiento de manera “natural”. Inspirado en el método de interpolación de vecinos cercanos y en el funcionamiento de las redes de retroalimentación, la separación entre los puntos en la malla tridimensional disminuye al multiplicar la información en el espacio estudiado. Dentro del desarrollo de los modelos neuronales de esta tesis este método juega un rol medular para construir variadores espaciales que alcancen predicciones confiables en puntos del espacio donde no se tienen valores muestreados, y/o cuando los valores en un mismo pozo son escuetos.

El método sigue las siguientes etapas generales.

1. Se indica la situación (x_n, y_n, z_n) de un pozo real (“real” en esta investigación significa que se realizó medición en campo y/o laboratorio de esa propiedad). Las coordenadas deben estar en el dominio definido por $0 < x < 52.94$, $0 < y < 48.71$ y $0 < z < -14$ (x y y en kilómetros y z en metros).
2. Se entrena la red con la información de los pozos reales.

3. Con esta red se estiman valores neuronales de los vecinos cercanos a cada pozo real.
4. Los valores “cercanos” se añaden a la tabla de entrenamiento y se inicia el proceso de entrenamiento nuevamente. La red se detiene cuando el error entre el valor de salida estimado y el deseado es mínimo, para posteriormente pedir a la red una evaluación más en los vecinos cercanos de cada nueva situación x, y, z . Esta información se vuelve a colocar en la tabla de entrenamiento, se abre el proceso de aprendizaje, se espera por la estabilidad del error y se cierra para estimar nuevos vecinos cercanos de los más recientes pobladores añadidos.
5. Este procedimiento es iterativo y se detiene hasta que dos vecinos se encuentran.

La figura 6.11 muestra de manera esquemática el crecimiento de la población alrededor de un punto de medición.




Figura 6.11 Incremento de información inspirada en la técnica de vecinos cercanos, para z constante

Cabe mencionar que la discretización de los puntos evaluados en el espacio $x-y$. generó 2,579 situaciones separados a una distancia ortogonal de 1 km entre sí. Este proceso se repite a cada 0.5 m de profundidad hasta alcanzar 14 m.

Estimación espacial de la propiedad evaluada.

El modelo neuronal 3D muestra su capacidad para reflejar los patrones geométricos y mecánicos del medio, con notorias ventajas prácticas como su fácil uso y la posibilidad de entender y desarrollar interfaces gráficas de forma clara y asequible (García y Romo, 2004). Los VEN proporcionan información valiosa de las propiedades del suelo marino en cualquier punto del volumen estudiado.

VEN de γ'

Para el análisis espacial de la variable γ' la arquitectura neuronal más eficiente (después de intentar más de 10 combinaciones diferentes entre capas y número de nodos) cuenta con 3 capas ocultas (dos de 50 nodos sucedidas por una de 60 nodos). Gráficamente la relación de valores medidos *versus* evaluados (fase de entrenamiento) para esta red se muestra en la figura 6.12 donde los valores neuronales están muy cerca de los valores γ' objetivo, debido a que la RN generaliza satisfactoriamente para los casos de prueba.




Figura 6.12. Relación entre valores medidos y evaluados por la RN para γ' .

La variación espacial de γ' obtenida con VEN se calificó comparando los valores evaluados por el modelo *versus* los medidos en laboratorio (figura 6.13). Se observa la buena capacidad de generalización del modelo.

Para presentar y explicar los resultados de la variación espacial de γ' , la figura 6.14 muestra cortes sobre los pozos de exploración, de tal manera que se permite comparar los valores de las geopropiedades medidos *versus* los estimados por la red. En la figura 6.15 se puede observar que el medio se rigidiza con la profundidad con particularidades en el extremo cercano a los pozos C y D, en cuanto al vecindario de los pozos A y E predominan valores medios de γ' . Se puede observar también una tendencia de γ' altos a medios que va de la esquina cercana a C hacia la de E. Existe una pequeña región que se clasifica como bajo cercana a la superficie y que va de C a E. Los rangos que definen las etiquetas de la variable γ' siguen las recomendaciones del apartado 6.2.




Figura 6.13. Evaluación neuronal de la variable γ' en los pozos de exploración




Figura 6.14. Esquema en planta de la zona en estudio y cortes para leer los VEN




Figura 6.15. Distribución espacial de γ'

Con el fin de tener una mejor visualización de la variación de esta propiedad, se generaron cortes en áreas de interés. En la figura 6.16 se muestra la propiedad γ' sobre el trazo D-A (figura 6.14). Como puede observarse, existe un material con γ' predominantemente medio, al que subyace una capa de γ' alto, así como una región de bajo peso volumétrico sumergido entre el pozo C y el A y cercano a la superficie. Recordemos que esta propiedad es la que cuenta con un mayor número de valores medidos.

A pesar de que en la base de datos no se tienen valores de γ' por debajo de 3.5 kN/m^3 , debido al poder de extrapolación de las redes neuronales, se puede observar en el medio estudiado una zona con un bajo peso volumétrico sumergido.

En las figuras 6.17 a 6.19 se muestran la propiedad γ' sobre los trazos E-D, E-A y B-A respectivamente.




Figura 6.16. Corte D-A en el medio para mostrar la variación de γ' calculada con VEN




Figura 6.17. Corte E-D en el medio para mostrar la variación de γ' calculada con VEN

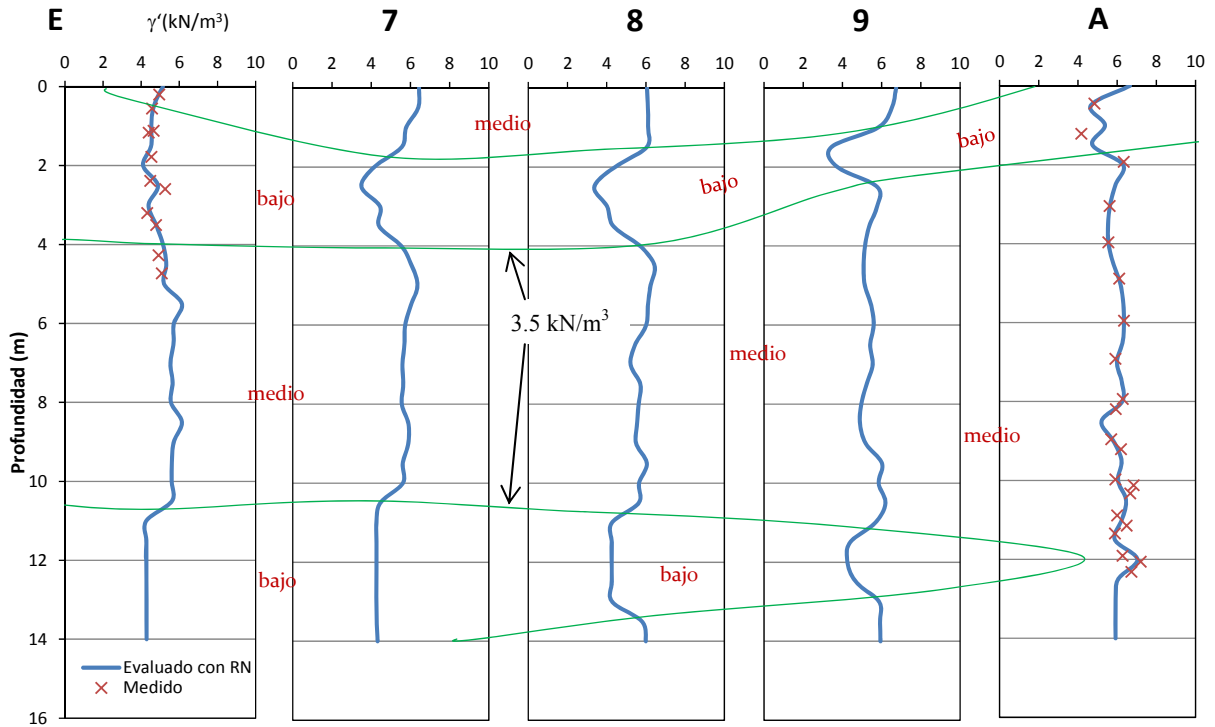


Figura 6.18. Corte E-A en el medio para mostrar la variación de γ' calculada con VEN




Figura 6.19. Corte B-A en el medio para mostrar variación de γ' calculada con VEN

VEN de $Su-vmini$

El modelo neuronal más eficiente cuenta con 2 capas ocultas (una de 70 y otra de 50 nodos). Gráficamente la relación de valores medidos *versus* evaluados para esta red se muestra en la figura 6.20, donde los valores neuronales están muy cerca de los valores de $Su-vmini$ objetivo, por lo que se puede concluir que la RN generaliza satisfactoriamente.

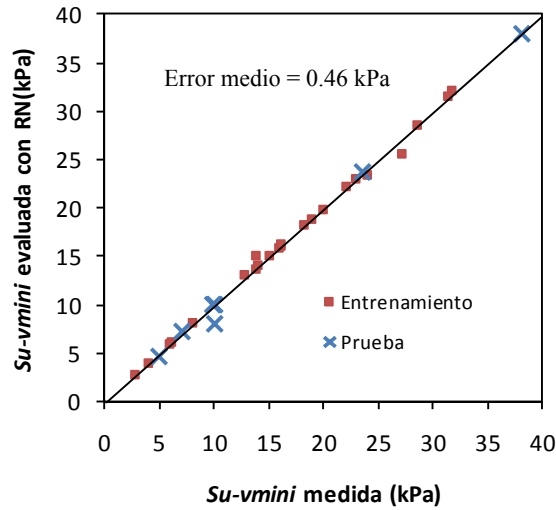


Figura 6.20. Relación entre valores medidos y evaluados por la RN para $Su-vmini$

En cada pozo se realizó un perfil de evaluaciones con la RN para observar su comportamiento ante los valores medidos en el laboratorio. La figura 6.21 muestra la correspondencia entre estos valores.

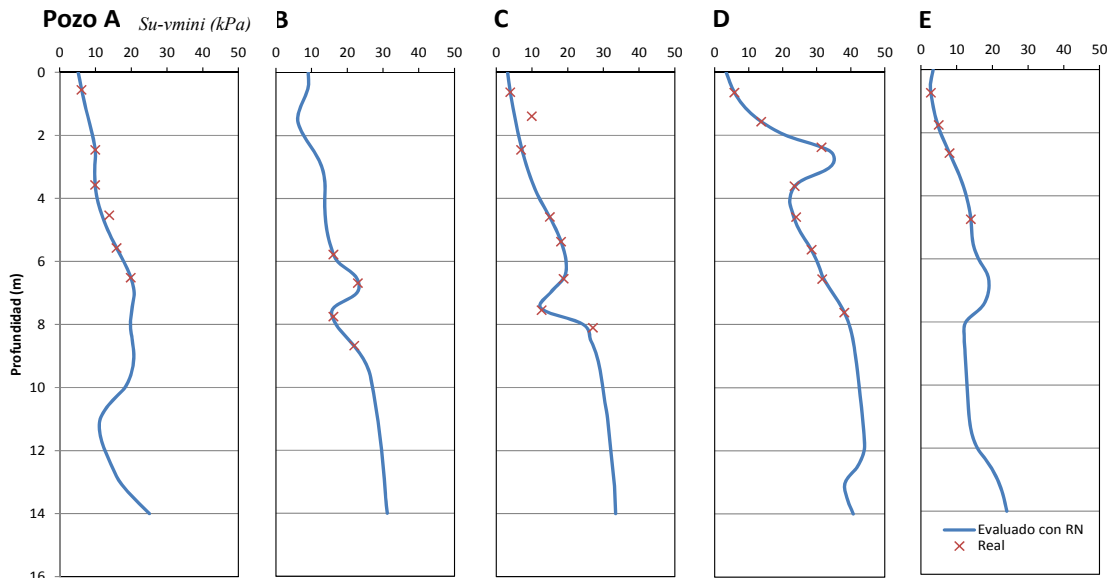


Figura 6.21. Evaluación neuronal de la variable $Su-vmini$ en los pozos de exploración

La figura 6.22 muestra la variación espacial de $Su-vmini$, donde los intervalos que definen las etiquetas de la variable siguen las recomendaciones de la sección 6.2. En la superficie del medio se muestra una capa de material de consistencia “muy suave” cuyo espesor no excede los 4 m. Sin embargo, se observa que conforme se profundiza se presentan tonalidades ligeramente verdosas que son índice del incremento de la consistencia del material, hasta llegar a una profundidad tal que el material se considera firme. Se observa también que la región donde se presentan los mayores espesores de material firme es en la cercanía del pozo D y donde se estiman las menores resistencias son en la cercanía a los pozos E y A.




Figura 6.22. Distribución espacial de $Su-vmini$

En el corte D-A mostrado en la figura 6.23 se observa que en la zona cercana al pozo D es la que cuenta con el mayor espesor de material de consistencia firme. Este espesor disminuye con dirección al pozo A. A este material le superyace otro de consistencia suave y sucesivamente otro de consistencia muy suave (típico de las arcillas del lecho marino). En las figuras 6.24 a 6.26 se muestra la variación de la propiedad $Su-vmini$ en los cortes E-D, E-A y B-A, respectivamente.

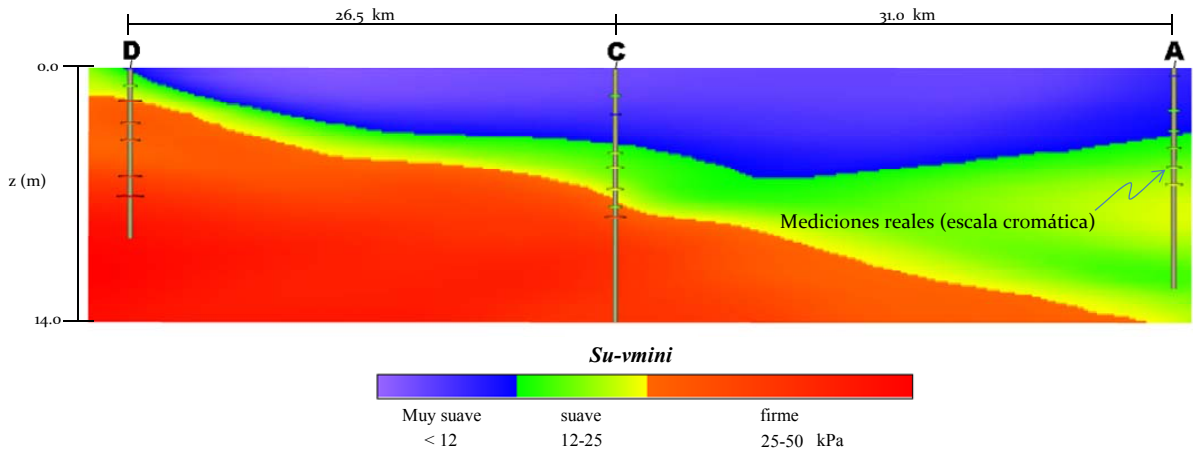


Figura 6.23. Corte D-A en el medio para mostrar la variación de $Su-vmini$ calculada con VEN




Figura 6.24. Corte E-D en el medio para mostrar la variación de $Su-vmini$ calculada con VEN




Figura 6.25. Corte E-A en el medio para mostrar la variación de $Su-v_{mini}$ calculada con VEN




Figura 6.26. Corte B-A en el medio para mostrar la variación de $Su-v_{mini}$ calculada con VEN

VEN de $Su-torc$

Este modelo tiene 3 capas ocultas de 50 nodos cada una. Gráficamente la relación de valores medidos *versus* evaluados para esta red se muestra en donde las evaluaciones neuronales están muy cerca de los valores de $Su-torc$ objetivo. En este modelo, se observa que los valores de prueba quedan ligeramente fuera de la línea con pendiente unitaria (figura 6.27).




Figura 6.27. Relación entre valores medidos y evaluados por la RN para $Su-torc$

En cada pozo se realizó un perfil de evaluaciones con la RN para observar su comportamiento ante los valores medidos en el laboratorio. La figura 6.28 muestra la correspondencia entre estos valores.

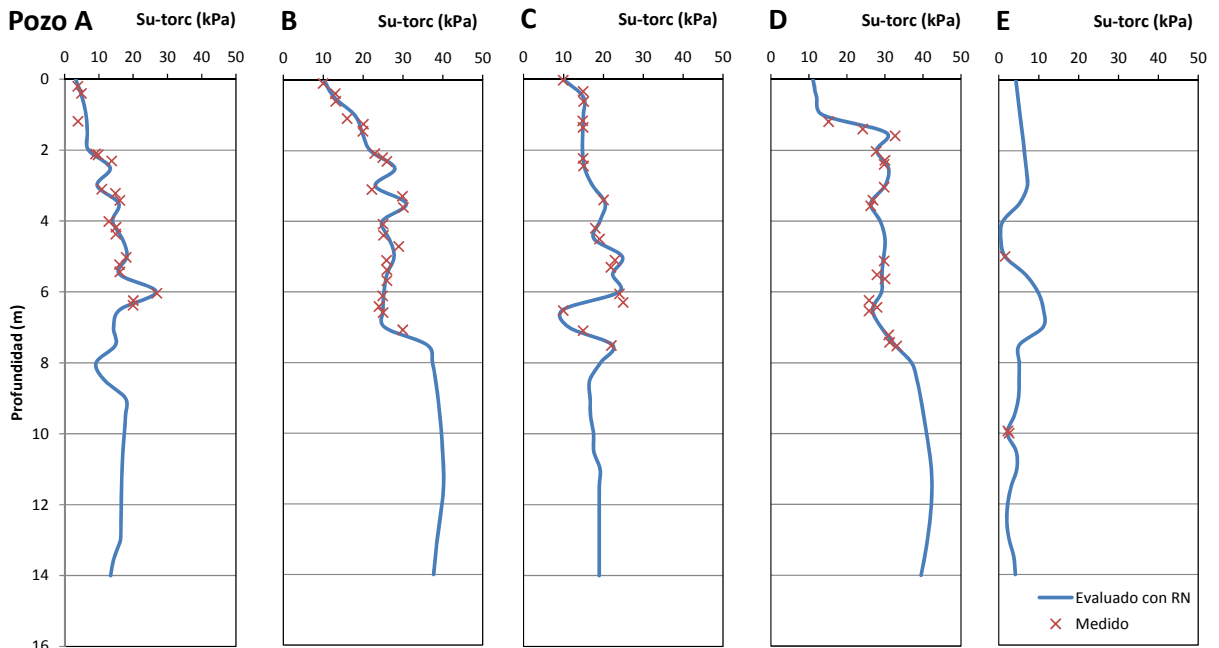


Figura 6.28. Evaluación neuronal de la variable $Su-torc$ en los pozos de exploración

La variación espacial de la resistencia muestra tres grandes bloques de material con diferentes consistencias, concentrándose las resistencias más altas hacia la esquina cercana a los pozos B y D y las más bajas hacia el pozo E (figura 6.29). Es necesario remarcar que ésta es una de las variables que más valores medidos tiene, sin embargo la variación espacial de esta propiedad no muestra congruencia con la propuesta en los VEN de γ' y $Su-vmini$. Es posible que esta incongruencia se deba a la poca precisión de la prueba que permite la manipulación directa del operador.




Figura 6.29. Distribución espacial de $Su-torc$

Por su parte, la variación obtenida para Su_{-torc} en el corte D-A muestra también que la consistencia es firme en la zona cercana al pozo D y que cae abruptamente al acercarse al pozo C, donde la consistencia es en su mayoría suave y permanece constante hasta el pozo A (figura 6.30). Cabe mencionar que a pesar de que las curvas de igual resistencia corresponden correctamente con las mediciones reales mostradas no existe una congruencia con respecto al corte D-A de γ' . En las figuras 6.31 a 6.34 se muestra la variación de la propiedad Su_{-torc} sobre los trazos E-D, E-A y B-A respectivamente.

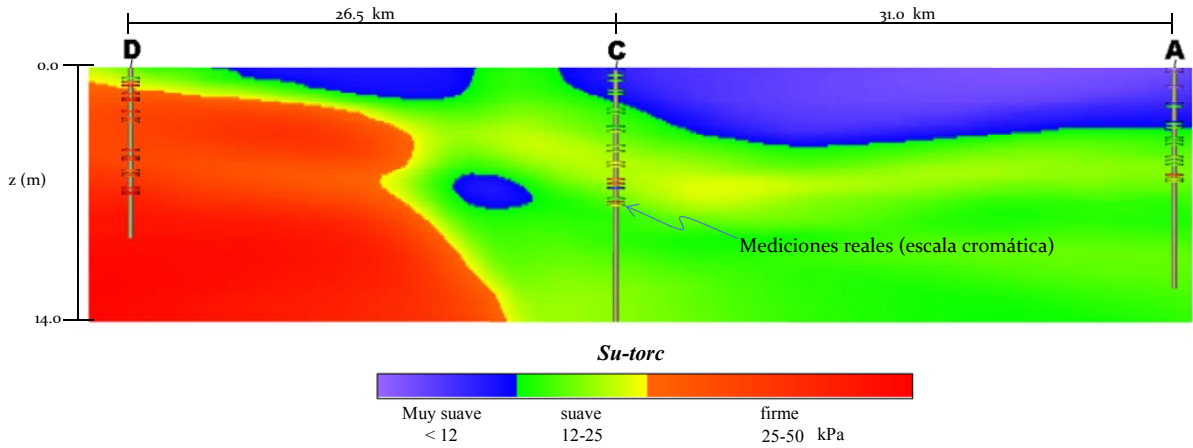


Figura 6.30. Corte D-A en el medio para mostrar la variación de Su_{-torc} calculada con VEN




Figura 6.31. Corte E-D en el medio para mostrar la variación de Su_{-torc} calculada con VEN




Figura 6.32. Corte E-A en el medio para mostrar la variación de Su-torc calculada con VEN




Figura 6.33. Corte B-A en el medio para mostrar la variación de Su-torc calculada con VEN

VEN de *Su-vcampo*

Después de numerosos intentos por modelar una RN satisfactoria que estime la variación espacial de la resistencia al corte medida con veleta de campo (*Su-vcampo*), se observó que la de mejor comportamiento ante la relación valor medido *versus* evaluado, cuenta con 2 capas ocultas de 75 nodos cada una. Esta relación se muestra en la figura 6.34. Se puede observar que la red generaliza correctamente solo para los valores de entrenamiento y no así con los de prueba (datos con los que no se entrenó a la red), lo que indica que este modelo, a pesar de ser el de menor error medio (3.19 kPa), es incapaz de predecir correctamente el valor de *Su-vcampo*.




Figura 6.34. Relación entre valores medidos y evaluados por la RN para *Su-vcampo*

Al visualizar perfiles entre valores medidos contra evaluados (figura 6.35), se observa también que la red no generaliza correctamente en los puntos de prueba. Esto se puede deber en el caso particular de esta investigación, a que las mediciones contenidas en la base de datos con las que se entrena la red son inconsistentes o insuficientes para caracterizar al medio y requieren de un tratamiento especial o a que el modelo neuronal no es el más óptimo, por lo que se requieren modelar más redes neuronales que salen del alcance de la tesis. Por lo que, debido a los resultados obtenidos ante la relación medido *versus* evaluado para casos de prueba, este modelo quedó descartado para seguirse usando en esta investigación. No obstante, esta prueba no debe discriminarse para la caracterización general del medio.

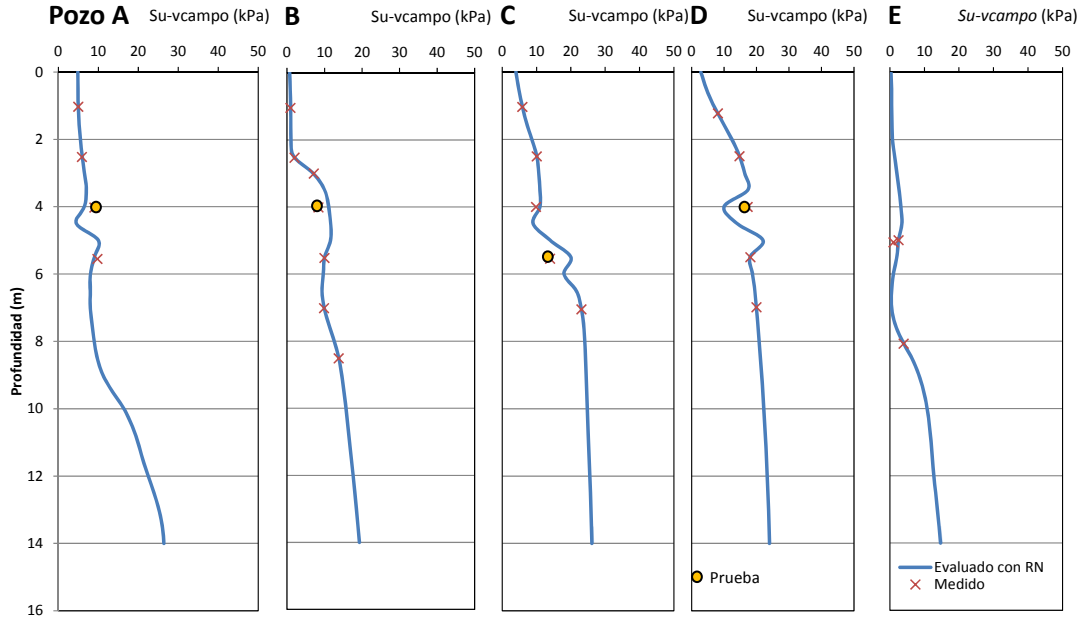


Figura 6.35. Evaluación neuronal de la variable $Su\text{-vcampo}$ en los pozos de exploración

VEN de $Su\text{-vmr}$

Esta variable sólo fue registrada en los pozos A y C. La cantidad de mediciones en estos pozos solo permite tomar 11 patrones para entrenamiento y 2 para prueba. La red que otorgó el menor error entre valores evaluados y deseados consta de una capa oculta de 75 nodos. La relación entre estos valores se muestra gráficamente en la figura 6.36.




Figura 6.36. Relación entre valores medidos y evaluados por la RN para $Su\text{-vmr}$

En perfiles evaluados con la RN en los pozos A, B, C, D y E se muestra que la red persigue correctamente los valores de $Su-vmr$ de entrenamiento, sin embargo esto no lo logra con los valores de prueba (figura 6.37, pozo C). A diferencia de los resultados obtenidos con la veleta de campo, la base de datos cuenta con información de $Su-vmr$ únicamente en los pozos A y C, lo que impide tener una caracterización general de la resistencia al corte del medio medida con esta prueba. Estas razones hacen que este modelo quede descartado para seguirse usando en esta investigación.

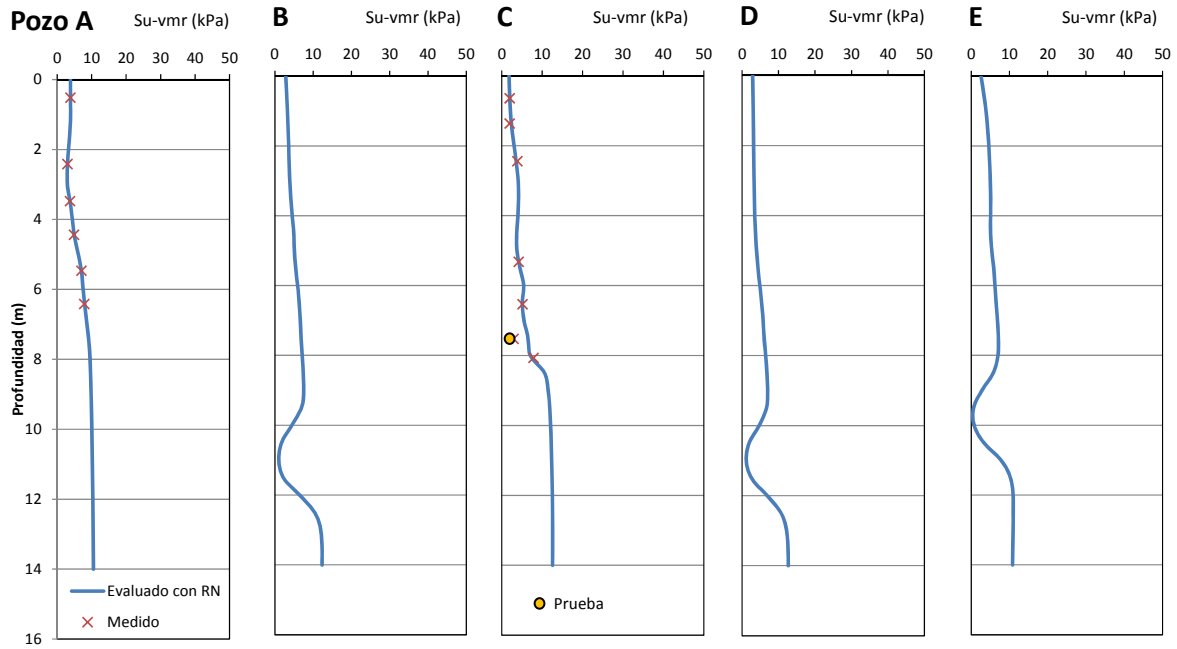


Figura 6.37. Evaluación neuronal de la variable $Su-vmr$ en los pozos de exploración

VEN de $Su-vcr$

Al igual que $Su-vmr$, esta variable sólo fue registrada en los pozos A y C, con la misma cantidad de mediciones y por consiguiente se permitió tomar 8 patrones para entrenamiento y 2 para prueba. La red que otorgó el menor error entre valores evaluados y deseados consta de una capa oculta de 75 nodos. La relación entre estos valores se muestra gráficamente en la figura 6.38.




Figura 6.38. Relación entre valores medidos y evaluados por la RN para $Su-vcr$

En perfiles evaluados con la RN en los pozos A, B, C, D y E se muestra que la red persigue correctamente los valores de $Su-vcr$ de entrenamiento, sin embargo, esto no lo logra con los valores de prueba (figura 6.47, pozo C). De igual manera que en los resultados de la prueba de $Su-vmr$, las mediciones registradas en la base de datos solo fueron tomadas para los pozos A y C, lo que provoca que no se pueda caracterizar correctamente al medio. Por esta razón, este modelo quedó descartado para seguirse usando en esta investigación.

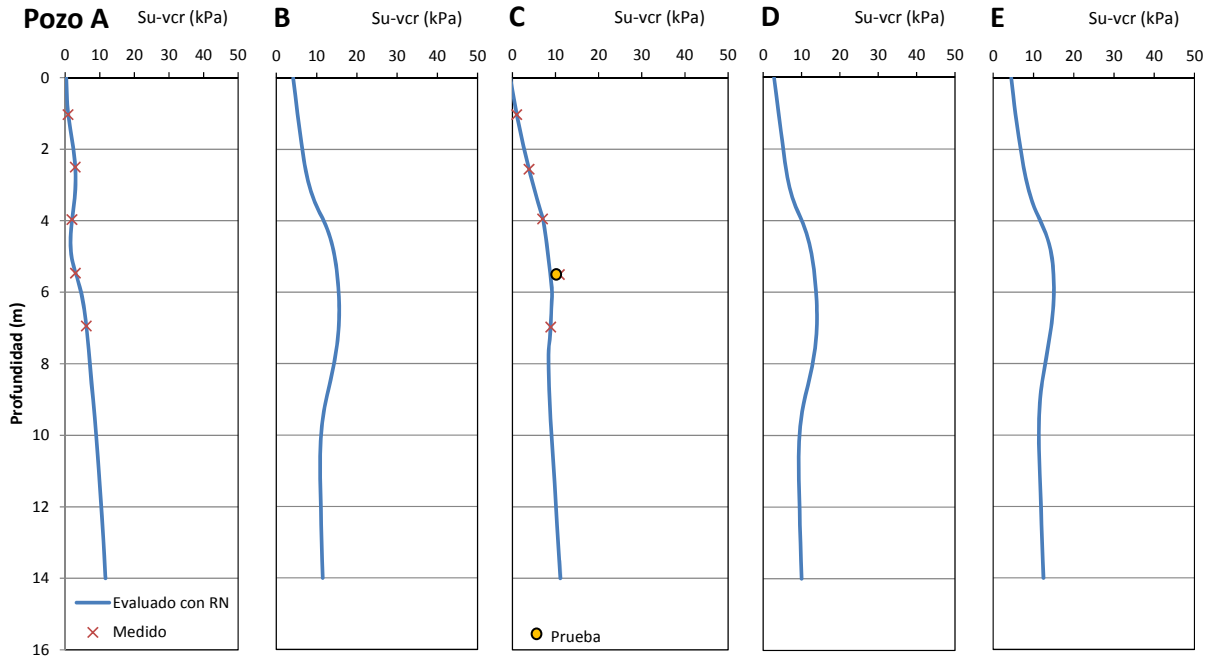


Figura 6.39. Evaluación neuronal de la variable $Su-vmr$ en los pozos de exploración

6.3.2. Aproximador neuronal indirecto de la resistencia al corte Su_{uu} en suelos marinos, ANIRC

Estimar la variación de la resistencia al corte medida con la prueba de compresión triaxial no consolidada-no drenada (Su_{uu}) resulta una tarea complicada debido a la poca cantidad de muestras ensayadas (ver tabla 6.7). Por esta razón es necesario estimar y evaluar la relación que existe entre esta variable y alguna otra, cuya variación espacial en el mismo medio sea aceptable. Los variadores espaciales neuronales VEN construidos en la sección anterior son utilizados para evaluar la o las variables que mejor permitan construir el ANIRC.

El ANIRC es una herramienta neuronal que permite estimar de manera indirecta la resistencia al corte que podría obtenerse mediante una prueba triaxial monotónica tipo UU a partir de geo-propiedades del medio (suelo marino) obtenidas con pruebas más sencillas y menos costosas. Para la construcción del ANIRC es necesario, como primera etapa, determinar cuál o cuáles serán las geo-propiedades o variables de entrada que alimentarán al modelo. El proceso para elegir dichas variables no es trivial y se debieron construir RN con cada una de las descripciones geotécnicas disponibles (γ' , Su_{vmini} , Su_{vcampo} , Su_{torc} , Su_{vmr} y Su_{vcr}). Según lo mostrado en la sección 6.3.1, los resultados de las redes que incluían a γ' , Su_{vmini} y Su_{torc} mostraron congruencia entre los valores de Su_{uu} medidos en laboratorio y los evaluados con la RN, mientras que las que incluían a Su_{vcampo} , Su_{vmr} y Su_{vcr} no mostraron correspondencia espacial, por lo que se descartó el uso de estas últimas para la construcción del ANIRC quedando los siguientes parámetros como variables de entrada:

- profundidad z ,
- peso volumétrico sumergido γ' y
- Su_{vmini} / Su_{torc}

La *profundidad* z proporciona la posición vertical de las estimaciones neuronales de la resistencia al corte y es adherida al pozo de exploración. En medios homogéneos esta variable juega un papel importante en la resistencia al corte debido a que los esfuerzos efectivos aumentan con la profundidad y por consiguiente también su resistencia.

Si bien el *peso volumétrico* γ' no siempre se puede relacionar directamente con la resistencia al corte, permite tener una idea del tipo de material y de la conformación geológica del medio (Terzaghi, 1948). Sin embargo, exploraciones realizadas en medios homogéneos (Thales Geosolutions, 2002) han demostrado que este medio se densifica ligeramente con la profundidad y por consiguiente la resistencia al corte aumenta.

Para decidir entre las variables de entrada relacionadas directamente con $Su-uu$ se realizaron modelos en los que se incluyen en conjunto y por separado las variables $Su-vmini$ y $Su-torc$. Las figuras 6.40 a 6.42 muestran esquemáticamente las características principales que conforman cada una de las RN. Para analizar cada una de las redes se definieron tres casos: **caso 1** es el que incluye las dos variables de entrada ($Su-vmini$ y $Su-torc$), el **caso 2** excluye a $Su-torc$ y el **caso 3** excluye a $Su-vmini$.

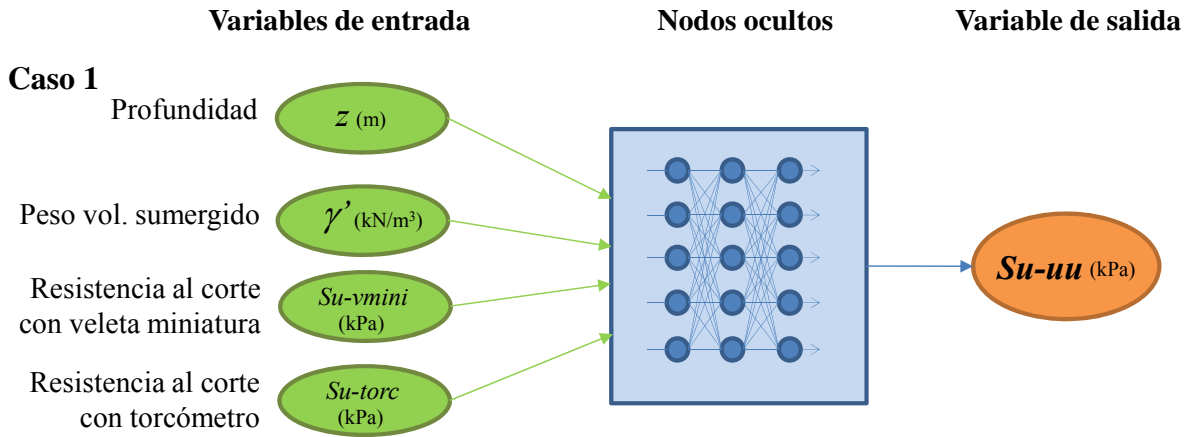


Figura 6.40 Red Neuronal con $Su-vmini$ y $Su-torc$ para la estimación indirecta de $Su-uu$




Figura 6.41 Red Neuronal con $Su-vmini$ para la estimación indirecta de $Su-uu$




Figura 6.42 Red Neuronal con $Su\text{-}torc$ para la estimación indirecta de $Su\text{-}uu$

Al igual que las RN con las que se construyeron los VEN, la arquitectura de estas redes son del tipo Multicapa de alimentación al frente con regla de aprendizaje de Propagación del error hacia atrás.

La base de datos de la variable indirecta $Su\text{-}uu$ cuenta con 3 registros en el pozo B y con 8 en el pozo D (ver tabla 6.7), por lo que los patrones con los que se entrenó la RN son los correspondientes al pozo D, los del pozo B sirvieron para validar el comportamiento en prueba.

Con ayuda de los VEN se pueden estimar las variables γ' , $Su\text{-}vmini$ y $Su\text{-}torc$ en cualquier punto del espacio, por lo que se construyó la tabla 6.11 que muestra la base de datos con las mediciones de $Su\text{-}uu$ obtenidas en laboratorio de muestras extraídas de los pozos B y D.

Tabla 6.11. Base de datos para el entrenamiento del estimador indirecto ANIRC

Coordenadas (x , y) del pozo D (18.72 , 1.00).					
z (m)	γ' (kN/m ³)	$Su\text{-}vmini$ kPa	$Su\text{-}torc$ kPa	$Su\text{-}uu$ kPa	Pozo
2.11	6.47	23.11	27.57	19.17	D
3.10	6.61	33.23	29.49	21.25	
3.28	6.28	27.21	28.47	20.00	
5.19	6.31	25.83	29.42	25.21	
6.08	6.84	30.43	29.09	19.79	
6.27	6.70	31.12	27.92	27.08	
7.08	6.34	35.31	42.60	28.96	
7.27	6.34	36.64	29.65	26.04	
5.32	5.75	14.88	26.49	12.42	B
8.30	5.85	18.59	37.88	22.21	
9.32	5.71	25.20	39.09	19.16	

El crecimiento tanto del número de capas ocultas como el de sus nodos se determinó siguiendo la actuación entre valores medidos *versus* evaluados por el modelo, considerando exitosa a la red que presenta menor dispersión entre ambos valores.

Debido a que todas las redes neuronales que se modelaron para el caso 1 presentaron poca congruencia entre los valores de $Su-uu$ medidos contra los evaluados por la red, se descartó que el ANIRC pueda incluir ambas variables ($Su-vmini$ y $Su-torc$) como sus entradas. Por esta razón es pertinente modelar redes que incluyan por separado ambas variables. Tales redes son el caso 2 y 3.

Después de hacer varias evaluaciones con diferentes RN se concluyó que la red que incluye a $Su-vmini$ (caso 2) y que mejor responde ante los casos de prueba tiene, 8 nodos ocultos, mientras que la que considera a $Su-torc$ (caso 3) cuenta con 10 nodos.

La figura 6.43 muestra las gráficas de dispersión (medido *versus* evaluado) de la RN exitosa para los dos casos donde se usan los 11 puntos medidos en ambos pozos (B y D)




Figura 6.43 Relación entre valores medidos y evaluados por las RN exitosas. a) Relación obtenida con el caso 2. b) Relación obtenida con el caso 3


Como se puede observar en ambas redes los valores de $Su-uu$ medidos *versus* evaluados muestran una relación 1 a 1, es decir que existe buena congruencia entre ambos valores con valores de error medio de 0.14 y 0.02 kPa para el caso 2 y 3 respectivamente, sin embargo, aunque el error es ligeramente menor

para el caso 3 y debido a la poca cantidad de puntos medidos de Su_{uu} y a los pocos patrones con los que se probaron las redes, este resultado no es un indicador de mejor variable de entrada del ANIRC. Veamos que ocurre si se grafican valores de Su_{uu} evaluados con ambas redes en el pozo D (ver figura 6.44).

En la figura 6.44a se observa la estimación de la secuencia de Su_{uu} a partir de Su_{vmini} respecto a la profundidad del pozo D y en la figura 6.44b, la obtenida usando Su_{torc} . Se puede ver que los valores evaluados coinciden de cierta forma con los medidos. Sin embargo, al realizar estimaciones de Su_{uu} en el pozo B observamos que para caso 3 (

figura 6.45b), dichas estimaciones no son congruentes con respecto a la homogeneidad de las variables mostradas en la sección 6.3.1 (Su_{vmini} , Su_{vcampo} , Su_{torc} , etc.). El perfil calculado para el caso 2 (

figura 6.45a) estima una variación de la resistencia al corte congruente con dichas variables.



a) b)

Figura 6.44. Estimación indirecta de S_u - u_u en pozo D. a) Perfil del pozo D para el caso 1. b) Perfil del pozo D para el caso 2

Para explicar cómo se concluyó sobre la pertinencia de las entradas en el 3D se presentan cortes a distintas profundidades. Es la comparación entre los mapas de contornos a igual profundidad lo que ayuda a decidir si las variaciones de propiedad guardan relación y en qué grado, como se observa esquemáticamente en las figuras 6.46 a 6.51 para profundidades de 3, 7 y 11 m respectivamente. La figura 6.46 muestra tres mapas de contornos de las 3 variables evaluadas a 3 m de profundidad




Figura 6.45 Estimación indirecta de Su - uu en el pozo B. a) Perfil del pozo B para el caso 1. b) Perfil del pozo B para el caso 2

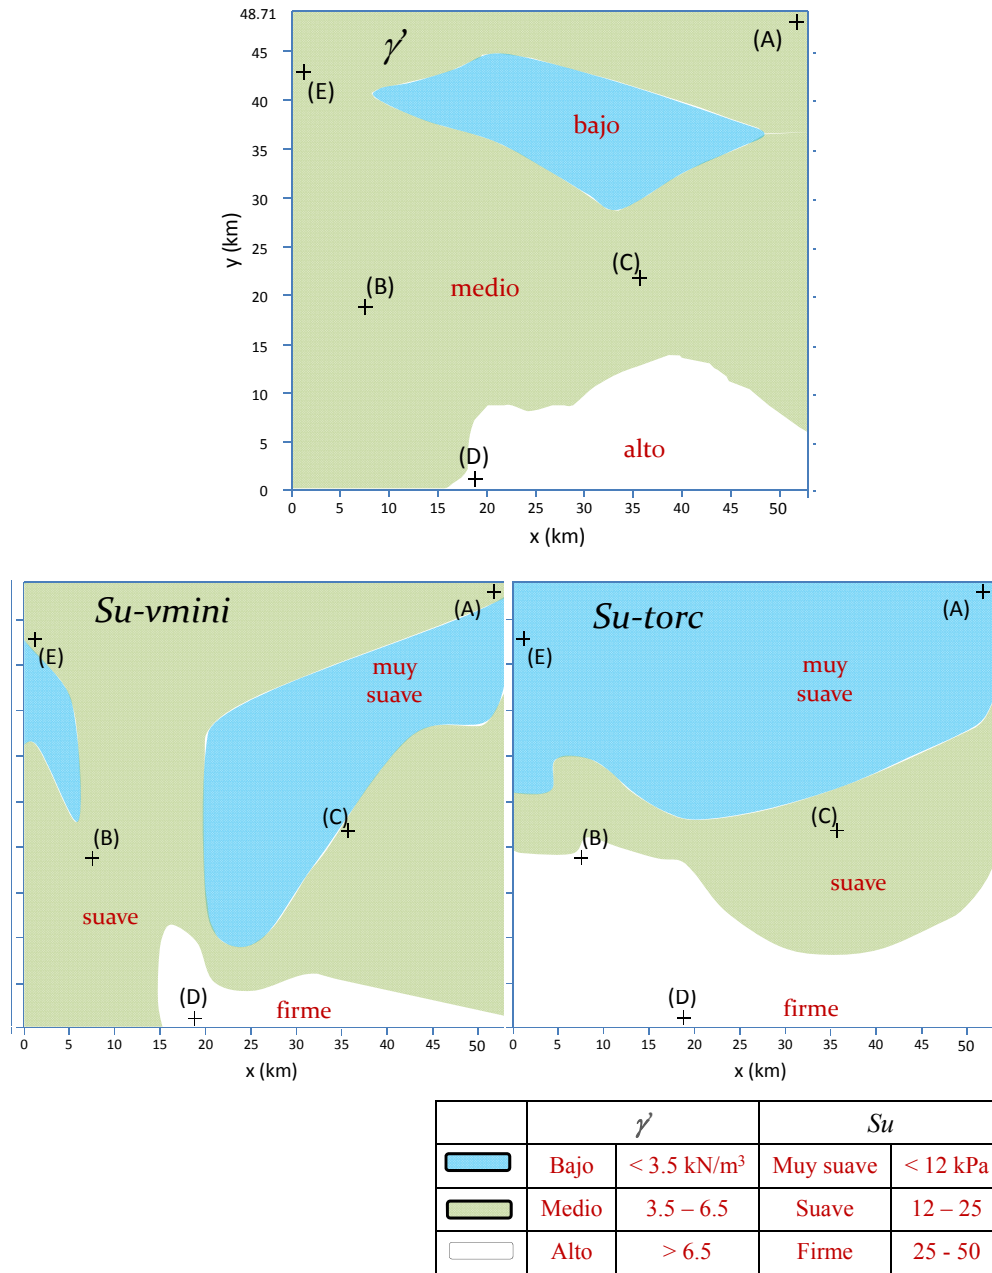


Figura 6.46. Mapas de contornos con $z=3$ m para (γ' , Su - $vmini$ y Su - $torc$)

En esta figura se muestra la correspondencia en zonas donde aparentemente el mapa de Su - $vmini$ corresponde de mejor manera con el mapa de γ' . Para visualizar de mejor manera dicha comparación en la figura 6.47 se muestra la superposición de los mapas de Su - $vmini$ y Su - $torc$ sobre el correspondiente a la misma profundidad de γ' .




Figura 6.47. Superposición de mapas $z=3$ m a) $\gamma' + Su-vmini$ y b) $\gamma' + Su-torc$

En las zonas donde las regiones coinciden hay congruencia entre las variables. En la figura 6.47a se observa que aproximadamente en un 70% del mapa existe congruencia y en la figura 6.47b alrededor del 35%. Esto quiere decir que el mapa de *Su-vmini* tiene una mejor correspondencia con respecto al de γ' (para esta profundidad) que el de *Su-torc*.

Veamos ahora que sucede a una profundidad de 7 m. La figura 6.48 muestra mapas de contornos de cada una de las 3 variables a dicha profundidad.

A primera instancia se puede observar que el mapa de *Su-torc* presenta una pequeña zona de material “muy suave” (azul claro) que no se presenta en los otros dos mapas. En la figura 6.49 se presenta la superposición de los mapas de *Su-vmini* y *Su-torc* sobre el correspondiente de γ' a la misma profundidad. El área de incongruencias en la figura 6.49a es ligeramente menor que la de la figura 6.49b, por lo que se puede concluir que para esta profundidad ($z = 7$ m) γ' parece estar más relacionada con *Su-vmini* que con la información del torcómetro.

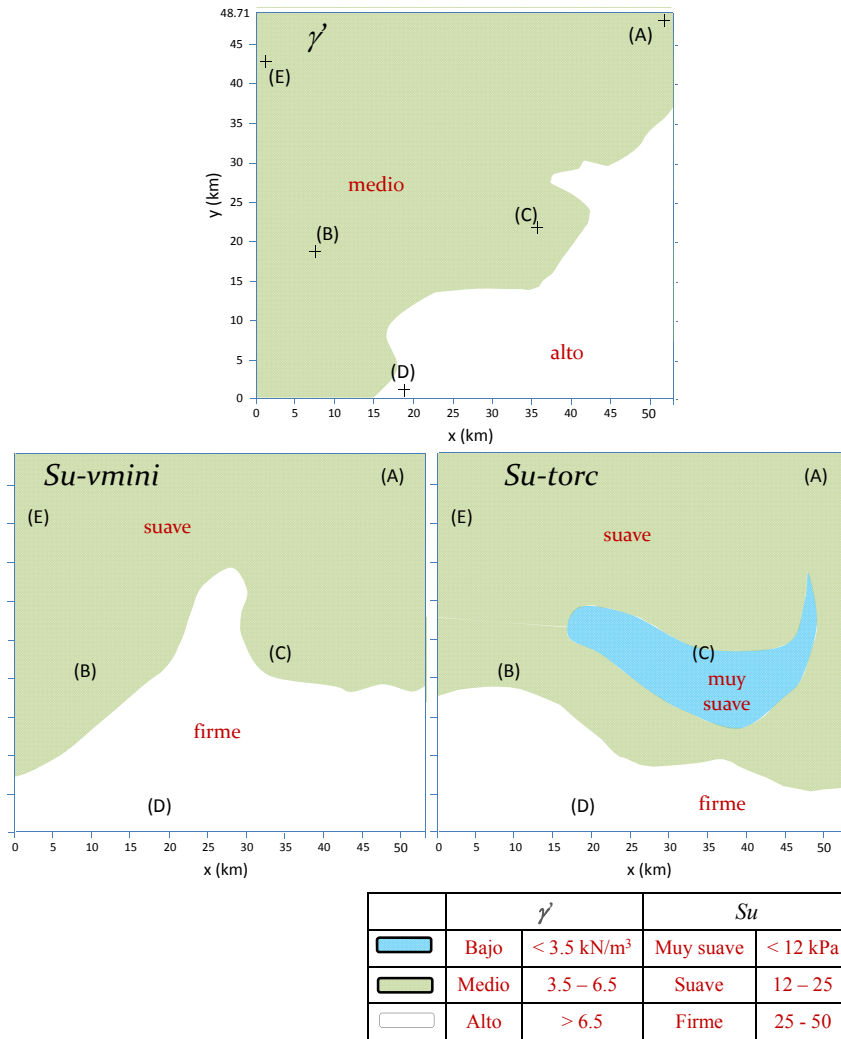


Figura 6.48. Mapas de contornos $z = 7$ m para (γ' , S_u -vmini y S_u -torc)




Figura 6.49. Superposición de mapas de contornos $z = 7$ m a) γ' + S_u -vmini y b) γ' + S_u -torc

Finalmente, se realizó la comparación entre los mapas de contornos de las mismas tres variables pero esta vez a 11 m de profundidad. figura 6.50.

Nuevamente se observa que existe una pequeña región de material “muy suave” en el mapa de *Su-torc*, así como una zona relativamente grande de material “suave”

Al realizar la superposición de los mapas de esta profundidad como se muestra en la figura 6.51. Se observan claramente las regiones incongruentes, las cuales son mayores en el caso de *Su-torc* que en el caso de *Su-vmini*, por lo que se puede concluir que para esta profundidad (11 m) los mapas de *Su-vmini* presentan mejor correlación respecto a los de γ' .

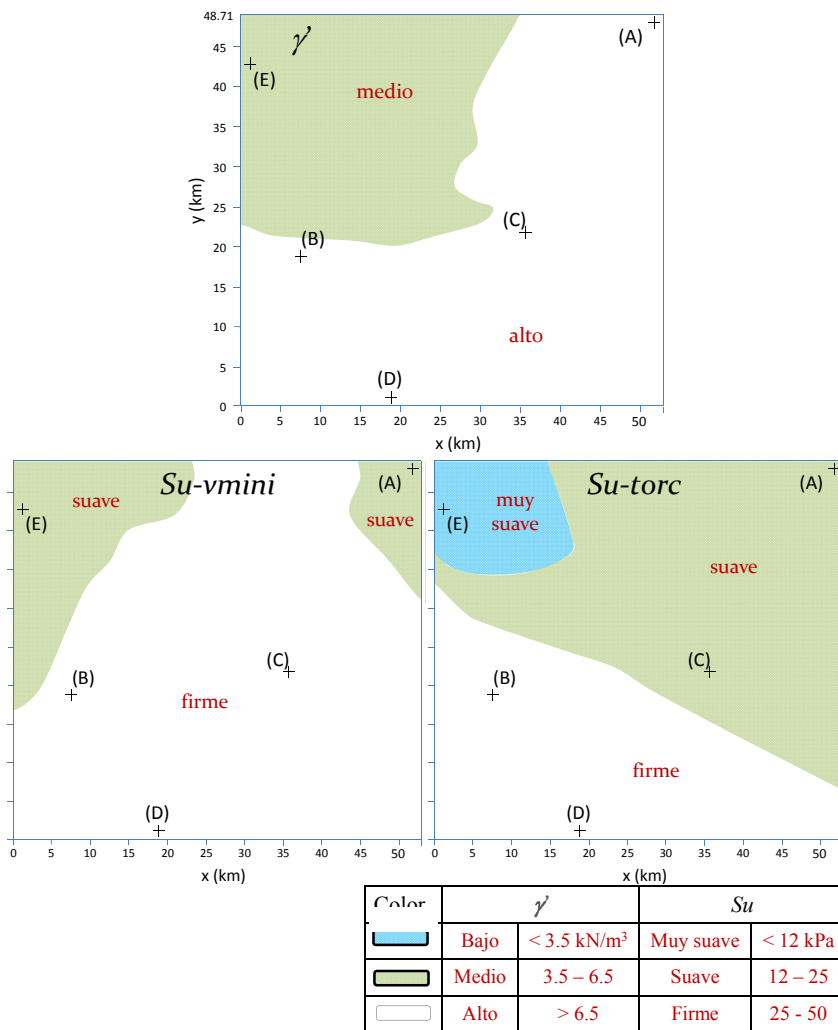


Figura 6.50. Mapas de contornos $z = 11$ m para (γ' , *Su-vmini* y *Su-torc*)




Figura 6.51. Superposición de mapas de contornos $z = 11 \text{ m}$ a) $\gamma' + Su-vmini$ y b) $\gamma' + Su-torc$

Con base en lo descrito por los parámetros (geopropiedades) estudiados en la sección 6.3.1, así como la congruencia o incongruencia entre los pozos B y D estimados con los modelos del caso 2 y 3, se elige a la variable $Su-vmini$ como variable de entrada del ANIRC. Esto sin despreciar la importancia que tiene el torcómetro, ya que $Su-torc$ pudiera ser también una variable de entrada al ANIRC pero requeriría un tratamiento especial, así como probablemente el desarrollo de más redes neuronales que van más allá de los alcances de esta tesis.

Con base en lo anterior, el esquema neuronal representativo del ANIRC consta de 3 entradas (z , γ' , $Su-uu$), una capa oculta de 10 nodos y un nodo de salida que es la resistencia al corte relacionada con la prueba triaxial UU (figura 6.52).

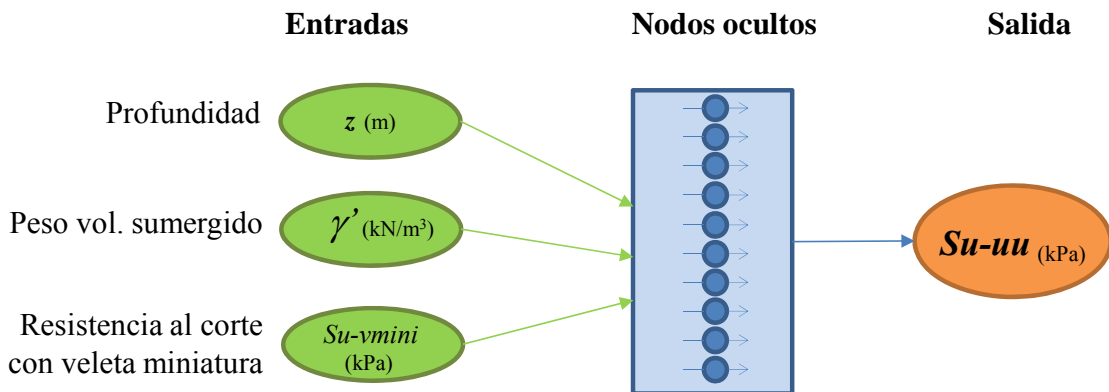


Figura 6.52. Esquema neuronal de ANIRC

Gráficamente la relación de valores medidos *versus* evaluados para el ANIRC se muestra en donde las evaluaciones neuronales están muy cerca de los valores de Su_{uu} objetivo. En la figura 6.53 se observa dicha relación.

La relación de valores medidos versus evaluados por el ANIRC se puede observar gráficamente mediante perfiles de Su_{uu} realizados en cada uno de los pozos A, B, C, D y E. Se recuerda al lector que la variable Su_{uu} solo fue medida en los pozos B y E, por lo que los perfiles en pozos A, C y E solo muestran evaluaciones neuronales. La figura 6.54 muestra dichos perfiles.




Figura 6.53. Relación entre valores medidos y evaluados por ANIRC para Su_{uu}




Figura 6.54. Evaluación neuronal de la variable S_u-uu obtenida con ANIRC en pozos A, B, C, D y E

7.1. VISUALIZACIÓN DEL MEDIO CON ANIRC

Una vez construido ANIRC se pueden realizar evaluaciones en cualquier punto del espacio donde se conozcan las variables de entrada z , γ' y $Su-vmini$.

A pesar de que el ANIRC no es un variador espacial, ya que en sus entradas no están comprendidas de manera directa las coordenadas x y y , es posible construir una variación espacial de los resultados de del modelo neuronal. Esto es posible debido a que de manera indirecta, cada valor de γ' y $Su-vmini$ con el que se alimenta al modelo está implícitamente adherido a las tres coordenadas espaciales. Para mostrar el trabajo del ANIRC, se analizan $Su-uu$ sobre los cortes presentados la figura 7.1, En las figuras 7.2 a 7.5, se representan las regiones obtenidas como salida a partir de comportamientos de las entradas.

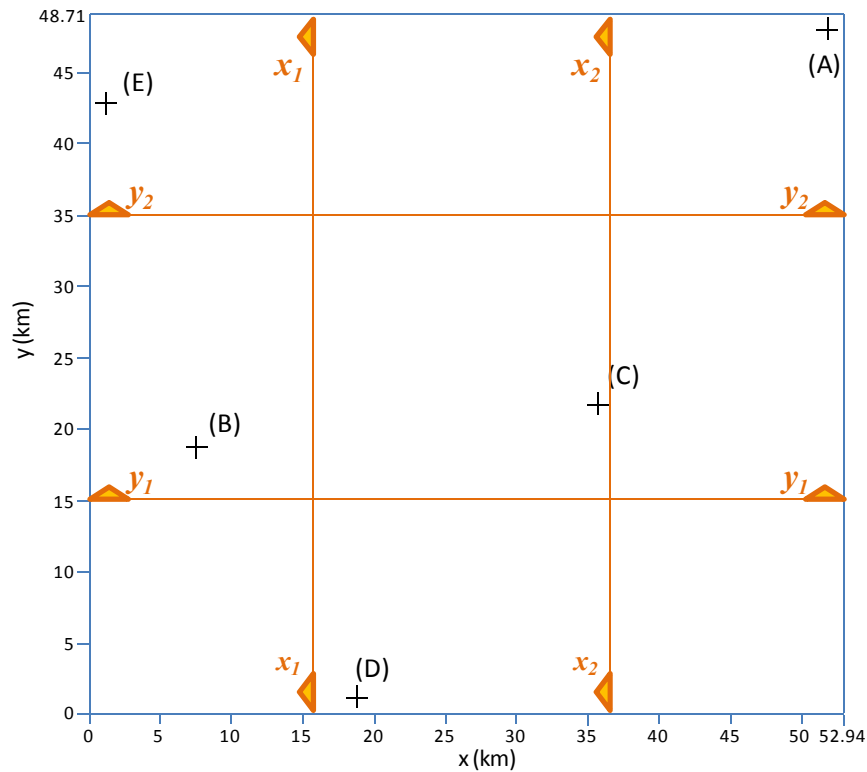


Figura 7.1 Ubicación de cortes para evaluación del ANIRC




Figura 7.2. Corte x_1-x_1 a) Entrada VEN de γ' , c) Entrada VEN de $Su-vmini$ y d) Salida $Su-uu$

Si se comparan las figuras 7.2 y 7.3 se observa cierta correspondencia estratigráfica con materiales de mayor resistencia con respecto a la profundidad del volumen en cuestión, y una tendencia de encontrar materiales con valores menos firmes hacia la derecha de ambas figuras.




Figura 7.3. Corte $x_2 - x_2$ a) Entrada VEN de γ' , c) Entrada VEN de $Su-vmini$ y d) Salida $Su-uu$

La orientación del corte $y_1 - y_1$

figura 7.4 sigue mostrando material de consistencia suave al que le subyace un material más competente. Sin embargo, la entrada de $Su-vmini$ es el único que presenta una capa superficial de consistencia muy suave, la cual no es definida por la salida del ANIRC.




Figura 7.4. Corte y_1-y_1 a) Entrada VEN de γ' , c) Entrada VEN de $Su-vmini$ y d) Salida $Su-uu$

En la figura 7.5 se muestra que el material más resistente y denso se encuentra en la parte inferior del medio. El peso volumétrico sumergido más alto se observa cargado un poco a la derecha de la imagen. También se observa, como era de esperarse, que en la parte superior del medio se encuentren los suelos menos resistentes y menos densos según lo mostrado en la salida del ANIRC.




Figura 7.5. Corte y_2-y_2 a) Entrada VEN de γ' , c) Entrada VEN de $Su-vmini$ y d) Salida $Su-uu$

De manera tridimensional, la variación espacial de la de $Su-uu$ estimada con el ANIRC, se muestra en las figuras 7.6, a 7.9.




Figura 7.6 Distribución espacial de Su-uu indirecto ANIRC (vista 1)




Figura 7.7 Distribución espacial de $Su-uu$ indirecto ANIRC (vista 2)




Figura 7.8 Distribución espacial de Su-uu indirecto ANIRC (vista 3)




Figura 7.9 Distribución espacial de Su-uu indirecto ANIRC (vista 4)

Con base en la representación tridimensional de los resultados de la variación espacial de la resistencia al corte no drenada Su_{uu} estimada con ANIRC (figura 7.6 a 7.9) que es alimentada con la información de los VEN de γ' (figura 6.15) y de Su_{vmini} (figura 6.22), se aprecia que el material predominante en el medio tiene un peso volumétrico sumergido medio tabla 6.10 y es de consistencia suave tabla 2.1. También existen algunas regiones superficiales que tienen características de muy baja consistencia y bajo peso volumétrico en zonas aisladas, así como una región con material de consistencia firme y alto peso volumétrico sumergido que subyace a los otros dos materiales cuya frontera superior se profundiza en dirección a los pozos A y E.

8 CONCLUSIONES

En esta tesis se usan Redes Neuronales RN para modelar la variación espacial de la resistencia al corte en condiciones no drenadas del suelo marino en una región de la denominada Sonda de Campeche, en el Golfo de México. Las dimensiones del medio estudiado son de 53×48 km de área y 14 m de profundidad.

Las propiedades del suelo fueron obtenidas mediante pruebas (peso volumétrico sumergido, veleta de campo, veleta miniatura, torcómetro, compresión triaxial), que con ayuda de las RN se modelaron para determinar la variación espacial de dichas propiedades.

El objetivo de esta tesis no es determinar cuál es la mejor prueba para caracterizar la resistencia al corte no drenada del medio, sino con base en los datos muestreados generar variadores espaciales de dicha propiedad para definir cuál es el mejor variador para estimar de manera indirecta la resistencia al corte no drenada que se obtendría de una prueba de compresión triaxial.

El mayor problema enfrentado en esta investigación es el desequilibrio entre el número de pozos, el número de muestras ensayadas y las dimensiones del área en estudio, por lo que se propone el uso de una metodología para incrementar las bases de datos inspirada en la técnica de vecinos cercanos y en redes de retroalimentación. La información obtenida con esta metodología permite cubrir el espacio estudiado de manera más uniforme y eficiente.

Con respecto a los Variadores Espaciales Neuronales (VEN), se concluye que a pesar de la limitada información contenida en la base de datos, estos tienen la capacidad de estimar la variación espacial de las propiedades geotécnicas de manera efectiva, ya que la distribución de la resistencia al corte no drenada obtenida entre cada VEN es compatible y congruente, mostrando que dicha propiedad incrementa con la profundidad y que la capa de consistencia firme es de más superficial hacia el pozo D y se profundiza hacia los pozos E y A.

El VEN de *Su-vcampo* (resistencia al corte no drenada medida con veleta de campo), presenta cierta inexactitud para generalizar casos de prueba. Esto no indica que la prueba sea una mala herramienta para determinar dicha propiedad, sino que es posible que los pocos patrones que se tienen para entrenar a la red requieran de algún tratamiento especial y del desarrollo de más redes neuronales que salen del alcance de la tesis. Por su parte las variables *Su-vmr* y *Su-vcr* (resistencia al corte no drenada en condiciones remoldeadas, medidas con veleta miniatura y de campo respectivamente), no pudieron ser

modeladas debido los muy escasos puntos de medición registrados en la base de datos en los pozos A y C únicamente.

A pesar de la escasa información contenida en la base de datos a cerca de la resistencia al corte no drenada obtenida mediante la prueba de compresión triaxial no consolidada no drenada, el Aproximador Neuronal Indirecto de la Resistencia al Corte (ANIRC) estima indirectamente esta propiedad a partir de dos pruebas sencillas y económicas (prueba de veleta miniatura y peso volumétrico sumergido). ANIRC cuenta con la suficiente confianza para ser tomado como una aproximación preliminar, por ejemplo para programar una batería de pruebas de campo.

Si bien el ANIRC en principio no es un estimador de la variación espacial de la resistencia al corte S_u , ésta se puede obtener a partir de las matrices tridimensionales de geoinformación de los VEN. Con ANIRC se puede observar la variación espacial de esta propiedad en el medio (suelo marino), que permite estimar, de manera preliminar, volúmenes y procedimientos constructivos preliminares para obras civiles desplantadas en este material. La función principal del ANIRC es cubrir la demanda de los ingenieros geotecnistas sobre el valor de la resistencia al corte del suelo marino correspondiente al que se obtendría de un ensayo de compresión triaxial del tipo UU.

9 REFERENCIAS

- Aguayo, J. E. (2005). Neotectónica de facies sedimentarias cuaternarias en el suroeste del Golfo de México, dentro del marco tectónico-estratigráfico regional evolutivo del Sur de México. *Ingeniería: Investigación y Tecnología*, VI (1), 19-45.
- Aguayo, J. E., & Trápaga, R. (1996). *Geodinámica de México y minerales del mar* (1a ed.). México: SEP-Ciencia.
- Antonie, J. (1972). Contributions on the Geological and geophysical Oceanography of the Gulf of Mexico. *Gulf Publishing Company*, 1.34.
- Aronoff, S. (1989). Geographical Information Systems: A management perspective. *WDL Publications Ottawa*, 249.
- Auvinet, G. (2009). Advances in geotechnical characterization of Mexico City basin subsoil. *Proceedings, 17th International Conference on Soil Mechanics and Geotechnical Engineering, International Society for Soil Mechanics and Geotechnical Engineering, Alexandria, Egypt*, III, 2679-2682.
- Auvinet, G. (1997). El concepto de confiabilidad en Geotecnia. *Memoria, IV Congreso Nacional de Ingeniería Civil, Universidad de las Américas, Cholula, Puebla*.
- Auvinet, G. (2002). Incertidumbre en Geotecnia. *Decimosexta Conferencia Nabor Carrillo, Sociedad Mexicana de Mecánica de Suelos, Querétaro, México*.
- Auvinet, G. (1984). Variabilidad de los depósitos de carbón. Un enfoque estocástico. *Estudio realizado para Minera Carbonífera de Río Escondido, Coahuila, México*.
- Aymerich, M., & Navarrina, F. (1985). Interpolación Mínimo-cuadrática de superficies a partir de datos irregularmente distribuidos. *Revista Internacional de Métodos Numéricos para cálculo y diseño en ingeniería*, 1 (1), 21-36.
- Bartzko, A., & Kopf, A. (2006). The relationship of undrained shear strength and porosity with depth in shallow (<50 m) marine sediments. *Sedimentary Geology* (196), 235-249.
- Benett, R., Freeland, G., Lambert, D., Sawyer, W., & Keller, G. (1980). Geotechnical properties of surficial sediments in megacorrridor: U.S: Atlantic continental slope, rise, and deep-sea basin. *Marine Geology*, 38, 123-140.

Bologna, J., & Walsh, A. (1997). *The Accountant's Handbook of Information Technology*. John Wiley and Sons.

Bonham-Carter, G. F. (1994). *Geographic Information Systems for Geoscientists: Modelling with GIS*. Elsevier .

Brand, E. W. (1967). The Vane Shear Test its use for Strength Measurements of Cohesive Soils. *Reilem Bulletin No.36* .

Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and Regression Trees*. Wadsworth: Belmont .

Bruun, P. (1989). Port Engineering. *Offshore Technology Conferences; Gulf Publications, Houston , I.*

Bryant, W. R., Hottman, W., & Trabant, P. (1976). Permeability of unconsolidated and consolidated marine sediments, Gulf of Mexico. *Marine Geotechnics* , 1-14.

Burgess, T., & Webster, R. (1980). Optimal interpolation and isarithmic mapping of soil properties: The semi-variogram and punctual kriging. *Journal of Soil Sci. , 31*, 315-331.

Burrough, P. A., & Webster, R. (1998). *Principles of Geographical Information Systems*. Oxford University Press .

Burrough, P. (1985). *Principles of Geographical Information Systems for Land Resource Assessment*. Clarendon Press, Oxford .

Cherkassky, V., Friedman, J. H., & Wachsler, H. (1994). *From statistics to neural networks*. Berlin: Springer-Verlag.

Churchland, P. (1986). *Neurophilosophy: Toward a Unified Science of the Mind/Brain*. Cambridge, MA.: MIT Press.

Croall, I. F., & Mason, J. P. (1992). *Industrial applications for neural networks*. Berlin: Hillsdale, N.J.

Day, R. W. (2010). *Foundation Engineering Handbook*. McGraw-Hill Companies.

Deadman, P. J., & Gimblett, H. R. (1997). Applying neural networks to vegetation management plan development. *AI Application* (11), 107-112.

DeGroot, D. J., Lunne, T., & Tjelta, T. I. (2011). Recommended best practica for geotechnical site characterisation of cohesive offshore sediments. *Frontiers in Offshore Geotechnics II - Gourvenec & White* .

- Dempster, A. (1967). Upper and lower probabilities induced by multivalued mapping. *Annals of Mathematical Statistics* , 38, 325-339.
- Eberhat, R., & Dobbins, R. (1990). Chap. 1, Background and History. En *Newral Networks PC Tools: A practical Guide*. San Diego, CA, USA: Eberhat, R.C. and Dobbins, R.W. eds. Academic Press.
- Elragi, A. F. (2006). *Softoria It services and solutions*. (Softoria, Ed.) Recuperado el 27 de 01 de 2012, de Selected Engineering Properties and Applications of EPS Geofoam: <http://www.softoria.com/institute/geofoam/manufacturing.html>
- Fayyad, U., Piatetsky, G., & Smyth, P. (1997). From Data Mining to Knowledge Discovery in Databases. *AI Magazine* , 37-54.
- Flaate, K. (1966). Factors influencing the results of Vane Test. *Canadian Geotéchnical Journal* , III (1).
- Flexer, A. (1995). Connectionist and statisticians, friends or foes? *The Australian Research Institute for Artificial Intelligence* .
- Fukue, M., & Nakamura, T. (1996). Effects of carbonate on cementation of amrine soils. *Marine Georesources and Geotechnology* , 14, 37-35.
- Fukue, M., Takami, Y., & Ide, T. (2000). Evaluation of strength of marine surface sediments. *Costal Geotechnical Engineering in Practice* .
- Fukuoka, M., & Nakase, A. (1973). Problems of soil mechanics of the ocean floor. *Proceedings 8th International Conference of Soil Mechanics and Foundations Engineering* (4.2), 205 - 222.
- Galván, E. (2009). Evaluación geoestadística y geotécnica del estrato del fondo marino en la Sonda de Campeche afectado por emanaciones de hidrocarburos. En *Tesis de doctorado*. UNAM.
- García, S. (2009). *Cómputo Aproximado en la Solución de Problemas Geosismicos*. D.F., México: Tesis de Doctorado en Ingeniería. UNAM.
- García, S., & Romo, M. P. (2004). Sistema de Infromación Geográfica y Redes Neuronales. *Memorias de la Reunión Nacional de Mecánica de Suelos, Nov. 18-20* .
- García, S., Chimalpopoca, T. R., & Bonetti, C. (2012). Cognitive-Spatial Variation: Local amplification of Ground Motions. *Precedings of the 15TH World Conference on Earthquake Engineering WCEE* .

García, S., Romo, M. P., & Ortega, M. (2005). Spatial variation of soil properties using soft computing. *Proceedings of the 11th International Conference IACMAG* , 611-618.

Garson, G. D. (1991). A comparison of neural network and expert systems algorithms with common multivariate procedures for analysis of social science data. *Social Science Computer Review* , 9, 399-434.

Geer, R. L. (1982). Engineering challenges for offshore exploration in the 80's. *Keynote Address, 3rd BOSS Conf., Cambridge, Mass.*

Gemeinhardt, J. P., & Wong, V. (1978). Progress of Consolidation of Amarine Clay in Borne. *Offshore Technology Congerence, Houston, Texas.*

Gerwich, B. (2000). *Construction of Marine and Offshore Structures* (Second ed.). CRC Press LLC.

Gilboy, G. (1928). The compressibility of sand-mica mixtures. *Proc. American Society of Civil Engineering* , 54, 555-568.

Goovaerts, P. (1997). Geostatistics for Natural Resources Evaluation. *Oxford Univ. Press* .

Hamilton, E. L. (1974). *Prediction of deep-sea sediment properties: state of the art. In Deep-sea Sediments.* New York: Plenum Press: A.L. Inderbitzen.

Hamilton, E. L., Bachman, R. T., Berger, W. H., Johnson, T. C., & Mayer, L. A. (1982). Acoustic and related properties of calcareous deep-sea sediments. *J. Sed. Petrol* , 3 (52), 733-753.

Hassoun, M. H. (1995). Fundamentals of Artificial Neural Networks. *The MIT Press* .

Haykin, S. (1994). *Neural Networks a comprehensive foundation.* USA: Macmillan College Publishing Company, Inc.

Head, K. H. (1994). Manual of Soil Laboratory Testing. *Pentech Press.*

Hectht-Nielsen, R. (1990). *Neurocomputing.* Addison-Wesley. Cal.

Hertz, J., Krogh, A., & Palmer, R. G. (1991). *Introduction to the Theory of Neural Computing.* Addison-Wesley Publishing Company.

Hilera, J. R., & Martínez, V. J. (1995). *Redes neuronales artificiales.* Madrid: Ra-ma.

Holland, J. H. (1975). Adaptation in natural an artificial systems. *MIT Press* , 66-121.

- Hopfield, J. J. (1982). Neural Networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences* (79), 2554-2558.
- Huang, W. Y., & Lippmann, R. P. (1987). Comparisons between neural nets and conventional classifiers. *Proceedings of the IEEE International Conference on Neural Networks* , I, 485-494.
- Journel, A. G., & Huijbregts, C. J. (1978). Mining Geostatistics. *Academic Press London* .
- Juárez , M., & Auvinet, G. (2000). Caracterización geoestadística del subsuelo del Valle de México. *Memorias técnicas de la XX Reunión Nacional de Mecánica de Suelos, Sociedad Mexicana de Mecánica de Suelos, México* .
- Keller, G., & Benett, R. (1970). Variations in the mass physical properties of selected submarine sediments. *Marine Geology* , 9, 215-223.
- Kendel, E. R., & Hawkins, R. D. (1992). Bases biológicas del aprendizaje y de la individualidad. *Investigación y Ciencia* , 58.
- Killen, P. G. (1997). Nuclear techniques for ore grade estimation. *Proceedings of Exploration 97: Fourth Decennial Conference on Mineral Exploration* , 677-684.
- Knackstedt, M. A., Latham, S., Madadi, M., Sheppard, A., Varlot, T., & Arns, C. (2009). Digital Rock Physics: 3D Imaging of Core Material and Correlations to Acoustic and Flow Properties. *The Leading Edge* , 28, 28-33.
- Kolk, H. J., Hoop, J., & Imms, B. W. (1988). Evaluation of offshore in situ vane test results. . *Vane Shear Strength Testing of Soils: Field and Laboratory Studies. ASTM STP1014* , 339-353.
- Kollias, V. J., Kalivas, D. P., & Tassoglou, N. J. (1999). Mapping the soil resources of a recent alluvial plain in Greece using fuzzy sets in a GIS environment. *European Journal of Soil Science* , 50, 261-273.
- Krige, D. G. (1962). Statistical application in mine valuation. *Institute Mine Survey, South Africa*.
- Ladd, C., & Foott, R. (1974). New design procedure for stability of soft clays. *Journal, Geotechnical Engineering Division, ASCE* , 100 (GT7), 763-786.
- Laslett, G. M., & McBratney, A. B. (1990). Further comparison of spatial methods for predicting soil pH. *Soil Sci. Soc. Am. J* , 54, 1553-1558.

Leenaers, H., Okx, J. P., & Burrough, P. A. (1990). Employing elevation data for efficient mapping of soil pollution on floodplain. *Soil Use and Management* , 6, 105-113.

Matheron, G. (1965). *Les variables généralisées et leur estimation*. France: Masson et Cie.

McCulloch, W., & Pitts, W. (1943). A logical calculus of the ideas immament in nervous activity. *Bulletin of Mathematical Biophysics* , 7., 115-133.

Medina, Z. (2001). *Interpretación geoestadística de campañas de reconocimiento del suelo*. México, DF: Tesis de Maestría, DEPI, UNAM.

Mejía, A. G. (2009). *Tesis de maestria: Suelos marinos, Nautraleza y Propiedades*. Mexico: UNAM.

Meyerhof, G. G. (1979). Geotechnical properties of offshore soils. *1st Can. Conf. Mar. Geotech. Engng* , 253-260.

Michie, D., Spiegelharter, D. J., & Taylor, C. C. (1994). *Machine learning and statistical calassification*. Londres: Ellis Horwood.

Minsky, M., & Papert, S. (1969). *Perceptrons*. MIT Press .

National Engineering Handbook. (2007). *Soil properties and special geotechnical probles related to stream stabilization proyects* (Technical Supplement 14 A ed.). NEH.

Noorany, I. (1989). Clasification of marine sediments. *ASCE Journal of Geotechnical Engineering* , 115 (1), 23-37.

Olsen, H. W., McGregor, B. A., Booth, J. S., Cardinell, A. P., & Rice, T. L. (1982). Stability of near-surface sediment on the Mid-Atlantic upper contiental solpe. *14th Annual OTC, Houston. Paper OCT 4303* , 21-35.

Peck, R. B., Hanson, W. E., & Thornburn, T. H. (1953). *Foundation Engineering*. USA: John Wiley & Sons, Inc.

Poulos, H. G. (1988). *Marine Geotechnics*. London: Unwin Hyman.

Quinn, A. D. (1975). *Design and Construction of Ports and Marine Structures*. New York: McGraw Hill.

Quiros, G. W., Young, A. G., Pelletier, J. H., & Chan, J. (1983). Shear Strength Interpretation for Gulf of Mexico Clays. *Geotechnical Practice in Offshore Engeenering* , 144-165.

- Radolph, M. F. (2004). Characterisation of soft sediments for offshore applications. *Proc. 2nd Int. Conf. on Site Characterisation. Porto. Portugal* , 209-231.
- Richards, A. F. (1988). *Vane Shear Test in Soils. Field and Laboratory Studies. Special Publication* (1014 ed.). ASTM.
- Richards, A. F., Palmer, H. D., & Perlow, M. (1975). Review of continental shelf marine geotechnics: distribution of soils, measurement of properties, and environmental hazards. *Marine Geotechnology* , 1, 33-67.
- Rosenblatt, F. (1959). Mechanization of Thought Processes: Two Theorems of Statical Separability in the Perceptron. *Symposium at National Physical Laboratory* .
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagation errors. *Nature* 323 , 533-536.
- Rumelhart, D. E., McClelland, J., & PDP Research Group. (1986). Parallel Distributed Processing: Exploration in the Microstructure of Cognition. *MIT Press* , 1: *Foundations*, 318-368.
- Rumelhart, D., & McClelland, J. L. (1986). Parallel distributed processing. *Cambridge, Mass, MIT Press* , 1.
- Samarasinghe, S. (2007). *Neural Networks for Applied Sciences and Engineering: from fundamentals to complex pattern recognition*. USA: Taylor and Francis Group, LLC.
- Santoyo, E. (2010). Vigésima Conferencia Navor Carrillo: Exploración de suelos, métodos directos e indirectos, muestreo y pruebas de campo. Acapulco, Gro.: Sociedad Mexicana de Ingeniería de Geotécnica.
- Sarle, W. S. (1998). *Neural network FAQ*. Recuperado el 24 de febrero de 2013, de <ftp://ftp.sas.com/pub/neural/FAQ.html>
- Sarle, W. S. (1994). Neural networks and statistical models. *Proceedings of the 19th Annual SAS Group conference* , 1538-1550.
- Schnaid, F. (2009). *In situ testing in geomechanics. The main test*. (1014 ed.). (F. A. Richards, Ed.) London and New York: ASTM Special Publication.
- Shafer, G. (1967). A mathematical theory of evidence. In *Princeton University Press*.

Terzaghi, K. (1948). *Soil Mechanics in Engineering Practice*. John Wiley & Sons, Inc.

Thales Geosolutions. (2002). *Levantamientos Geofísicos y Geotécnicos, Campaña 2001-2002, Localización de Amoca*. Pemex Exploración y Producción.

Thales Geosolutions. (2002). *Levantamientos Geofísicos y Geotécnicos, Campaña 2001-2002, Localización de Carpa*. Pemex Exploración y Producción.

USACE. (1994). *Engineer and Design; Design of Sheet Pile Walls. EM 1110-2-2504*. USACE.

VanMarcke, E. H. (1983). *Random Fields: Analysis and Synthesis. Massachusetts Institute of Technology, Press Cambridge, Massachusetts, USA*.

Wasserman, P. D. (1989). *Neural computing: Theory and practice*. N.Y.: Van Nostrand Reinhold.

Wentworth, C. K. (1922). A scale of grade and class terms of clastic sediments. *J. Geol.* , 381.

Worzel, J. L., Leyden, R., & Ewing, M. (1968). Newly discovered diapirs in Gulf of Mexico. *Amer. Assoc. Petrol. Geol. Bull.* , 52, 1194-1203.

Xin-Gang, C., & De-Hua, H. (2009). Lithology and Fluid Differentiation Using a Rock Physics Template. *The Leading Edge* , 28, 60-65.

Young, A. G., Quiros, G. W., & Ehlers, C. J. (1983). Effects of Offshore Sampling and Testing on Undrained Soil Shear Strength. *Offshore Technology Conference (OTC 4445)*.

Zadeh, L. A. (1994). Fuzzy logic, neural network, and soft computing. *Comm. ACM* .

Zadeh, L. A. (1965). *Fuzzy sets: Information and Control (Vol. 8)*.

Zadeh, L. (1988). Fuzzy logic. *IEEE Computer* .

Zadeh, L. (1993). Fuzzy Logic and Soft Computing. *Proceedings of IEEE International Workshop on Neuro Fuzzy Control*. Muroran: Japan.

