

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO



**PROGRAMA DE MAESTRÍA Y DOCTORADO EN
INGENIERÍA**

FACULTAD DE INGENIERÍA

**ESTIMACIÓN DE LA VELOCIDAD DE ONDAS DE CORTE
A PARTIR DE LA RESISTENCIA A LA PENETRACIÓN
ESTÁNDAR MEDIANTE EL USO DE
REDES NEURONALES**

T E S I S

QUE PARA OBTENER EL GRADO DE:

**MAESTRO EN INGENIERÍA
INGENIERÍA CIVIL (GEOTECNIA)**

P R E S E N T A :

EDWIN ROJAS TOLEDO

TUTOR:
DR. EFRAÍN OVANDO SHELLEY

México D.F., Noviembre de 2005





Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

JURADO ASIGNADO:

Presidente: ING. JESÚS ALBERRO ARAMBURU
Secretario: DR. RAÚL FLORES BERRONES
Vocal: DR. EFRAÍN OVANDO SHELLEY
1er. Suplente: DR. RIGOBERTO RIVERA CONSTANTINO
2do. Suplente: DR. JESÚS FIGUEROA NAZUNO

Lugar o lugares donde se realizó la tesis:

DIVISIÓN DE ESTUDIOS DE POSGRADO, SALA DE EXAMENES.

TUTOR DE TESIS:

DR. EFRAÍN OVANDO SHELLEY

FIRMA

DEDICATORIA

A Dios, por permitirme estar aquí y brindarme las fuerzas necesarias para derribar todas las barreras que he encontrado a mi paso, gracias por poner en mi camino tantas personas que de un modo u otro han participado en esta tesis.

A mis padres Leney y Álvaro con mi más profundo cariño, por su orientación y apoyo incondicional, porque siempre están conmigo, en mi mente y en mi corazón.

A mis hermanos Johana y Álvaro E., cómplices y amigos, espero que esto se constituya en un estímulo para ustedes.

A mi familia, por su apoyo, respeto y confianza.

Al M en I Gabriel Moreno P., con mi mayor respeto y admiración, por ser otro padre para mí. Gracias por sus sabias palabras y esos momentos de aliento, siempre dispuesto reforzar mi persistencia cuando existieron momentos de adversidad. Gracias su amistad, por confiar en mí.

AGRADECIMIENTOS

Terminar esta tesis significa el fin de una etapa y el comienzo de una nueva. Quiero aprovechar este momento para agradecer a todas las personas cuya paciencia, cariño y apoyo hicieron que lograra terminar este ciclo.

Agradezco a la UNAM y el Instituto de Ingeniería, por darme la oportunidad de ampliar mis conocimientos y terminar este trabajo.

Al Dr. Efraín Ovando Shelley, por quien siento profunda admiración y gran aprecio. Gracias por el apoyo en la dirección de este trabajo y sus valiosas palabras de aliento en los momentos precisos.

A los Doctores Raúl Flores, Rigoberto Rivera y Jesús Figueroa, al M en I Jesús Alberro por los aportes y comentarios dirigidos a este trabajo.

A Silvia García, por su valioso aporte en el conocimiento de redes e inteligencia artificial, por sus comentarios hacia este trabajo. Gracias también, por esas palabras de amistad y momentos de risa que tras un café surgían, por su capacidad de brindar amistad y buena energía, eso no se olvida.

A Erika Valle, por los grandiosos momentos de amistad, por estar allí, aunque implicara un poco de sacrificio para ti, siempre brindando una voz de aliento incondicional y una que otra risa para continuar.

A Mario Flores, por su gran compañerismo y amistad en todo momento.

A mis amigos Marcela González, Marcela Baena, David Sigrist, Mario Aguilar, Francisco Correa, Sergio Hernández, Juliana Zapata, Alexandra Ossa, quienes fueron un gran apoyo en momentos de alegría y desesperación, estando de manera especial en diversas circunstancias de mi vida.

A la sección administrativa de la UNAM, Norma y Alma Nieto además por su apoyo moral. A los Lic. Leticia Cruz, Jorge Becerril y Yanina Muñoz, por su confianza y apoyo para hacer posible que tuviera la oportunidad de desarrollar y culminar este triunfo.

CONTENIDO

CONTENIDO	1
RESUMEN	3
1.0 INTRODUCCIÓN	4
1.1 ANTECEDENTES	4
1.2 OBJETIVOS	5
2.0 DESCRIPCIÓN DE LA BASE DE DATOS	6
2.1 ASPECTOS GEOLÓGICOS GENERALES	6
2.1.1 Comalcalco, Tabasco	6
2.1.2 Minatitlán, Veracruz	8
2.1.3 Zapotlán de Juárez, Hidalgo	9
2.1.4 Santiago Ixcuintla, Nayarit	9
3.0 EXPLORACIÓN GEOTÉCNICA	11
3.1 PROCEDIMIENTOS Y TÉCNICAS DE RECOLECCIÓN DE DATOS	11
3.1.1 Prueba de penetración estándar (SPT)	11
3.1.2 Medición de la velocidad de propagación de ondas en campo	19
3.2 CONCLUSIONES	19
4.0 REDES NEURONALES	20
4.1 INTRODUCCIÓN	20
4.1.1 El paradigma de la computación conexionista	20
4.2 ESTRUCTURA DE UN MODELO NEURONAL	21
4.2.1 <i>Función de propagación o de red</i>	22
4.2.2 <i>Función de activación</i>	24
4.2.3 <i>Salida</i>	25
4.3 ESTRUCTURA Y FORMAS DE INTERCONEXIÓN	26
4.3.1 Topología	27
4.4 MODO DE OPERACIÓN	27
4.5 <i>VENTAJAS DE LOS MODELOS NEURONALES</i>	31

5.0 ANÁLISIS DE REGRESIÓN	32
5.1 <i>MODELOS DE REGRESIÓN</i>	32
5.2 <i>ANÁLISIS DE REGRESIÓN ENTRE V_s Y N</i>	34
5.3 <i>ANÁLISIS DE REGRESIÓN PROPUESTA PARA LOS VALORES DE V_s-N</i>	36
5.4 <i>ANÁLISIS DE RESULTADOS.</i>	41
6.0 MODELO DE APRENDIZAJE AUTOMÁTICO PARA LA ESTIMACIÓN DE V_s A PARTIR DE N (SPT)	42
6.1 <i>PROCESO DE CONSTRUCCIÓN DE UN MODELO NEURONAL</i>	42
6.2 <i>FORMULACIÓN DEL PROBLEMA</i>	43
6.3 <i>PROCESAMIENTO DE LA INFORMACIÓN</i>	43
6.3.1 <i>Banco 1: Categorización por tipo de suelo</i>	44
6.3.2 <i>Banco 2: Categorización por profundidad</i>	45
6.4 <i>DEFINICIÓN DE EXPERIMENTOS</i>	45
6.4.1 <i>Combinaciones de las variables de entrada</i>	45
6.4.2 <i>Experimento variando la Ley de Aprendizaje</i>	48
6.4.3 <i>Experimento variando la Función de Transferencia o salida</i>	49
6.4.5 <i>Experimentos Variando la Topología de la Red</i>	51
6.5 <i>EJECUCIONES EN EL MODO DE TRABAJO (VALIDACIÓN Y PRUEBA DE LA RED)</i>	52
6.6 <i>RESUMEN DE RESULTADOS</i>	54
6.6.1 <i>Valoración de los modelos</i>	54
6.6.2 <i>Validación de las redes</i>	55
7.0 CONCLUSIONES	60
ANEXO 1. PERFILES ESTRATIGRÁFICOS DE LOS SITIOS EN ESTUDIO	62
ANEXO 2. MEDICIÓN DE LA VELOCIDAD DE PROPAGACIÓN DE ONDAS EN CAMPO	76
ANEXO 3. REDES NEURONALES BIOLÓGICAS	83
ANEXO 4. REDES DE RETROPROPAGACIÓN (BACK-PROP)	85
REFERENCIAS	90

RESUMEN

El contenido de éste trabajo está organizado en un capítulo de introducción, cinco capítulos centrales y un capítulo de conclusiones, además, de dos apéndices.

El capítulo 2.0 contiene la descripción, localización y aspectos geológicos generales de los sitios que comprende la base de datos usada para el desarrollo de este trabajo de tesis. Se detallan en el capítulo 3.0, las labores de exploración geotécnica y procedimientos de recolección de datos útiles para definir los perfiles estratigráficos de los sitios estudiados.

El capítulo 4.0 justifica el uso de las redes neuronales en la identificación, parametrización y control de procesos. Se dan las pautas para la creación de una red neuronal y se describen algunas funciones y topologías típicas en el modelado con redes neuronales artificiales (RNA).

Los resultados de este trabajo se formalizan en los capítulos 5.0 y 6.0, en los que se analizan los datos mediante análisis de regresión simple y redes neuronales. A la vez, se discuten las cotas de error máximo que dichos métodos pueden presentar al relacionar las variables de velocidad de onda cortante V_s y el número de golpes de la prueba de Penetración Estándar N. En el capítulo 6.0, se describe una metodología para el uso de las redes neuronales y se refieren varios ejemplos de aplicación los que permiten validar las estructuras neuronales desarrolladas en la tesis.

Finalmente, el capítulo 7.0 recoge las conclusiones, aportaciones, valoraciones y líneas de trabajo abiertas a partir de los resultados de este estudio.

1.0 INTRODUCCIÓN

La motivación para realizar esta tesis se encuentra en la necesidad de revisar y mejorar las correlaciones existentes entre el valor de la resistencia a la penetración N y la velocidad de onda cortante en un estrato.

En este trabajo, se describe el estudio realizado y el marco de trabajo propuesto para el desarrollo de una red neuronal que permita estimar la velocidad de ondas de corte a partir de la resistencia a la penetración estándar tomando en cuenta las características del suelo en estudio. Además, se incluyen estudios de análisis de regresión, aplicados convencionalmente para obtener funciones matemáticas que tratan de describir la correlación existente entre las variables V_s (velocidad de onda cortante) y N (Número de golpes del ensaye de Penetración Estándar) para todo tipo de suelo.

1.1 ANTECEDENTES

En el desarrollo de la ingeniería civil, cuando se pretende identificar la relación entre dos o más variables, ha sido frecuente recurrir a estudios estadísticos como un método fiable, rápido y sencillo, en el cálculo e interpretación de las medidas características de una variable aleatoria para describir en forma general el comportamiento de la población representada. El objetivo de un análisis de regresión es generar un modelo que "explique" el comportamiento de una variable (variable dependiente) utilizando la información proporcionada por otro conjunto de variables (explicativas o independientes).

Para la predicción de algunas propiedades dinámicas en una masa de suelo se han propuesto muchas correlaciones matemáticas, tal es el caso de la velocidad de propagación de onda cortante predicha a partir del número de golpes N (SPT), para que la mayoría de los modelos presentan una estructura matemática del tipo potencial de la forma $V_s = AN^B$, siendo A y B parámetros determinados a partir de registros obtenidos en campo. Estas propuestas han delimitado la población de datos en clases menores dependiendo del tipo de suelo según el Sistema Unificado de Clasificación de Suelos (SUCS), con el fin de acotar el disperso comportamiento de la masa de suelo.

Por otro lado, el desarrollo de las Redes Neuronales Artificiales (RNAs) como modelos computacionales no lineales, ha generado una profunda revolución en el ámbito de la ciencia y la tecnología de nuestros días. Las RNAs son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de extraer características esenciales a partir de entradas que representan información relevante, etc.

Actualmente en el ámbito de la ingeniería civil, los modelos con RNAs están siendo aplicados en la valoración de efectos sísmicos, amplificación de onda, solución de problemas de gerencia de construcción, diagnóstico de daños, etc.

1.2 OBJETIVOS

Modelar el problema y formular una solución mediante un algoritmo neuronal consiguiendo el reconocimiento del comportamiento detrás de las propiedades medidas en el campo.

Comparar los resultados del método propuesto (RNAs), con los obtenidos por los métodos clásicos (análisis de regresión).

2.0 DESCRIPCIÓN DE LA BASE DE DATOS

2.1 ASPECTOS GEOLÓGICOS GENERALES

La base de datos se construyó con la información obtenida de sondeos realizados en los estados de Tabasco, Veracruz, Hidalgo y Nayarit (tabla 2.1); los sitios explorados presentan gran diversidad en estratigrafía, comportamiento mecánico y sísmico, por lo que arcillas, limos, arenas, gravas y boleos se ven representados en esta muestra geotécnica (ver anexo 1).

Tabla 2.1 Sitios involucrados en la base de datos

ESTADO	% DE LA SUPERFICIE DEL PAÍS	PUNTOS EXTREMOS DEL ESTADO				SITIO	SONDEO	PROF. MAX. EXPLORADA (m)
		Norte	Sur	Este	Oeste			
Tabasco	1.3%	18°39'N	17°15'N	91°00'W	94°07'W	Comalcalco	Sitio 46	30.0
							Sitio 70	30.0
Veracruz	3.7%	22°28'N	17°09'N	93°36'W	98°39'W	Minatitlán	Sitio 1	44.0
							Sitio 2	41.0
							Sitio 3	20.0
Nayarit	1.4%	23°05'N	20°36'N	103°43'W	105°46'W	Santiago Ixcuintla	Sitio 1	17.0
							Sitio 2	21.0
Hidalgo	1.1%	21°24'N	19°36'N	97°58'W	99°53'W	Zapotlán de Juárez	Sitio 5	40.0
							Sitio 6	34.0

2.1.1 Comalcalco, Tabasco

Tabasco comparte con los estados de Veracruz, Chiapas y Campeche terrenos de la Llanura Costera del Golfo Sur, y con Chiapas, los de la provincia denominada Sierras de Chiapas y Guatemala (figura 2.1). El desarrollo geológico del territorio tabasqueño, que está determinado por eventos estratigráficos y estructurales del Mesozoico y Cenozoico, ha dado lugar a la base petrológica sobre la cual se ha configurado el actual paisaje del estado.

Los depósitos del Cuaternario son los más extensos en la Llanura Costera del Golfo, entre ellos destacan los palustres, los aluviales, los litorales y los lacustres. Todos éstos se manifiestan como testigos del desarrollo de los ambientes actuales, desde el Plioceno hasta el presente.

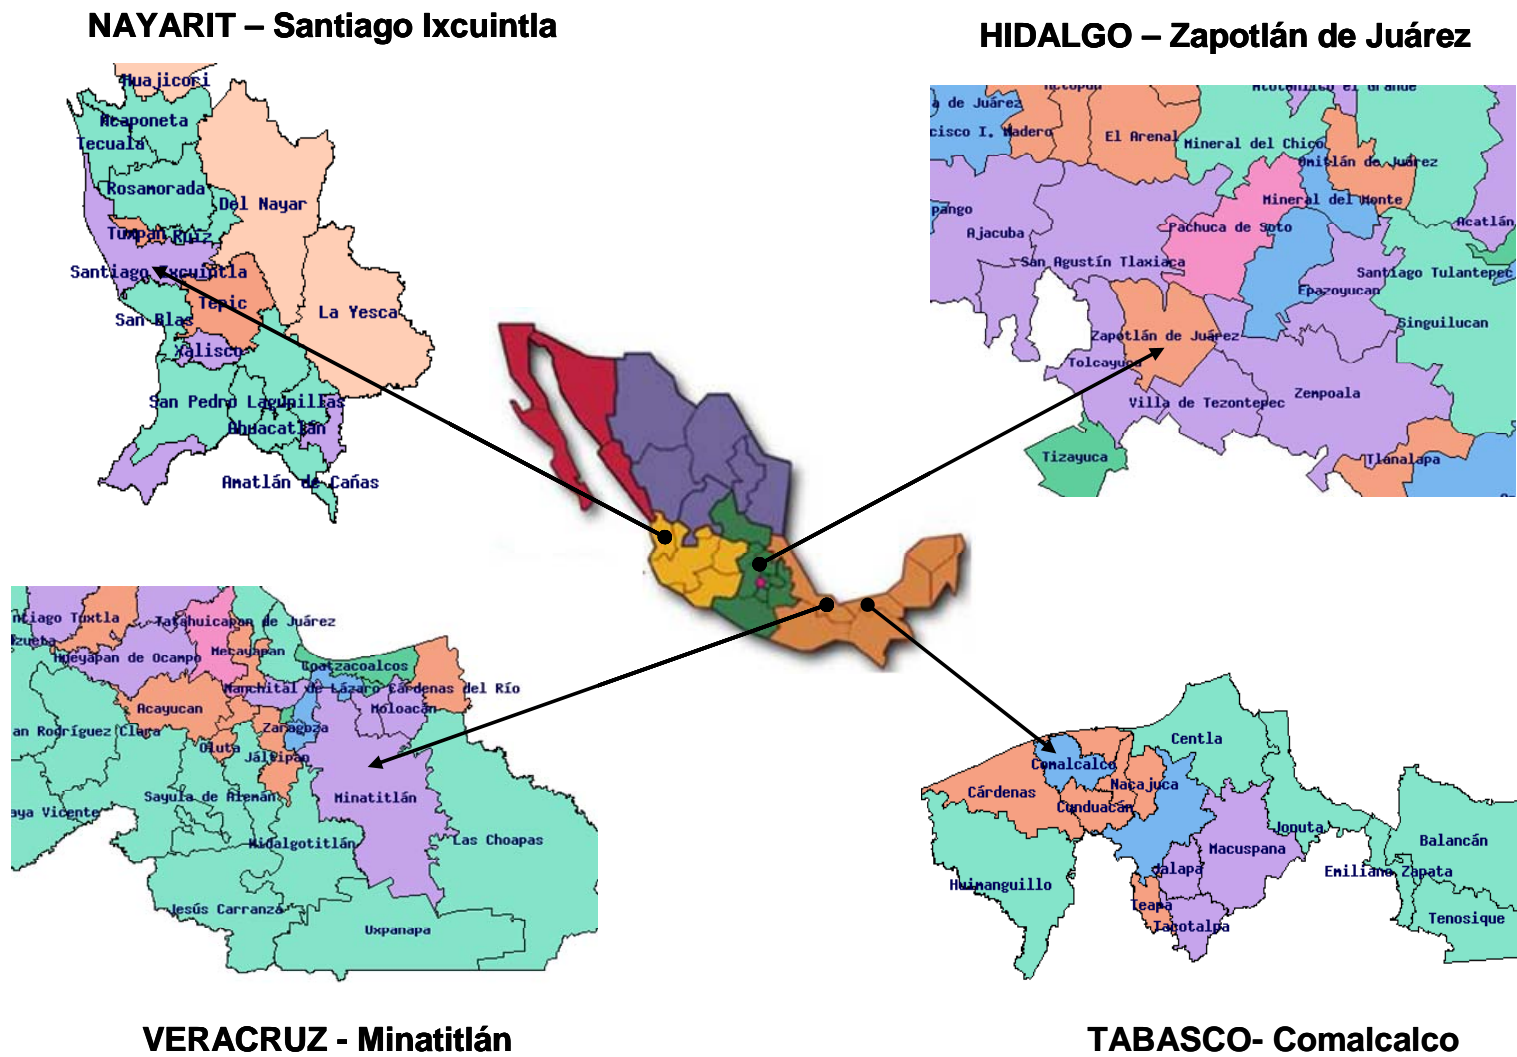


Figura 2.1 Localización geográfica de los sitios estudiados.

Geología superficial

La geología superficial de Comalcalco, indica la presencia general de depósitos cuaternarios de arenas, suelos residuales y arcillas superficiales ligera o moderadamente expansivas. En las zonas de lomerío se presentan los depósitos de arcillas y arenas, limitados perimetralmente por arcillas carbonatadas y lignitas, y éstas a su vez por arenas.

Los sitios estudiados presentan un relleno superficial (0.0 a 0.6 m) compuesto por arcilla y lentes de arena fina seguido por una secuencia estratigráfica de limo y arcilla de mediana plasticidad con lentes de materia orgánica y arcilla arenosa color ocre.

2.1.2 Minatitlán, Veracruz

En el estado se identifican siete provincias geológicas: Llanura Costera del Golfo Norte, Sierras de Chiapas y Guatemala, Sierra Madre Oriental, Sierra Madre del Sur, Cordillera Centroamericana y Eje Neovolcánico Transmexicano (a la que pertenece los sitios en estudio); cada una de ellas con características litológicas, estructurales y geomorfológicas propias y definidas (figura 2.1).

Geología superficial

La región es una penillanura donde el río Coatzacoalcos erosiona en sentido lateral, divagando por la extensa llanura de inundación formando cauces y meandros temporales, además de grandes extensiones de aguas someras y de pantanos.

La ciudad de Minatitlán y sus alrededores, pueden dividirse en dos zonas geológicas (Vieitez et al, 1970):

Zona alta: La mayor parte de la ciudad presenta alternancia de arenas limosas y capas de arcilla poco arenosa, que parecen ser suelos residuales de la formación Filisola (Mioceno). Subyaciendo estos depósitos se encuentran arenas poco limosas más compactas y arcillas de consistencia dura, consideradas como material de la formación Filisola no intemperizada.

Zona baja: La ciudad está rodeada por partes bajas donde prevalecen los depósitos aluviales de llanura de inundación, caracterizadas por arenas finas sueltas y arcillas blandas de alta plasticidad y alta compresibilidad, por turbas y otros suelos típicos de pantano.

2.1.3 Zapotlán de Juárez, Hidalgo

Zapotlán forma parte de la provincia fisiográfica conocida como Eje Neovolcánico Transmexicano (figura 2.1). Principalmente el estado se compone de roca ígnea extrusiva originada en el periodo cuaternario y en menor proporción, del periodo terciario. Presenta formaciones sedimentarias del Cenozoico y en mayor escala del Mesozoico en el periodo cretácico. Abundan los derrames y productos piroclásticos de composición andesítica, aunque existen numerosas unidades dacíticas y aún riodacíticas. Existen manifestaciones aisladas de vulcanismo riolítico reciente.

Geología superficial

La zona en estudio básicamente comprende una planicie aluvial con estratigrafía compuesta por materiales aluviales y granulares del Cuaternario intercalados con suelo arcilloso. Superficialmente se presenta una arcilla color café oscuro con poca arena y algo de caliche, subyaciendo por una serie de limos color café olivo claro con poca arena fina. Existen intercalaciones de ceniza volcánica y arena fina gris a diferentes profundidades.

2.1.4 Santiago Ixcuintla, Nayarit

El municipio de Santiago Ixcuintla forma parte de la provincia Sierra Madre Occidental (figura 2.1), compuesta por rocas ígneas extrusivas y hacia las partes más elevadas por rocas como tobas, ígneas, volcánicas y algunos derrames riolíticos de configuración pseudohorizontal, lo cual le confiere a esta sierra la apariencia de una gran meseta. La base de este sistema consta de sedimentos y metasedimentos, en algunos sitios muy plegados y de expresión morfológica abrupta. Estos materiales están cubiertos en su mayoría por las dos secuencias volcánicas que conforman el complejo montañoso de la Sierra Madre Occidental: la primera, que consiste en lomeríos y cerros escarpados expuestos en la zona de transición entre la propia Sierra madre Occidental y la provincia Llanura Costera del Pacífico; la segunda, principalmente de composición ácida, con cadenas montañosas de formas volcánicas escarpadas, valles intermontanos y cañones con perfiles en V, producto de fuertes emisiones piroclásticas.

Las principales estructuras geológicas están representadas por aparatos volcánicos, extensos derrames de lava, fallas y fracturas regionales que afectan a las rocas que han formado grandes fosas tectónicas por donde las corrientes de diversos ríos tienen un control en su curso.

Geología superficial

El estado presenta típicamente rocas ígneas (intrusivas y extrusivas) del Terciario, seguido de depósitos aluviales, palustres y litorales de edad cuaternaria que caracterizan a la provincia de la Llanura Costera del Pacífico. En menor cantidad están los depósitos sedimentarios clásicos del Terciario y Cuaternario y volcánicos de diferentes edades; y aun más escasos son los afloramientos de rocas sedimentarias marinas del Mesozoico.

Los suelos que conforman los sitios en estudio son de origen aluvial; su formación y conformación se vio afectada por su cercanía al Río Grande de Santiago localizado a 3 kilómetros del sitio, en donde las avenidas y desbordamientos inundaban estas tierras que originalmente eran destinadas a la agricultura. Se presenta una capa superficial (0.0 a 1.5 m) de arcilla de baja plasticidad que conformaron la parte superficial de un suelo destinado a la agricultura, seguido de arenas limosas (1.5 a 2.5 m), arena y gravas arenosas (2.5 a 7.5 m) de tipo andesítico con forma angulosa y subredondeadas en matriz de arena gruesa, finalizando hasta la profundidad explorada con gravas y gravillas, así como boleos en una matriz de limo y arena.

3.0 EXPLORACIÓN GEOTÉCNICA

Los trabajos de exploración geotécnica consisten en la realización de sondeos para efectuar ensayos de campo y recuperar muestras de suelo de los sitios estudiados. Con base en los resultados obtenidos de estos trabajos y de pruebas de laboratorio efectuadas en las muestras recuperadas, se definen los perfiles estratigráficos de los sitios estudiados, así como sus propiedades índice y mecánicas.

3.1 PROCEDIMIENTOS Y TÉCNICAS DE RECOLECCIÓN DE DATOS

Aún con los avances en los procedimientos de ensaye y las técnicas para monitorear las variables resultado de la exploración geotécnica, existe gran incertidumbre en la aplicación de metodologías estándar y al criterio de interpretación de las respuestas monitoreadas en sistemas de suelo. Asociada a la recolección de datos encontramos dos tipos de incertidumbre: la *aleatoria* debida a la naturaleza propia de la respuesta del suelo ante la prueba misma y la *epistémica*, originada por la falta de conocimiento del proceso que liga la causa con el efecto.

El incremento en la cantidad y calidad de las bases de datos pueden reducir la incertidumbre *epistémica*, pero en el caso de la incertidumbre *aleatoria* se requiere del conocimiento profundo sobre el tipo de prueba, condiciones de ensaye, limitaciones prácticas y criterios de interpretación de resultados. A continuación se describen brevemente aspectos referidos a las pruebas de campo dinámicas y penetración estándar (*Standard Penetration Test*, SPT), para establecer el marco teórico que permitirá la construcción de modelos empíricos de correlación entre los resultados de estas pruebas y propiedades del suelo de uso práctico.

3.1.1 Prueba de penetración estándar (SPT)

Los primeros registros de la prueba de Penetración Estándar SPT, se remontan a inicios de la década de los 20's con los trabajos del Coronel Chares R. Gow. A finales de los años veinte e inicio de los treinta, el procedimiento fue estandarizado por Harry Mohr para finalmente ser ajustado en 1947 por Karl Terzaghi.

El penetrómetro estándar es un tubo de dimensiones normalizadas que se hince a percusión. Consiste en un tubo de pared gruesa partido longitudinalmente, provisto en sus extremos de dos piezas roscadas; la pieza inferior es una zapata afilada de acero endurecido y la superior es la cabeza que sirve para unir el muestreador con la columna de barras huecas de acero que se utilizan para hincarlo hasta el fondo de la perforación. El tubo muestreador estándar tiene una longitud de 60 cm, diámetro interior de 3.5 cm y diámetro exterior de 5.0 cm; la longitud total del muestreador es de 75 cm; la cabeza tiene un conducto para la salida de azolves a través de una válvula esférica o una válvula de varilla (*CFE, 1980 Y ASTM D 1586-99*).




Figura 3.1 Diseño del tubo muestreador estándar (*ASTM D1586-99*)

Para hincar el tubo muestreador se usa una masa golpeadora de acero de 64 kg, con guía de caída libre de 75 cm y barras de perforación AW ó BW (4.44 y 5.40 cm de diámetro, 6.53 kg/m y 6.23 kg/m, respectivamente) y con un yunque de golpeo incorporado a la columna de barras. La masa golpeadora se levanta con un malacate de fricción. El penetrómetro estándar o tubo muestreador se hince 45 cm en el fondo de una perforación de 7.5 cm de diámetro mínimo con los impactos de la masa de 64 kg y caída libre de 75 +/- 1 cm. El procedimiento se puede realizar de forma manual, semi-automática o automática según la forma de elevar el martillo.

Se cuenta el número de golpes para hincar cada tramo de 15 cm. Se define como resistencia a la penetración estándar, al número de golpes N necesarios para hincar el penetrómetro los dos últimos tramos de 15 cm. Cuando debido a la dureza del suelo no se puede penetrar los 45 cm, se define N por extrapolación (*CFE, 1980*).

Schmertmann y Palacios (1979), investigaron sobre la energía potencial aplicada por el martillo al muestreador estándar y concluyen experimentalmente, que la energía impartida por el muestreador es inversamente proporcional al valor de N, hasta el umbral de 50 impactos, a partir del cual esta relación es directa, es decir, al

generar mayor energía de impacto se incrementa el valor de N (mayor número de golpes para penetrar 30 cm). En la prueba SPT para un valor N superior a 50 se utiliza la extrapolación.




Figura 3.2 Procedimiento general del mecanismo manual de la prueba SPT




Figura 3.3 Esquema del martillo de peso fijo, martillo cilíndrico o de dona y martillo de seguridad

Después del hincado se saca el penetrómetro a la superficie para recuperar la muestra alterada, que se coloca en un recipiente hermético, y se registra la información del hincado y clasificación del suelo. Con la interpretación de los resultados obtenidos de esta prueba se pueden definir:

- La estratigrafía del sitio.
- La compacidad relativa de suelos granulares y la consistencia de suelos cohesivos mediante correlaciones.
- Se obtienen muestras alteradas para su uso en laboratorio.

Los factores que afectan el valor de N están relacionados con las condiciones del equipo usado en la prueba, el procedimiento de montaje y operación. A continuación se discuten algunas correcciones que toman en cuenta la influencia de diversos agentes externos a la prueba para uniformizar resultados SPT en términos de N.

Factor de corrección por esfuerzo efectivo (C_N)

Al aumentar la profundidad de la prueba SPT se presenta un incremento de la presión del suelo sobre el tubo muestreador, por lo que a mayor profundidad se incrementa la energía potencial (mayor número de golpes) necesaria para efectuar la prueba SPT.

El factor de corrección C_N normaliza los valores de N medidos en el campo debido al incremento de esfuerzos efectivos con la profundidad. Este factor afecta directamente a N y crece de forma inversa a la profundidad de la prueba:

$$N_1 = C_N N$$

Donde:

N_1 : Número de golpes normalizado por esfuerzo vertical efectivo.

C_N : Factor de corrección por esfuerzo vertical efectivo.

N : Datos de campo de la prueba SPT.

Se han propuesto varias fórmulas para estimar el valor de C_N ; las más consistentes y representativas se muestran en la tabla 3.1 y se comparan gráficamente en la figura 3.4. Nótese que existe mayor congruencia entre las fórmulas propuestas en fechas más recientes y marcan estrechos valores de corrección, lo que da una idea de que el concepto se estandariza o tiende a ser único, independientemente del tipo

de material y condiciones de sitio o estructura matemática usada para la expresión del fenómeno.

Tabla 3.1 Representación matemática de los valores C_N propuestos más representativos

AUTOR	Factor de corrección C_N	UNIDADES DE σ'_v
Teng (1962)	$C_N = \frac{50}{10 + \sigma'_v}$	psi
Bazaraa (1967)	$C_N = \begin{cases} \frac{4}{1 + 2\sigma'_v} & \sigma'_v \leq 5 \\ \frac{4}{3.25 + 0.5\sigma'_v} & \sigma'_v > 1.5 \end{cases}$	Ksf
Peck, Hansen, and Thornburn (1974)	$C_N = 0.77 \log_{10} \frac{20}{\sigma'_v}$	tsf
Seed (1976)	$C_N = 1 - 1.25 \log_{10} \sigma'_v$	tsf
Tokimatsu and Yoshimi (1983)	$C_N = \frac{1.7}{0.7 + \sigma'_v}$	kg/cm ²
Liao and Whitman (1986)	$C_N = \sqrt{\frac{1}{\sigma'_v}}$	tsf o kg/cm ²

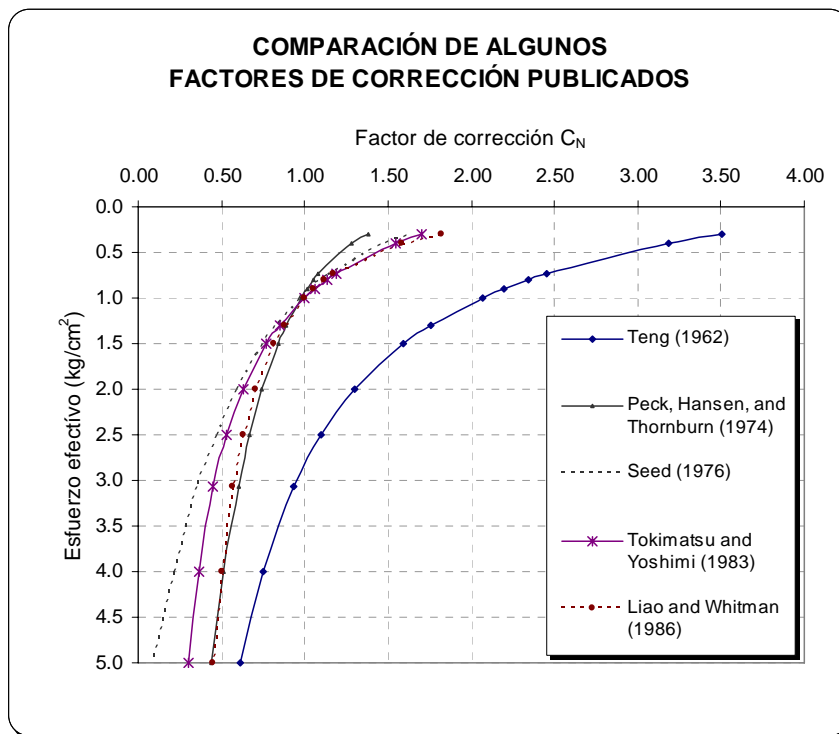


Figura 3.4 Comparación gráfica de C_N .

Factor de corrección por eficiencia (C_E)

Este factor se relaciona con la energía que imprime el martillo en caída libre al tubo muestreador estándar durante la ejecución de la prueba de penetración estándar, la cual se disipa principalmente por la presencia de fricción en los mecanismos de movimiento (poleas, engranajes, etc.) y excentricidad en la caída del martillo.

El factor C_E pretende normalizar los valores N medidos en el campo considerando la razón de energía entregada por el martillo al tubo muestreador respecto a la energía teórica.

La energía potencial teórica de la prueba SPT está dada por:

$$E_{teorica} = W * h$$

$$E_{teorica} = 64kg * 75cm = 4800kg - cm$$

La energía aplicada a la prueba difiere para diferentes partes del mundo, variando entre 40% y 90% de la energía teórica (Schmertmann 1976).

$$ER = \frac{E_{real}}{E_{teórica}}$$

donde: ER es la razón de energía entregada por el martillo al tubo muestreador estándar.

Como aplicación (especialmente a la evaluación del potencial de licuefacción de suelos) la razón ER se normaliza para un valor del 60%, propuesto por Seed et al (1984).

$$N_{60} = \frac{ER_r}{60} N$$

donde: ER_r es la razón ER normalizada para el 60%.

El valor ER_r se puede obtener mediante calibraciones (*ASTM D4633*) o asumiendo un valor típico para cada región según el tipo de equipo utilizado (ver tablas 3.2 y 3.3).

En México, Colombia y algunos países latinoamericanos es frecuente el uso del martillo de seguridad; desafortunadamente no se cuentan con mediciones de su

eficiencia. Es común determinar el factor C_E en función del tipo de martillo usado en la prueba SPT (ver figura 3.3), según se indica en la tabla 3.3.

Tabla 3.2: Valores típicos de ER_r (Skempton, 1986; Clayton, 1990)

PAÍS	TIPO DE MARTILLO	MECANISMO ELEVADOR	$ER_r(\%)$	$C_E = ER_r(\%)/60$
USA	De seguridad Cilíndrico	2 giros de la sogá en el torno	55	0.92
			45	0.75
Japón	Automático Cilíndrico	2 giros de la sogá en el torno	78-85	1.30-1.42
			65-67	1.08-1.12
China	Automático Cilíndrico	Transportador o relevador Manual	60	1.00
			55	0.92
UK	Automático	Transportador o relevador	73	1.22

Tabla 3.3. C_E típicos según la relación de energía dependiendo del tipo de martillo usado en la prueba SPT (Youd e Idriss, 1997)

TIPO DE MARTILLO	FACTOR DE CORRECCIÓN C_E
Martillo cilíndrico	0.5-1.0
Martillo de seguridad	0.7-1.2
Martillo automático cilíndrico	0.8-1.3

Factores de corrección adicionales

Un aumento en el diámetro de perforación disminuye el confinamiento *in situ* y aunque en arcillas, debido a la cohesión, no se generan cambios apreciables en la obtención de N y se puede omitir el efecto, en arenas se pueden obtener valores relativamente bajos.

El peso y la rigidez del sistema de varillaje generan efectos en la obtención del valor N . Al aumentar la longitud de este sistema, la razón de la energía entregada al muestreador estándar respecto a la energía teórica aumenta con la profundidad.

Un muestreador estándar con guías requiere aumentar el número de impactos en aproximadamente 20% respecto al muestreador estándar sin guías, aumentando en arenas densas.

Variables como el diámetro de perforación en la prueba, la longitud del varillaje y el tipo de muestreador son factores que afectan la medición de N en la prueba SPT (ver tabla 3.4.).

Tabla 3.4 Correcciones de la prueba SPT modificados por Skempton (1986) y listados por Robertson y Wride (1998)

FACTOR DE CORRECCIÓN	VARIABLE DEL EQUIPO	CORRECCIÓN
Diámetro de perforación C_B	65 – 115 mm	1.00
	150 mm	1.05
	200 mm	1.15
Longitud del varillaje C_R	3 - 4 m	0.75
	4 - 6 m	0.85
	6 - 10 m	0.95
	10 - 30 m	1.0
	> 30 m	<1.0
Tipo de muestreador C_S	Muestreador estándar	1.0
	Muestreador sin guías	1.1 – 1.3

Finalmente el valor normalizado de la penetración estándar será resultado de multiplicar el valor N obtenido en el campo por los factores de corrección correspondientes:

$$(N_1)_{60} = C_N \cdot C_E \cdot C_B \cdot C_S \cdot C_R \cdot N$$

Como ejemplo práctico y para ilustrar el efecto que tienen estos valores de corrección sobre N , se muestra el resultado de una prueba SPT $N=35$ obtenido profundidad de 10 m de un estrato de suelo con un peso específico de 1.7 ton/m^3 y las características que se detallan en la tabla 3.5. El valor de N corregido (N_1) será:

$$(N_1)_{60} = 0.77 \cdot 0.8 \cdot 1.05 \cdot 0.85 \cdot 1.0 \cdot N$$

$$(N_1)_{60} = 0.55N$$

Tabla 3.5 Ejemplo para la determinación de los factores de corrección en la prueba SPT

FACTOR DE CORRECCIÓN	DATOS DEL EJEMPLO	CORRECCIÓN
Por esfuerzo efectivo (Liao and Whitman, 1986) C_N	$N = 10$ golpes $Z = 10$ m $\gamma = 1.7 \text{ ton/m}^2$	$C_N = \frac{1}{\sqrt{1.7}} = 0.77$
Por eficiencia C_E	Martillo de seguridad	$(0.7 - 1.2) \cdot 0.8$
Diámetro de perforación C_B	150 mm	1.05
Longitud del varillaje C_R	4 - 6 m	0.85
Tipo de muestreador C_S	Muestreador estándar	1.0

Aplicando los factores de corrección, en este caso se llega a reducir hasta un 45% del valor obtenido de N , es decir el nuevo valor corregido $(N_1)_{60}$ será aproximadamente de 19 golpes. Generalmente en las pruebas SPT no hay reporte de todas las variables que afectan los resultados de la prueba (diámetro de perforación, longitud de varillaje, tipo de equipo utilizado), por lo tanto, los factores C_B , C_R y C_S no son usualmente considerados. En el ejemplo anterior entonces,

$$N_1 = 0.77N$$

El valor de N sería "castigado" en un 23% ($N_1 = 27$) y no un 45% ($(N_1)_{60} = 19$) que resulta de considerar todos los factores de corrección, es decir, si se conoce o detalla la prueba cabalmente, el suelo analizado resulta ser más blando que en el caso donde ésta se desconozca, lo cual muestra un alto grado de incertidumbre e indeterminación que acompañan la aplicación de estos factores.

3.1.2 Medición de la velocidad de propagación de ondas en campo

Fuera del objetivo de ésta tesis se encuentra la descripción y evaluación de las pruebas de campo para medir V_s ; sin embargo, y para hacer de éste trabajo un texto autosostenible, se anexa (anexo 2) una breve introducción de dicho tema.

3.2 CONCLUSIONES

La prueba de penetración estándar se encuentra contaminada en alto grado por *incertidumbre e indeterminación* lo cual se refleja en el número y naturaleza de los factores de corrección al valor raíz que arroja la prueba (N). Como se demuestra en el ejemplo de aplicación (ver tabla 3.5), cambios mínimos en los valores de los parámetros de ajuste o bien, la deficiencia en la descripción de la prueba y equipo, pueden originar cambios sustanciales en el valor de N y por lo tanto, al valor de la propiedad correlacionada.

Esta discrepancia se debe a que estos factores de corrección se derivan de la descomposición de los sucesos (tarea obligada por la linealidad de las herramientas matemáticas de análisis), obviando la naturaleza de la estructura (fenómeno) y el efecto que todos en conjunto alcanzan, siendo el modelo de un sistema, así definido, divergente con el comportamiento monitoreado para efectos individuales.

4.0 REDES NEURONALES

4.1 INTRODUCCIÓN

El cerebro es un procesador de información capaz de procesar a gran velocidad grandes cantidades de información procedentes de los sentidos, combinarla o compararla con información almacenada y dar respuestas adecuadas, incluso en situaciones nuevas. Logra discernir un susurro en una sala ruidosa, distinguir una cara en una calle mal iluminada o leer entre líneas en una declaración política; pero lo más impresionante de todo es su capacidad de aprender a representar la información necesaria para desarrollar tales habilidades sin instrucciones explícitas para ello (ver anexo 4.1 Redes Neuronales Biológicas).

Aún se ignora mucho sobre la forma en que el cerebro *aprende* a partir de la información. Se han desarrollado modelos que tratan de mimetizar tales habilidades, como las llamadas redes neuronales ó modelos de computación conexionista (otras denominaciones son computación neuronal y procesamiento distribuido paralelo PDP), en los que se intenta en primer lugar, la deducción de los rasgos o características esenciales de las neuronas y sus conexiones, y en segundo lugar, la implementación del modelo en una computadora de forma que se pueda simular un comportamiento específico. Estos modelos son idealizaciones burdas de las redes neuronales biológicas, en muchos casos de dudosa plausibilidad neurofisiológica, pero resultan interesantes por su ventajosa capacidad de aprendizaje computacional.

4.1.1 El paradigma de la computación conexionista

La inteligencia artificial (IA), entendida de manera general como el modelado y la simulación de las actividades cognitivas complejas (percepción, memoria, solución de problemas, etc.) que caracterizan a los organismos avanzados, y en particular a los seres humanos, se separó casi desde su inicio en dos ramas bien diferenciadas (Waltz & Feldman 1988): por un lado se trató de modelar la actividad racional mediante sistemas formales de reglas y manipulación simbólica (generalmente mediante sistemas lógicos), constituyendo quizás la rama más conocida de la IA, y a la que podríamos denominar simbólico - deductiva (se postulan una serie de reglas y el sistema resuelve los problemas realizando deducciones sobre las reglas existentes); y por otro lado se desarrollaron modelos computacionales inspirados en

las redes neuronales biológicas, denominados inductivos o subsimbólicos, que extraen la información necesaria para resolver un problema de un conjunto de ejemplos, sin necesidad de indicarle las reglas necesarias para resolverlo.

El progreso de las neurociencias conduce a una comprensión cada vez mayor de la estructura física y lógica del cerebro; los avances tecnológicos ofrecen recursos cada vez mayores para representar estructuras más complejas, realizar cálculos a gran velocidad y en paralelo, apoyando y fomentando así la investigación en el campo de los modelos conexionistas.

Los modelos conexionistas se originan con la definición de la neurona formal dada por McCulloch y Pitts en 1943 como un dispositivo binario con varias entradas y salidas. D.O. Hebb introdujo en 1949 (Hebb, 1949) dos ideas fundamentales que han influido de manera decisiva en el campo de las redes neuronales: la idea de que una percepción o un concepto se representa en el cerebro por un conjunto de neuronas activas simultáneamente; y la idea de que la memoria se localiza en las conexiones entre las neuronas (sinapsis). Las hipótesis de Hebb, basadas en investigaciones psicofisiológicas, describen de manera intuitiva el modo en que las neuronas memorizan la información y se plasman sintéticamente en la famosa regla de aprendizaje de Hebb (también conocida como regla del producto).

4.2 ESTRUCTURA DE UN MODELO NEURONAL

Las neuronas biológicas se modelan computacionalmente mediante unidades de proceso llamados "nodos". Cada unidad de proceso se compone de una red de conexiones de entrada, una función de red (de propagación), encargada de computar la entrada total combinada de todas las conexiones, un núcleo central de proceso, encargado de aplicar la función de activación, y la salida, por dónde se transmite el valor de activación a otras unidades.

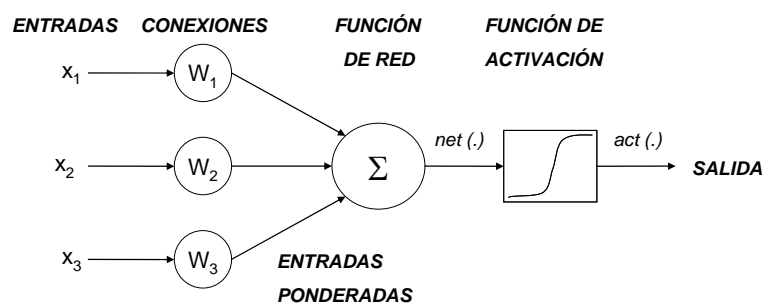


Figura 4.1 Unidad de proceso típica.

La función de red es típicamente el sumatorio ponderado, mientras que la función de activación suele ser alguna función de umbral o una función sigmoideal.

4.2.1 Función de propagación o de red

Biológicamente, se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con ellas mismas. En el caso de las RNA, se puede considerar que el conocimiento se encuentra representado en los *pesos* de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. Puede decirse que se aprende modificando los valores de los pesos de la red. La modificación del comportamiento inducido por la interacción con el entorno y como resultado de experiencias, conducen al establecimiento de nuevos modelos de respuesta a estímulos externos.

En la fase de aprendizaje se produce el ajuste de los parámetros libres de la red mediante un proceso de entrenamiento llevado a cabo debido a la modificación de los pesos sinápticos siguiendo una cierta regla de aprendizaje, construida a partir de la optimización de una función de error, que mide la eficacia actual de la operación de la red.

Las conexiones que unen las neuronas que forman una RNA tienen asociado un peso que es el que hace que la red adquiera conocimiento. Consideremos y_i como el valor de salida de una neurona i en un instante dado. Una neurona recibe un conjunto de señales que le dan información del estado de activación de todas las neuronas con las que se encuentra conectada. Cada conexión (sinápsis) entre la neurona i y la j está ponderada por un peso w_{ji} . Normalmente, como simplificación, se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona net_j , es la suma de cada señal individual por el valor de la sinapsis que conecta ambas neuronas:

$$net_j = \sum_i^N w_{ji} * net_i$$

Esta regla muestra el procedimiento a seguir para combinar los valores de entrada a una unidad con los pesos de las conexiones que llegan a esa unidad y es conocida como *regla de propagación*, la cual calcula el valor de base o entrada total a la unidad, generalmente como simple suma ponderada de todas las entradas recibidas, es decir, de las entradas multiplicadas por el peso o valor de las conexiones. Equivale a la combinación de las señales excitatorias e inhibitorias de las neuronas biológicas.

En la etapa inicial del aprendizaje es importante definir los algoritmos existentes:

Dot Product: Esta función define la suma de pesos de entrada más un valor que determina cada peso según la influencia relativa

Distance imput function (L1): Calcula la distancia entre dos vectores, obteniendo automáticamente la distancia que existe entre el elemento de entrada y el objeto en proceso. Es útil al usar la regla general de regresión (*RE-Gression*).

Back Propagation (BP): Es un algoritmo de descenso que ajusta los pesos iterativamente hasta llegar a un mínimo error de la función, es decir cuando se minimice la diferencia entre valores esperados y valores computados. Su ventaja no es productiva en redes grandes ya que su velocidad de convergencia es lenta y puede detenerse en un mínimo local.

Quick propagation (QP): Es un algoritmo de aprendizaje dirigido a minimizar el tiempo requerido para encontrar un conjunto de pesos apropiado. Esta regla evalúa la tendencia preliminar de pesos y actualizaciones que después puede ser perfeccionada

Conjugate Gradient (CG): Es un método numérico clásico que se encarga de minimizar funciones arbitrarias cuando la derivada de ellas está disponible. Aplicarla a los métodos neuronales puede llegar a ser una técnica excelente de aprendizaje, usando la pendiente de los pesos para escoger la dirección inicial de búsqueda; el método seleccionado para trabajos NN fue propuesto por *Heatness-Stiffel (Johansson et al, 1990)*.

Levenberg-Marquard (LV): Este algoritmo contiene procedimientos heurísticos para facilitar transiciones entre el método de descenso y el método de Gauss Newton (Hagan y Menhaj, 1994). El método de Gauss Newton tiene la característica de converger al mínimo de una función de energía cuadrática en una sola iteración del algoritmo. El procedimiento LV es uno de los algoritmos de mayor convergencia disponible para el entrenamiento de redes neuronales pequeñas de una salida, siendo esta una limitación al igual que el alto requerimiento de memoria.

General Regression (GR): Es una regla de aprendizaje memoria – base enfocada en la estimación de funciones de densidad de probabilidad. Ofrece tiempos de entrenamiento rápidamente, puede modelar funciones no lineales y se ha mostrado buen funcionamiento cuando hay ruido en una base de datos bastante amplia (Specht, 1992). A cada punto (x, y) es asignado un peso y los valores de Y son

evaluados para un X , siendo computados, midiendo la influencia que cada valor Y trae para afectar X .

4.2.2 Función de activación

En un principio se pensó que las neuronas usaban una función de umbral, es decir, que permanecían inactivas y se activaban sólo si la estimulación total superaba cierto valor límite; esto se puede modelar con una función escalón: la más típica es el escalón unitario: la función devuelve 0 por debajo del valor crítico (umbral) y 1 por encima.

Después se comprobó que las neuronas emitían impulsos de actividad eléctrica con una frecuencia variable, dependiendo de la intensidad de la estimulación recibida, y que tenían cierta actividad hasta en reposo, con estimulación nula. Estos descubrimientos llevaron al uso de funciones no lineales con esas características, como la función sigmoideal, con un perfil parecido al escalón de una función de umbral, pero continua.

La función de activación es quizás la característica principal o definitoria de las neuronas, la que mejor expresa el comportamiento de la misma. Se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total. Se usan diferentes tipos de funciones, desde funciones simples de umbral a funciones no lineales:

- Función escalón
- Función lineal y mixta
- Sigmoideal
- Función gaussiana

La *función escalón* se asocia a neuronas binarias en las cuales cuando la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1, si es menor, la activación es 0 (ó -1). Las redes formadas por este tipo de neuronas son fáciles de implementar en hardware, pero sus capacidades están limitadas, siendo poco útil implementar esta función en el trabajo de tesis ya que no se busca una red que arroje salidas de tipo binario.

La *función lineal o mixta* corresponde a la función $F(x) = x$. En las neuronas con función mixta si la suma de las señales de entrada es menor que un límite inferior, la activación se define como 0 (ó -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entrada está comprendida entre

ambos la activación se define como una función lineal de suma de las señales de entrada.

Con la *función sigmoideal*, para la mayoría de los valores del estímulo de entrada, el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace posible que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide.

Para la *función gaussiana*, el centro y anchura puede ser adaptado, lo cual las hace más adaptativas que las funciones sigmoideales.

4.2.3 Función de salida

Calcula la salida de la neurona en función de la activación de la misma, aunque normalmente no se aplica más que la función identidad, y se toma como salida el valor de activación. El valor de salida cumpliría la función de la tasa de disparo en las neuronas biológicas.

Función de activación

Se suele distinguir entre funciones lineales, en las que la salida es proporcional a la entrada; funciones de umbral, en las cuales la salida es un valor discreto (típicamente binario 0/1) que depende de si la estimulación total supera o no un determinado valor de umbral; y funciones no lineales, no proporcionales a la entrada.

Casi todos los avances recientes en conexionismo se atribuyen a arquitecturas multicapa que utilizan funciones de activación no lineales como una función de umbral, una gaussiana ó en la mayoría de los casos una función sigmoideal (Quinlan 1991). El problema de trabajar con modelos no lineales radica en que son difíciles de describir en términos lógicos o matemáticos convencionales (Rumelhart & McClelland 1986)).

La función de activación sigmoideal o logística es probablemente la más empleada en la actualidad.

$$act_j(net_j) = \frac{1}{(1 + e^{-net_j / \sigma})}$$

Se trata de una función continua no lineal con bastante plausibilidad fisiológica. La función sigmoideal posee un rango comprendido entre 0 y 1. Esto, aplicado a las unidades de proceso de una red neuronal artificial significa que, sea cual sea la entrada, la salida estará comprendida entre 0 y 1.

Esta función depende del parámetro s , que usualmente toma el valor 1. La salida de una unidad vale 0.5 cuando la entrada es nula, esto significa que la unidad tiene cierta actividad aún en ausencia de estimulación. Al aumentar la estimulación la unidad aumenta su activación, y la disminuye si la estimulación es inhibitoria, de forma parecida a como se comportan las neuronas reales.

La función sigmoideal permite el acomodo de señales muy intensas sin producir saturación, admite señales débiles sin excesiva atenuación y es fácilmente derivable, ya que:

$$f'(x) = f(x) \cdot (1 - f(x))$$

La principal limitación de esta función es que no sirve para expresar polaridades, da siempre valores positivos. Una función alternativa con cualidades parecidas pero con un rango entre -1 y 1 es la función tangente hiperbólica. Desde un punto de vista fisiológico, el signo negativo se puede interpretar como una disminución de la tasa de disparo de una neurona por debajo de la tasa de disparo en reposo.

4.3 ESTRUCTURA Y FORMAS DE INTERCONEXIÓN

Para diseñar una red se debe establecer la manera en que estarán conectadas unas unidades con otras y determinar adecuadamente los pesos de las conexiones. Lo más usual es disponer las unidades en forma de capas, pudiéndose hablar de redes de una, de dos o de más de dos capas (redes multicapa). En algunos trabajos (por ejemplo, Wassermann, 1989), se cuentan sólo aquellas capas que poseen conexiones de entrada modificables; según este criterio la capa de entrada no contaría como tal.




Figura 4.4 Modelo de red en cascada de tres capas.

Aunque inicialmente se desarrollaron redes de una sola capa, lo más usual es disponer tres o más capas: la primera capa actúa como almacenamiento de entrada, acumulando la información bruta suministrada a la red ó realizando un sencillo pre-proceso de la misma (capa de entrada); otra capa actúa como interfaz ó almacenamiento de salida, acumulando la respuesta de la red para que pueda ser leída (capa de salida); y las capas intermedias, principales encargadas de extraer, procesar y memorizar la información (capas ocultas).

4.3.1 Topología

Consiste en la organización de las neuronas en la red formando capas ó agrupaciones de neuronas más o menos alejadas de la entrada y salida de la red. Los parámetros fundamentales para el diseño de la topología son: El número de capas, número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

Además del número de capas de una red, en función de cómo se interconectan unas capas con otras, podemos hablar de redes recurrentes (feed-back) y redes no recurrentes o redes en cascada (feed-forward). En las redes en cascada la información fluye unidireccionalmente de una capa a otra (desde la capa de entrada a las capas ocultas y de éstas a la capa de salida), y además, no se admiten conexiones intracapa. En las redes recurrentes la información puede volver a lugares por los que ya había pasado, formando bucles, y se admiten las conexiones intracapa (laterales), incluso de una unidad consigo misma.

Las conexiones entre una capa y otra pueden ser totales, es decir, cada unidad se conecta con todas las unidades de la capa siguiente, o parciales, en las cuales una unidad se conecta con sólo algunas de las capas de la unidad siguiente, generalmente siguiendo algún patrón aleatorio o pseudo-aleatorio (por ejemplo, mediante algoritmos genéticos).

Desde una aproximación temporal se puede distinguir además entre conexiones sin retardo y conexiones con retardo, lo que permite modelar aspectos dinámicos.

4.4 MODO DE OPERACIÓN

En cualquier red neuronal se distinguen las fases o proceso de aprendizaje, opcionalmente una fase de prueba o *test*, y la fase de aplicación.

El aprendizaje consiste en la presentación de patrones a la red, y la subsiguiente modificación de los pesos de las conexiones siguiendo alguna regla de aprendizaje que trata de optimizar su respuesta, generalmente mediante la minimización del error ó la optimización de alguna "función de energía". El modo de aprendizaje más sencillo consiste en la presentación de patrones de entrada junto a los patrones de salida deseados (targets) para cada patrón de entrada, por eso se llama aprendizaje supervisado. Si no se le presentan a la red los patrones de salida deseados, diremos que se trata de aprendizaje no supervisado, ya que no se le indica a la red que resultados debe dar, sino que se le deja seguir alguna regla de auto-organización. Un tercer tipo de aprendizaje, a medio camino entre los anteriores, es el llamado aprendizaje reforzado, en este caso el supervisor se limita a indicar si la salida ofrecida por la red es correcta o incorrecta, pero no indica que respuesta debe dar.

Cualquiera que sea el tipo de aprendizaje usado, una característica esencial de la red es la regla de aprendizaje usada, que indica como se modifican los pesos de las conexiones en función de los datos usados en la entrada, es decir, de la historia de aprendizaje de la red. Por ejemplo, entre los algoritmos de aprendizaje supervisado, la regla delta generalizada, modifica los pesos realizando en cada ciclo de aprendizaje un incremento los pesos proporcional a la tasa de variación del error respecto al peso, en sentido negativo.

El aprendizaje requiere la presentación repetida de un número relativamente amplio de ejemplos de entrenamiento hasta lograr una respuesta satisfactoria del sistema (según la medida de error o función de energía utilizada).

Es usual disponer de un conjunto de datos distintos a los usados para el entrenamiento, para los cuales se conoce la respuesta correcta, y se usan como *test*, evaluando con ello si la red responde adecuadamente frente a datos distintos a los usados durante el aprendizaje (generalización), si es así, se considera que la red funciona bien y se puede pasar a la fase de aplicación (recall), es decir, se puede usar para obtener un resultado frente a datos totalmente nuevos para los que no se conoce la respuesta correcta.

Aunque la capacidad de aprendizaje es esencial y casi definitoria de lo que sería una RNA, se han desarrollado modelos que no requieren modificar los pesos de las conexiones, sino que son precalculados y pre-establecidos antes de presentarle patrones a la red, como en las redes de Hamming y en redes de Hopfield.

El aprendizaje de una red se puede producir de tres formas:

- Aprendizaje supervisado: consiste en introducir una serie de patrones de entrada a la red y a su vez mostrar la salida que se quiere tener. La red es capaz de ajustar los pesos de las neuronas de forma que a la presentación posterior de esos patrones de entrada la red responde con salida memorizada.
- Aprendizaje no supervisado: se presentan los patrones de entrada a la red y ésta los clasifica en categorías según sus rasgos más sobresalientes.
- Aprendizaje auto supervisado: la propia red corrige los errores en la interpretación empleando una realimentación.


Aprendizaje supervisado

Ya sabemos que en el aprendizaje supervisado se presentan a la red una serie de patrones de entrada junto a los patrones de salida deseados. El aprendizaje consiste en la modificación de los pesos de las conexiones en el sentido de reducir la discrepancia entre la salida obtenida y la deseada. Los pasos generales a seguir por este algoritmo son los siguientes:

- Aleatorizar los pesos de todas las conexiones (preferiblemente con valores pequeños).
- Seleccionar un par de entrenamiento, es decir, un patrón de entrada y el patrón de salida deseado (target) correspondiente.
- Presentar el patrón de entrada y calcular la salida de la red mediante las operaciones usuales: sumatoria de las entradas ponderadas, función de activación y transferencia a la siguiente capa, hasta llegar a la capa de salida. (Inicialmente obtenemos salidas aleatorias, ya que los pesos de las conexiones son aleatorios).
- Cálculo del error o discrepancia entre la salida obtenida y la deseada. El error (función objetivo) se suele definir como la suma de los cuadrados de las diferencias entre las salidas reales obtenidas y las deseadas, promediado para todas las unidades de salida y todos los patrones de entrenamiento. Si el error es menor de cierto criterio fijado de antemano, incrementar el número de ejemplos correctos; si todos los ejemplos se han clasificado correctamente, finalizar, sino continuar.
- Aplicar la regla de aprendizaje, es decir, ajustar los pesos de las conexiones tratando de disminuir el error, generalmente mediante el cálculo de tasas de variación o gradientes del error; por eso hablamos de reglas de aprendizaje por gradiente descendiente. Para reducir el error habrá que modificar los pesos de las conexiones, en proporción a la tasa relativa de variación del error con respecto a la variación del peso, o sea, la derivada del error

respecto al peso, EP (error respecto al peso). Una forma de calcular el EP sería perturbar levemente un peso y observar como varía el error, pero no resultaría eficiente si trabajamos con muchas conexiones (este es el fundamento de algunos métodos estadísticos comentados en otro apartado).

El aprendizaje supervisado se usa fundamentalmente en los asociadores de patrones o memorias hetero-asociativas. Al principio se aplicó el aprendizaje supervisado en redes con una sola capa de conexiones, como el Perceptrón (Roseblatt, 1962).



En los primeros perceptrones, con salida binaria, el aprendizaje era tan sencillo como sumar o restar las entradas a los pesos de las conexiones, dependiendo de si la salida incorrecta era un 0 o un 1 respectivamente.

Pronto se elaboró una generalización para salidas continuas, conocida como regla delta: La modificación de cada peso se calcula sumándole la discrepancia entre la salida deseada y la obtenida, multiplicado por la entrada y por un coeficiente de aprendizaje:

$$w(t+1) = w(t) + \eta \cdot x_i \cdot (\text{Salida deseada} - \text{Salida calculada})$$

Donde:

$w(t)$: Vector de pesos en el instante t

$w(t+1)$: Vector de pesos en el instante $t+1$

η : Tasa de aprendizaje.

En los años 80 se popularizó el algoritmo de retropropagación y la regla delta generalizada, que permiten entrenar redes no lineales de dos o más capas, mediante la propagación hacia atrás (hacia las capas ocultas). La mayoría de las reglas empleadas actualmente en el aprendizaje supervisado son modificaciones de la regla delta generalizada. Se calcula que el 80% de las aplicaciones

tecnológicas en redes neuronales se fundamentan en el algoritmo de retropropagación y en alguna versión de la regla delta generalizada.

4.5 VENTAJAS DE LOS MODELOS NEURONALES

A continuación se describen algunas de las ventajas de los modelos neuronales:

- *Aprendizaje inductivo:* No se le indican las reglas para dar una solución, sino que extrae sus propias reglas a partir de los ejemplos de aprendizaje, modifican su comportamiento en función de la experiencia. Esas reglas quedan almacenadas en las conexiones y no representadas explícitamente como en los sistemas basados en conocimiento (simbólico-deductivos)
- *Generalización:* Una vez entrenada, se le pueden presentar a la red datos distintos a los usados durante el aprendizaje. La respuesta obtenida dependerá del parecido de los datos con los ejemplos de entrenamiento
- *Abstracción o tolerancia al ruido:* Las redes neuronales artificiales son capaces de extraer o abstraer las características esenciales de las entradas aprendidas, de esta manera pueden procesar correctamente datos incompletos o distorsionados.
- *Procesamiento paralelo:* las neuronas reales trabajan en paralelo; en el caso de las redes artificiales es obvio que si usamos un solo procesador no podrá haber proceso paralelo real; sin embargo hay un paralelismo inherente, lo esencial es que la estructura y modo de operación de las redes neuronales las hace especialmente adecuadas para el procesamiento paralelo real mediante multiprocesadores (se están desarrollando máquinas específicas para la computación neuronal).
- *Memoria distribuida:* el conocimiento acumulado por la red se halla distribuido en numerosas conexiones, esto tiene como consecuencia la tolerancia a fallos: una red neuronal es capaz de seguir funcionando adecuadamente a pesar de sufrir lesiones con destrucción de neuronas o sus conexiones, ya que la información se halla distribuida por toda la red; sin embargo, en un programa tradicional, un pequeño fallo en cualquier punto puede invalidarlo todo y dar un resultado absurdo o no dar ningún resultado.

5.0 ANÁLISIS DE REGRESIÓN

El término *regresión* fue introducido por Galton en 1889 (GALTON, 1889). En un Análisis de Regresión Simple se considera una variable de respuesta o dependiente (en esta investigación, la velocidad de onda cortante V_s) y una variable explicativa o independiente (valores de N obtenidos con la prueba SPT). El propósito es obtener una función sencilla de la variable explicativa que sea capaz de describir lo más certeramente posible el comportamiento de la variable dependiente, usando como criterio de selección aquella representación que presente una mínima variación residual; es decir, que describa la variable dependiente con la menor diferencia entre los valores observados y predichos.

5.1 MODELOS DE REGRESIÓN

La relación entre las dos variables de interés, (variables dependiente e independiente) en el plano que forman ambas, se puede expresar por medio de relaciones del tipo lineal y no lineal, como se representan en la figura 5.1:

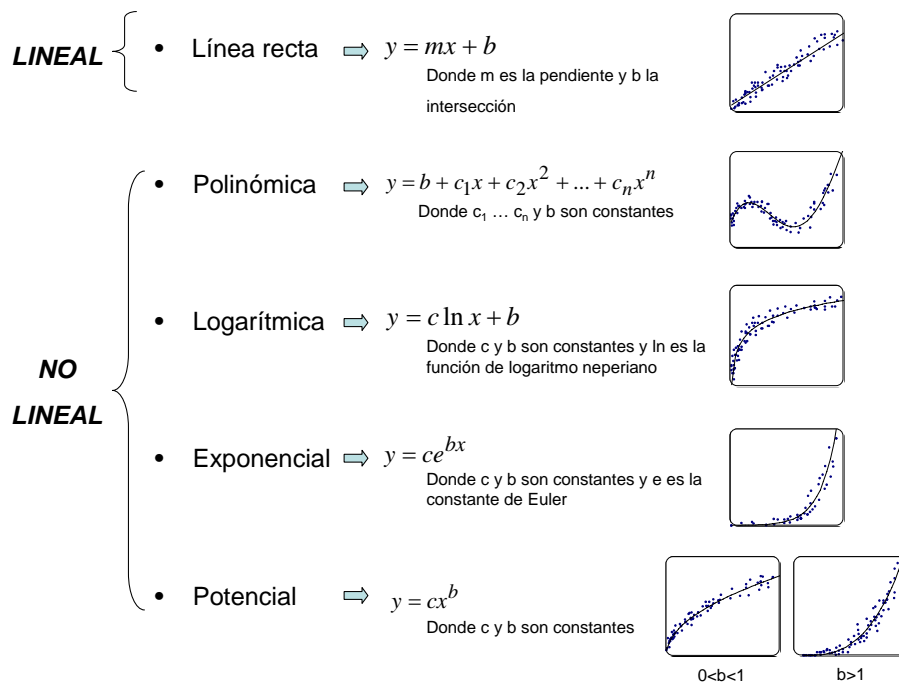


Figura 5.1 Tipos de representación para la línea de ajuste en una regresión

El coeficiente de determinación R^2

Al establecer una curva de regresión a la *nube* de observaciones, es importante disponer de una medida que determine la “bondad” del ajuste realizado. El coeficiente de determinación R^2 es llamado también índice de correlación y representa la proporción de la variación total en la variable dependiente que se explica por, o se debe a, la variación de la variable independiente.

La desviación total de la variable dependiente $(Y - \bar{Y})$ es igual a la desviación explicada por el modelo de regresión $(\hat{Y} - \bar{Y})$ sumada a la desviación inexplicada $(Y - \hat{Y})$:

$$(Y - \bar{Y}) = (\hat{Y} - \bar{Y}) + (Y - \hat{Y}) \quad (5.1)$$

donde,

Y : Variable dependiente V_s .

\bar{Y} : Promedio aritmético de la variable V_s .

\hat{Y} : Valor V_s obtenido del modelo de regresión.

De igual forma resulta ser válido para la suma de los cuadrados (SC) de estas desviaciones:

$$(Y - \bar{Y})^2 = (\hat{Y} - \bar{Y})^2 + (Y - \hat{Y})^2 \quad (5.2)$$

Este factor se relaciona con la proporción de variabilidad total de la variable dependiente (suma total de los cuadrados) respecto a su medida que es explicada por el modelo de regresión:

$$R^2 = \frac{\text{suma de cuadrados explicados por la regresión}}{\text{suma de cuadrados total}} \quad (5.3)$$

El factor R^2 es adimensional y se puede calcular para cualquier ecuación de regresión; además, es la medida de correlación más ampliamente usada.

$$R^2 = \frac{\sum(Y - \bar{Y})^2 - \sum(Y - \hat{Y})^2}{\sum(Y - \bar{Y})^2} = \frac{\sum(\hat{Y} - \bar{Y})^2}{\sum(Y - \bar{Y})^2} \quad (5.4)$$

En la ecuación (5.4) debido a que el numerador nunca superará el denominador, el valor máximo de R^2 será 1 y hace referencia a la explicación del 100% del comportamiento de los datos explicados por la regresión, por lo tanto, en la medida que este valor se aproxime a 1, mayor es el grado de correlación entre las variables. El valor mínimo de R^2 es 0 y representa la no correlación o no explicación de la variable dependiente dada por el modelo de correlación.

5.2 ANÁLISIS DE REGRESIÓN ENTRE V_s y N

Se han propuesto muchas correlaciones matemáticas entre la velocidad de propagación de onda cortante y el número de golpes N (SPT) obtenidos de una masa de suelo. Estas propuestas incluso, delimitan la población de datos en clases menores dependiendo del tipo de suelo según la clasificación SUCS, como se muestra en la tabla 5.1.

Tabla 5.1 Algunas ecuaciones propuestas por diversos autores para relacionar V_s y N

AUTOR (ES)	TIPO DE SUELO	V_s (m/s)
Kanai, et al (1966)	Todo	$V_s = 19N^{0.60}$
Ohsaki & Iwasaki (1973)	Todo	$V_s = 82N^{0.39}$
Imai & Yoshimura (1975)	Todo	$V_s = 92N^{0.329}$
Imai, et al (1975)	Todo	$V_s = 90N^{0.341}$
Imai (1977)	Todo	$V_s = 91N^{0.337}$
Ohta & Goto (1978)	Todo	$V_s = 85N^{0.348}$
Seed & Idris (1981)	Todo	$V_s = 61N^{0.5}$
Imai & Tonouchi (1982)	Todo	$V_s = 97N^{0.314}$
Imai & Yoshimura (1990)	Todo	$V_s = 76N^{0.33}$
Yolota, et al (1991)	Todo	$V_s = 121N^{0.27}$
Safari, et al (1997)	Todo	$V_s = 22N^{0.85}$
Shibata (1970)	Arena	$V_s = 32N^{0.5}$
Ohta, et al (1972)	Arena	$V_s = 87N^{0.36}$
Ohta & Goto (1978)	Arena	$V_s = 88N^{0.34}$
JRA (1980)	Arena	$V_s = 80N^{1/3}$
Seed, et al (1983)	Arena	$V_s = 56N^{0.5}$
Lee (1990)	Arena	$V_s = 57N^{0.49}$
JRA (1980)	Arcillas	$V_s = 100N^{1/3}$
Lee (1990)	Arcillas	$V_s = 114N^{0.31}$
Lee (1990)	Limos	$V_s = 106N^{0.32}$

La mayoría de los modelos presentan una estructura matemática del tipo potencial de la forma $V_s = AN^B$, siendo A y B parámetros determinados de la regresión matemática cuando se aplica a registros obtenidos en campo. Aunque algunas de estas relaciones enmarcan el comportamiento de un solo tipo de suelo, gráficamente se puede observar pequeñas diferencias representativas entre una u otra propuesta (Ver figura 5.2), siendo difícil elegir un modelo potencial para predecir los valores de velocidad de onda cortante V_s para cada tipo de suelo ya que no se discrimina por tipo de material y no existe convergencia a un modelo específico.




Figura 5.2 Representación gráfica de algunas ecuaciones propuestas para $V_s = f(N)$

5.3 ANÁLISIS DE REGRESIÓN PROPUESTO PARA LOS VALORES DE V_s - N

Comúnmente los valores de N obtenidos en la prueba SPT se normalizan de acuerdo al confinamiento al cual se somete el muestreador estándar. Debido al desconocimiento de los detalles en la ejecución de la prueba SPT (tipo de martillo, tipo de muestreador, longitud de las barras de perforación y diámetro de la perforación), en este trabajo se propone una aproximación en la cual se omite la aplicación de algunos de los factores que afectan los resultados de ésta (ver capítulo 3).

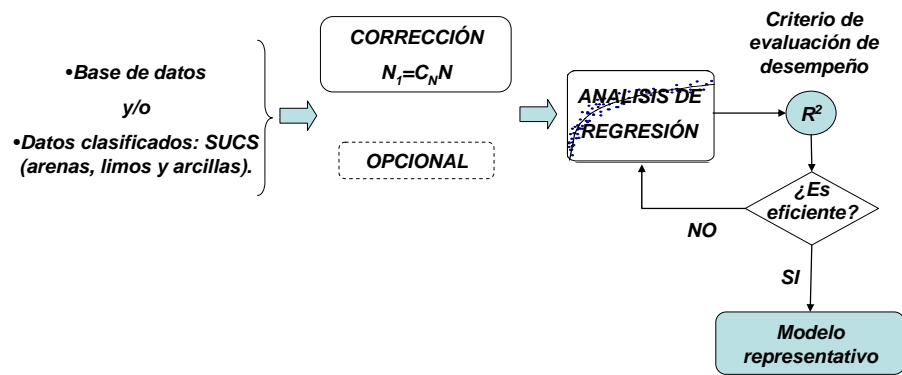


Figura 5.3 Esquema general del análisis de regresión propuesto

El suelo se clasificó según su granulometría (arenas, arcillas, limos) y se realizó el análisis de regresión potencial y logarítmica sobre datos de N (sin corregir) y N_1 (datos corregidos por esfuerzo vertical efectivo), siendo los modelos que más se ajustan al comportamiento que presenta la base de datos. Se considera el factor de corrección propuesto por *Liao y Whitman (Liao and Whitman, 1986)*:

$$C_N = \sqrt{\frac{1}{\sigma'_v}} \text{ kg/cm}^2 \quad (5.6)$$


$$N_1 = C_N \cdot N \quad (5.7)$$

Para cada grupo de suelo y la base de datos en general, se realizó un diagrama de dispersión con el fin de representar gráficamente el grado de asociación entre las variables. La evaluación del desempeño del modelo de regresión que representa el comportamiento de los datos se basa en el factor R^2 . Se hace además una comparación del modelo propuesto, con aproximaciones dadas por otros autores para todo tipo de suelo y tomando en cuenta la clasificación SUCS (ver figuras 5.4 a la 5.6).

A continuación se presentan las tendencias gráficas para comportamientos propuestos por otros autores y las estructuras sugeridas en este trabajo (potenciales y logarítmicas). Las figuras 5.4 a la 5.7 muestran las mejores representaciones matemáticas y su respectivo valor R^2 tomando como variables explícitas N ó N_1 . En estos gráficos se incluyen los puntos obtenidos en campo para hacer más evidente el rango de R^2 alcanzado por cada modelo funcional de la regresión.

A. POTENCIAL

TIPO DE SUELO	CORRELACIÓN	R^2
Arena	$V_s = 90.851N^{0.344}$	0.2756
	$V_s = 126.12N_1^{0.218}$	0.101



A. LOGARÍTMICA

TIPO DE SUELO	CORRELACIÓN	R^2
Arena	$V_s = 111.16Ln(N) + 10.306$	0.2798
	$V_s = 70.91Ln(N_1) + 115.02$	0.1039

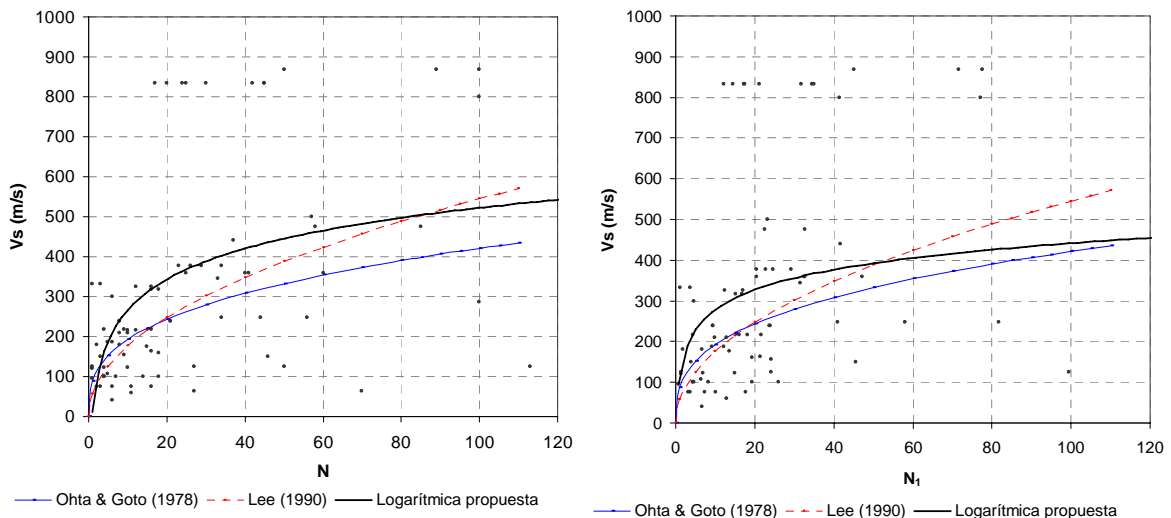
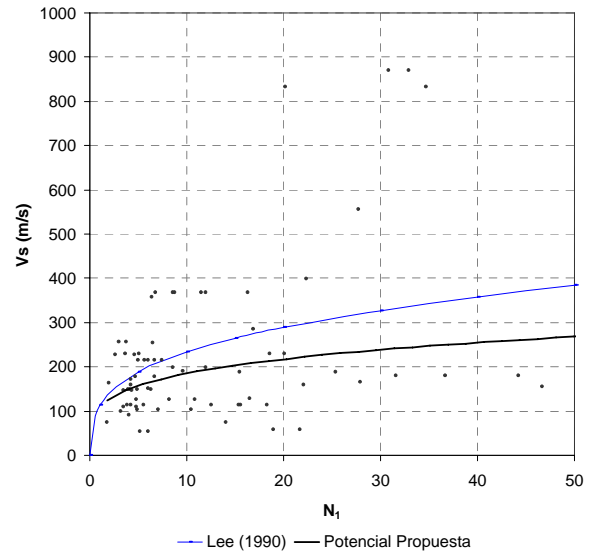



Figura 5.4 Análisis de regresión $N - V_s$ en arenas

A. POTENCIAL

TIPO DE SUELO	CORRELACIÓN	R ²
Arcilla	$V_s = 93.727N^{0.2949}$	0.1932
	$V_s = 109.13N_1^{0.2298}$	0.1089



A. LOGARÍTMICA

TIPO DE SUELO	CORRELACIÓN	R ²
Arcilla	$V_s = 87.959Ln(N) + 25.733$	0.206
	$V_s = 75.64Ln(N_1) + 55.292$	0.1415







Figura 5.5 Análisis de regresión N - Vs en arcillas.

A. POTENCIAL

TIPO DE SUELO	CORRELACIÓN	R ²
Limos	$V_s = 269,69N^{0,1931}$	0.079
	$V_s = 387,85N_1^{0,1151}$	0.0394



A. LOGARÍTMICA

TIPO DE SUELO	CORRELACIÓN	R ²
Limos	$V_s = 12368L_n(N) + 15213$	0.0885
	$V_s = 70932L_n(N_1) + 39403$	0.0408


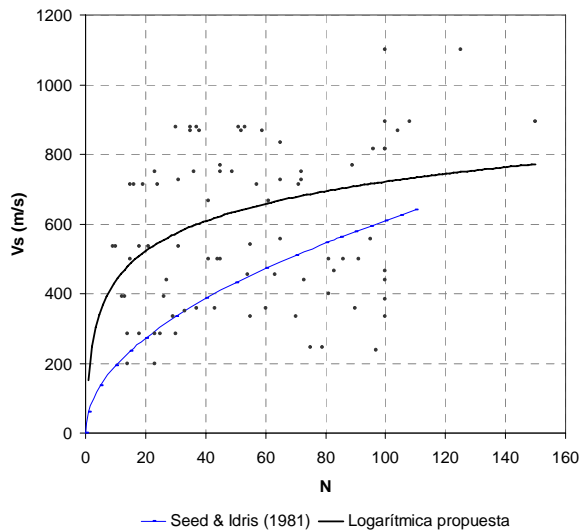



Figura 5.6 Análisis de regresión N - Vs en limos.

A. POTENCIAL

TIPO DE SUELO	CORRELACIÓN	R ²
Todo	$V_s = 14877 \text{Ln}(N) - 46975$	0.3368
	$V_s = 11077 \text{Ln}(N_1) + 89331$	0.1543



A. LOGARÍTMICA

TIPO DE SUELO	CORRELACIÓN	R ²
Todo	$V_s = 84.267N^{0.4194}$	0.388
	$V_s = 12492N_1^{0.309}$	0.174




Figura 5.7 Análisis de regresión N - Vs para todos los grupos (arena, limo y arcillas).

5.4 ANÁLISIS DE RESULTADOS.

En general los modelos de regresión *no lineal*, específicamente de tipo potencial y logarítmico, resultaron ser los que mejor describen el comportamiento de la base de datos, ya sea general o para cada tipo de suelo. Al usar la variable explícita N se incrementa el valor de R^2 para cada grupo de datos. Es decir, incluir el factor de corrección por esfuerzo efectivo (implícito en N_1) dispersa los pronósticos de V_s de la vecindad de un comportamiento como el trazado por las curvas potenciales y logarítmicas (ver figura 5.8). Como se expresó en el capítulo 3, el esfuerzo efectivo produce una variación en la obtención de N , pero es evidente que este efecto no repercute en la variación de V_s que describen las estructuras matemáticas (al menos para la base de datos que se estudia en este trabajo).




Figura 5.8 Coeficiente de determinación R^2 obtenido de las técnicas de regresión aplicadas para cada tipo de suelo, para (N y N_1)

Las regresiones propuestas en este trabajo para el pronóstico de V_s , en general se aproximan a las propuestas en la literatura sobre el tema, pero aplicadas a la base de datos, el coeficiente de determinación es bastante bajo, en promedio menor de 0.3 en todos los casos individuales.

En términos generales y bajo las condiciones de modelado potencial/logarítmico, N resulta funcional en suelos gruesos pero es poco representativo en suelos finos. De alguna forma la cohesión en los suelos finos delimita un comportamiento específico en la prueba de penetración estándar, diferente a los suelos tipo limo o suelos de transición, los cuales presentan gran dificultad para ser representados por un mismo modelo matemático (ver figura 5.6), por ser suelos de difícil caracterización y correlación con N y V_s .

6.0 MODELO DE APRENDIZAJE AUTOMÁTICO PARA LA ESTIMACIÓN DE V_s A PARTIR DE N (SPT)

En éste capítulo se examina el uso de las redes neuronales para el modelado de sistemas no lineales. Considerando la cantidad y calidad de los sondeos que componen la base de datos, se propone una metodología de aprendizaje automático/entrenamiento neuronal, para optimizar el planteamiento del modelo neuronal que relaciona a N (prueba de penetración estándar) y la velocidad de onda cortante V_s a través de las características generales de los materiales que se identifican en las estratigrafías de los sitios analizados.

6.1 PROCESO DE CONSTRUCCIÓN DE UN MODELO NEURONAL

El proceso de búsqueda/optimización de las estructuras matemáticas automáticas o funciones neuronales, tiene un carácter estocástico (las leyes causa-efecto iniciales son al azar). El planteamiento que se sigue en este punto es empírico: se genera un gran número de pruebas en el entorno neuronal, de modo que logre alcanzar un modelo que cumpla con los criterios de eficiencia y eficacia computacional (respuestas estimadas adecuadas en tiempos de cómputo mínimos). Para sistematizar el proceso fue necesario diseñar los experimentos por etapas (ver figura 6.1):




Figura 6.1 Esquema general del planteamiento y ejecución de las pruebas

- a. Formulación del problema
- b. Procesamiento de la información (clasificación y codificación de datos)
- c. Definición de experimentos
- d. Ejecuciones en modo de trabajo (validación y prueba de la red).

6.2 FORMULACIÓN DEL PROBLEMA

Las propiedades dinámicas de los suelos son parámetros básicos en la aplicación de modelos matemáticos que permitan predecir la respuesta dinámica de depósitos de suelo, estudios de licuación y en problemas de interacción suelo-estructura. Los métodos directos para su determinación, como los ensayos geofísicos, pueden resultar muy costosos, por lo que se plantea que indirectamente, a partir del ensayo de penetración estándar, se tenga la posibilidad de caracterizar esta propiedad en áreas más grandes de manera más económica.

El problema se define como el desarrollo de una topología neuronal que sea capaz de obtener valores de velocidad de onda cortante V_s (relativas a pruebas dinámicas como el cono sísmico, Down Hole y sonda suspendida) a partir del número de golpes N obtenidos en campo de la prueba de penetración estándar y la caracterización del tipo de suelo (SUCS). El uso de esta técnica permite determinar a partir de una variable obtenida en campo (N), los valores de una variable fundamental en la etapa de diseño y análisis sísmico (V_s) (figura 6.2).




Figura 6.2 Esquema general del planteamiento del problema

6.3 PROCESAMIENTO DE LA INFORMACIÓN

Con el desarrollo de las pruebas de campo y a partir de las muestras obtenidas mediante el tubo muestreador partido de la prueba SPT, se identificaron las propiedades índice del suelo y el peso específico con el fin de calcular el esfuerzo efectivo a una profundidad dada.

Cada tipo de suelo fue codificado (mediante combinaciones 0 y 1) para hacer que el sistema establezca y verifique los patrones de comportamiento que,

numéricamente, expresan los patrones de entrada/salida. Con base en los planteamientos tradicionales que otorgan al tipo de suelo un efecto importante sobre el valor de V_s medido en el campo, aquí se presentan dos variantes de análisis que obligan a generar dos tipos de bases de datos. En la primera se aplica una categorización de los datos según el tipo de suelo y en la segunda los datos se agrupan en función de la profundidad.

6.3.1 Banco 1: Categorización por tipo de suelo

La base total se subdividió en dos categorías básicas: SUELOS FINOS y SUELOS GRUESOS, de los cuales según la clasificación SUCS, se subdividieron en CL, CH, ML y MH para la categoría FINOS y SP, SM, SC y Gravas-Boleos en el caso de GRUESOS (figura 6.3).

Este banco de datos se construyó de tal forma que la red pueda analizar el comportamiento de cada tipo de suelo sin relacionar materiales adyacentes o una disposición estratigráfica en particular. De esta manera se podrán obtener resultados puntuales y cerrados para un tipo de suelo específico sujeto a ciertas condiciones de esfuerzo, cuando se conoce el valor de N obtenido en una prueba de campo.




Figura 6.3 Esquema de clasificación de la información disponible (banco uno).

6.3.2 Banco 2: Categorización por profundidad

En este banco de datos se incluyen todas las clases de suelo (CL, CH, ML, MH, SP, SM, SC Y Gravas-Boleos) codificadas mediante 0 y 1 (suelo fino y grueso respectivamente), las condiciones de esfuerzo vertical efectivo, el valor de N y la profundidad a la cual se obtuvo este valor.

Con la conformación de este banco se logra incluir el efecto que tienen el patrón de disposición continuo de $N - V_s$ con el fin de plantear entrenamientos para el caso de perfiles de V_s contra profundidad.



Figura 6.4 Esquema de clasificación de la información disponible (banco dos).

6.4 DEFINICIÓN DE EXPERIMENTOS

El objeto de los experimentos fue encontrar la mejor red neuronal en términos de su capacidad para predecir el valor de V_s a partir de los datos de entrada. Las funciones de transferencia, las reglas de aprendizaje y el número de nodos y capas, se evalúan en diferentes combinaciones de tal forma que se alcance un conjunto de funciones de donde se selecciona el modelo óptimo.

6.4.1 Combinaciones de las variables de entrada

Dependiendo de la combinación de las variables de entrada, se identificaron siete redes neuronales artificiales (RNA) a partir de las cuales se formaron cinco tipos de modelos (ver figura 6.5).

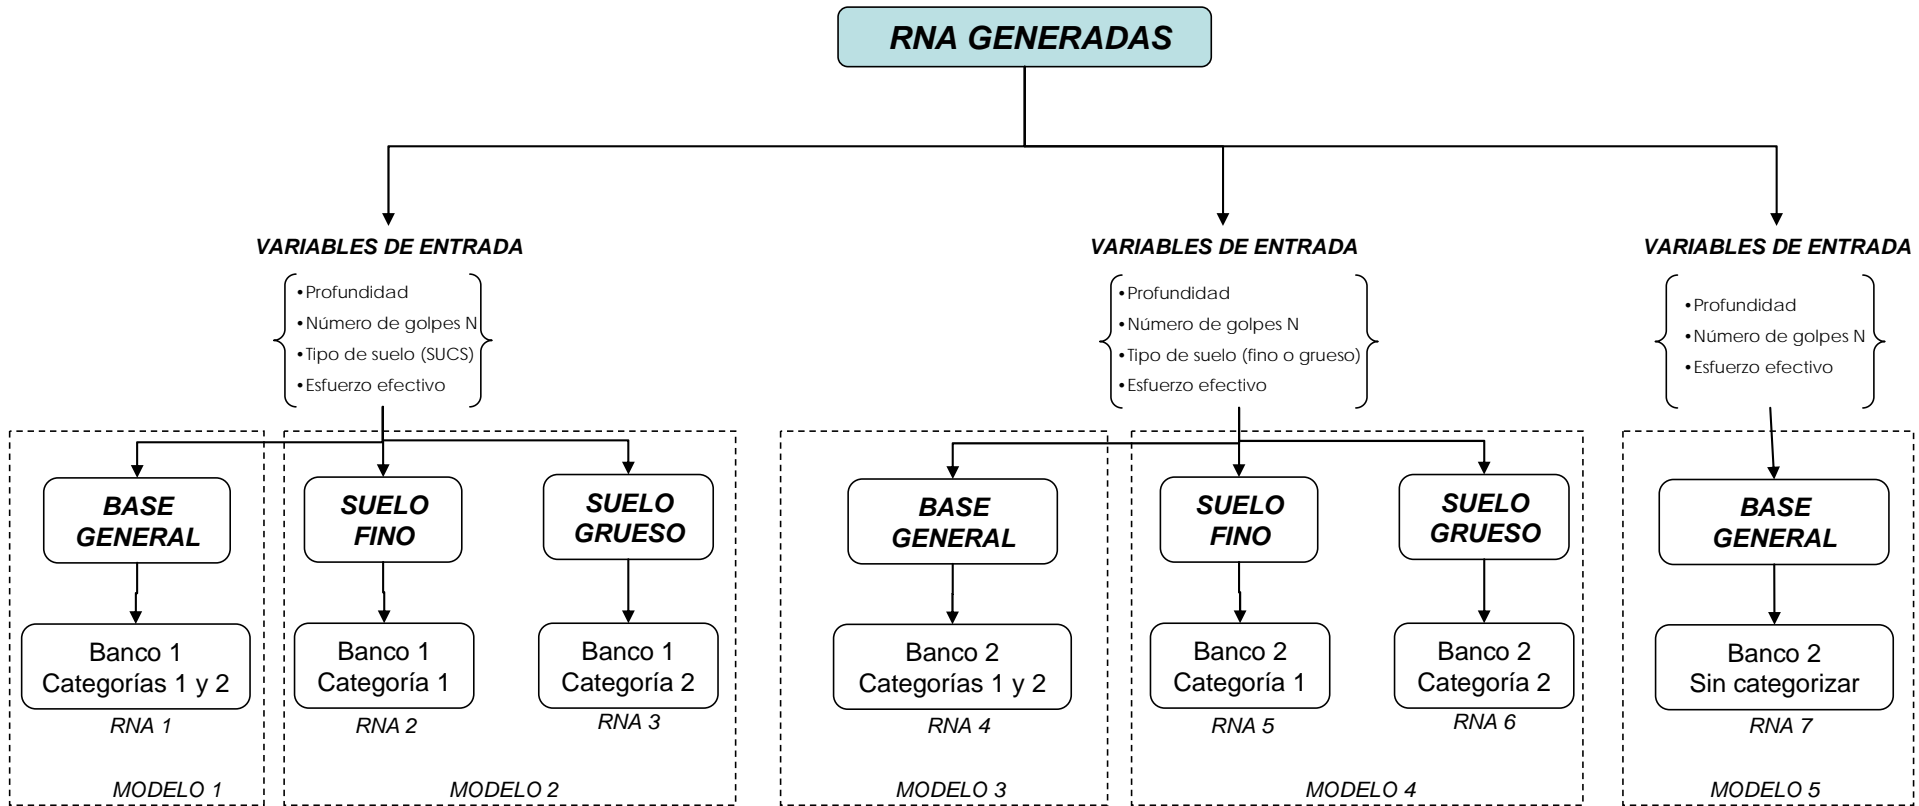


Figura 6.5 Diagrama conceptual sobre el proceso y generación de experimento

a) Modelo 1:

En este modelo, se generó una red neuronal (RNA1) entrenada con la base de datos general incluyendo la clasificación SUCS (datos del banco uno). Esta red se compone de seis entradas: Profundidad, N , esfuerzo efectivo y tres nodos en los que se utiliza la clasificación SUCS interpretada mediante números binarios (ver tabla 6.1).

Tabla 6.1 Variables de entrada usadas para identificar el tipo de suelo en la RNA 1

NODO CLASIFICADOR			TIPO DE SUELO QUE REPRESENTA (SUCS)
0	0	1	Suelo grueso tipo Arena SP
0	1	1	Suelo grueso tipo Arena SM
1	0	1	Suelo grueso tipo Arena SC
1	1	1	Suelo grueso tipo Gravas y boleos
0	0	0	Suelo fino tipo Arcilla CL
0	1	0	Suelo fino tipo Arcilla CH
1	1	0	Suelo fino tipo Limo MH
1	0	0	Suelo fino tipo Limo ML

b) Modelo 2:

Este modelo esta compuesto por dos redes neuronales: una red para suelo fino (RNA 2) y otra para suelo grueso (RNA 3), conformadas con los datos del Banco 1, donde se usaron cinco variables de entrada N , profundidad, esfuerzo efectivo y dos nodos para distinguir al suelo según la clasificación SUCS (ver tablas 6.2 y 6.3).

Tabla 6.2 Variables de entrada usadas para identificar el tipo de suelo en la RNA 2

NODO CLASIFICADOR		TIPO DE SUELO QUE REPRESENTA (SUCS)
0	0	Arcilla CL
0	1	Arcilla CH
1	1	Limo MH
1	0	Limo ML

Tabla 6.3 Variables de entrada usadas para identificar el tipo de suelo en la RNA 3

NODO CLASIFICADOR		TIPO DE SUELO QUE REPRESENTA (SUCS)
0	0	Arena SP
0	1	Arena SM
1	0	Arena SC
1	1	Gravas y boleos

c) Modelo 3:

Este modelo entrena una red (RNA 4) con la base de datos del Banco 2 (datos clasificados por profundidad), discriminando únicamente el suelo tipo, es decir, distingue a los de tipo fino (pasa la malla número 200) y a los suelos gruesos, usando

cuatro variables de entrada: N , profundidad, esfuerzo efectivo y un clasificador binario.

d) Modelo 4:

Similar al modelo 2, se entrenaron dos redes independientes (RNA5 para suelo tipo fino y RNA 6 para suelo tipo grueso) pero usando los datos del Banco 2 (no se consideran las subclases de suelo dada por el SUCS) Cada red tiene tres variables de entrada: N , profundidad y esfuerzo efectivo.

e) Modelo 5:

En este modelo, se entrenó una red (RNA 7) a partir de los datos del Banco 2 sin tomar en cuenta la clasificación del SUCS, limitando las variables de entrada a la profundidad, número de golpes N y esfuerzo efectivo.

Los modelos 1 al 5 se utilizaron para llevar a cabo los experimentos mediante los cuales se encontró un modelo óptimo variando la ley de aprendizaje, la función de transferencia y la topología. En total se llevaron a cabo 56 experimentos (8 en promedio por red) cuyos resultados es imposible de presentar en su totalidad, por lo cual, únicamente se presentan a manera de ejemplo los resultados obtenidos del modelo 2, que contienen la RNA 2 (suelo fino) y RNA 3 (suelo grueso). Estos experimentos son llevados en forma iterativa.

6.4.2 Experimento variando la Ley de Aprendizaje

En este trabajo, el "aprendizaje" se define como el proceso de búsqueda del conjunto de pesos (ponderación de trabajo asignada a cada nodo o neurona) que generan el mínimo error entre las predicciones del modelo y los valores que se obtuvieron en el campo. En esta etapa se analizaron resultados dados por los algoritmos de aprendizaje teóricamente mejor respaldados (*Gradiente Conjugado CG*, *Propagación rápida QP*, *Levenberg Marquard LV* y *Regresión Lineal GR*). Al efectuar estos análisis se mantuvieron constantes la función de transferencia (sigmoideal) y la topología (2 capas de 35 nodos cada red).

A continuación se presenta como ejemplo los resultados para el modelo 2. Para fines comparativos, en la figura 6.6 se presentan los algoritmos de propagación que ofrecen mejores resultados en la fase de entrenamiento. Para este trabajo, el algoritmo de propagación rápida *Quick Propagation* o *QP* (ver capítulo 4) demostró ser el mejor algoritmo de aprendizaje, pues adopta rápidamente los factores de

peso tal que se obtengan mejores respuestas en el aprendizaje y reducción de la tasa de error con buen nivel de convergencia entre los valores estimados y los objetivo. Los resultados de los experimentos realizados con los algoritmos *Levenberg Marquard (LV)* y *Regresión Lineal (GR)* no se presentan debido a que se generan matrices demasiado complejas e imposibles de procesar por la computadora.

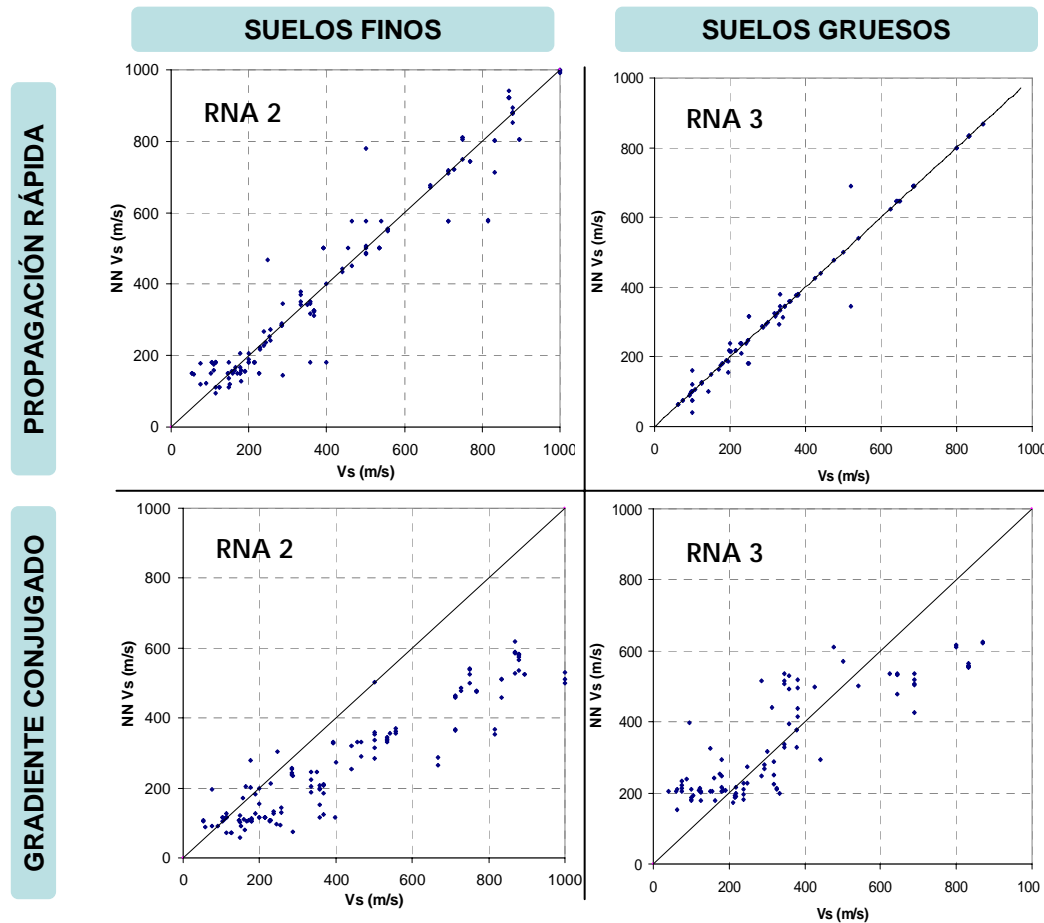


Figura 6.6 Resultados obtenidos en el análisis 2, variando el algoritmo de aprendizaje, manteniendo constante la topología (2 capas y 35 nodos cada una) y la función de transferencia (sigmoideal) para los datos de entrenamiento.

6.4.3 Experimentos variando la Función de Transferencia o Salida

Así como es necesaria una regla que combine las entradas de una neurona con los pesos de las conexiones, también se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. La salida total está determinada por la función de transferencia, la cual puede ser una función lineal o no lineal de grado n , y que se escoge dependiendo de las especificaciones del problema que la red tenga que resolver.

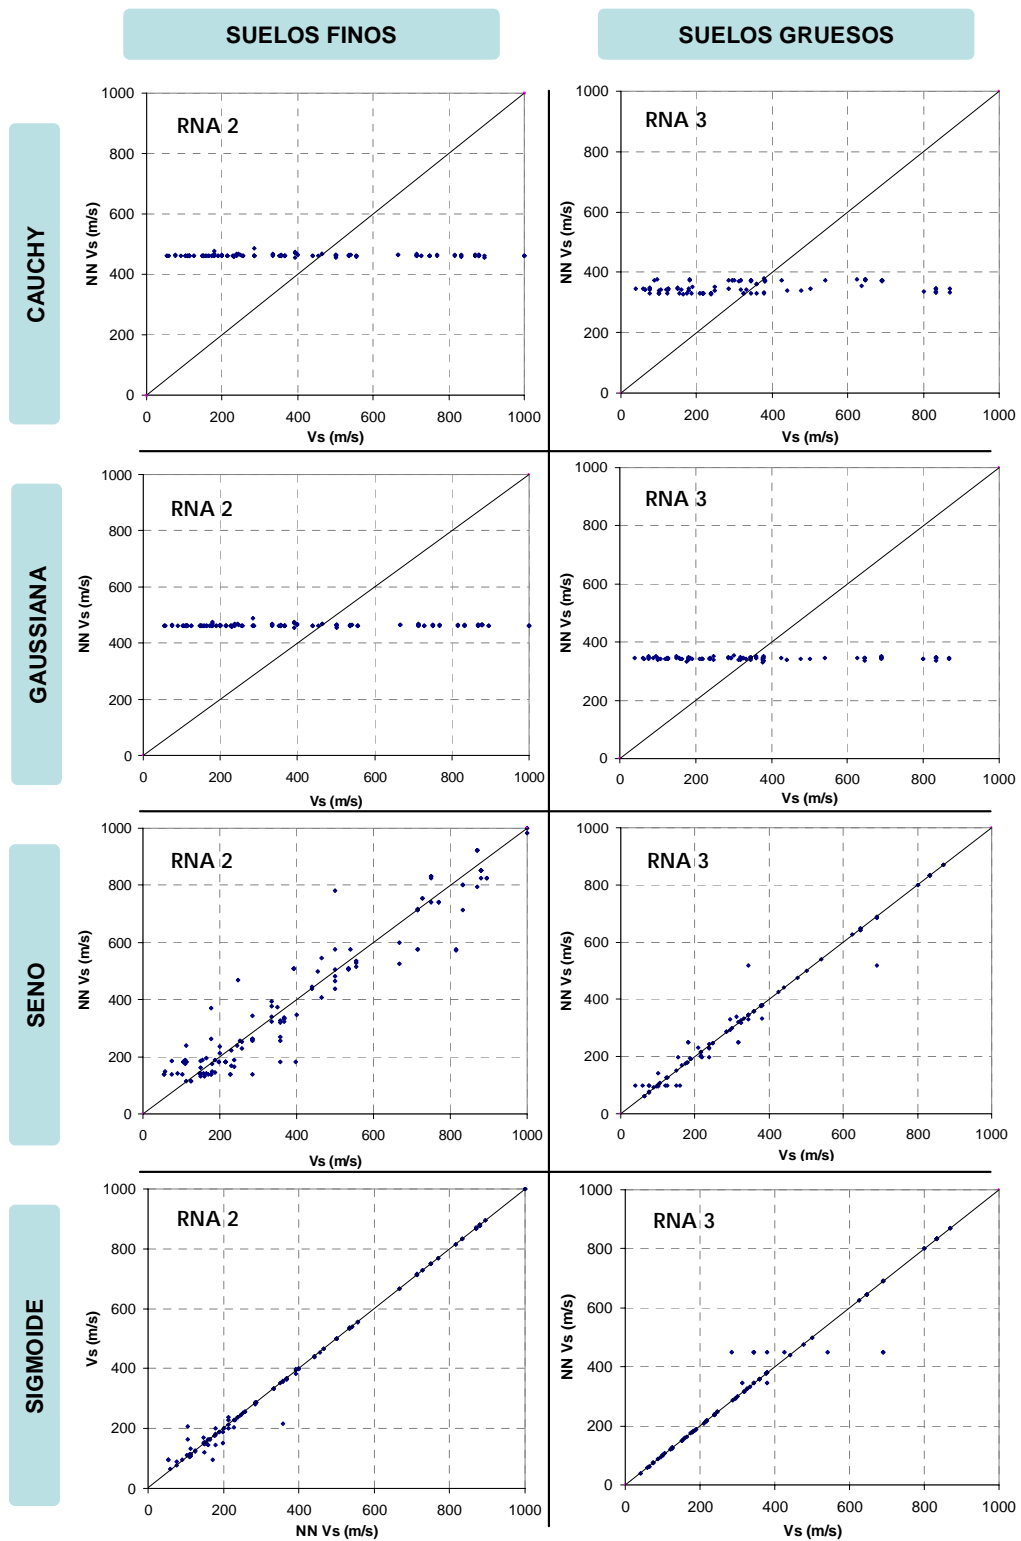


Figura 6.7 Resultados obtenidos para el análisis 2, variando la función de transferencia, manteniendo constante la topología (2 capas y 35 nodos cada una) y el algoritmo de aprendizaje (Propagación rápida) para los datos de entrenamiento.

Para este trabajo de tesis, durante el entrenamiento de las redes se analizaron distintas funciones de transferencia (escalón, lineal, sigmoideal y gaussiana), manteniendo constante la topología de la red (2 capas de 35 nodos cada una) y el algoritmo de propagación rápida (QP) como regla de aprendizaje óptimo encontrado de forma preliminar en los experimentos del inciso anterior (ver figura 6.6). Las mejores predicciones se obtuvieron con las funciones seno y sigmoideal (ver figura 6.7), siendo las más apropiadas cuando queremos como salida información numérica. Las funciones Cauchy y Gaussiana solo predecían V_s como un valor medio del rango de datos V_s de entrada y no obtenían una alta correlación o dispersaban los resultados.

6.4.5 Experimentos variando la Topología de la Red

Se construyeron redes de una sola capa oculta (monocapa) con conectividad hacia delante o *Feedforward*, donde las señales se reciben de una capa anterior (entrada) y se envían a una capa posterior (salida).

La red monocapa intercambia señales con el exterior y establece conexiones laterales entre las neuronas. Las redes multicapa a pesar de disponer de conjuntos de neuronas jerarquizadas en distintas capas, generaron ruido en el proceso de convergencia para determinar el error mínimo arrojado por la red.




Figura 6.8 Coeficiente de correlación obtenido de los datos de prueba de la RNA 4, variando el número de nodos o neuronas para la red monocapa.

Para encontrar el número de neuronas requeridas en la capa oculta, se realizaron pruebas variando el número de nodos con el fin de predecir los valores de los datos de prueba y calcular el coeficiente de correlación estadístico. Para el caso de la

RNA 4, todas las pruebas lograron realizar predicciones con una confiabilidad superior al 80%, siendo el óptimo de 87.3% para un número de 80 nodos en la capa oculta (ver figura 6.8), es decir, la topología óptima para esta red es 4X80X1 (cuatro variables de entrada, 80 nodos en una capa oculta y una variable de salida).

La tabla 6.4 reúne las propiedades óptimas encontradas después de sucesivas iteraciones entre el algoritmo de aprendizaje, la función de transferencia y el número de nodos en la capa oculta, para las siete redes que se utilizaron en los cinco análisis.

Tabla 6.4 Relación de las propiedades óptimas para las redes generadas en el experimento

MODELO	RNA	Algoritmo de aprendizaje	Función de transferencia	Topología
1	RNA 1	Propagación rápida	Sigmoidal	6X80X1
2	RNA 2	Propagación rápida	Sigmoidal	5X35X1
	RNA 3			5X30X1
3	RNA 4	Propagación rápida	Sigmoidal	4x80x1
4	RNA 5	Propagación rápida	Sigmoidal	3X35X1
	RNA 6			3X30X1
5	RNA 7	Propagación rápida	Sigmoidal	3x80x1

6.5 EJECUCIONES EN MODO DE TRABAJO (VALIDACIÓN Y PRUEBA DE LA RED)

El 20% de la base de datos total no se incluyó en el entrenamiento y la generación de experimentos, a fin de realizar las pruebas necesarias para identificar la red que optimice las predicciones. Con los resultados de las características obtenidas en los experimentos (ley de aprendizaje, función de transferencia y topología de la red), se probaron los cinco modelos con los cuales se predijeron los valores de velocidad de onda cortante en un estrato. A partir de los valores del número de golpes N , cada uno representa un posible modelo de predicción de V_s .

Tabla 6.5 Valor de R^2 para modelos con redes independientes

MODELO	RNA	R^2
1	RNA 1	0.4059
2	RNA 2	0.5597
	RNA 3	0.8577
3	RNA 4	0.6841
4	RNA 5	0.7557
	RNA 6	0.8614
5	RNA 7	0.4324

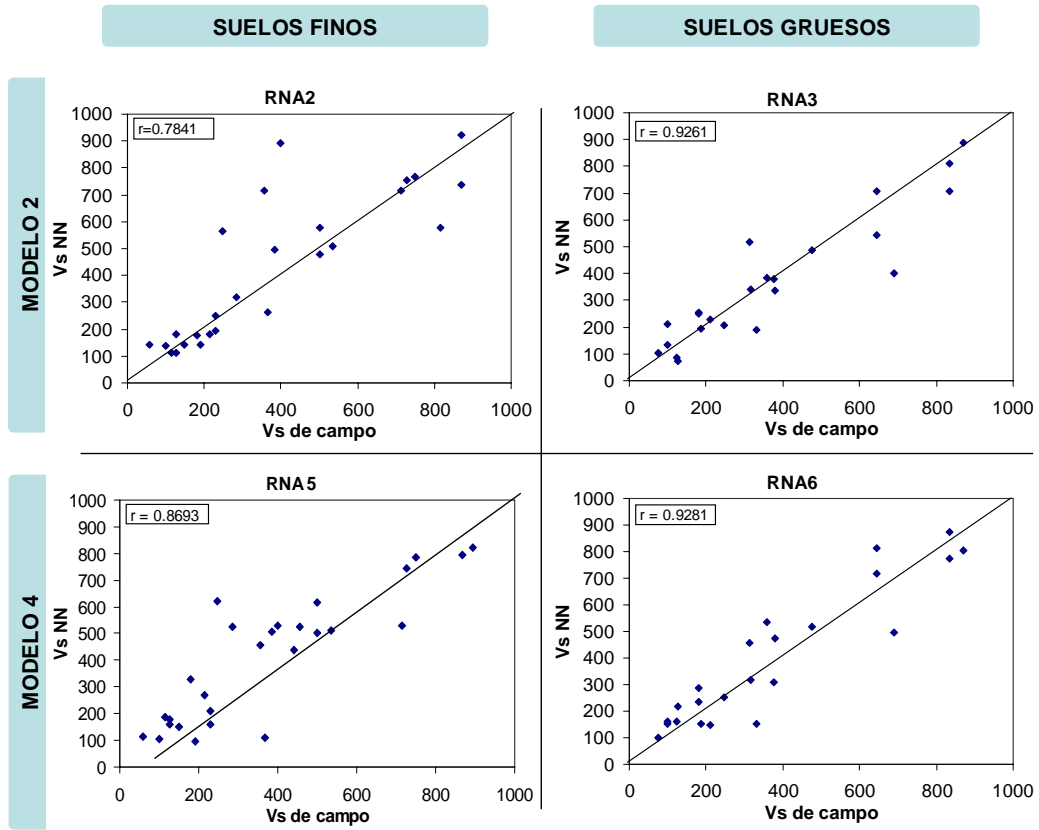


Figura 6.9. Análisis de predicción para redes independientes (fino y grueso de la base de datos de los Bancos 1 y 2).

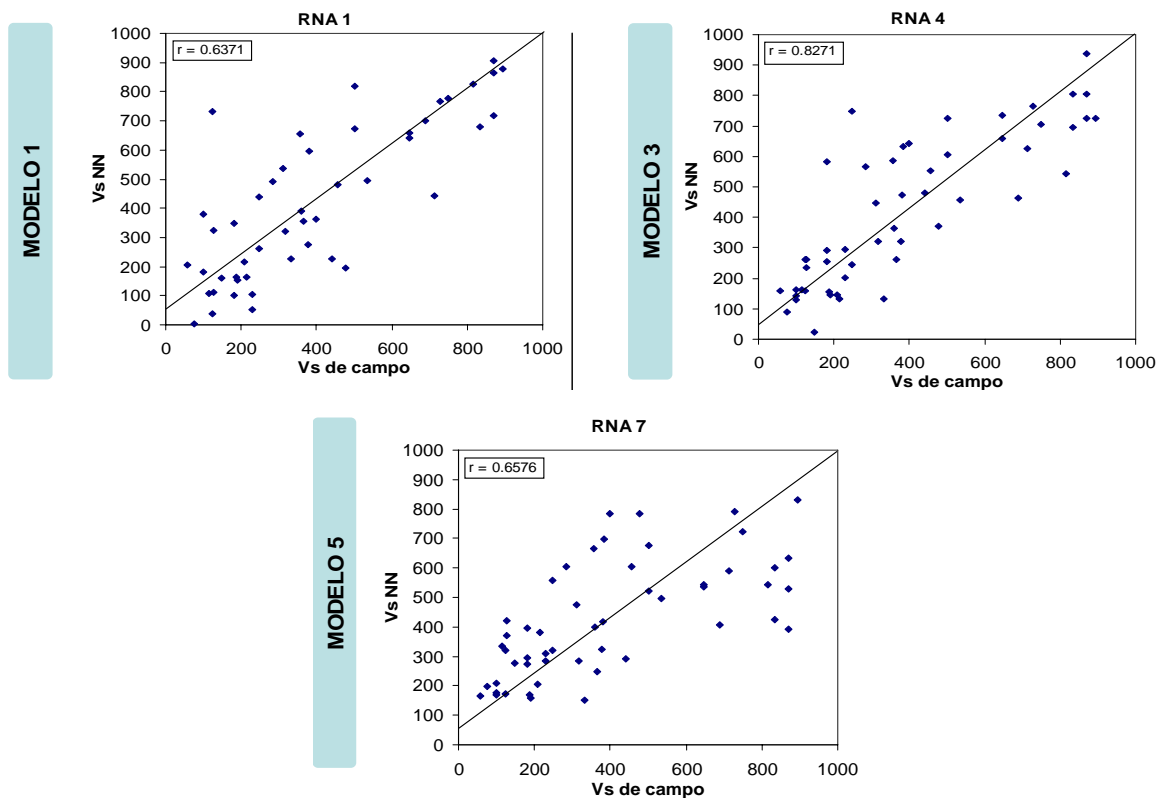


Figura 6.10. Análisis de predicción para redes entrenadas con la base de datos general de los Bancos 1 y 2.

Dependiendo del manejo de la base de datos para cada modelo, la tabla 6.5 contiene el valor del coeficiente de determinación R^2 hallado con los datos de prueba. Así mismo, las figuras 6.9 y 6.10 presentan el valor de V_s de campo y V_s predicho por las redes neuronales que componen los modelos.

6.6 RESUMEN DE RESULTADOS

Para determinar el modelo que mejor predice a partir de N , V_s , se tomó como criterio de selección el coeficiente de determinación (R^2), descrito en el capítulo 5.

6.6.1 Valoración de los modelos

Por ser modelos compuestos por dos redes neuronales, inicialmente se compararon los resultados obtenidos de los modelos 2 y 4, los cuales contienen cada uno dos redes independientes: una para suelo grueso y otra para suelo fino; la diferencia entre ellas radica en que el modelo 2 incluye la subclasificación del SUCS. Según los resultados mostrados en la tabla 6.5, en general los valores R^2 son mayores en el modelo 4, (modelo 2 $R^2 = 0.5597$, modelo 4 $R^2 = 0.7557$), mientras que para las redes de suelo grueso ambos modelos tienen R^2 cercanos a 0.86.

Según lo anterior, incluir la variable de clasificación del SUCS en los modelos, genera discrepancias en la predicción de V_s para suelos finos. Respecto a los suelos gruesos, considerar el SUCS no es algo que pueda ser relevante para predecir V_s y no le aporta información adicional.

Para los modelos 1, 3 y 5 (no modular) (ver figura 6.5), agregar la variable de clasificación SUCS genera pobres predicciones de V_s (ver figura 6.10). Este estudio indica que es suficiente clasificar al suelo en: i) fino y ii) grueso para lograr valores mas aproximados a los medidos en campo.




Figura 6.11 Esquema general del modelo óptimo para la predicción de V_s en un suelo estratificado a partir de N .

Se selecciono como óptimo el modelo 4 (ver figura 6.11), el cual presentó valores superiores de R^2 .

6.6.2 Validación de las redes

Para esta fase se usaron algunos perfiles de N -Profundidad y V_s -profundidad obtenidos de los sitios de Nayarit, Comalcalco y Zapotlán descritos en el capítulo tres de este trabajo, con el objetivo de identificar posibles divergencias o incongruencias en el reconocimiento e interpretación de los datos. Se presenta el comportamiento en entrenamiento para verificar la estabilidad del modelo neuronal.

De igual, forma se determinaron los valores de V_s usando la expresión hallada en el capítulo 5 de este trabajo, la cual relaciona N y V_s para todo tipo de suelo, en una expresión de tipo potencial:

$$V_s = 84.267N^{0.4194}$$

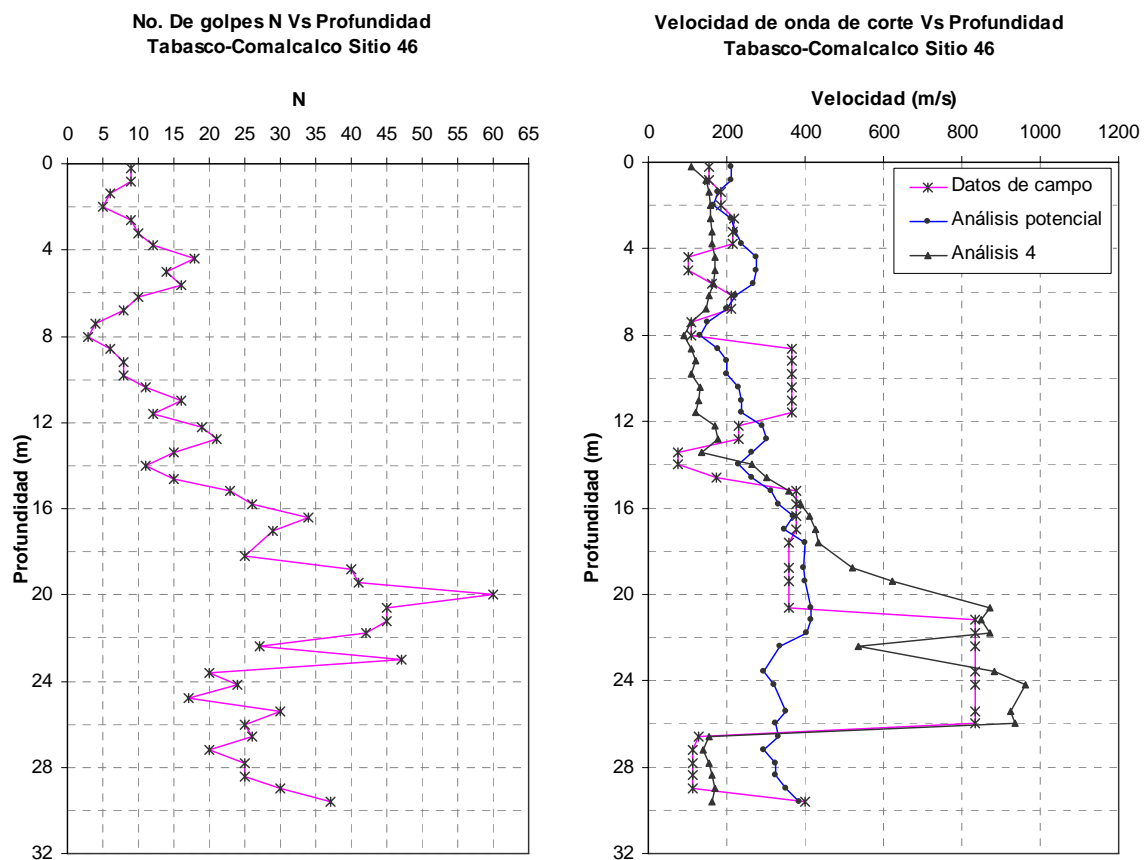


Figura 6.12 Tendencia de las predicciones con el modelo 4 de RNA y el análisis potencial del sondeo en el sitio 46 de la base de datos




Figura 6.13 Tendencia de las predicciones con el modelo 4 de RNA y el análisis potencial del sondeo en el Zapotlán 5 de la base de datos

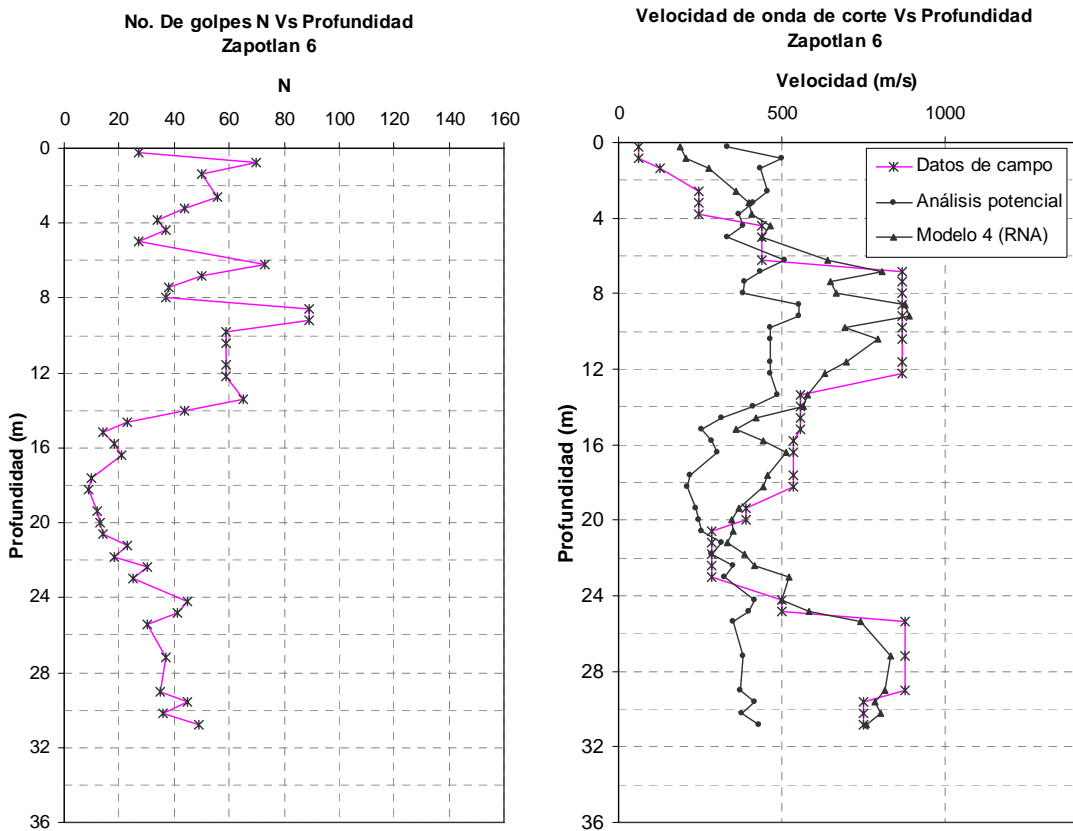


Figura 6.14 Tendencia de las predicciones con el modelo 4 de RNA y el análisis potencial del sondeo 5 en el sitio de Zapotlán

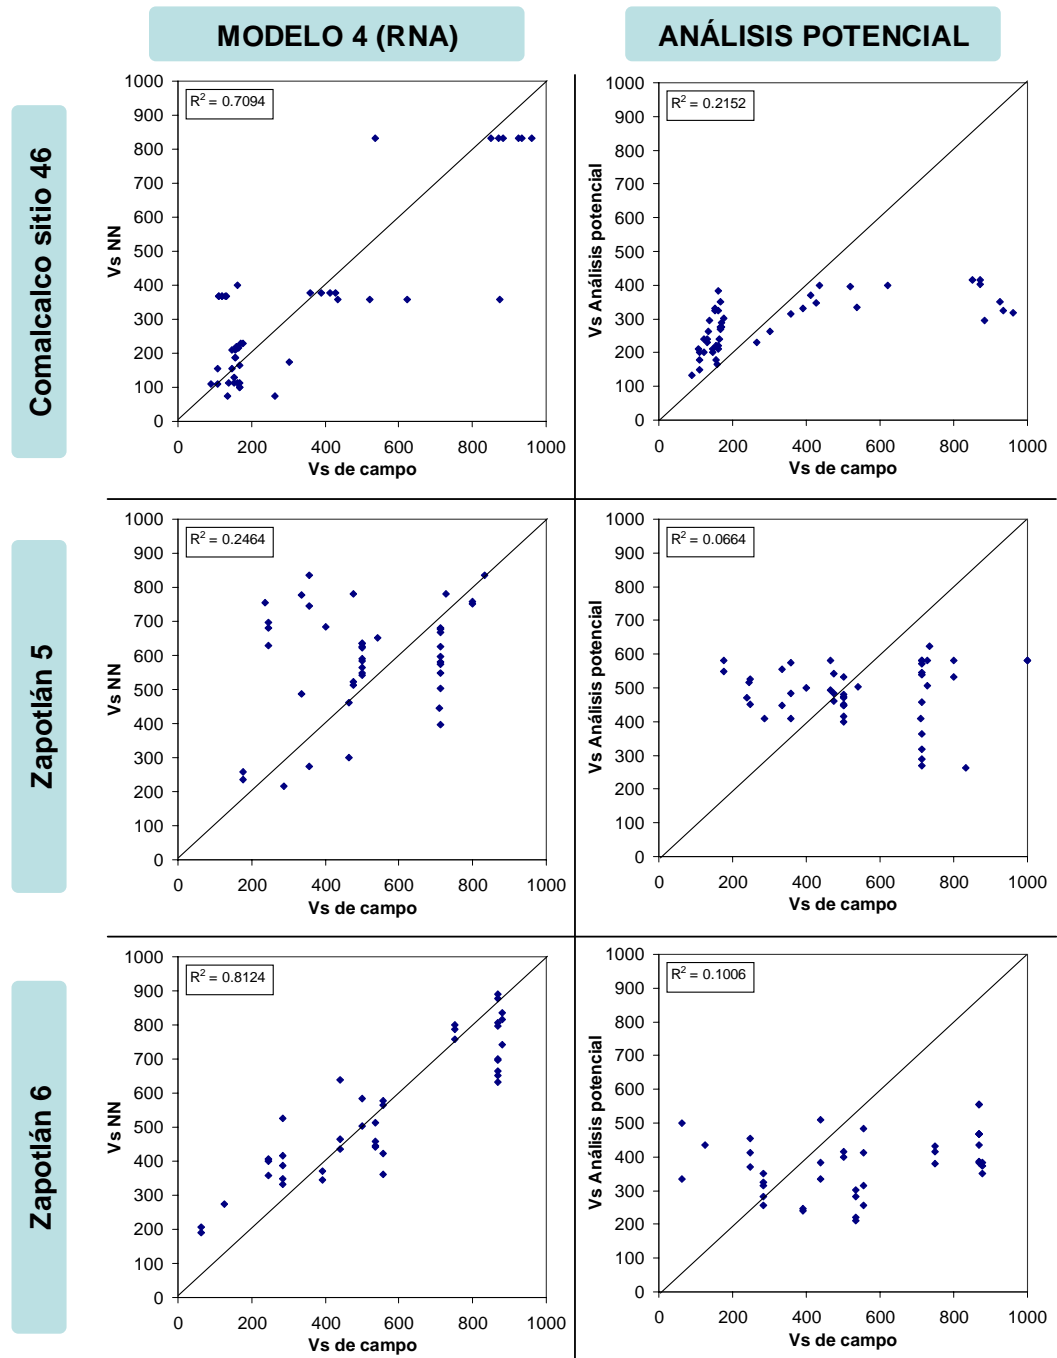


Figura 6.15. Predicciones con el modelo 4 de RNA y el análisis potencial contra V_s medido en campo, en los sitios de Comalcalco 46, Zapotlán 5 y 6

Los resultados obtenidos de las predicciones en el modelo neuronal muestran un buen nivel de estabilidad y los hacen válidos debido a que siguen con buena aproximación al perfil de campo V_s -profundidad (ver figuras 6.12 a la 6.14), mientras que las predicciones obtenidas del modelo potencial, se ajustan a la tendencia del perfil de campo V_s -profundidad promediando los picos altos y bajos que se presentan.

También se realizó una comparación entre los valores de V_s en campo y predichos con la ecuación potencial y el modelo óptimo (ver figura 6.11), usando un perfil N-profundidad que no pertenece a la base de datos (ver figura 6.16).

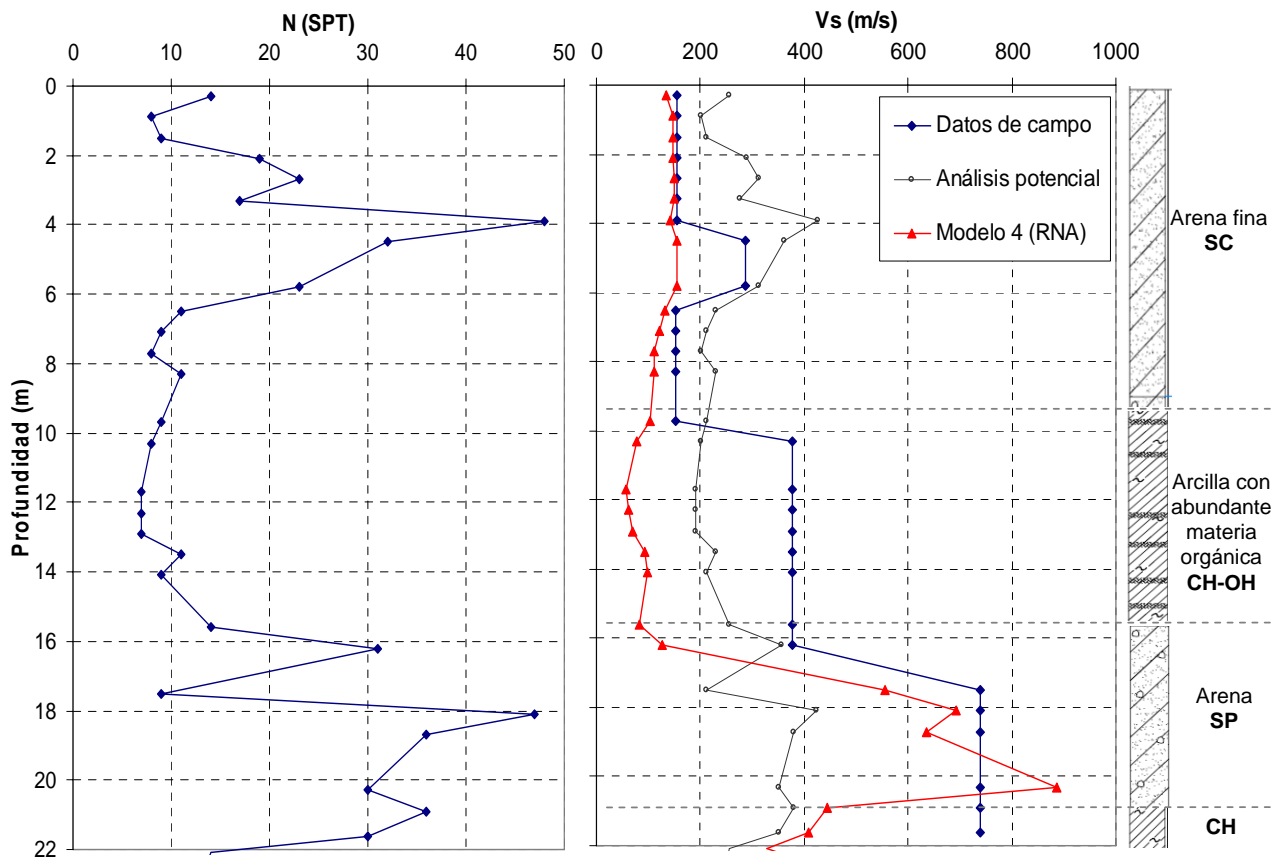


Figura 6.16 Tendencia de las predicciones con el modelo 4 de RNA y análisis potencial para un perfil de campo

Para las predicciones logradas mediante el modelo óptimo de redes neuronales, se evidencia en el perfil de V_s -profundidad (ver figura 6.16), la capacidad de sensibilidad al aumento de la profundidad y a cambios que se producen en la estratigrafía. Este hecho se hace notorio de 18 a 22 m de profundidad. Sin embargo, aunque el valor de N a 4 m de profundidad (48 golpes) sea prácticamente similar al valor dado a 18 m (47 golpes), el modelo neuronal propuesto toma en cuenta la profundidad e incluso el tipo de suelo donde se encuentran estos valores (variables declaradas en la entrada del modelo), prediciendo valores comparables con los datos de campo.

La correlación de tipo potencial dada por el análisis de regresión tiende a predecir un perfil promedio de V_s , sobrestimando este valor para pequeñas profundidades y

en la medida que la profundidad aumenta, este tipo de correlaciones tiende a subestimarlos (ver figuras 6.12 a la 6.14 y 6.16).

Tomando como criterio el coeficiente de determinación R^2 , el análisis mediante redes neuronales definitivamente presenta ventajas sobre los análisis de regresión. En general, las redes neuronales predicen tendencias que se muestran en los perfiles de V_s - Profundidad medidos en campo pero en ocasiones, se observan discrepancias principalmente en patrones cuyas entradas resultan incongruentes si se comparan con las "típicas" usadas en la construcción del modelo.

7.0 CONCLUSIONES

Se revisaron algunos de los modelos de regresión más comúnmente empleados y usando la base de datos aquí conformada, se propuso uno cuya capacidad predictiva es cuando menos igual a la que se presenta en la literatura. El modelo potencial propuesto encontrado por análisis de regresión desarrollado en este trabajo (ver capítulo 5), presenta un coeficiente de determinación R^2 muy bajo. Sin embargo, este modelo no se aleja de los más usados y es evidente la similitud entre éstos y el propuesto aquí. Los modelos de regresión suavizan los contrastes que se presentan en la estratigrafía y por ello no identifican cambios abruptos en el perfil de V_s contra profundidad.

La predicción de V_s con redes neuronales, representa una mejora importante con respecto a los modelos de regresión debido a su capacidad para identificar discontinuidades en el perfil de V_s -profundidad en un sondeo, mostrando las tendencias que se observan en los perfiles medidos en campo. Se determinó que los modelos neuronales permiten hacer mejores estimaciones de V_s a partir de redes neuronales, que los modelos basados en el análisis de regresión. Estos no sustituyen la medición directa y sólo deben usarse para predicciones preliminares.

La arquitectura de las redes neuronales que componen el modelo se organiza de tal forma que internamente identifiquen las tendencias de los datos, adquiriendo la habilidad de reconstruir los perfiles de V_s -profundidad con buena aproximación.

Debe reconocerse que la bondad de los modelos basados en redes neuronales para el modelado de sistemas no lineales depende de la calidad de los sondeos y las pruebas asociadas (penetración estándar y pruebas dinámicas) que compone la base de datos. En este caso, la calidad de los datos mejoraría si se redujera la incertidumbre asociada a la ejecución de las pruebas de campo.

Aún con la supuesta regencia de normas que estandarizan la prueba de penetración estándar, existe gran incertidumbre en la aplicación y efecto de estas sobre los valores medidos en campo. A pesar de contar con coeficientes de corrección para estandarizar la variable N obtenida de la prueba de penetración estándar, en general, no mejora la interpretación de V_s y sólo aportan ligeros desfases en el perfil V_s -profundidad.

Las pruebas para medir la velocidad de propagación de ondas cortantes S no se encuentran estandarizadas, al menos en México. Por ejemplo, en ocasiones no es posible mantener constante el intervalo de profundidad al cual se efectúan las mediciones, lo cual afecta los resultados obtenidos. Esto disminuye la calidad de la base de datos y por consiguiente disminuye efectividad a los modelos de predicción.

Uno de los aspectos a tomar en cuenta en una futura modificación a éste modelo es la posible integración del valor de la presión de poro medida en campo, lo que enriquecerá las conclusiones sobre los resultados que discrepan de los valores de V_s medidos y evaluados.

ANEXO 1

PERFILES ESTRATIGRÁFICOS DE LOS SITIOS EN ESTUDIO




Figura 1.1 Registro de exploración geotécnica (SPT) en el Sitio 46, Tabasco – Comalcalco, (continúa).




Figura 1.2 Registro de exploración geotécnica (SPT) en el Sitio 46, Tabasco - Comalcalco.




Figura 1.3 Registro de exploración geotécnica (SPT) en el Sitio 70, Tabasco – Comalcalco, (continúa).




Figura 1.4 Registro de exploración geotécnica (SPT) en el Sitio 70, Tabasco – Comalcalco.

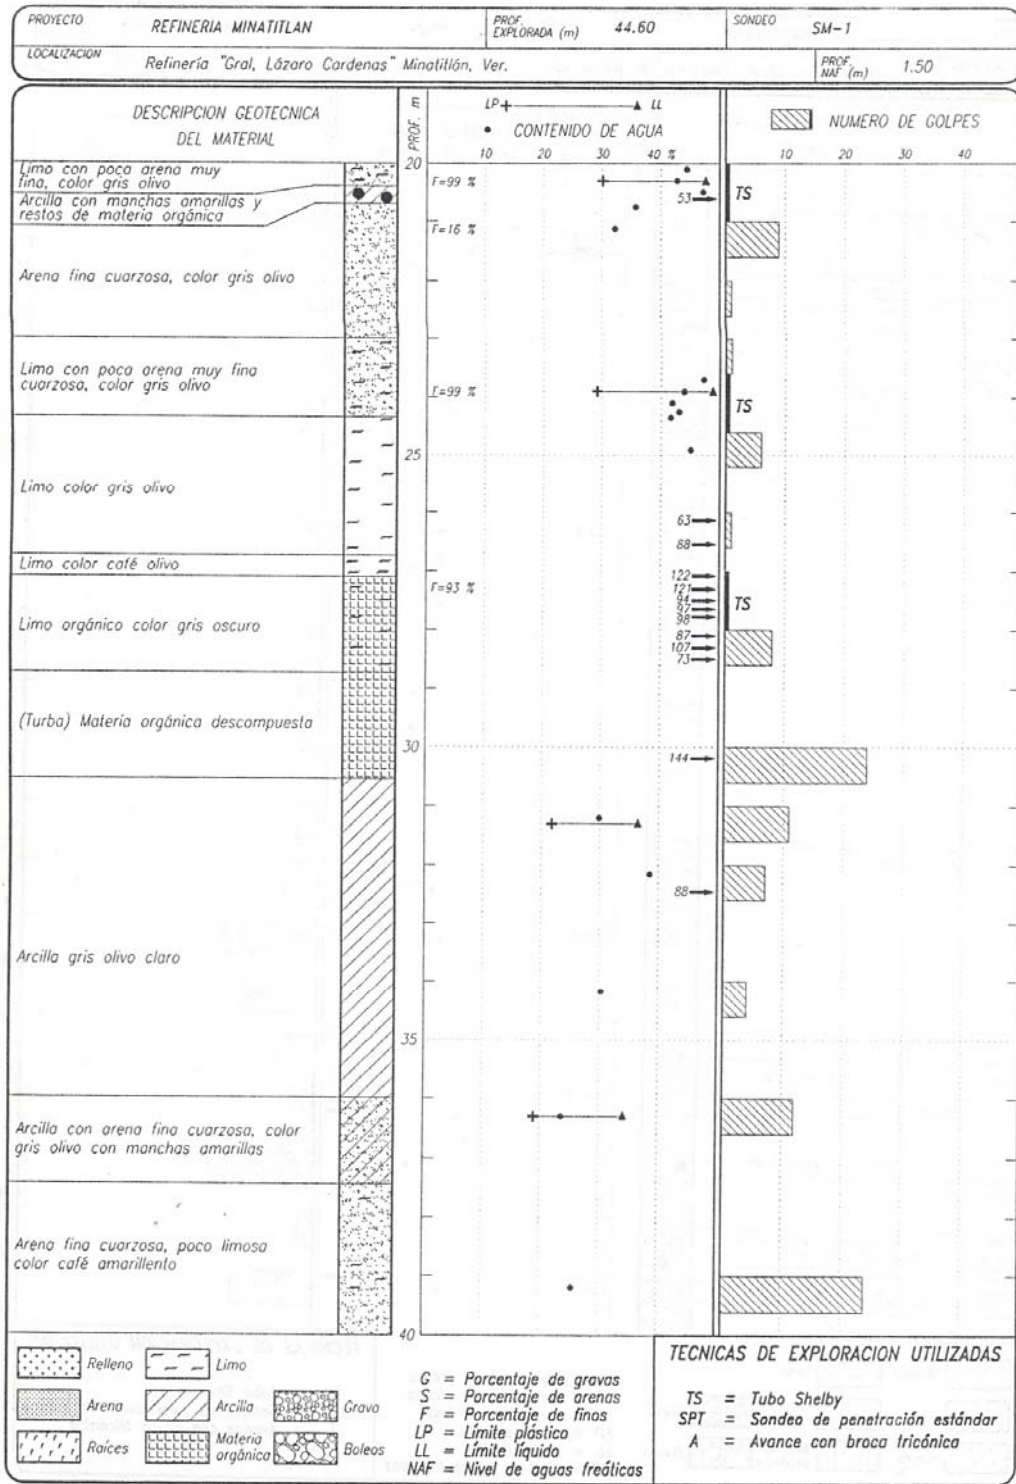


Figura 1.5 Registro de exploración geotécnica (SPT) en el Sitio 1, Minatitlán - Veracruz.



Figura 1.6 Registro de exploración geotécnica (SPT) en el Sitio 2, Minatitlán - Veracruz, (continúa).




Figura 1.7 Registro de exploración geotécnica (SPT) en el Sitio 2, Minatitlán - Veracruz.




Figura 1.8 Registro de exploración geotécnica (SPT) en el Sitio 3, Minatitlán – Veracruz, (continúa).

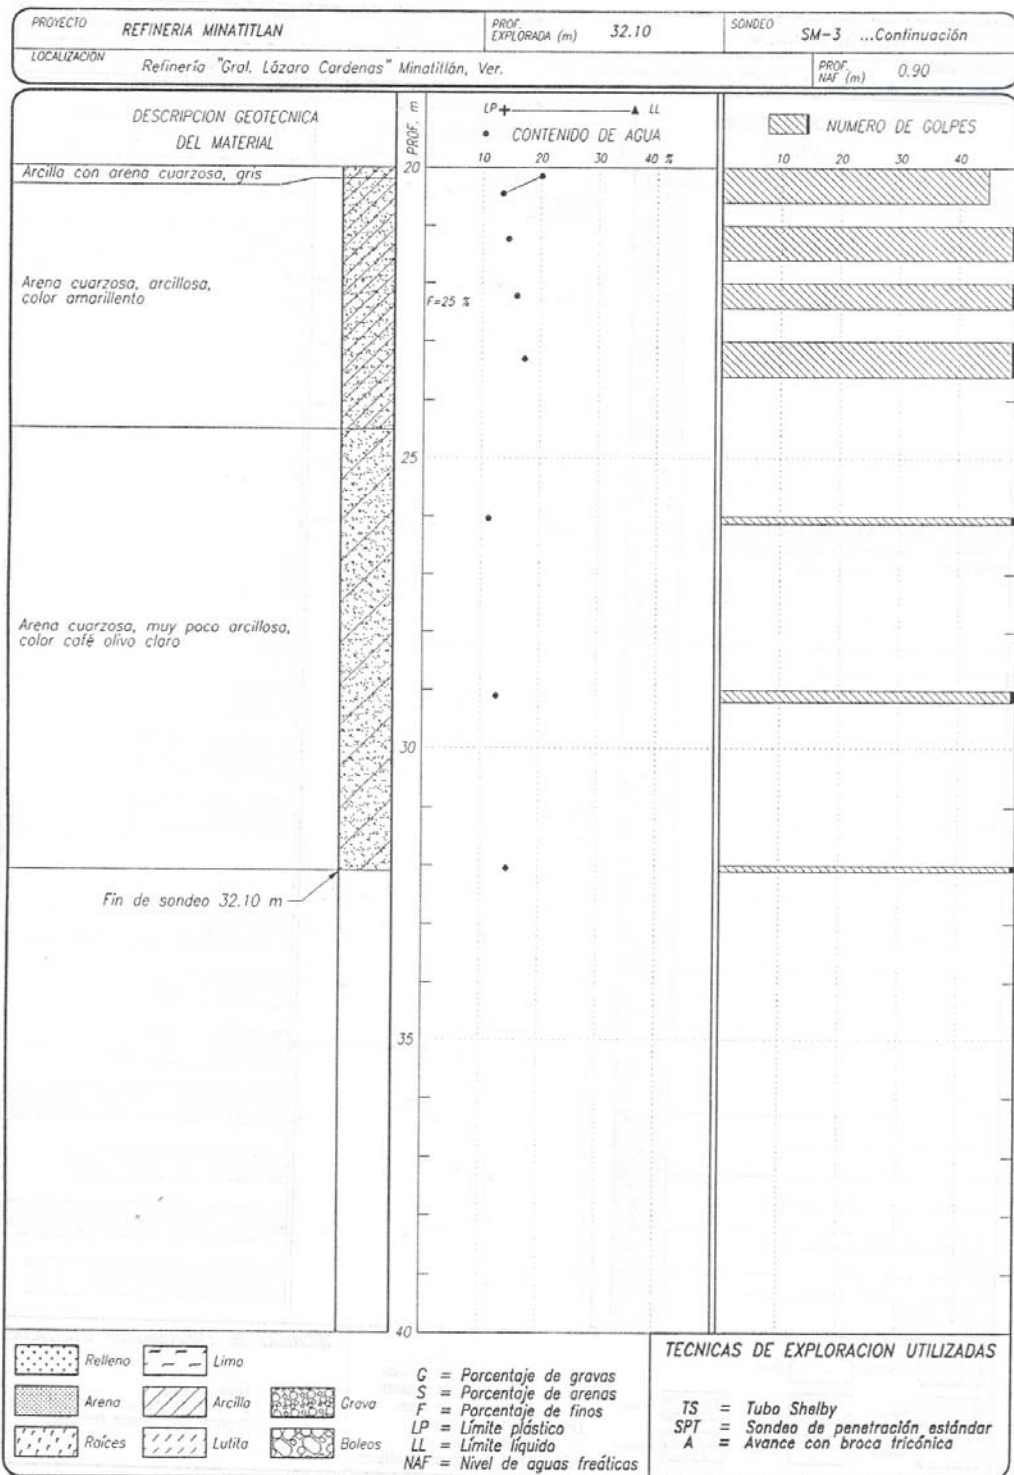


Figura 1.9 Registro de exploración geotécnica (SPT) en el Sitio 3, Minatitlán - Veracruz,

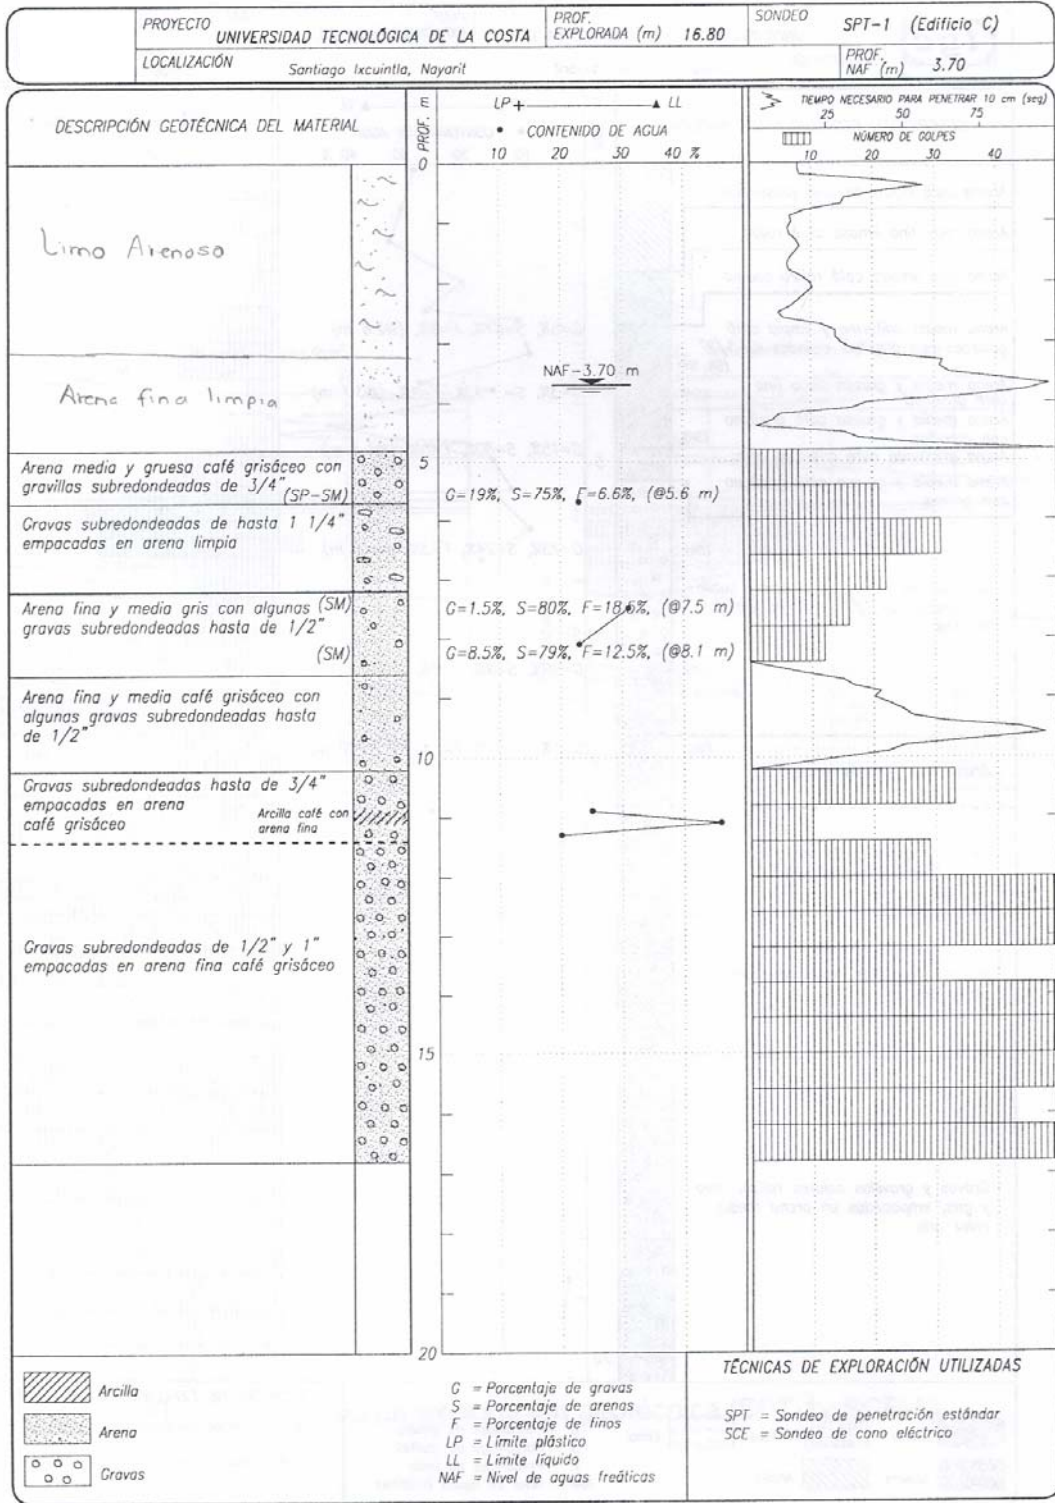


Figura 1.10 Registro de exploración geotécnica (SPT) en el Sitio 1, Santiago Ixcuintla – Nayarit.




Figura 1.11 Registro de exploración geotécnica (SPT) en el Sitio 5, Zapotlán - Hidalgo, (continúa).




Figura 1.12 Registro de exploración geotécnica (SPT) en el Sitio 5, Zapotlán - Hidalgo,

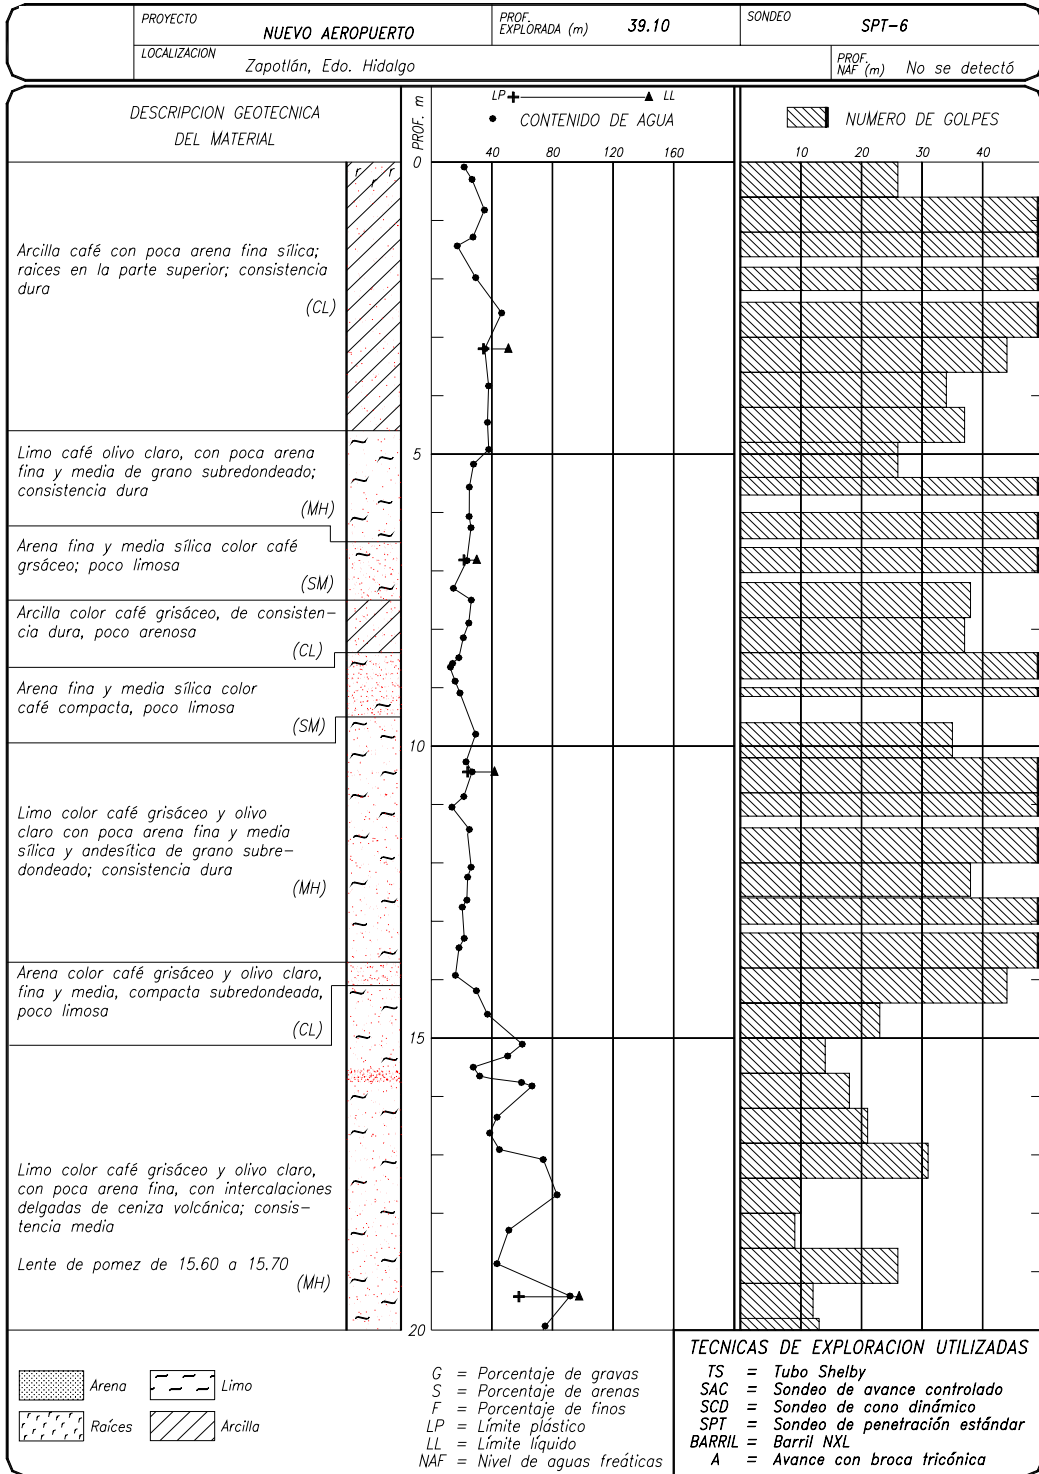


Figura 1.13 Registro de exploración geotécnica (SPT) en el Sitio 6, Zapotlán - Hidalgo, (continúa).




Figura 1.14 Registro de exploración geotécnica (SPT) en el Sitio 6, Zapotlán - Hidalgo.

ANEXO 2

MEDICIÓN DE LA VELOCIDAD DE PROPAGACIÓN DE ONDAS EN CAMPO

A continuación se describen las técnicas más comunes en la determinación de las propiedades dinámicas del suelo en campo.

Pozos cruzados (cross-hole)

El ensayo sísmico *cross-hole*, de pozos cruzados o de sondeos en paralelo permite medir la velocidad de propagación de ondas de cuerpo compresionales y cortantes (V_P y V_S respectivamente) para puntos colocados a la misma profundidad. Es necesario realizar un mínimo de dos barrenos de igual diámetro alineados horizontalmente y conservando una separación constante; uno de los sondeos es usado como fuente y los otros como sondeos receptores.

El material del ademe puede ser aluminio o plástico y su diámetro no debe ser menor a 7.6 cm. con el fin de colocar los geófonos acuñados contra el mismo; en su interior se deslizan un conjunto de geófonos, el espacio entre el ademe y la pared del barreno se rellena con algún material o se inyecta alguna mezcla para asegurar la transmisión de las ondas. En uno de los barrenos se coloca una varilla con la que por medio de impactos verticales es posible propagar las ondas P y S; las ondas generadas son captadas en los geófonos de los barrenos adyacentes.




Figura 2.1 Sección transversal (Hoar y Stokoe, 1978).




Figura 2.2 Vista en planta (Hoar y Stokoe, 1978).

La perturbación en el barreno fuente se puede realizar a través del penetrómetro en el ensayo de penetración estándar (SPT); para ello, un transductor de velocidad vertical se coloca en la barra de perforación y cuando el martillo golpea el penetrómetro, este produce una señal que dispara el osciloscopio al tiempo que se activa el registro de trazas de los geófonos receptores colocados a la misma profundidad de la perturbación.

Conociendo el tiempo en que se produce el impacto en uno de los barrenos y el tiempo en que hacen su arribo las ondas a los barrenos adyacentes, es posible calcular la velocidad de las ondas de corte para cierta profundidad.

Aunque el método requiere varios barrenos, permite medir la velocidad de la onda de corte en un estrato del suelo y controlar el nivel de deformación del mismo, generar ondas de corte con polarización inversa así como alcanzar grandes profundidades sin problemas de atenuación. Cualquier desviación en la verticalidad de los barrenos introduce errores en la medición de los tiempos de arribo de las ondas.

Pozo abajo (down hole)

Los primeros trabajos relacionados con la obtención de ondas de corte son los que reportan Schwarz y Musser (1972). Warrick (1974), Ballard y Malea (1975), Auld (1977), Beeston y McEvilley (1977) y Wilson (1978). Con esta técnica solo es necesario un barreno y pueden propagarse ondas de corte con polarización inversa; las ondas de corte generadas y detectadas durante la prueba se propagan verticalmente, lo que es similar para efectos de un sismo que ocurre a gran profundidad.




Figura 2.3 Down Hole, planta (Hoar y Stokoe, 1974).

Para este procedimiento es necesario perforar un sondeo vertical adomado de 7.6 cm. de diámetro y hasta la profundidad de exploración requerida; básicamente consiste en instalar una fuente (F) en la superficie y una serie de geófonos o receptores (R) en el interior del

sondeo a la profundidad de exploración, con el fin de captar el arribo de las ondas generadas en la superficie.




Figura 2.4 Down Hole, perfil (Hoar y Stokoe, 1974)

La manera más común de generar ondas de corte es golpeando un tablón de madera unido finalmente al suelo por medio de un lastre o ancla, colocando un pequeño bloque de concreto de aproximadamente 0.6 m de lado. Se coloca a la profundidad Z un geófono de tres componentes dentro del barreno y se acuña contra el ademe. El impulso se logra mediante el golpe con un martillo de 4.5 kg de peso al bloque de concreto, generando ondas de cuerpo debido al impacto.

Se registra la traza del impacto y las trazas de llegada de las ondas del geófono. El procedimiento se repite de cada 1.5 a 3.0 m, hasta la profundidad final.

Con el tiempo de arribo y la distancia entre el punto de perturbación al receptor, se pueden calcular las ondas compresionales (V_p) o las ondas de corte (V_s). Este ensaye mide la velocidad de propagación de ondas promedio entre los puntos de impacto y de medida.

En este método existen dos maneras de obtener la velocidad de la onda de corte: con el método de tramos de avance y con el método de tramos de avance relativos. En el primero, se lleva a cabo el registro del arribo de las ondas en los geófonos a la profundidad deseada y para cada impacto en la superficie. En el método de tramos de avance relativos por cada impacto superficial se realizan dos registros de tiempos de arribo en dos geófonos con una separación a lo largo del barreno.

El rango de deformaciones de este tipo de ensaye está comprendido entre $10^{-1}\%$ y $10^{-3}\%$. Su principal desventaja es la rápida atenuación de la energía con la profundidad.

Pozo arriba (up - hole)

Es similar al tipo pozo abajo, con la única diferencia de que en las pruebas pozo arriba la fuente de impactos o perturbaciones se localiza en el interior del sondeo a una cierta profundidad y el receptor o geófonos detectores se instalan en la superficie.




Figura 2.5 Up Hole, perfil.

Sonda suspendida (suspension p-s logging system)

La fuente de impactos y los sensores están incluidos en un dispositivo que se desplaza a lo largo del barreno. La propagación de onda S es en el sentido del eje del barreno, mientras que las ondas P se propagan en dirección perpendicular a éste.




Figura 2.6 Ensayo de sonda suspendida visto de perfil

Al aplicar una fuerza en un excitador suspendido en agua o cualquier otro fluido se generan cambios de presión en el frente y en la parte posterior de este, estos cambios de presión son de signo contrario.

Las partes del barreno son excitadas indirectamente por el movimiento del fluido, bajo la hipótesis de que el agua es incompresible. El sistema de excitación lo conforma una bobina móvil electromagnética. Las bobinas se colocan en las aberturas en donde se produce un cambio magnético gracias a un sistema permanente de magneto y yugo. La bobina se mueve suavemente en dirección horizontal, de tal forma que con solo interrumpir la corriente en la bobina, su movimiento cambia de dirección.

El agua contenida en el barreno se mueve en fase con las paredes del mismo, la detección del desplazamiento del barreno puede reemplazarse por el desplazamiento del agua, si la longitud de la onda S es suficientemente más grande que el diámetro del barreno, ambos desplazamientos son iguales. Consecuentemente, el problema puede tratarse suponiendo que el barreno tiene paredes rígidas y el agua es incompresible.

Los sensores utilizados para detectar ondas de corte son del tipo libremente suspendido y se mueven en fase con el agua. La fuente y los detectores están conectados por un tubo flexible y elástico para evitar la incidencia del ruido o de algunas otras interferencias, aunque para ello la sonda cuenta con un sistema de filtros. El impulso generado en la fuente se detecta en los sensores superiores que están a una separación constante (0.5 o 1.0 m).

Con este método se pueden alcanzar grandes profundidades de exploración, además de que se eliminan los problemas de refracción de ondas. Sin embargo, es más costoso que los métodos anteriores.

La velocidad de onda se calcula mediante la siguiente expresión:

$$V_s = \frac{1}{t_{s2} - t_{s1}}$$

donde:

t_{s1} : Tiempo de arribo en el sensor 1, en segundos.

t_{s2} : Tiempo de arribo en el sensor 2, en segundos.

V_s : Velocidad de la onda de corte a cierta profundidad (m/s)

Cono sísmico

Los primeros trabajos realizados con cono sísmico son reportados en la Universidad de British Columbia en Canadá (Rice, 1984). Los componentes principales del cono sísmico son los acelerómetros, celda de carga, transductor de presión de poro, un sistema de adquisición y

visualización de datos. El dispositivo estaba formado por dos paquetes de geófonos (radial, vertical y transversal) espaciados 1.00 m, funda de fricción de 225 cm²., sección transversal de 15 cm² y una punta cuyo ángulo de ataque era de 60°.

En México los primeros trabajos efectuados con cono sísmico fueron realizados por el Instituto de Ingeniería de la UNAM (Ovando, Sámano y Díaz, 1991). La forma de generar las ondas de cortante y la interpretación de los resultados fue similar a aquella empleada por Rice (1984) y Robertson et al, (1986); posteriormente se desarrollo en el Instituto de Ingeniería de la UNAM un cono sísmico como dispositivo para medir la velocidad de onda de corte en el campo (Contreras G., Tesis UNAM 1997).




Figura 2.7 Esquema del sondeo de cono sísmico (SCS)

En la prueba de cono sísmico se generan ondas en la superficie del terreno mediante impactos. Las ondas generadas dentro de la masa de suelo se registran con sensores colocados dentro de barras de perforación hincadas en el suelo. Conocido el tiempo que tardan en viajar desde la superficie hasta el punto de medición, se determina la velocidad promedio de las ondas generadas. En la superficie del terreno se instala un geófono cuya señal se utiliza para definir el tiempo en el que se inicia el impacto.

El ensaye consiste en hincar en el suelo un cono con punta cónica en cuyo interior se encuentran un par de acelerómetros verticales que responden a la excitación provocada

con impactos en la superficie del suelo con un mazo y una placa convencional. Este tipo de prueba es similar a una prueba tipo *Down Hole*. Con esta técnica se obtiene la velocidad de propagación de las ondas de corte V_s en cada profundidad de interés. Como resultado de este tipo de sondeos se obtiene un perfil de velocidad de ondas de corte contra profundidad. Los sensores con los que se detectan las ondas de corte generadas en la superficie se encuentran cerca de una punta cónica que se hace penetrar a presión dentro del terreno.

ANEXO 3

REDES NEURONALES BIOLÓGICAS

El cerebro humano se compone de decenas de billones de neuronas interconectadas formando circuitos o redes que desarrollan funciones específicas. Una neurona típica (ver figura 3.1) recoge señales procedentes de otras neuronas a través de una pléyade de delicadas estructuras llamadas dendritas. La neurona emite impulsos de actividad eléctrica a lo largo de una fibra larga y delgada denominada axón, que se escinde en millares de ramificaciones.




Figura 3.1 Neurona y conexiones sinápticas.

Las extremidades de estas ramificaciones llegan hasta las dendritas de otras neuronas y establecen unas conexiones llamadas sinapsis, en las cuales se produce una transformación del impulso eléctrico en un mensaje neuroquímico mediante la liberación de unas sustancias llamadas neurotransmisores (ver figura 3.2). El efecto de los neurotransmisores sobre la neurona receptora puede ser excitatorio o inhibitorio, y es variable, de manera que se puede hablar de fuerza o efectividad de una sinapsis.




Figura 3.2 Neurona y conexiones sinápticas.

Las señales excitatorias e inhibitorias recibidas por una neurona se combinan, y en función de la estimulación total recibida, la neurona toma un cierto nivel de activación, que se traduce en la generación de breves impulsos nerviosos con una determinada frecuencia o tasa de disparo, y su propagación a lo largo del axón hacia las neuronas con las cuales sinapta.




Figura 3.3 Activación y disparo de una neurona.

De esta manera la información se transmite de unas neuronas a otras y va siendo procesada a través de las conexiones sinápticas y las propias neuronas. El aprendizaje de las redes neuronales se produce mediante la variación de la efectividad de las sinapsis, de esta manera cambia la influencia que unas neuronas ejercen sobre otras, de aquí se deduce la arquitectura, el tipo y la efectividad de las conexiones en un momento dado, representando en cierto modo la memoria o estado de conocimiento de la red.

Tabla 3.1 Comparación entre las neuronas biológicas reales y las unidades de proceso artificiales

Redes Neuronales Biológicas	Redes Neuronales Artificiales
Neuronas	Unidades de proceso
Conexiones sinápticas	Conexiones ponderadas
Efectividad de las sinapsis	Peso de las conexiones
Efecto excitatorio o inhibitorio de una conexión	Signo del peso de una conexión
Efecto combinado de las sinapsis	Función de propagación o de red
Activación y tasa de disparo	Función de activación y salida

ANEXO 4

REDES DE RETROPROPAGACIÓN (BACK-PROP)

Origen

Al parecer el algoritmo fue ideado a principios de los 70 por Werbos, y redescubierto a principios de los 80 por Parker y Rumelhart independientemente, sin embargo, no se hizo popular hasta 1986, cuando Rumelhart, Hinton y Williams presentaron una descripción clara y concisa del mismo. Y es que en un primer momento no se valoró como se merecía. El hecho de que permaneciera en el olvido tanto tiempo también debe ser una consecuencia de la condición interdisciplinar del campo, repartido entre las matemáticas y ciencias de la computación, las neurociencias y la psicología.

Desde 1986 han surgido nuevas versiones que han tratado de aumentar la velocidad de convergencia del algoritmo y han tratado de superar algunos de sus inconvenientes, como la tendencia a alcanzar mínimos locales y no globales, punto que será discutido más tarde.

Descripción matemática del algoritmo de retropropagación

Se explica una versión del algoritmo (Hinton, 1992) para redes con las siguientes características:


- No recurrentes
- Función de activación sigmoideal
- Capas totalmente interconectadas
- Operación totalmente sincrónica

Proceso:

1. De manera aleatoria se toman los pesos de las conexiones.
2. Se presenta un patrón de entrada y calculamos la salida.
3. Dada una unidad j -ésima de la capa de salida y i -ésimas de la capa oculta inmediatamente anterior, calculamos la entrada total ponderada y la salida o activación de la misma.

$$x_j = \sum_{i=1}^n (y_i \cdot w_{ij})$$

$$y_j = \frac{1}{1 + e^{-x_j}}$$



4. Una vez computadas las actividades de todas las unidades de salida se calcula una estimación del error, generalmente una función cuadrática de los errores individuales cometidos por cada unidad, siendo cada error individual la diferencia entre la salida deseada y la obtenida.

$$E = \frac{1}{2} \sum_j (d_j - y_j)^2$$

siendo d_j la salida deseada para la unidad j -ésima.

Nota: Se van a indicar por un lado las expresiones matemáticas y por otro lado la explicación intuitiva de cada paso. Conviene recordar que nuestro objetivo es calcular como varía el error al variar el peso de cada conexión (tasa de variación del error respecto al peso de una conexión, EP)

5. Cálculo de la rapidez de variación del error al cambiar la actividad de cada unidad de salida (EA, error respecto a la actividad)

$$EA_j = \frac{\partial E}{\partial y_j} = d_j - y_j$$

es justamente la diferencia entre la salida deseada y la salida real obtenida, es decir, la diferencia entre la actividad deseada y la actividad real

6. Cómputo de la rapidez de variación del error al cambiar la entrada total que recibe cada unidad de salida.

$$\delta_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial x_j} = EA_j y_j (1 - y_j) = y_j (1 - y_j) (d_j - y_j)$$


es igual a la tasa de variación del error al variar su activación multiplicado por la tasa de variación de la activación al diferenciar su entrada (que es justamente la derivada de la función sigmoidea).

7. Cálculo de la rapidez de variación del error al ser modificado un peso de la conexión aferente a una unidad de salida.

$$EP_{ij} = \frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial w_{ij}} = \delta_j \cdot y_j$$

Es igual a la tasa de variación del error al variar su entrada, por la tasa de variación de la entrada al diferenciar ese peso.

Hasta ahora sabemos calcular el EA sólo para las unidades de salida. En este caso no tenemos una estimación directa del error aportado por cada unidad oculta; aquí es donde interviene la retropropagación o propagación hacia atrás del error:



La unidad i -ésima de la capa oculta afecta a todas las unidades de salida, por lo tanto, para estimar como cambia el error al variar la actividad de esa unidad oculta, habrá que sumar los efectos individuales de su actividad sobre todas las neuronas de salida. Cada efecto individual sobre el cambio del error, será igual a la tasa de variación del error de la unidad de salida al cambiar su entrada total, multiplicado por la tasa de variación de su entrada al variar la actividad de la unidad oculta.

$$EA_i = \frac{\partial E}{\partial y_i} = \sum_{j=1}^m \left(\frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial y_i} \right) = \sum_{j=1}^m (\delta_j \cdot w_{ij})$$

8. Conociendo EA para las unidades de cualquier capa podemos calcular δ y EP con las expresiones ya conocidas.

$$\delta_i = EA_i y_i (1 - y_i) = y_i (1 - y_i) \sum_{j=1}^m (\delta_j w_{ij})$$

$$EP_{ij} = \delta_i \cdot y_{ij}$$

9. Disponiendo de la tasa de variación del error respecto al peso de una conexión (EP), podemos usar distintas reglas para modificar ese peso con el fin de reducir dicho de error. Una de las primeras reglas que aprovechó este algoritmo es la regla delta generalizada, que calcula el incremento a aplicar a un peso como una proporción directa de la tasa de variación del error. Siendo h el coeficiente de aprendizaje, típicamente con valores comprendidos entre 0.01 y 1.0.

$$\Delta w_{ij} = \eta \delta_j y_i$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}$$

Valoración

El algoritmo de retropropagación presenta ciertos problemas, algunos referentes a su dudosa plausibilidad neurofisiológica, y otros referentes a ciertos aspectos computacionales.

- Los resultados dependen de los valores iniciales –aleatorios- de las conexiones. Esto hace que sea conveniente entrenar varias redes con distintos valores iniciales y elegir la que mejor funcione.
- A veces se requiere mucho tiempo para obtener soluciones sencillas. Este problema se reduce gracias al aumento de potencia de los procesadores y al uso de nuevas tecnologías, sin embargo, el tiempo de cómputo aumenta mucho al aumentar el tamaño de la red. Si bien el volumen de cálculo es proporcional al número total de conexiones, en la práctica, al aumentar el tamaño de la red, hacen falta más ejemplos de aprendizaje, y eso provoca un aumento en el tiempo de aprendizaje. Para incrementar la velocidad de convergencia se han desarrollado diferentes modificaciones del algoritmo básico (quick propagation, por ejemplo).
- La "interferencia catastrófica" o empeoramiento en el rendimiento del sistema, como consecuencia de la incorporación de nuevos ejemplos de aprendizaje.
- La parálisis: esto sucede cuando los pesos quedan ajustados a valores muy grandes, esto hace operar a las unidades de proceso con una activación muy próxima a 1, y por lo tanto, el gradiente del error tiende a 0, en consecuencia no se producen modificaciones en los pesos, el aprendizaje queda detenido. Por eso es conveniente tomar de forma aleatoria los pesos de las conexiones con valores pequeños y usar la tasa de aprendizaje también pequeña, a pesar de que el aprendizaje sea un proceso lento.
- Inestabilidad temporal. Si usamos un coeficiente de aprendizaje elevado, se van a producir incrementos grandes en los pesos, de manera que es fácil pasarse de incremento y tener que tratar de compensarlo en el siguiente ciclo, de manera que se producirían oscilaciones continuas. Esto se soluciona usando un coeficiente pequeño, o, para no tener un aprendizaje muy lento, modificar dicho coeficiente de

manera adaptable (aumentarlo si el error global disminuye, y disminuirlo en caso contrario).

- El problema de los mínimos locales. El algoritmo de retropropagación usa una técnica por gradiente descendiente, esto significa que sigue la "superficie del error" siempre hacia abajo, hasta alcanzar un mínimo local, pero no garantiza que se alcance una solución globalmente óptima. Sin embargo, se ha comprobado que el hecho de alcanzar mínimos locales no impide que se consigan resultados satisfactorios. Por otro lado, se han desarrollado métodos para solventar este problema, como el modo de operación asíncrono o probabilístico y el uso de métodos estadísticos, como el equilibrio termodinámico simulado (ver siguiente apartado).
- Podemos considerar el error como una superficie llena de desniveles, si soltamos una pelota caerá en algún valle, pero no necesariamente en el más hondo, sino en el más cercano (un mínimo local). Una idea intuitiva para solucionar esto, sería aplicarle cierta energía a esa superficie agitándola o haciéndola vibrar, esto haría saltar a la pelota de valle en valle, como de los valles más profundos es más difícil salir, tendería a estar en valles cada vez más profundos. Si dejamos de agitar esa superficie poco a poco, al final tendremos la pelota en el valle más profundo de la superficie.
- Otras técnicas que pueden ayudar a no caer en mínimos locales consisten en añadir cierto nivel de ruido a las modificaciones de los pesos de las conexiones. Otra medida propuesta es añadir ruido a las conexiones, pero esto es más útil para darle robustez y aumentar la capacidad de generalización de la red. Estas medidas, por contra, aumentan el tiempo de aprendizaje.

BIBLIOGRAFÍA

ASTM D1586-99 "Standard Test Method for Penetration Test and Split-Barrel Sampling of Soils", American Society for Testing and Materials, West Conshohocken, PA.

Ballard R. F. Jr., "Method for Crosshole Seismic Testing", Geotechnical Engineering Division, ASCE, vol. 102, No. GT12, Dec., Paper 12646, pp: 1261-1273, 1976.

Beeston H. E., Mc. Evilly T. V., "Shear wave velocities from Dow-Hole Measurements" Earthquake Engineering and Structural Dynamics, vol. 5, No. 2, pp: 191-190, 1977.

Campanella R.G., Robertson P.K., "A seismic cone penetrometer to measure engineering properties of soil", Proceedings, 54th Annual International Meeting and Exposition of the Society of Exploration Geophysics, Atlanta, Ga., pp: 138-141, 1984.

Contreras G. R., "Desarrollo y aplicaciones de un dispositivo para medir la velocidad de ondas de corte en el campo", Tesis DEPEFI, UNAM, 1997.

C. R. I. Clayton, "SPT Energy Transmission: Theory, Measurement, and significance", Ground Engineering, Vol. 23 (10), pp: 35-43, 1990.

Díaz R. A., "Determinación de las propiedades dinámicas de los suelos", Tesis DEPEFI UNAM, 2000.

García S, Romo M P and Sarmiento N, "Artificial Neural Network Modeling of Mexico City Ground Seismic Response" Proceedings of the XVth International Conference on Soil Mechanics and Geotechnical Engineering, Istanbul, Turkey, Satellite Conference on "Lessons learned from recent strong earthquakes", pp 155-159, August, 2001.

García S, Romo M P and Sarmiento N, "Modeling ground motion in Mexico City using artificial neural networks ", Geofísica Internacional, Vol. 42, Num. 2, pp 173-183, 2003.

García S, Romo M P and Figueroa-Nazuno J, "Soil dynamic properties determination: A neurofuzzy system approach", The Journal Control and Intelligence System (aceptado para su publicación), 2004.

Hoar R.J., Stokoe K. H., "Generation and measurement of shear waves in situ", Dynamic Geotechnical Testing, ASTM SPT 654, American Society for Testing and Materials, pp. 3-29, 1978.

Imai T., Tonouchi, K., "Correlation of N-Value with S-wave Velocity and Shear Modulus", Proceedings of the Second European Symposium on Penetration Testing, Amsterdam, The Netherlands, pp: 67-72, 1982.

Jafari, M.K., Asghari, A., Rahmani, I., "Empirical Correlation between Shear Wave Velocity (V_s) and SPT-N Value for South of Tehran Soils", Proc. 4th International Conference on Civil Engineering, Tehran, Iran (Persian), 1997.

Jafari M. K., "Dynamic Properties of Fine Grained Soils in South of Tehran", vol. 4 (1), JSEE, Spring 2002.

Jafari, Sykora, D.W. and Koester, P.J., "Correlations between Dynamic Shear Resistance and Standard Penetration Resistance in Soils", *Earthquake Engineering and Soil Dynamics II*, pp: 389-404, 1988.

Lippman R. P., "An introduction to computing whit neural networks", IEE Acoust Speech Signal Process Mag, 4(2), pp: 4-22, 1987.

Ohta, Y., Goto, N., "Empirical Shear Wave Velocity Equations in Terms of Characteristic Soil Indexes", *Earthquake Engineering and Structural Dynamics*, 6, pp: 167-187, 1979.

Ohsaki Y., and Iwasaki R., "On Dynamic Shear Moduli and Poisson's Ratio of Soil Deposits", *Soil and Foundations*, vol 13 (4), pp: 61-73, 1973.

Ovando E., Miguel P. R., "Estimación de la velocidad de ondas s en la arcilla de la ciudad de México con ensayos de cono", *Sismogeodinámica* 2, pp: 107-123, 1991.

Ovando E., Sámano A., Díaz L., "Un dispositivo para la medición de velocidades de propagación de ondas sísmicas", Informe del Instituto de Ingeniería, UNAM, al Departamento del Distrito Federal, 1991.

Ovando E., Sámano A., Contreras R., "Ensayos de cono sísmico en la Ciudad de México", Informe del Instituto de Ingeniería, UNAM, al Departamento del Distrito Federal, 1993.

Rojas E., García S., Ovando E., "Modelos de aprendizaje automático para la estimación de velocidad de ondas de corte a partir de la resistencia a la penetración", XV Congreso Nacional de Ingeniería Sísmica, SMIS C. A., México DF, 2005.

Robertson P. K., Campanella R. G., Gillespie D., Rice A., "Seismic CPT to measure in situ shear wave velocity" ASCE., *Journal of Geotechnical Engineering*, 112(GT8), pp: 791-803, 1986.

Romo M P and García S R, "Neurofuzzy mapping of CPT values into soil dynamics properties", *International Journal of Soil Dynamics and Earthquake Engineering*, Vol. 23, Num. 6, August, pp 473-482, 2003.

Romo M P, Rangel J L, García S and Ovando E, "Forecasting of Shear Wave Velocities from CPT Resistances by Means of ANN", YEAR 2000 - GEOTECHNICS, Geotechnical Engineering Conference, Asian Institute of Technology, Tailand, Vol I, pp 75-80, November, 2000.

Seed, H. B. Idriss, I. M., Arango, I., "Evaluation of Liquefaction Potential Using Field performance Data", *Journal of the Geotechnical Engineering Division, American Society of Civil of Civil Engineers*, Vol 111 (12), pp: 1425-1445, 1983.

Schmertmann, J., Palacios A., "Energy dynamics SPT." J. Geotech. Engrg. Div. ASCE, 105(8), 909-926, 1979.

Shibata, T., "The Relationship Between the N-value and S-wave Velocity in the Soil Layer", Disaster Prevention Research Laboratory, Kyoto University, Kyoto, Japan, 1970.

Skempton A. W., "Standard penetration test procedures and the effects in sands of overburden pressure, relative density, particle size, ageing and overconsolidation", Geotechnique 36 (3), pp: 425-447, 1986.

S. S. C. Liao, R. V. Withman, "Overburden Correction Factors for SPT in Sand", Journal of Geotechnical Engineering, A.S.C.E., Vol 112 (3), pp: 373-377, 1986.

Steven C., Raymond P., "Métodos numéricos para ingenieros", tercera edición, P., McGraw-Hill, México, 1999.

Stokoe K. H., Woods R. D., "In situ shear wave velocity by Cross-Hole Method", Journal of the Soils Mechanics and Foundations Division, Proceedings of the American Society of Civil Engineering, May 1972.

TGC Geotecnia, "Evaluación del potencial de licuación Universidad Tecnológica de la costa Santiago Ixcuintla, Nayarit", Informe para la Secretaría de Obras Públicas del Estado de Nayarit, 2002.

Waltz, D., Feldman, J. A., "Connectionist Models and Their Implications" Norwood, NJ: Ablex, pp: 1-12, 1988.

Wonnacott, Ronald J. W., "Introducción a la estadística", Limusa Noriega Editores, segunda edición, México, 1997.