UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA DE CAMINOS, CANALES Y PUERTOS

MÁSTER UNIVERSITARIO EN SISTEMAS DE INGENIERÍA CIVIL

PROYECTO DE FIN DE MÁSTER:

Predicción de la estabilidad de presas heterogéneas mediante redes neuronales artificiales

AUTOR:

César Costa Costa

DIRECTORES:

Miguel Ángel Toledo Municio
Rafael Morán Moya

Marzo, 2016

Predicción de la estabilidad de presas heterogéneas mediante redes neuronales artificiales

(Parte A)

Autor: César Costa Costa

Directores: Miguel Ángel Toledo Municio

Rafael Morán Moya

ÍNDICE

1. INTRODUCCIÓN 3
2. PRESAS HETEROGÉNEAS CON NÚCLEO CENTRAL 4
3. LA FILTRACIÓN 6
3.1. Red de corriente 7
3.2. Condiciones de contorno 9
4. ESTABILIDAD DE LAS PRESAS DE MATERIALES SUELTOS 10
4.1. Métodos de equilibrio al límite 11
4.2. Método simplificado de Bishop 15
4.3. Propiedades geotécnicas de los materiales 16
4.3.1. Núcleo 17
4.3.2. Espaldones 19
4.3.3. Cimiento 21
5. REDES NEURONALES ARTIFICIALES 23
5.1. Neuronas y pesos sinápticos 24
5.2. Estrategia de aprendizaje 26
5.3. Arquitectura de la red 27
5.4. Funciones de activación 28
5.5. Flujo de datos 31
5.6. Algoritmo retro-propagación 32
5.7. Funciones de entrenamiento 33
6. ESTUDIOS SIMILARES PREVIOS 35
7. PROPUESTA DE OBJETIVOS 38
8. REFERENCIAS 39

1. INTRODUCCIÓN

Hoy en día resulta difícil concebir la gestión del agua sin la existencia de las presas, tanto en sistemas de aprovechamiento de agua como en los de control de defensa frente a avenidas. De la variedad de presas, se destacan las de materiales sueltos por su gran capacidad de adaptación a las condiciones topográficas, geológicas y a los materiales disponibles en la zona de implantación. Por esta razón, los ingenieros geotécnicos se encuentran constantemente desarrollando técnicas y modelos que permitan estimar de manera adecuada el comportamiento de las presas bajo diferentes solicitaciones.

Múltiples han sido los métodos desarrollados para el cálculo estimado de la estabilidad de presas, se destacan los métodos de equilibrio al límite han sido usados en la ingeniería geotécnica por muchas décadas (Duncan, 1996). Con la llegada de los ordenadores, y su posterior facilidad de acceso a casi todo profesional de la ingeniería, han revolucionado la manera de enfrentar los retos inherentes al cálculo y estimación de la estabilidad de las infraestructuras, quizá principalmente porque esa accesibilidad ha permitido desarrollar comercialmente programas computacionales que potencian las posibilidades de mejorar las técnicas existentes (Krahn, 2004b).

Las interacciones entre los factores que pueden afectar a la estabilidad de taludes son complejas, obedecen a múltiples factores, y a menudo son difíciles de describir en forma matemática, esto supone un reto importante para la predicción de la estabilidad de presas de materiales sueltos.

El potencial de los sistemas de redes neuronales deriva de la utilidad deriva del comportamiento de sus elementos dentro del sistema, en lugar del conocimiento de sus relaciones explícitas. Una red neuronal provee un mecanismo computacional que tiene la capacidad de representar el mapeo dentro de un sistema de información multi-factor y otro, dando un conjunto de datos que representan el mapeo (Ellis, Yao, Zhao, & Penumadu, 1995).

2. PRESAS HETEROGÉNEAS CON NÚCLEO CENTRAL

Las presas de materiales sueltos pueden clasificarse en tres grandes grupos de acuerdo con la ubicación del elemento principal de estanqueidad: homogéneas, de núcleo y de pantalla. Según el Comité Nacional Español de Grandes Presas (SPANCOLD, 2015), en España existen 441 presas de materiales sueltos que representan cerca del 38% del total, de las cuales 259 son presas homogéneas, 102 son de núcleo de arcilla, 60 de pantalla y otras 20 son presas de materiales sueltos combinadas con mampostería y hormigón.

Tomando en cuenta los criterios de selección utilizados en España podría concluirse que las presas homogéneas tienen generalmente menos de 25 m de altura. Sólo cuatro de ellas tienen alturas por encima de los 50 m. Las presas de núcleo, vertical o inclinado, han resultado ser más adecuadas cuando la altura está por encima de los 50 m y el cimiento tiene la suficiente capacidad para soportar unos taludes exteriores más escarpados, corresponde precisamente a esta tipología la presa de materiales sueltos más alta de España, la presa Canales de 155 m de altura. En la conformación de los espaldones que abrigan al núcleo, se admiten hoy en día materiales con calidades menores a las exigidas años atrás (SPANCOLD, 2015).

La selección del tipo de presa de materiales sueltos depende en gran medida de los materiales disponibles en las inmediaciones de la cerrada, en las zonas de préstamo, de esta manera, cuando existe un único material, relativamente impermeable, la opción más ventajosa suele ser construir una presa homogénea. Por otro lado, cuando los materiales impermeables no abundan pero coexisten con otros más permeables, las presas de núcleo abrigado por espaldones de materiales de otras características son generalmente la mejor solución. Es claro que las presas con núcleo diferenciado son más versátiles en relación con la disponibilidad de los materiales cercanos a la cerrada, característica fundamental en presas de alturas importantes y consecuentemente grandes volúmenes de material requeridos para su construcción.

Como se mencionó anteriormente, las presas de núcleo diferenciado son una tipología muy frecuente en España cuya ventaja principal radica en el empleo óptimo de los materiales próximos disponibles que se distribuyen en el interior de la sección tipo en función de sus características geotécnicas. El presente estudio está enfocado en las presas de núcleo central, la Fig. 1 muestra un esquema con los elementos principales de esta tipología de presas.

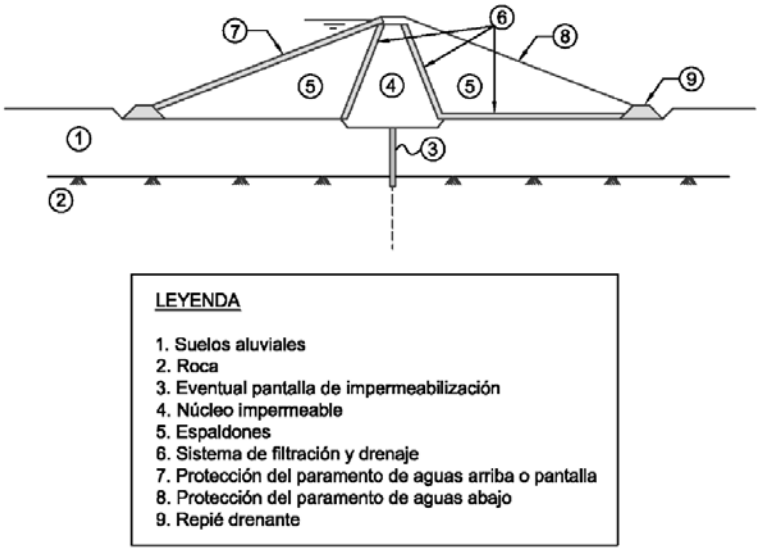

Fuente: (SPANCOLD, 2015)

Figura 1: Elementos principales de las presas de materiales sueltos con núcleo diferenciado

3. LA FILTRACIÓN

El flujo de agua que se filtra a través de una presa de materiales sueltos o de su cimiento produce los siguientes efectos: a) la pérdida de agua, efecto que suele ser el menos importante y el más fácil de controlar; b) la generación de presiones internas con componentes opuestas al efecto estabilizador del peso, además al estar mojados los materiales, su cohesión y su resistencia al rozamiento disminuyen, añadiéndose estos efectos al de las componentes desestabilizadoras de las presiones internas; y c) el arrastre de partículas en zonas con materiales finos producido por el paso del agua, y el peligro consecuente de erosión interna. Este fenómeno es conocido como sifonamiento o piping. De los tres efectos arriba descritos, el sifonamiento es el más peligroso, porque afecta de manera directa a la estabilidad de la presa; este efecto es, después del vertido sobre la presa, la causa más importante de accidentes o roturas de las presas de materiales sueltos. El sifonamiento es, además, el efecto más difícil de controlar de los tres que se han

enunciado. Por otro lado, el control de los efectos desestabilizadores de la presión intersticial depende del drenaje, por esta razón, los cálculos de estabilidad son hasta cierto punto predecibles (Vallarino, 2006).

3.1. Red de corriente

La expresión de la Ecuación 1 es común a todos los fenómenos de potencial y define dos familias de curvas ortogonales entre sí. La primera familia la forman las trayectorias de las partículas de agua o líneas de corriente (LDC) que son las envolventes del vector de la velocidad. La otra familia es la de las líneas equipotenciales (LEP) que cortan ortogonalmente a las anteriores. En la Ecuación 1, h es un potencial.

$$\nabla h = \frac{\partial^2 h}{\partial x^2} + \frac{\partial^2 h}{\partial y^2} = 0 \qquad \text{Ecuación 1}$$

De manera general, la red de corriente se determina por diferencias o elementos finitos, por aproximaciones sucesivas o mediante modelos. Una primera consecuencia de la Ecuación 1 es que la red de corriente es únicamente una función de las formas y dimensiones del medio permeable y de la posición relativa del nivel del agua, pero es independiente del coeficiente de permeabilidad. Suele dibujar la red de corriente espaciando las curvas según diferencias constantes entre cada potencial para las equipotenciales y de nivel de arranque inicial para las de corriente (ver Fig. 2). Dos líneas de corriente definen un tubo de flujo de agua, entre estas líneas el caudal filtrado es constante, por lo que en las zonas donde estas líneas se aproximan, la velocidad aumenta. De esta manera, la red de corriente está definida por cuadriláteros curvilíneos relativamente semejantes en todo el espacio, ya que sus dos dimensiones se acortan o se alargan

simultáneamente según la velocidad aumente o disminuya. La más alta de todas las LDC se llama línea de saturación (LDS), y representa el borde superior de la zona filtrante y su contacto con la presión atmosférica, por encima de la LDS el material se encuentra seco, ajeno al fenómeno (Vallarino, 2006).

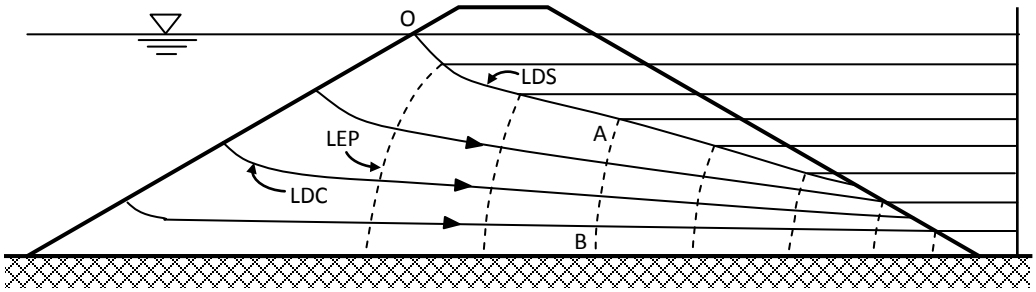

Fuente: (Vallarino, 2006)

Figura 2: Esquema de red de corriente

La forma de la red de corriente viene fijada por las condiciones de borde o de contorno. En las zonas limitadas por cuerpos impermeables el flujo está obligado a seguir una trayectoria por las LDC de forma paralela al borde; otras fronteras definitorias son los paramentos. En el paramento de aguas arriba, las LDC son normales a este, debido a que el agua no se mueve a lo largo del paramento, sino a través de él; por tanto, el paramento es una LEP, la primera y de potencial más alto, definida por el nivel del embalse. El paramento libre no es una LDC ni una LEP, es una isobara de presión nula, en cada punto del paramento su potencial es igual a su altura sobre la referencia. El conocimiento de la red de corriente tiene dos aplicaciones: el conocimiento de la filtración que se producirá a través de la presa y el cálculo de las presiones

intersticiales. En las presas de materiales sueltos es conveniente conocer las presiones en varios puntos, por su efecto singular y por su acción conjunta a lo largo de una superficie interior a la presa, ya que dichos efectos contribuyen a un posible deslizamiento de la masa situada sobre dicha superficie, al restarse al peso a través de sus componentes verticales (Vallarino, 2006).

3.2. Condiciones de contorno

El programa computacional SEEP/W de GeoStudio es un modelo numérico que puede simular matemáticamente el proceso físico real del flujo de agua a través de un medio particular. Especificar las condiciones de contorno de un problema es uno de los componentes clave de un análisis numérico. Las soluciones alos problemas numéricos son una respuesta directa de las condiciones de contorno; sin estas no es posible obtener una solución. La ecuación para el análisis de filtración, al igual que todas las ecuaciones de elementos finitos, justo antes de la resolución de las incógnitas, en definitiva, se reduce a la siguiente expresión:

$$[K]\{H\} = \{Q\} \qquad \text{Ecuación 2}$$

Donde:

[K] =matriz de coeficientes relacionados con la geometría y las propiedades de los materiales,

{H} = vector de la carga hidráulica total en el nodo, y

{Q} = vector del caudal en el nodo.

El objetivo primordial es resolver las principales incógnitas, las cuales en un análisis de filtración son las cargas hidráulicas totales en cada nodo. Las incógnitas se calculan con respecto

a los valores especificados de H en algunos nodos y/o con respecto a los valores especificados de Q en algunos otros nodos. Sin especificar ya sea H o Q en algunos nodos, no se puede obtener una solución de la ecuación de elementos finitos. En un análisis en estado estacionario (steady-state), al menos un nodo de toda la malla debe tener una condición especificada de H. Los valores especificados de H o Q son las condiciones de contorno (Krahn, 2004a).

4. ESTABILIDAD DE LAS PRESAS DE MATERIALES SUELTOS

Existen múltiples estudios en los que se presenta información sobre incidentes, accidentes y roturas en presas, se destacan las publicaciones de la Comisión Internacional de Grandes Presas (ICOLD, 1973; 1983) que ha realizado en varias ocasiones encuestas a nivel mundial para recopilar dicha información. Estos trabajos establecen que el porcentaje más elevado de incidentes tiene lugar en las presas que se encuentran entre los 15 y los 30 m de altura, que corresponde precisamente al grupo que representa el mayor porcentaje de presas construidas. Se conoce también que los casos de mal comportamiento de presas homogéneas de tierra son casi diez veces más numerosos que los ocurridos en presas de núcleo con espaldones de escollera o de gravas, mucho mayor que la proporción existente entre ambos tipos de presas.

Para las presas de materiales sueltos, de manera general, son aplicables los modos de fallo establecidos por ICOLD (1973), descritos a continuación:

1. Sobrevertido o desbordamiento (Insuficiencia frente a la solicitación hidrológica).
2. Inestabilidad de laderas en el vaso (Insuficiencia de resistencia al corte).
3. Inestabilidad dinámica (Insuficiencia ante la solicitación sísmica).

4. Erosión interna del cuerpo de presa (Insuficiencia de estabilidad interna en cuerpo de presa) y/o del cimiento.
5. Inestabilidad de taludes de presa (Insuficiencia de resistencia al corte), pudiendo afectar o no al cimiento.

El presente trabajo está enfocado en el último modo de fallo antes enumerado, la estabilidad de taludes de la presa, este modo de falla es generalmente analizado mediante métodos de equilibrio al límite. Estos métodos requieren información acerca de los parámetros geotécnicos y geométricos de la masa de suelo o roca. En los métodos de equilibrio al límite, la estabilidad de taludes se analiza calculando en primer lugar el factor de seguridad, cuyos valores deben ser determinados por la superficie con mayor probabilidad de fallo, la denominada superficie de deslizamiento crítico. Estos métodos tienen diferentes grados de precisión que depende de cuan adecuada ha sido la hipótesis de simplificación empleada en el análisis.

4.1. Métodos de equilibrio al límite

El modo potencial de falla en roca puede ser en cuña o plano, o circular en suelos y rocas altamente fracturadas. En la evaluación de estabilidad al deslizamiento por medio de los métodos de equilibrio al límite, es necesario determinar la ubicación de la superficie crítica de deslizamiento y el correspondiente valor mínimo del factor de seguridad mediante múltiples pruebas de un considerable número de posibles superficies de deslizamiento. La precisión de estos métodos depende de las hipótesis y de la precisión con la que se mide la resistencia al corte. Generalmente se asume que el suelo es isotrópico y homogéneo, estas hipótesis no

corresponden a la realidad pero pueden llevar a resultados rasonables cuando se aplican con sensatez.

En el análisis de estabilidad de taludes, los métodos de equilibrio al límite han sido usados en la ingeniería geotécnica por muchas décadas. La idea de dividir una potencial masa de deslizamiento en rebanadas verticales fue introducida en los primeros años del siglo veinte, es la técnica de análisis numérico más antiguo en la ingeniería geotécnica. La Fig. 3 muestra una típica masa de deslizamiento dividida en rebanadas y las posibles fuerzas que actúan sobre la rebanada.

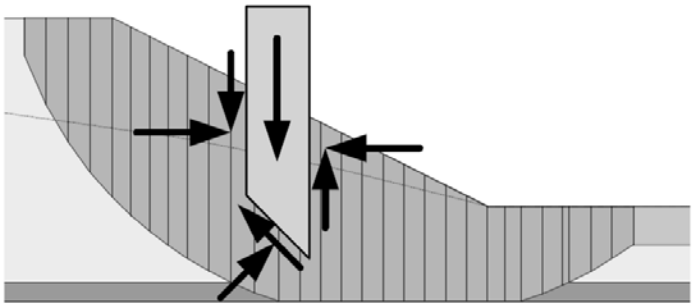

Fuente: (Krahn, 2004b)

Figura 3: Fuerzas actuantes en una rebanada de la masa potencial de deslizamiento

En 1916, Petterson (1955) presentó el análisis de estabilidad del muelle Stigber en Suecia, análisis en el que la superficie de deslizamiento fue asumida como circular y la masa de deslizamiento fue dividida en rebanadas. Durante las próximas décadas, Fellenius (1936) introdujo el método Ordinario o Sueco. Posteriormente Janbu (1954) y Bishop (1955)

introdujeron avances en el método. La llegada de los ordenadores electrónicos en los 60's del siglo anterior hizo posible un manejo más facil de los procesos iterativos inherentes al método, lo cual permitió formulaciones matemáticas más rigurosas como las desarrolladas por Morgenstern y Price (1965) y por Spencer (1967). En la Tabla 1 se presenta un resumen de las características de los métodos de equilibrio para el análisis de estabilidad al deslizamiento.

Tabla 1: Características de los métodos de equilibrio para el análisis de estabilidad al deslizamiento

Método	Características
Método ordinario de rebanadas (Fellenius, 1936)	Sólo para superficies de deslizamiento circular Satisface el equilibrio de momentos No satisface el equilibrio de fuerzas horizontales o verticales
Método modificado de Bishop (A. W. Bishop, 1955)	Sólo para superficies de deslizamiento circulares Satisface el equilibrio de momentos Satisface el equilibrio de fuerzas verticales No satisface el equilibrio de fuerzas horizontales
Métodos de fuerza de equilibrio (Lowe & Karafiath, 1960)	Cualquier forma de superficie de deslizamiento No satisface el equilibrio de momentos Satisface el equilibrio de fuerzas horizontales y verticales
Método de Morgenstern y Price (Morgenstern & Price, 1965)	Cualquier forma de superficie de deslizamiento Satisface todas las condiciones de equilibrio Permite la variación de la orientación de las fuerzas laterales
Método de Spencer (Spencer, 1967)	Cualquier forma de superficie de deslizamiento Satisface todas las condiciones de equilibrio Se asume que las fuerzas laterales son paralelas
Procedimiento Generalizado de Rebanadas de Janbu (Janbu, 1968)	Cualquier forma de superficie de deslizamiento Satisface todas las condiciones de equilibrio Permite la variación de la ubicación de las fuerzas laterales Problemas numéricos más frecuentes que en algunos otros métodos

Fuente: (Duncan, 1996)

Todos los métodos definen al factor de seguridad como la relación entre la resistencia al corte del suelo y el esfuerzo cortante requerido para el equilibrio; es decir que es la relación de la reacción sobre la acción, expresado en términos de momentos o fuerzas, y, eventualmente, en términos de tensiones, en función de la geometría de la superficie de deslizamiento asumida. En fallos circulares, el factor de seguridad es definido como la relación entre el momento de la resistencia al corte a lo largo del arco de fallo sobre el momento del peso de la masa de fallo, en ambos casos, los momentos son respecto al centro del arco de falla. Otra manera de expresar esta definición es la empleada por Lowe (1967), quien lo define como "el factor por el cual la resistencia al corte del suelo tendría que ser dividido para llevar al talud a un estado de equilibrio apenas estable”.

Históricamente, los métodos de equilibrio para el análisis de estabilidad al deslizamiento fueron desarrollados antes de la llegada de los ordenadores, pero una vez que estuvieron presentes en el mundo de la ingeniería, han revolucionado el análisis de estabilidad al deslizamiento de dos maneras principalmente (Duncan, 1996):

1. Los análisis pueden realizarse usando métodos avanzados que satisfacen todas las condiciones de equilibrio. Consecuentemente los ordenadores han hecho posible estudiar con gran minuciosidad algunos aspectos fundamentales de la precisión del cálculo de estabilidad de taludes.

2. Un gran número de superficies de deslizamiento pueden ser analizadas, permitiendo localizar la superficie crítica de deslizamiento con un alto grado de confiabilidad. Se puede encontrar superficies críticas circulares y no circulares.

Más específicamente, con la introducción de los ordenadores personales en la década de los 80's del siglo pasado se tornó económicamente viable el desarrollo de programas computacionales comerciales basados en las técnicas de equilibrio al límite, y su actual disponibilidad ha llevado al uso rutinario de estas técnicas para el análisis de estabilidad en la práctica ingenieril. Los programas computacionales modernos tales como el SLOPE/W de GeoStudio están haciendo posible manejar la creciente complejidad en los análisis. Ahora es posible hacer frente a estratigrafías complejas, condiciones de presiones intersticiales muy irregulares, una variedad de modelos lineales y no lineales de resistencia al corte, prácticamente cualquier forma de superficie de deslizamiento, cargas concentradas, y refuerzo estructural. Mientras que los programas computacionales modernos hacen posible el análisis de problemas cada vez más complejos, al mismo tiempo, las mismas herramientas están haciendo posible comprender de mejor manera el método de equilibrio límite. La visualización gráfica asistida por ordenador de los datos utilizados en los cálculos hace posible mirar más allá del factor de seguridad (Krahn, 2004b).

4.2. Método simplificado de Bishop

Como se mencionó, Bishop (1955) desarrolló otro método de rebanadas verticales en el que se tienen en cuenta las fuerzas normales interfajas, pero ignora las fuerzas de corte interfajas; el método propone una superficie deslizante circular. Bishop desarrolló una ecuación para la

normal en la base de la rebanada asumiendo que las fuerzas son verticales. La consecuencia de esto es que la fuerza normal en la base llega a ser una función del factor de seguridad. Esto a su vez hace que la ecuación del factor de seguridad sea no lineal, requiriéndose consecuentemente un proceso iterativo para calcular este factor (Krahn, 2004a). Una forma simple de la ecuación del factor de seguridad según el método simplificado de Bishop en ausencia de cualquier presión de poro se presenta en la Ecuación 3.

$$FS = \frac{\sum\left[(c\beta + W\tan\varphi)\left(\cos\alpha + \frac{\sin\alpha\tan\varphi}{FS}\right)\right]}{\sum W\sin\alpha} \qquad \text{Ecuación 3}$$

Donde:

c = cohesión,

W = peso de la rebanada,

α = inclinación de la base de la rebanada,

β = longitud de la base de la rebanada, y

φ = ángulo de rozamiento interno.

4.3. Propiedades geotécnicas de los materiales

Como se verá más adelante, la geometría de la presa se ha simplificado a un modelo en el que existen únicamente tres zonas diferenciadas: el núcleo, los espaldones y el cimiento, cuyas propiedades geotécnicas tomaron diferentes valores dentro de cierto que se verá en el presente apartado.

4.3.1. Núcleo

Históricamente se creía que los núcleos de las presas debían ser construidos con arcillas plásticas en lugar de limos, debiéndose en algunos casos transportar las arcillas por 30 kilómetros o más hasta el sitio de la presa; esta creencia era popular porque la arcilla es menos permeable que el limo y porque se consideraba que la arcilla es menos vulnerable a la erosión interna bajo fugas concentradas. Hoy en día, siempre que sean impermeables, se tiende a utilizar los materiales disponibles en la proximidad de la presa, teniendo en cuenta las ventajas y desventajas de los materiales muy cohesivos así como de los poco cohesivos. Las arcillas plásticas resisten mejor a la erosión del agua en una fisura que un limo no cohesivo, pero las arcillas pueden favorecer la formación y mantenimiento de una fisura por el efecto arco, mientras que los limos se saturan con rapidez y, una vez mojados, caen cerrando la fisura; por esta razón, la decisión de escoger entre uno y otro material, puede depender de los materiales disponibles. El tamaño y forma del núcleo dependerá de la disponibilidad de los materiales y sus propiedades, especialmente de la conductividad hidráulica (Vallarino, 2006).

De manera general, las principales propiedades que se consideran convenientes en un material para el núcleo son: baja permeabilidad, facilidad de compactación, escasa colapsabilidad, no contener grandes cantidades de materias orgánicas ni solubles, resistencia adecuada y humedad natural próxima a la óptima de compactación, preferiblemente por debajo de ella. Todo ello dentro de una razonable homogeneidad de la cantera. Se debe evitar también que el material sea claramente dispersivo, ya que en caso contrario habrá que diseñar un filtro aguas abajo más fino de lo normal, en función del material a retener. El material a utilizar en el núcleo debe tener una permeabilidad menor de 10^{-5} cm/s para ser considerado como

impermeable; esto suele lograrse cuando por el tamiz 0.080 UNE pasa, como mínimo, alrededor de un 20% del material, dependiendo también de la plasticidad que presente. Por lo que un material que sea mezcla de gravas, arenas y arcillas o limos que cumpla esta condición es aceptable para el núcleo (SPANCOLD, 2015).

El Comando de Ingeniería de Instalaciones Navales de los Estados Unidos (NAVFAC, 1971) publicó hace varios años algunos trabajos en los que se presentan las propiedades típicas de los suelos compactados, en la Tabla 2, se incluyen algunas de esas características para suelos cohesivos.

Tabla 2: Propiedades típicas de los suelos compactados

Símbolo del grupo	Tipo de suelo	Cohesión material compactado (Kpa)	Cohesión material saturado (Kpa)	Ángulo de rozamiento efectivo (˚)	Coeficiente de permeabilidad (cm/s)
SM	Arenas limosas, mezclas de arena-limo mal graduadas	50,3	20,1	34	$> 2{,}5 \times 10^{-5}$
SC	Arenas arcillosas, mezclas de arena-arcilla mal graduadas	74,2	11,0	31	$> 2{,}5 \times 10^{-7}$
ML	Limos inorgánicos y limos arcillosos	67,0	9,1	32	$> 5{,}0 \times 10^{-6}$
CL	Arcillas inorgánicas con baja o mediana plasticidad	86,2	12,9	28	$> 5{,}0 \times 10^{-8}$

MH	Limos arcillosos inorgánicos, limos elásticos	71,8	20,1	25	> 2,5 × 10^{-7}
CH	Arcillas inorgánicas muy plásticas	102,9	11,0	19	> 5,0 × 10^{-8}

Fuente: (NAVFAC, 1971)

Otras autores (Aydin & Özgüler, 2008), han presentado valores de las propiedades geotécnicas de materiales impermeables dentro de rangos más amplios como se puede observar en la Tabla 3.

Tabla 3: Descripción y parámetros geotécnicos del material impermeable

Propiedad	Sitio A	Sitio B	Sitio D	Sitio E	Sitio F	Sitio G
Coeficiente de permeabilidad (10^{-8} cm/s)	7,06 - 100	1,65 - 700	3,70 - 554	35 - 35	2,90 - 20	8,90 - 60
Cohesión (Kpa)	83 - 137	69 - 176	29 - 176	142 - 186	88 - 93	20 - 132
Ángulo de rozamiento (°)	12,0 – 27,0	8,5 – 27,0	12,0 – 27,0	14,0 – 22,0	12,0 – 15,0	3,0 – 29,0
Tipo de suelo	CL, CL-CH, GC-SC, SC-CL, SC	CL, CL-CH, GC-SC, SC-CL	CL, CL-CH	CL, CL-CH	CL, CL-CH	CL, CL-CH, GC-SC

Fuente: (Aydin & Özgüler, 2008)

4.3.2. Espaldones

Los espaldones cumplen con la exclusiva función de dar forma y estabilidad a la presa, por esta razón la única cualidad requerida es el peso; la resistencia al corte puede resolverse

mediante la inclinación del talud. Conviene también que el material sea permeable para que drene y libere en lo posible al espaldón de presiones intersticiales, sea este el de aguas abajo o el de aguas arriba.

El material más usado en los espaldones, y a la vez el más económico, es el denominado todo-uno obtenido del cauce o de las terrazas fluviales que se encuentran en la mayor parte de los emplazamientos para presas, que además suele ser bastante permeable. Suele emplearse prácticamente en su estado natural, se le retira la materia orgánica que por su putrefacción es inestable, y en ocasiones los finos para mejorar su permeabilidad; en cualquier caso. Cuando no hay graveras o terrazas con volumen suficiente, o su permeabilidad es poco satisfactoria y costosa de corregir, y por otro lado, hay buenas canteras próximas, los espaldones pueden ser de escollera, que es bastante resistente y drena muy bien. La principal ventaja de la escollera es su buen drenaje (Vallarino, 2006).

Para el caso de las escolleras no existen especificaciones claras sobre la calidad de roca y la granulometría que debe emplearse en la construcción de una presa determinada; tomando las debidas precauciones, rocas de baja calidad y resistencia han sido utilizadas con éxito en algunas ocasiones. En las escolleras es normal especificar un huso granulométrico con un porcentaje apreciable que puede ser incluso mayor que el 50% de tamaños inferiores a 25 mm y con un porcentaje máximo de finos pequeño, generalmente no mayor al 5%, con el objeto de garantizar una permeabilidad mayor de 10^{-3} cm/seg. Con ello se pretende conseguir una elevada capacidad de drenaje (SPANCOLD, 2015).

Soroush y Jannatiaghdam (2012) incluyen en su publicación: “Behavior of rockfill materials in triaxial compression testing” (Comportamiento de los materiales de escollera en el ensayo de compresión triaxial), una tabla en la que se presentan las propiedades mecánicas de varios tipos de escollera; los valores del ángulo de rozamiento interno varía en un rango comprendido entre 30,6° y 56,7° y han sido calculados en cada ensayo triaxial asumiendo una cohesión nula. Cruz, Materón y Freitas (2009) recopilan las propiedades geotécnicas de varias presas, en las que los ángulos de rozamiento interno de las escolleras toman diferentes valores entre 38° y 72°.

4.3.3. Cimiento

La idoneidad de los diferentes tipos de suelo y roca como cimentación y los materiales de construcción son aspectos geológicos que deben ser considerados. La geología del cimiento en un sitio de presa a menudo dicta el tipo de presa adecuada para ese sitio. La resistencia, el espesor, y la inclinación de los estratos; la permeabilidad; la fracturación; y fallas, son todas consideraciones importantes en la selección del tipo de presa.

Las cimentaciones con roca competente que están libres de defectos geológicos significativos, tienen relativamente altas resistencias al cizallamiento o corte, y son resistentes a la erosión y la percolación, existen pocas restricciones en cuanto al tipo de presa que se puede construir sobre estos cimientos. Las rocas más débiles como las rocas arcillosas, algunas areniscas, el basalto meteorizado, entre otras, pueden presentar problemas significativos en el diseño y la construcción de una presa y pueden influir en gran medida en la selección del tipo de presa (US Bureau of Reclamation, 1987).

Las condiciones estratigráficas tienen una gran influencia sobre las posibles superficies de deslizamiento. En situaciones de homogeneidad, las superficies circulares son bastante realistas, pero esta situación es poco común en casos reales; generalmente, hay múltiples capas con variaciones en las condiciones de presión de poros que pueden tener un efecto sobre la forma de la superficie de deslizamiento crítico. Una situación común es cuando los suelos superficiales recubren a materiales considerablemente más fuertes en la profundidad.

En suelos superficiales existe un potencial deslizamiento a lo largo del contacto entre dos materiales contrastantes; este caso puede ser analizado a través de una superficie de deslizamiento compuesta. El suelo subyacente más fuerte se marca como impenetrable o "bedrock" según GeoStudio (Krahn, 2004b). La superficie de deslizamiento de prueba comienza como un arco de círculo hasta que interseca la superficie impenetrable y luego continúa a través de la misma como se ilustra en la Fig. 4.

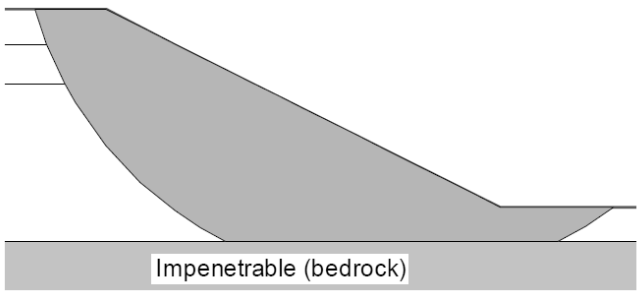

Fuente: (Krahn, 2004b)

Figura 4: Superficie de deslizamiento compuesta controlada por una capa impenetrable

5. REDES NEURONALES ARTIFICIALES

Desde hace varias décadas se han empezado a desarrollar modelos matemáticos que intentan emular el comportamiento del cerebro humano. Se han propuesto una gran cantidad de estos modelos, todos usan una estructura en red en la cual los nodos o neuronas son procesos numéricos que involucran estados de otros nodos según sus uniones. Una clase de estos modelos son las redes de neuronas artificiales (RNA). Se considera a una neurona como un elemento formal o módulo o unidad básica de la red que recibe información de otros módulos o del entorno; la integra, la computa y emite una única salida que se va a transmitir idéntica a múltiples neuronas posteriores (Wasserman, 1989). La neurona artificial o elemento formal está conceptualmente inspirada en la neurona biológica; y al igual que las redes neuronales biológicas, las redes neuronales artificiales pueden aprender y ser entrenadas para encontrar soluciones, reconocer patrones, clasificar datos y pronosticar futuros eventos.

Kohonen (1989) empleaba la siguiente definición: “Las redes neuronales son conjuntos de elementos de cálculo simples, usualmente adaptativos, interconectados masivamente en paralelo y con una organización jerárquica que le permite interactuar con algún sistema del mismo modo que lo hace el sistema nervioso biológico”. McCulloch y Pitts (1943) podrían ser considerados como los padres de las Redes Neuronales Artificiales, ya que fueron los primeros en diseñar una neurona artificial, propusieron un modelo en el que la neurona es un dispositivo binario con un umbral fijo que hay que superar para que cambie de estado; el dispositivo recibe sinapsis excitadoras de otros elementos, los cuales tienen la característica de tener el mismo valor. Puede recibir sinapsis inhibidoras que son de acción total, lo cual supone que la recepción de una, impide el cambio de estado del elemento, sin importar la cantidad de sinapsis excitadoras

que hubiese. Algunas de las ventajas y las limitaciones de las redes neuronales artificiales se pueden resumir de la siguiente manera (Sakellariou & Ferentinou, 2005):

Ventajas:

- Las restricciones geométricas y físicas del problema, que aparecen en las ecuaciones gobernantes y leyes constitutivas, no son tan dominantes en la modelación
- Reconocen diferentes conjuntos de datos dentro de un conjunto total de datos.
- No requieren conocimientos o experiencia preexistente.
- No requieren un modelo estadístico preexistente para entrenar los datos.
- Dan resultados razonables, incluso cuando los datos son imprecisos e incompletos.

Limitaciones:

- El modelo no puede realizar estimaciones fiables fuera de su rango de parámetros de entrenamiento.
- Mecanismos críticos pueden ser omitidas en el modelo de entrenamiento.
- Hace falta una base teórica para la verificación y validación de estas técnicas y sus resultados.

5.1. Neuronas y pesos sinápticos

Los pesos sinápticos se consideran como la fuerza de unión entre las neuronas, es decir, la fuerza de la sinapsis. Se considera que una sinapsis es fuerte o tiene un alto grado de conexión cuando la información que transmite contribuye, en gran medida, a un nuevo estado o a la alteración que se produzca en la neurona receptora y, por tanto, en la respuesta que esta elabora.

En una red de neuronas existe un peso o fuerza sináptica que va a ser un valor numérico que pondera las señales que se reciben por sus entradas. Este peso es un valor que determina la fuerza de conexión entre dos neuronas.

Al evaluar una neurona se calcula el valor del conjunto de todas las fuerzas sinápticas; posteriormente una función de activación es aplicada para determinar el valor del estado interno de la neurona, valor que es transmitido a su salida. La función de activación y la función de transferencia son las encargadas de definir el nuevo estado de activación y la respuesta de la neurona. Tanto el estado de activación como la salida de la neurona van a variar en función de las entradas que recibe en un determinado momento y del estado de activación previo que tenga esa neurona. La Fig. 5 muestra un esquema de la neurona artificial i que procesa un vector X de n entradas (x_1, x_2, x_3, …, x_j, …, x_n), y donde w_{ij} representa el peso de la conexión entre una neurona emisora j y la neurona receptora i.

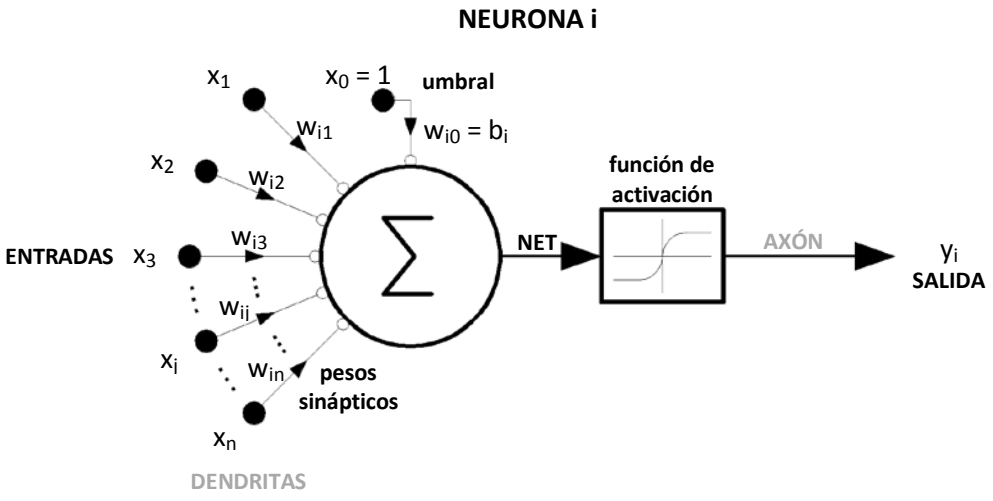

Elaboración: Autor, Fuente: (Haykin, 1994)

Figura 5: Esquema de neurona artificial

La función de activación es modelada por un peso modificable que se asocia con cada conexión. En las redes neuronales reales, la sinapsis se compone del axón y las dendritas, sin embargo, la mayoría de las redes artificiales no reflejan esta geometría y expresan la respuesta eléctrica de una neurona como un único número que representa su actividad. Cada unidad convierte la señal que recibe en una sola actividad saliente. En primer lugar, se multiplica cada actividad entrante por el peso de la conexión asociada. La entrada total es la suma de todas estas entradas ponderadas. En segundo lugar, una función de transformación se aplica con el fin de relacionar la actividad de entrada (estimulación) con la actividad de salida (respuesta).

5.2. Estrategia de aprendizaje

En general, las redes neuronales pueden ser categorizadas como supervisadas o no supervisadas. La diferencia fundamental entre los dos tipos depende del conjunto de datos conocidos que se utilizará con el fin de entrenar a la red. Las redes neuronales supervisadas son entrenadas para producir los resultados deseados en respuesta al conjunto de entrenamiento de las entradas; es por esta razón que se utilizan normalmente en la modelación y control de sistemas dinámicos, la clasificación de los datos de sonido, y en la predicción de eventos futuros. Por otra parte, las redes neuronales no supervisadas son entrenadas para dejar que la red se ajuste continuamente con las nuevas entradas; estas descubren relaciones no lineales dentro de los datos y pueden definir los esquemas de clasificación que se adaptan a los cambios en los nuevos datos.

5.3. Arquitectura de la red

En el presente estudio, se ha utilizado el modelo de red neuronal supervisada más ampliamente usado, la red Perceptron Multi-Capa (PMC). Las redes PMC son modelos no lineales flexibles y de uso general, que consisten en un número de elementos de proceso dispuestos en múltiples capas. Generalmente se requieren tres o más capas de procesamiento: una capa de entrada que acepta las variables de entrada utilizados en el procedimiento de clasificación, una o más capas ocultas que identifican la estructura interna de los datos de entrada, y una capa de salida con un nodo por clase. La Fig. 6 ilustra la arquitectura de una red PMC.

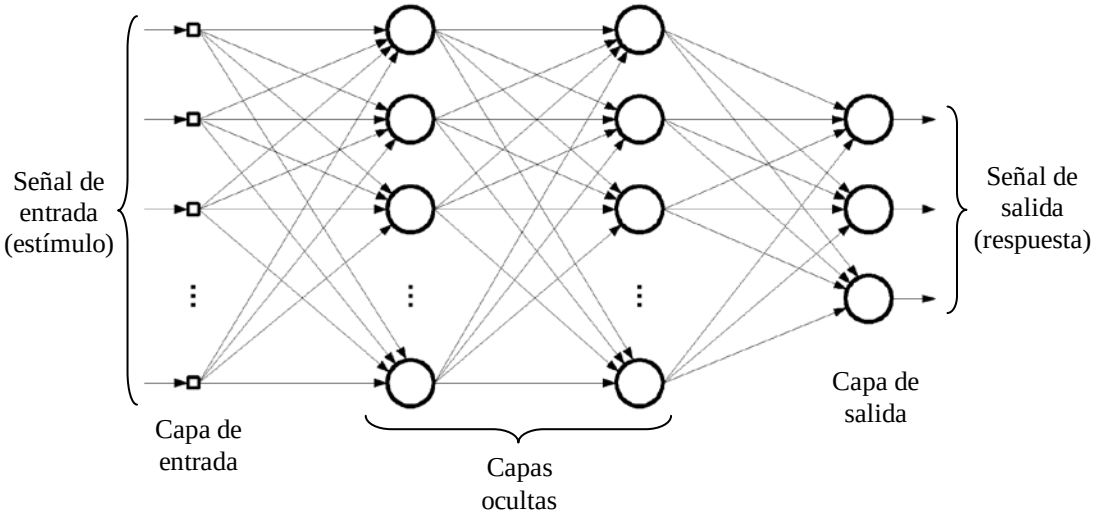

Fuente: (Haykin, 1994)

Figura 6: Arquitectura de una red Perceptron Multi-Capa con dos capas ocultas

La complejidad de la red PMC puede cambiarse variando el número de capas y el número de unidades en cada capa. Dando unidades ocultas y datos suficientes, se ha demostrado que las redes PMC pueden aproximarse prácticamente a cualquier función para cualquier precisión

deseada (Haykin, 1994). Como se mencionó anteriormente, todas las conexiones entre neuronas tienen asociado un peso, que generalmente se asigna de forma aleatoria al inicio del entrenamiento. Cuando algunos valores pasan a una neurona a través de las interconexiones, estos son multiplicados por el peso asociado con estas interconexiones y se suman. A continuación, la función de activación determina el valor de salida de esta neurona.

5.4. Funciones de activación

La función de activación de una neurona es la encargada de relacionar la información de entrada de la neurona con el siguiente estado de activación que tenga esa neurona. Existen dos modelos de función de activación. Modelos acotados: El valor de la activación de la neurona puede ser cualquiera dentro de un rango continuo de valores. Modelos no acotados: No existe ningún límite para los valores de activación.

En el diseño de una red neuronal debe establecerse cómo van a ser los valores de activación de cada neurona y se debe decidir la función de activación con la que cada neurona procesará las entradas. Por lo tanto, como se muestra en la Ecuación 4 la función de activación va a actuar sobre las señales de entrada, es decir, sobre los pesos sinápticos asociados con cada entrada y sobre el valor de activación que tenía la neurona en el momento de recibir las señales.

$$Ai_{(t)} = FA\ (Ai_{(t-1)}, NETi_{(t-1)}) \qquad \text{Ecuación 4}$$

$Ai_{(t)}$: Valor del estado de activación de la neurona i en el instante t

FA: Función de activación

$Ai_{(t-1)}$: Valor del estado de activación de la neurona i en el instante (t -1)

$NETi_{(t-1)}$: Valor del conjunto de todos los pesos sinápticos en el instante (t -1)

Teóricamente, cualquier función derivable se puede utilizar como una función de activación. Sin embargo, una función de activación que tiene un carácter no lineal es muy importante para que sea capaz de discriminar las complejas relaciones que existen en el conjunto de características. Mientras que las funciones lineales son utilizadas particularmente en las capas de entrada y de salida, las funciones de activación no lineales pueden usarse en las capas ocultas y de salida. La elección de las funciones de activación puede influir fuertemente en la complejidad y el desempeño de las redes neurales.

Un gran número de funciones de activación alternativas han sido descritas en la literatura (Duch & Jankowski, 1999). Las formas funcionales no lineales más utilizadas de funciones de activación que cumplan las condiciones de aproximación de las redes neuronales artificiales son la sigmoidea (logística) y la función tangente-hiperbólica (Zeng, 1999). Las características de las funciones de activación lineal, sigmoidea y tangente-hiperbólica, así como de la función umbral se presentan en la Tabla 4.

Tabla 4: Funciones de activación lineal y no lineal

Función de activación	Ecuación matemática	Representación gráfica
Lineal pura (PURELIN)	$y = NET$	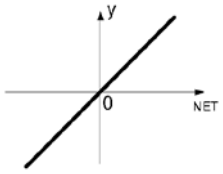
Umbral (HARDLIMIT)	$y = \begin{cases} +1 \text{ si } NET > 0 \\ -1 \text{ si } NET < 0 \end{cases}$	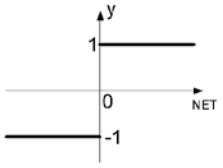
Sigmoidea o Logística (LOGSIG)	$y = \frac{1}{1 + e^{-NET}}$	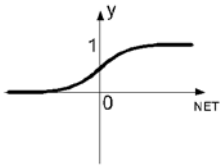
Tangente-hiperbólica (TANSIG)	$y = \frac{1 - e^{-NET}}{1 + e^{NET}}$	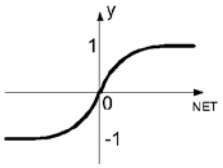

Elaboración: Autor, Fuente: (Duch & Jankowski, 1999)

La función de activación más utilizada es la función sigmoidea, esta produce la señal de salida en el rango cerrado de 0 a 1. Los valores 0 y 1 se obtienen únicamente para valores infinito negativo y positivo, respectivamente. Conforme los valores de salida se acercan a estos límites, las derivadas de esta función disminuyen. La segunda función de activación más utilizada es la función tangente-hiperbólica. La función de tangente-hiperbólica es una versión bipolar de la función sigmoidea. La función tangente-hiperbólica produce la salida escalada dentro del rango cerrado de -1 a +1. Los valores de salida de -1 y +1 se obtienen en el menos y más infinito, respectivamente. Debido a que el conjunto de salida de la función tangente-hiperbólica es más amplio, este puede ser más eficiente para el rendimiento de la clasificación de la red PMC.

En la literatura, se ha afirmado que el uso de la función de activación tangente provoca una convergencia más rápida de los algoritmos de aprendizaje que la función sigmoidea (C. M. Bishop, 1995). Haykin (1994) indicó que una función de activación asimétrica como la tangente-hiperbólica en lugar de la función sigmoidea asimétrica podría resultar mejor para la red PMC.

5.5. Flujo de datos

Desde el punto de vista del flujo de datos, las redes neuronales pueden clasificarse en dos grupos: redes alimentadas hacia adelante y redes con retroalimentación total o parcial. Las redes alimentadas hacia delante, o generalmente conocidas como redes feed-forward, son aquellas en las que, como su nombre indica, la información se mueve en un único sentido, desde la entrada hacia la salida. Estas redes están clásicamente organizadas en capas. Cada capa agrupa a un conjunto de neuronas que reciben sinapsis de las neuronas de la capa anterior y emiten salidas hacia las neuronas de la capa siguiente. Entre las neuronas de una misma capa no hay sinapsis. En redes así construidas es evidente que la información sólo puede moverse en un sentido: desde la capa de entrada hasta la capa de salida, atravesando todas y cada una de las capas intermedias una sola vez. El hecho de que no haya conexión entre las neuronas de una misma capa hace que no haya tiempos de espera en los que las neuronas estén interactuando unas sobre otras hasta que toda la capa adquiera un estado estable. Se trata por tanto de redes rápidas en sus cálculos.

Por otro lado, en las redes con retroalimentación los elementos pueden enviar estímulos a neuronas de capas anteriores, de su propia capa o a sí mismos, por lo que desaparece el concepto de agrupamiento de las neuronas en capas. Cada neurona puede estar conectada a todas las

demás; de este modo, cuando se recibe información de entrada a la red, cada neurona calcula y recalcula su estado varias veces, hasta que todas las neuronas de la red alcancen un estado estable. Un estado estable es aquel en el que no ocurren cambios en la salida de ninguna neurona. No habiendo cambios en las salidas, las entradas de todas las neuronas son también constantes, por lo que ya no es necesario modificar su estado de activación ni su respuesta, manteniéndose así en un estado global estable (Pearlmutter, 1990). Las redes retroalimentadas emulan más fielmente la estructura del cerebro humano, en donde los fenómenos de retroalimentación son fundamentales.

5.6. Algoritmo retro-propagación

El término retro-propagación se refiere a la forma en la que se calcula la gradiente de la función de error para redes multicapa no lineales. El vector de los pesos sobre el cual se calcula la gradiente debe ser un vector que comprenda todos los pesos de la red.

El algoritmo retro-propagación se basa en la selección de una adecuada función de error, dichos valores son determinados por las salidas real y deseada de la red la cual también depende de los parámetros de la red tales como los pesos y el umbral. La idea básicamente consiste en que la función de error tiene una superficie particular dentro del conjunto de pesos y, por lo tanto, el método de descenso de la gradiente puede ser usado para la minimización del error.

El método de descenso de la gradiente se basa en el hecho de que, debido a que la gradiente de una función siempre apunta en la dirección de incremento máximo de la función, entonces, un movimiento hacia la dirección del gradiente negativo induce un movimiento de

descenso máximo que eventualmente alcanzará el mínimo de la superficie de la función dentro de su conjunto de parámetros. Esta es una técnica rigurosa y bien aplicada para la minimización de las funciones y probablemente ha sido el principal factor detrás del éxito de la retro-propagación.

El entrenamiento retro-propagación se compone de dos fases de cálculo: un paso hacia adelante y un paso hacia atrás. Durante el paso hacia adelante se fijan los pesos sinápticos de la red. Durante el paso hacia atrás, los pesos sinápticos se ajustan de acuerdo con una señal de error, que se propaga hacia atrás a través de la red en sentido contrario al de las conexiones sinápticas. Los conceptos matemáticos básicos del algoritmo de retro-propagación se encuentran en la literatura (Goh, 1995).

5.7. Funciones de entrenamiento

Como una ilustración del funcionamiento del entrenamiento de una red neuronal, se puede tener en cuenta el algoritmo de optimización más simple, es decir el descenso de gradiente. Este algoritmo actualiza los pesos y sesgos de la red en la dirección en la que la función de desempeño disminuye más rápidamente, el negativo del gradiente. Una iteración de este algoritmo se puede escribir de la siguiente manera (Hagan, Demuth, & Beale, 1996):

$$x_{k+1} = x_k - \alpha_k g_k \qquad \text{Ecuación 5}$$

Esta ecuación se itera hasta que la red converge, donde:

x_k = vector de pesos y sesgos actuales,

g_k = gradiente de la corriente, y

α_k = tasa de aprendizaje.

Una lista de los algoritmos de entrenamiento que están disponibles en la herramienta "nntool" de MATLAB y que usa el método de gradiente, se muestra en la Tabla 5.

Tabla 5: Funciones de entrenamiento disponibles en "nntool" de MATLAB

Function	Algorithm
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traincgf	Fletcher-Powell Conjugate Gradient
traincgp	Polak-Ribiére Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

Fuente: (Beale, Hagan, & Demuth, 2015)

Hagan, Demuth, y Beale (1996), describen de manera detallada algunas de estas técnicas. El algoritmo de Levenberg-Marquardt, de uso frecuente en los problemas de mínimos cuadrados no lineales, se ha adaptado para el aprendizaje en las redes perceptron multicapa (PMC). Es una aproximación al método de Newton, en lugar de un descenso de gradiente puro. A pesar de que

sus requisitos de memoria lo hacen poco práctico para grandes redes neuronales, se compara favorablemente contra las técnicas de gradiente conjugado para el aprendizaje en las redes neurales de tamaño razonable.

El algoritmo "Bayesian Regularization" es una función de entrenamiento que actualiza los valores de los pesos y el sesgo de acuerdo con la optimización de Levenberg-Marquardt que minimiza una combinación de errores cuadráticos y pesos, luego determina la combinación correcta de manera que produzca una correcta red generalizada (Hagan & Menhaj, 1994). El algoritmo converge cuándo: 1) el número máximo de iteraciones es alcanzado, 2) el error es minimizado hacia el objetivo, o 3) el gradiente de rendimiento cae por debajo del valor mínimo. Este algoritmo es el que se ha utilizado en el presente estudio.

6. ESTUDIOS SIMILARES PREVIOS

A mediados de la década de los noventa del siglo anterior, numerosas publicaciones mostraron un creciente interés en la aplicación de las redes neuronales artificiales (RNA) en la ingeniería geotécnica para la modelización constitutiva, pruebas dinámicas de pilas, compactación del suelo, clasificación de suelos, análisis de elementos finitos, entre otras (ver por ejemplo: Flood & Kartam, 1994; Pande & Pietruszczak, 1995; Siriwardane & Zaman, 1994).

El concepto de las RNA ha encontrado resultados favorables en la ingeniería geotécnica; las RNA se han aplicado en la evaluación de las propiedades de suelos y rocas. Así por ejemplo, se han utilizado las RNA para modelar la relación tensión-deformación de arenas con diferente distribución del tamaño de grano e historial de esfuerzos. (Ellis et al., 1995). Lee, Lee y Kim

(2003) analizaron la estimación de la resistencia al corte en suelos no saturados usando redes neuronales artificiales, también desarrollaron un método en el que la cohesión aparente puede predecirse utilizando una RNA a partir de datos obtenidos en ensayos. Las RNA se han utilizado para la estimación del módulo de elasticidad de la roca intacta (Sonmez, Gokceoglu, Nefeslioglu, & Kayabasi, 2006), el mismo que se utiliza para muchos proyectos de ingeniería de roca, tales como túneles, taludes, y cimentaciones. Kuo, Jaksa, Lyamin y Kaggwa (2009) desarrolaron un método basado en redes perceptrón multicapa para la predicción de la capacidad de carga de zapatas continuas en suelos cohesivos de varias capas.

La estabilidad de taludes se ha considerado ampliamente dentro de las aplicaciones de las RNA. Lu y Rosenbaum (2003) ilustraron la aplicación de las RNA y los sistemas grises (Grey Systems) para predecir el estado de estabilidad de taludes; los autores emplearon los datos de 32 casos reportados en estudios anteriores, y concluyen que las RNA proveen una herramienta viable para situaciones donde se dispone de grandes cantidades de datos, mientras que la predicción con sistemas grises puede ser utilizada cuando los mecanismos explícitos responsables de los deslizamientos de tierra no son claras, pero la información relevante y los datos disponibles son limitados.

Sakellariou y Ferentinou (2005) ensayaron un número de RNA para la estimación de la estabilidad de taludes, emplearon el algoritmo de aprendizaje retro-propagación, la red predice el factor de seguridad modelado como un problema de función de aproximación, o el estado de estabilidad modelado, ya sea como un problema función de aproximación o como un modelo de clasificación. En el estudio emplea muestras cuyas formas de la superficie de deslizamiento son

circular y en forma de cuña. En el estudio se concluye que, en particular, hubo una mejor convergencia entre los valores del factor de seguridad (FS) estimados a partir de las redes neuronales y calculados a partir de los métodos de análisis, que en la convergencia entre los resultados del método de aproximación de mínimos cuadrados en comparación con los resultados de los métodos analíticos.

Farrokhzad, JanAliZadeh y Barari (2008) desarrollaron un estudio para predecir la estabilidad de taludes en un sitio específico mediante la aplicación de RNA. Los resultados de la predicción se compararon con los métodos de análisis más antiguos para validar el modelo. En el estudio se concluye que la correlación del modelo desarrollado con RNA y el modelo de Bishop en todo caso ha sido mayor al 92% y en la mayoría de casos se encuentra por encima del 95%. Los resultados experimentales demuestran que el modelo de red neuronal es una exitosa técnica en la predicción de la estabilidad de taludes.

Cho (2009) realizó un análisis de estabilidad de taludes probabilístico utilizando la superficie de respuesta basado en redes neuronales artificiales, en el estudio se presentó un procedimiento numérico para integrar un método comercial de elementos finitos en un análisis probabilístico de la estabilidad de taludes adoptando una red neuronal artificial para aproximar la función de estado límite.

Erzin y Cetin (2012) condujeron un estudio en el que desarrollaron modelos de regresión múltiple y de redes neuronales artificiales para estimar el valor crítico del factor de seguridad de

un talud artificial típico sometida a fuerzas sísmicas. En el estudio se concluye que el modelo de RNA ha mostrado una predicción de rendimiento más alto que el modelo de regresión múltiple.

Los mismos autores (Erzin & Cetin, 2013) realizaron otro estudio que se ocupa del desarrollo de modelos de regresión múltiple y redes neuronales para estimar valor del factor de seguridad crítico de taludes homogéneos finitos. Los resultados obtenidos a partir de modelos de RNA y de regresión múltiple se compararon con los calculados. Los valores predichos mediante RNA coinciden con los valores reales o calculados mucho mejor que los obtenidos a partir de regresión múltiple.

7. PROPUESTA DE OBJETIVOS

El análisis bibliográfico realizado en el presente trabajo permite evidenciar que, si bien la aplicación de las redes neuronales artificiales (RNA) ha despertado crecientemente el interés de muchos investigadores en la predicción de la estabilidad de taludes, aún no se ha desarrollado un estudio en el que la predicción de la estabilidad se enfoque de manera particular en las presas heterogéneas con núcleo central.

Hasta ahora las RNA se han utilizado únicamente en la predicción de materiales homogéneos, bien sea para estimar el estado de estabilidad o el factor de seguridad. Resulta entonces de gran interés científico indagar sobre el comportamiento y utilidad de estas técnicas en la predicción de la estabilidad de presas heterogéneas.

En el presente estudio se pretende establecer un método de predicción de la estabilidad de presas heterogéneas en base a la utilización de las redes neuronales artificiales y en base a dicho análisis establecer los parámetros geométricos y geotécnicos que provocan que el fallo en la presa afecte al núcleo central de la misma.

8. REFERENCIAS

1. Aydin, A., & Özgüler, E. (2008). Evaluation of dispersive properties of clays to be used in embankment of arsuz-gönençay dam. *International Conference on Case Histories in Geotechnical Engineering*, Missouri, USA. Paper 2.01.
2. Beale, M. H., Hagan, M. T., & Demuth, H. B. (Eds.). (2015). *Neural network toolbox™ user's guide*. Natick, MA, USA: The MathWorks, Inc.
3. Bishop, A. W. (1955). The use of the slip circle in the stability analysis of slopes. *Géotechnique*, *5*, 7-17.
4. Bishop, C. M. (Ed.). (1995). *Neural networks for pattern recognition* (1st ed.). Oxford, United Kingdom: Clarendon Press.
5. Cho, S. E. (2009). Probabilistic stability analyses of slopes using the ANN-based response surface. *Computers and Geotechnics*, *36*(5), 787-797.
6. Comité Nacional Español de Grandes Presas (Ed.). (2015). *Guía técnica de seguridad de presas nro. 2: Criterios para proyectos de presas y sus obras anejas* (1st ed.). Madrid: Gráficas Rito.

7. Cruz, P. T., Materón, B., & Freitas, M. (Eds.). (2009). *Concrete face rockfill dams* (1st ed.). Sao Paulo, Brasil: CRC Press/Balkema.
8. Duch, W., & Jankowski, N. (1999). Survey of neural transfer functions. *Neural Computing Surveys, 2*(1), 163-212.
9. Duncan, J. M. (1996). State of the art: Limit equilibrium and finite-element analysis of slopes. *Journal of Geotechnical Engineering, 122*(7), 577-596.
10. Ellis, G., Yao, C., Zhao, R., & Penumadu, D. (1995). Stress-strain modeling of sands using artificial neural networks. *Journal of Geotechnical Engineering, 121*(5), 429-435.
11. Erzin, Y., & Cetin, T. (2012). The use of neural networks for the prediction of the critical factor of safety of an artificial slope subjected to earthquake forces. *Scientia Iranica, 19*(2), 188-194.
12. Erzin, Y., & Cetin, T. (2013). The prediction of the critical factor of safety of homogeneous finite slopes using neural networks and multiple regressions. *Computers & Geosciences, 51*, 305-313.
13. Farrokhzad, F., JanAliZadeh, A., & Barari, A. (2008). Prediction of slope stability using artificial neural network (case study: Noabad, mazandaran, iran). *International Conference on Case Histories in Geotechnical Engineering, Paper 41*, Arlington, VA, USA.
14. Fellenius, W. (1936). Calculation of the stability of earth dams. *International Congress on Large Dams. 2d*, Washington, D.C. , *4* 445-463.
15. Flood, I., & Kartam, N. (1994). Neural networks in civil engineering. I: Principles and understanding. *Journal of Computing in Civil Engineering, 8*(2), 131-148.
16. Goh, A. T. C. (1995). Back-propagation neural networks for modelling complex systems. *Artificial Intelligence Eng., 9*, 143–151.

17. Hagan, M. T., Demuth, H. B., & Beale, M. H. (Eds.). (1996). *Neural network design*. Boston, MA: PWS Publishing.

18. Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks, 5*(6), 989-993.

19. Haykin, S. (Ed.). (1994). *Neural network: A comprehensive foundation* (1st ed.). New York, USA: Macmillan College Publishing Company, Inc.

20. International Commission on Large Dams. (1973). *Lessons from dam incidents*

21. International Commission on Large Dams. (1983). *Deterioration of dams and reservoirs - examples and their analysis*

22. Janbu, N. (1954). Applications of composite slip surfaces for stability analysis. *Fourth European Conference on Stability of Earth Slopes, , 3* 39-43.

23. Janbu, N. (1968). Slope stability computations. *Soil Mech, and found. Engrg. Rep., 23.8*, 66.

24. Kohonen, T. (Ed.). (1989). *Self-organization and associative memory*. New York: Springer Verlag.

25. Krahn, J. (Ed.). (2004a). *Seepage modeling with SEEP/W: An engineering methodology* (First Edition ed.). Alberta, Canada: GEO-SLOPE/W International Ltd.

26. Krahn, J. (Ed.). (2004b). *Stability modeling with SLOPE/W: An engineering methodology* (First Edition ed.). Alberta, Canada: GEO-SLOPE/W International Ltd.

27. Kuo, Y. L., Jaksa, M. B., Lyamin, A. V., & Kaggwa, W. S. (2009). ANN-based model for predicting the bearing capacity of strip footing on multi-layered cohesive soil. *Computers and Geotechnics, 36*(3), 503-516.

28. Lee, S. J., Lee, S. R., & Kim, Y. S. (2003). An approach to estimate unsaturated shear strength using artificial neural network and hyperbolic formulation. *Computers and Geotechnics, 30*(6), 489-503.

29. Lowe, J. (1967). Stability analysis of embankments. *Soil Mech, and found. Div., 93(4)*, 1-33.

30. Lowe, J., & Karafiath, L. (1960). Stability of earth dams upon draw-down. *1st Pan-Am. Conf. on Soil Mech. and found. Engrg.* Mexico City. , *2* 537-552.

31. Lu, P., & Rosenbaum, M. S. (2003). Artificial neural networks and grey systems for the prediction of slope stability . *Natural Hazards, 30*(3), 389-398.

32. McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biology, 5(4)*, 115-133.

33. Morgenstern, N. R., & Price, V. (1965). The analysis of the stability of general slip surfaces. *Geotechniquc, 15*, 79-93.

34. Naval Facilities Engineering Command. (1971). *Soil mechanics, foundations, and earth structures.* (No. NAVFAC Design Manual DM-7). Waghington, DC: US Navy.

35. Pande, G. N., & Pietruszczak, S. (1995). Numerical models in geomechanics. *Proc. 5Th Int. Symp. on Num. Models in Geomechanics,* Davos, Switzerland.

36. Pearlmutter, B. A. (1990). *Dynamic recurrent neural networks* . (Technical report No. CMU-CS). Pittsburgh: School of Computer Science, Carnegie Mellon University.

37. Petterson, K. E. (1955). The eraly history of circular sliding surfaces. *Geotechnique, 5*, 275-296.

38. Sakellariou, M. G., & Ferentinou, M. D. (2005). A study of slope stability prediction using neural networks. *Geotechnical & Geological Engineering, 23*(4), 419-445.

39. Siriwardane, H. J., & Zaman, M. M. (1994). Computer methods and advances in geomechanics. *Proc. 8Th Int. Conf. of Computer Met. and Advances in Geomech.* Morgantown, USA. 22-28.

40. Sonmez, H., Gokceoglu, C., Nefeslioglu, H. A., & Kayabasi, A. (2006). Estimation of rock modulus: For intact rocks with an artificial neural network and for rock masses with a new empirical equation. *International Journal of Rock Mechanics and Mining Sciences, 43*(2), 224-235.

41. Soroush, A., & Jannatiaghdam, R. (2012). Behavior of rockfill materials in triaxial compression testing. *International Journal of Civil Engineering, 10*(2), 153-183.

42. Spencer, E. (1967). A method of analysis of stability of the embankments assuming parallel interslice forces. *Geotechnique, 17(1)*, 11-26.

43. United States Department Of The Interior, Bureau Of Reclamation (Ed.). (1987). *Design of small dams* (Third Edition ed.). Washington, DC: Water Resources Technical Publication.

44. Vallarino, E. (Ed.). (2006). *Tratado básico de presas, tomo I* (6th ed.). Madrid, Spain: Colegio de Ingenieros de Caminos, Canales y Puertos.

45. Wasserman, P. D. (Ed.). (1989). *Neural computing: Theory and practice*. New York: Van Nostrand Reinhold Co.

46. Zeng, L. (1999). Prediction and classification with neural network models. *Sociological Methods & Research, 27*(4), 499-524.

Predicción de la estabilidad de presas heterogéneas mediante redes neuronales artificiales

(Parte B)

Autor: César Costa Costa

Directores: Miguel Ángel Toledo Municio

Rafael Morán Moya

ÍNDICE

RESUMEN 46
1. INTRODUCCIÓN 47
2. ESTADO DEL ARTE 52
3. MATERIALES Y MÉTODOS 55
3.1. Análisis de filtración 55
3.2. Análisis de estabilidad de taludes 56
3.3. Obtención de la muestra 57
3.4. Análisis de redes neuronales 60
3.4.1. Configuración de datos 61
3.4.2. Diseño y entrenamiento de la red 62
3.4.3. Validación de la red 63
4. RESULTADOS Y DISCUSIÓN 65
4.1. Predicción del tipo de falla 65
4.2. Predicción del factor de seguridad 68
4.3. Estudio paramétrico 72
4.4. Conclusiones generales 76
5. REFERENCIAS 77

RESUMEN

En el presente estudio se desarrolló un método para la predicción de la estabilidad de presas heterogéneas con núcleo central y cimiento rígido, las variables estimadas fueron el tipo de falla *T*, que es una variable discreta que puede adoptar dos valores según la presa se vea afectada de manera superficial o profunda, y el factor de seguridad *FS*. Las variables de entrada corresponden las características geométricas y geotécnicas de la presa (H, φ'_e, n_e, c'_n, φ'_n, n_n). El método de predicción se realizó mediante las redes neuronales artificiales *RNA*. Los datos de entrada se obtuvieron mediante el programa computacional SLOPE/W de GeoStudio, herramienta con la que se realizó el análisis de estabilidad de 729 casos específicos que son el resultado de una combinación de las variables de entrada a las cuales se les asignaron tres o cuatro valores dentro de un rango cercano a la realidad. El 60 % de los datos se emplearon en el entrenamiento de las redes y el 40 % restante se utilizó para simular la red entrenada y validar su funcionamiento. En la simulación del conjunto de datos que no formaron parte del entrenamiento se demostró que la probabilidad de acierto de la red en la predicción de *T* supera el 95 %. En la predicción de *FS* para casos con falla superficial se obtuvo un error cuadrático medio (*MSE*) menor a 10^{-5}, mientras que en la predicción de *FS* para casos con falla profunda, el MSE fue alrededor de 0.025. Se demostró que tanto en la estimación de T como de FS, las características geométricas y físicas del núcleo son muy importantes, especialmente la cohesión del material que lo conforma y su inclinación.

1. INTRODUCCIÓN

Hoy en día resulta difícil concebir la gestión del agua sin la existencia de las presas, tanto en sistemas de aprovechamiento de agua como en los de control de defensa frente a avenidas. De la variedad de presas, se destacan las de materiales sueltos por su gran capacidad de adaptación a las condiciones topográficas, geológicas y a los materiales disponibles en la zona de implantación. Por esta razón, los ingenieros geotécnicos se encuentran constantemente desarrollando técnicas y modelos que permitan estimar de manera adecuada el comportamiento de las presas bajo diferentes solicitaciones.

Para las presas de materiales sueltos, de manera general, son aplicables los modos de fallo establecidos por ICOLD (1973), descritos a continuación:

1. Sobrevertido o desbordamiento (Insuficiencia frente a la solicitación hidrológica).
2. Inestabilidad de laderas en el vaso (Insuficiencia de resistencia al corte).
3. Inestabilidad dinámica (Insuficiencia ante la solicitación sísmica).
4. Erosión interna del cuerpo de presa (Insuficiencia de estabilidad interna en cuerpo de presa) y/o del cimiento.
5. Inestabilidad de taludes de presa (Insuficiencia de resistencia al corte), pudiendo afectar o no al cimiento.

En el análisis de estabilidad de taludes, los métodos de equilibrio al límite han sido usados en la ingeniería geotécnica por muchas décadas. La idea de dividir una potencial masa de deslizamiento en rebanadas verticales fue introducida en los primeros años del siglo veinte, es la

técnica de análisis numérico más antiguo en la ingeniería geotécnica. En 1916, Petterson (1955) presentó el análisis de estabilidad del muelle Stigber en Suecia, análisis en el que la superficie de deslizamiento fue asumida como circular y la masa de deslizamiento fue dividida en rebanadas. Durante las próximas décadas, Fellenius (1936) introdujo el método Ordinario o Sueco. Posteriormente Janbu (1954) y Bishop (1955) introdujeron avances en el método. La llegada de los ordenadores electrónicos en los 60's del siglo anterior hizo posible un manejo más facil de los procesos iterativos inherentes al método, lo cual permitió formulaciones matemáticas más rigurosas como las desarrolladas por Morgenstern y Price (1965) y por Spencer (1967).

Todos los métodos definen al factor de seguridad como la relación entre la resistencia al corte del suelo y el esfuerzo cortante requerido para el equilibrio; es decir que es la relación de la reacción sobre la acción, expresado en términos de momentos o fuerzas, y, eventualmente, en términos de tensiones, en función de la geometría de la superficie de deslizamiento asumida. En fallos circulares, el factor de seguridad es definido como la relación entre el momento de la resistencia al corte a lo largo del arco de fallo sobre el momento del peso de la masa de fallo, en ambos casos, los momentos son respecto al centro del arco de falla. Otra manera de expresar esta definición es la empleada por Lowe (1967), quien lo define como "el factor por el cual la resistencia al corte del suelo tendría que ser dividido para llevar al talud a un estado de equilibrio apenas estable".

Como se mencionó, Bishop (1955) desarrolló otro método de rebanadas verticales en el que se tienen en cuenta las fuerzas normales interfajas, pero ignora las fuerzas de corte interfajas; el método propone una superficie deslizante circular. Bishop desarrolló una ecuación para la

normal en la base de la rebanada asumiendo que las fuerzas son verticales. La consecuencia de esto es que la fuerza normal en la base llega a ser una función del factor de seguridad. Esto a su vez hace que la ecuación del factor de seguridad sea no lineal, requiriéndose consecuentemente un proceso iterativo para calcular este factor (Krahn, 2004). Una forma simple de la ecuación del factor de seguridad según el método simplificado de Bishop en ausencia de cualquier presión de poro se presenta en la Ecuación 1.

$$FS= \frac{\sum\left[(c\beta+W\tan\varphi)\left(\cos\alpha+\frac{\sin\alpha\tan\varphi}{FS}\right)\right]}{\sum W\sin\alpha} \qquad \text{Ecuación 1}$$

Donde:

c = cohesión,

W = peso de la rebanada,

α = inclinación de la base de la rebanada,

β = longitud de la base de la rebanada, y

φ = ángulo de rozamiento interno.

Desde hace varias décadas se han empezado a desarrollar modelos matemáticos que intentan emular el comportamiento del cerebro humano. Se han propuesto una gran cantidad de estos modelos, todos usan una estructura en red en la cual los nodos o neuronas son procesos numéricos que involucran estados de otros nodos según sus uniones. Kohonen (1989) empleaba la siguiente definición: “Las redes neuronales son conjuntos de elementos de cálculo simples, usualmente adaptativos, interconectados masivamente en paralelo y con una organización

jerárquica que le permite interactuar con algún sistema del mismo modo que lo hace el sistema nervioso biológico".

En el presente estudio, se ha utilizado el modelo de red neuronal supervisada más ampliamente usado, la red Perceptron Multi-Capa (PMC). Las redes PMC son modelos no lineales flexibles y de uso general, que consisten en un número de elementos de proceso dispuestos en múltiples capas. Generalmente se requieren tres o más capas de procesamiento: una capa de entrada que acepta las variables de entrada utilizados en el procedimiento de clasificación, una o más capas ocultas que identifican la estructura interna de los datos de entrada, y una capa de salida con un nodo por clase.

La complejidad de la red PMC puede cambiarse variando el número de capas y el número de unidades en cada capa. Dando unidades ocultas y datos suficientes, se ha demostrado que las redes PMC pueden aproximarse prácticamente a cualquier función para cualquier precisión deseada (Haykin, 1994). Todas las conexiones entre neuronas tienen asociado un peso, que generalmente se asigna de forma aleatoria al inicio del entrenamiento. Cuando algunos valores pasan a una neurona a través de las interconexiones, estos son multiplicados por el peso asociado con estas interconexiones y se suman. A continuación, la función de activación determina el valor de salida de esta neurona.

La función de activación más utilizada es la función sigmoidea, esta produce la señal de salida en el rango cerrado de 0 a 1. Los valores 0 y 1 se obtienen únicamente para valores infinito negativo y positivo, respectivamente. Conforme los valores de salida se acercan a estos límites,

las derivadas de esta función disminuyen. La segunda función de activación más utilizada es la función tangente-hiperbólica que es una versión bipolar de la función sigmoidea. En la literatura, se ha afirmado que el uso de la función de activación tangente provoca una convergencia más rápida de los algoritmos de aprendizaje que la función sigmoidea (C. M. Bishop, 1995). Haykin (1994) indicó que una función de activación asimétrica como la tangente-hiperbólica en lugar de la función sigmoidea asimétrica podría resultar mejor para la red PMC.

El algoritmo retro-propagación se basa en la selección de una adecuada función de error, dichos valores son determinados por las salidas real y deseada de la red la cual también depende de los parámetros de la red tales como los pesos y el umbral. La idea básicamente consiste en que la función de error tiene una superficie particular dentro del conjunto de pesos y, por lo tanto, el método de descenso de la gradiente puede ser usado para la minimización del error.

La función de entrenamiento *Bayesian Regularization* actualiza los valores de los pesos y el sesgo de acuerdo con la optimización de *Levenberg-Marquardt* que minimiza una combinación de errores cuadráticos y pesos, luego determina la combinación correcta de manera que produzca una correcta red generalizada (Hagan & Menhaj, 1994). El algoritmo converge cuándo: 1) el número máximo de iteraciones es alcanzado, 2) el error es minimizado hacia el objetivo, o 3) el gradiente de rendimiento cae por debajo del valor mínimo. Este algoritmo es el que se ha utilizado en el presente estudio.

Las interacciones entre los factores que pueden afectar a la estabilidad de taludes son complejas, obedecen a múltiples factores, y a menudo son difíciles de describir en forma

matemática, esto supone un reto importante para la predicción de la estabilidad de presas de materiales sueltos. El potencial de los sistemas de redes neuronales deriva del comportamiento de sus elementos dentro del sistema, en lugar del conocimiento de sus relaciones explícitas. Una red neuronal provee un mecanismo computacional que tiene la capacidad de representar el mapeo dentro de un sistema de información multi-factor y otro, dando un conjunto de datos que representan el mapeo (Ellis, Yao, Zhao, & Penumadu, 1995).

En el presente estudio se pretende establecer un método de predicción de la estabilidad de presas heterogéneas en base a la utilización de las redes neuronales artificiales y en base a dicho análisis establecer los parámetros geométricos y geotécnicos que provocan que el fallo en la presa afecte al núcleo central de la misma.

2. ESTADO DEL ARTE

A mediados de la década de los noventa del siglo anterior, numerosas publicaciones mostraron un creciente interés en la aplicación de las redes neuronales artificiales (RNA) en la ingeniería geotécnica para la modelización constitutiva, pruebas dinámicas de pilas, compactación del suelo, clasificación de suelos, análisis de elementos finitos, entre otras (ver por ejemplo: Flood & Kartam, 1994; Pande & Pietruszczak, 1995; Siriwardane & Zaman, 1994).

El concepto de las RNA ha encontrado resultados favorables en la ingeniería geotécnica; las RNA se han aplicado en la evaluación de las propiedades de suelos y rocas. Así por ejemplo, se han utilizado las RNA para modelar la relación tensión-deformación de arenas con diferente distribución del tamaño de grano e historial de esfuerzos. (Ellis et al., 1995). Lee, Lee y Kim

(2003) analizaron la estimación de la resistencia al corte en suelos no saturados usando redes neuronales artificiales, también desarrollaron un método en el que la cohesión aparente puede predecirse utilizando una RNA a partir de datos obtenidos en ensayos. Las RNA se han utilizado para la estimación del módulo de elasticidad de la roca intacta (Sonmez, Gokceoglu, Nefeslioglu, & Kayabasi, 2006), el mismo que se utiliza para muchos proyectos de ingeniería de roca, tales como túneles, taludes, y cimentaciones. Kuo, Jaksa, Lyamin y Kaggwa (2009) desarrolaron un método basado en redes perceptrón multicapa para la predicción de la capacidad de carga de zapatas continuas en suelos cohesivos de varias capas.

La estabilidad de taludes se ha considerado ampliamente dentro de las aplicaciones de las RNA. Lu y Rosenbaum (2003) ilustraron la aplicación de las RNA y los sistemas grises (Grey Systems) para predecir el estado de estabilidad de taludes; los autores emplearon los datos de 32 casos reportados en estudios anteriores, y concluyen que las RNA proveen una herramienta viable para situaciones donde se dispone de grandes cantidades de datos, mientras que la predicción con sistemas grises puede ser utilizada cuando los mecanismos explícitos responsables de los deslizamientos de tierra no son claras, pero la información relevante y los datos disponibles son limitados.

Sakellariou y Ferentinou (2005) ensayaron un número de RNA para la estimación de la estabilidad de taludes, emplearon el algoritmo de aprendizaje retro-propagación, la red predice el factor de seguridad modelado como un problema de función de aproximación, o el estado de estabilidad modelado, ya sea como un problema función de aproximación o como un modelo de clasificación. En el estudio emplea muestras cuyas formas de la superficie de deslizamiento son

circular y en forma de cuña. En el estudio se concluye que, en particular, hubo una mejor convergencia entre los valores del factor de seguridad (FS) estimados a partir de las redes neuronales y calculados a partir de los métodos de análisis, que en la convergencia entre los resultados del método de aproximación de mínimos cuadrados en comparación con los resultados de los métodos analíticos.

Farrokhzad, JanAliZadeh y Barari (2008) desarrollaron un estudio para predecir la estabilidad de taludes en un sitio específico mediante la aplicación de RNA. Los resultados de la predicción se compararon con los métodos de análisis más antiguos para validar el modelo. En el estudio se concluye que la correlación del modelo desarrollado con RNA y el modelo de Bishop en todo caso ha sido mayor al 92% y en la mayoría de casos se encuentra por encima del 95%. Los resultados experimentales demuestran que el modelo de red neuronal es una exitosa técnica en la predicción de la estabilidad de taludes.

Cho (2009) realizó un análisis de estabilidad de taludes probabilístico utilizando la superficie de respuesta basado en redes neuronales artificiales, en el estudio se presentó un procedimiento numérico para integrar un método comercial de elementos finitos en un análisis probabilístico de la estabilidad de taludes adoptando una red neuronal artificial para aproximar la función de estado límite.

Erzin y Cetin (2012) condujeron un estudio en el que desarrollaron modelos de regresión múltiple y de redes neuronales artificiales para estimar el valor crítico del factor de seguridad de

un talud artificial típico sometida a fuerzas sísmicas. En el estudio se concluye que el modelo de RNA ha mostrado una predicción de rendimiento más alto que el modelo de regresión múltiple.

Los mismos autores (Erzin & Cetin, 2013) realizaron otro estudio que se ocupa del desarrollo de modelos de regresión múltiple y redes neuronales para estimar valor del factor de seguridad crítico de taludes homogéneos finitos. Los resultados obtenidos a partir de modelos de RNA y de regresión múltiple se compararon con los calculados. Los valores predichos mediante RNA coinciden con los valores reales o calculados mucho mejor que los obtenidos a partir de regresión múltiple.

3. MATERIALES Y MÉTODOS

3.1. Análisis de filtración

En el análisis de filtración se utilizó una función de conductividad hidráulica constante, en la que el valor del coeficiente de permeabilidad dentro del núcleo correspondía a 10^{-8} m/s. La isotropía, es decir la relación de la permeabilidad vertical sobre la permeabilidad horizontal, se asumió también constante e igual a 10^{-1}. En el presente estudio, se ha asumido que el material de los espaldones es absolutamente permeable. En la Fig. 1 se muestra el resultado del análisis de filtración realizado mediante el programa computacional *SEEP/W* de *GeoStudio*, se observa la línea de saturación.

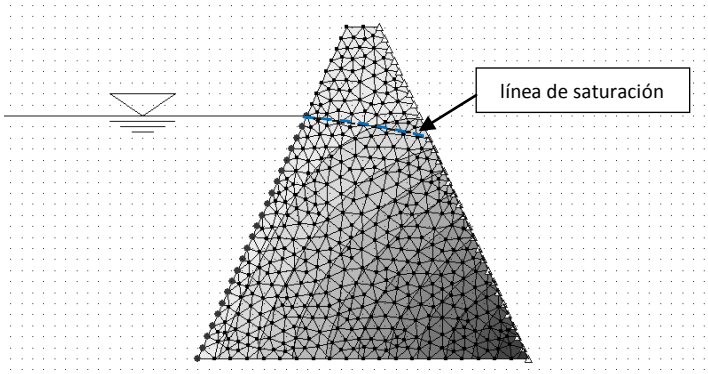

Fuente: Captura de pantalla del análisis SEEP/W de GeoStudio

Figura 1: Red de corriente del núcleo de la presa

3.2. Análisis de estabilidad de taludes

El análisis de estabilidad de taludes realizado mediante las herramientas computacionales de *GeoStudio* ha permitido obtener dos resultados: el tipo de falla *T* y el factor de seguridad *FS*. El tipo de falla es una variable discreta que puede tomar los valores de 0 o 1 según sea superficial o profunda respectivamente, en el segundo caso el círculo de falla afecta también al núcleo, como se ilustra en la Fig. 2. La herramienta computacional *SLOPE/W* de *GeoStudio* permite obtener el factor de seguridad según 4 métodos de análisis de estabilidad al deslizamiento, los métodos: Ordinario, Bishop, Janbu y Morgenstern-Price. En el presente estudio se ha utilizado el método de Bishop.

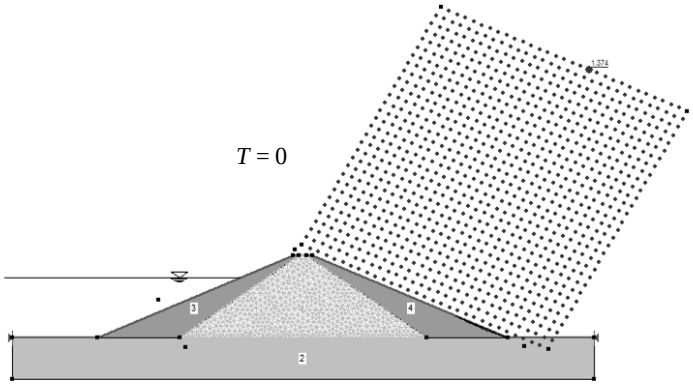

(a) Tipo de falla superficial

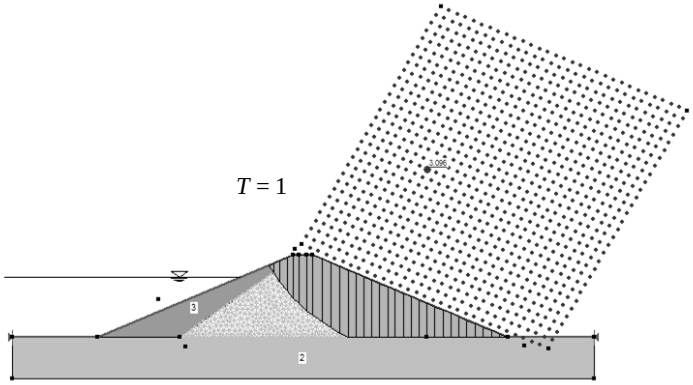

(b) Tipo de falla profunda

Fuente: Captura de pantalla del análisis SLOPE/W de GeoStudio

Figura 2: Ejemplos de falla superficial (a) y profunda (b)

Los pesos específicos del material del núcleo, así como del material de los espaldones, fueron asumidos como constantes en todos los casos descritos en la tabla 1, fijándose los valores de 18 y 22 KN/m^3 respectivamente. Para la cimentación se asumió un material rígido e impenetrable, definido como *bedrock* en el análisis *SLOPE/W* de *GeoStudio*.

3.3. Obtención de la muestra

Inicialmente se definió un modelo simplificado de presa con núcleo diferenciado en el que se asumió que ciertos parámetros geotécnicos y geométricos de la presa permanecen constantes, mientras que otros van a variar dentro de un rango de valores extremos. En el esquema de la Fig. 3 se ilustra el modelo simplificado que se ha utilizado en el presente estudio.

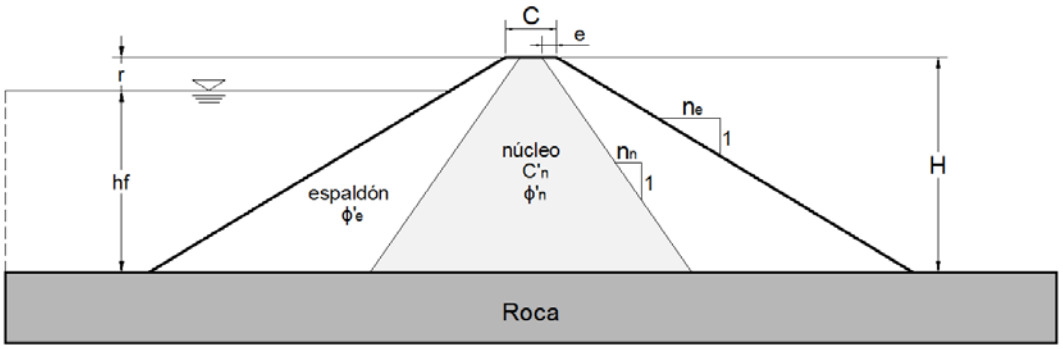

Figura 3: Esquema del modelo de presa utilizado en el estudio

Donde:

H: altura de la presa,

h_f: nivel del embalse,

r: resguardo,

C: ancho de la corona,

e: ancho del espaldón en la corona,

φ'_e: ángulo de rozamiento interno efectivo de la escollera,

φ'_n: ángulo de rozamiento interno efectivo del núcleo,

c'_n: cohesión efectiva del núcleo,

n_e: inclinación del espaldón,

n_n: inclinación del núcleo.

En las Ecuaciones 3 y 4, se expresa al factor de seguridad y al tipo de falla como dos funciones dependientes de los parámetros que se consideran variables en el presente estudio, es decir la altura total de la presa, la inclinación del talud del núcleo y de los espaldones, los ángulos de rozamiento efectivo de los materiales del núcleo y de los espaldones, y la cohesión efectiva del núcleo.

$$T = f\,(H,\ \varphi'_e,\ n_e,\ c'_n,\ \varphi'_n,\ n_n) \qquad \text{Ecuación 3}$$

$$FS = f\,(H,\ \varphi'_e,\ n_e,\ c'_n,\ \varphi'_n,\ n_n) \qquad \text{Ecuación 4}$$

La variación de los parámetros geotécnicos y geométricos que se consideraron en este estudio se resume en la Tabla 2. La combinación de estos parámetros, teniendo en cuenta que la inclinación del núcleo no puede ser superior a la del espaldón, arrojó un total de 729 casos diferentes de presas que constituyen la muestra con la que realizaremos el entrenamiento y la simulación de las redes neuronales artificiales.

Tabla 2: Resumen de los parámetros considerados en el estudio

Parámetros geométricos			Parámetros geotécnicos		
H (m)	n_e (m/m)	n_n (m/m)	φ'_e (°)	φ'_n (°)	c'_n (KPa)
30	1,22	0.45	30	15	0
80	1,88	0.95	50	30	100
130	2,38	1.45	70	40	500
		1.95			

En todos los casos analizados, independientemente de la altura total de la presa, se asumió un resguardo r = 8 m. Para determinar la anchura total de la coronación, se consideró una fórmula utilizada en la práctica española que depende de la altura de la presa y se considera recomendable según el SPANCOLD (2015). El espesor del espaldón en la parte superior se consideró como un valor constante e = 2 m en todos los casos.

$$C \geq 3 + 1.5 \sqrt[3]{H - 15} \qquad \text{Ecuación 2}$$

Donde:

C: ancho de la corona,

H: altura de la presa.

3.4. Análisis de redes neuronales

En el presente estudio se realizó el análisis de redes neuronales artificiales mediante el uso del programa computacional *MatLab v8.6* de *MathWorks*, específicamente mediante la herramienta *Neural Network Tool v8.4* convocada mediante el comando "*nntool*". Los pasos adoptados en el análisis pueden resumirse de la siguiente manera:

a) Configuración de datos,

b) Diseño y creación de la red,

c) Entrenamiento de la red,

d) Validación de la red.

3.4.1. Configuración de datos

Como se mencionó anteriormente, en el análisis de estabilidad al deslizamiento se asumió, en todos los casos, que ciertos parámetros son constantes y otros seis parámetros tomaron diferentes valores dentro de cierto rango. El análisis permitió obtener dos resultados: el tipo de falla *T* y el factor de seguridad *FS*.

El 60 % del conjunto total de datos, es decir 437 casos, fue empleado en la fase de entrenamiento de la red; mientras que para la fase de validación o simulación de respuesta de la red se empleó el 40 % restante, es decir 292 casos, tal como se indica en la Tabla 3. En ambas muestras (entrenamiento y simulación), se mantuvo la relación global aproximada de falla superficial sobre falla profunda, correspondiente a 7/3.

Tabla 3: Datos empleados en el entrenamiento y la simulación de las redes neuronales

Nro. de la muestra	$H,\ \varphi'_e,\ n_e,\ c'_n,\ \varphi'_n,\ n_n$	T	FS
1 2 3 ⋮ 437	Datos de entrada en la fase de entrenamiento	Datos objetivo del tipo de falla	Datos objetivo del factor de seguridad
1 2 3 ⋮ 292	Datos de entrada en la fase de simulación	–	–

3.4.2. Diseño y entrenamiento de la red

Con los datos configurados, a través de la herramienta *nntool* de *MatLab v8.6*, se establecieron dos grupos de redes neuronales, el primer grupo corresponde al entrenamiento de la red en la estimación del factor de seguridad y el segundo corresponde a la estimación del tipo de falla. Las redes fueron creadas utilizando el algoritmo de retro-propagación (*back-propagation*) alimentadas hacia adelante (*feed-forward*), es decir redes que son del tipo "*Feed-forward backprop*" según la nomenclatura del *MatLab v8.6*. En todas las redes se utilizó la función de entrenamiento *TRAINBR*, la función de aprendizaje para la adaptación *LEARNGDM* y la función de desempeño basada en la optimización del error cuadrático medio o *MSE* por sus siglas en inglés.

No existe ningún método que determine la arquitectura adecuada al resolver un problema específico, esta tarea se basa en la experiencia del analista que diseñe la red. Todas las redes fueron creadas con 3 capas: una capa de entrada, una capa oculta y una capa de salida. Para la capa oculta fueron utilizadas las funciones de transferencia tangente-hiperbólica (*TANSIG*) y

sigmoidea (*LOGSIG*). En el presente estudio, se analizaron en primera instancia los resultados de varias arquitecturas compuestas por 5, 10 y 15 neuronas o nodos en la capa oculta. La Fig. 4 muestra un esquema de la arquitectura de una red neuronal con los 6 nodos de entrada, 10 nodos en la capa oculta, y un nodo de salida, red neuronal 6-10-1.

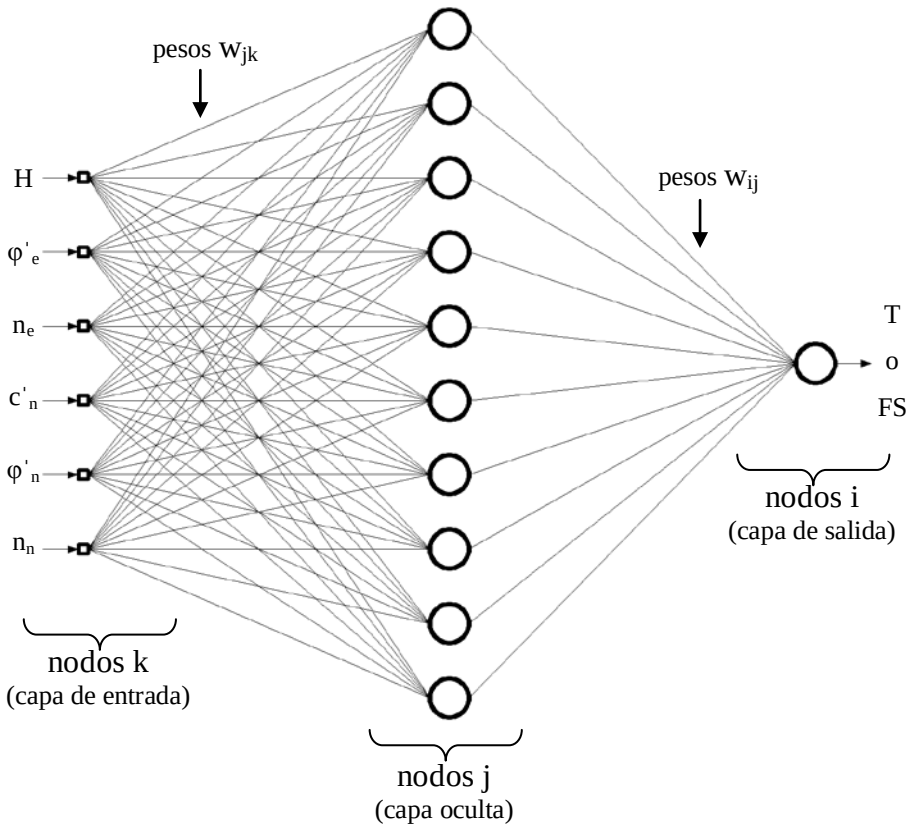

Figura 4: Arquitectura 6-10-1 para la predicción de T o FS

3.4.3. Validación de la red

La validación de la red ha sido realizada mediante un proceso de simulación de respuesta con el 40 % de los datos que no se utilizaron en el entrenamiento. Las salidas de la red en la fase

de entrenamiento así como las simuladas en la fase de validación fueron posteriormente comparadas con las salidas esperadas, es decir las calculadas con el *SLOPE/W* de *GeoStudio*.

Para establecer la bondad de la estimación mediante redes neuronales, se calculó el error cuadrático medio (*MSE* por sus siglas en inglés) para los conjuntos de salidas del entrenamiento y de la simulación, conforme a la siguiente expresión:

$$MSE=\frac{1}{n}\sum_{i=1}^{n}\left(y_i - y'_i\right)^2 \qquad \text{Ecuación 5}$$

Donde:

n: número de datos de entrada, 437 en el entrenamiento y 292 en la simulación,

y_i: respuesta de la red para *FS* y *T*, y

y'_i: respuesta esperada para *FS* y *T* calculados mediante el *SLOPE/W* de *GeoStudio*.

En la estimación del tipo de falla, adicional al cálculo del MSE, podría resultar conveniente realizar un análisis en el que se asume que todas las respuestas de la red cuyo valor se encuentra por encima de 0,5 corresponden al tipo de falla profundo; y que todas las respuestas de la red cuyo valor se encuentre por debajo de 0,5 corresponden al tipo de falla superficial, conforme se ha ilustrado en la Fig. 5. Este análisis permitiría establecer puntualmente cuáles han sido los casos en los que la estimación del tipo de falla a través de las redes neuronales ha sido efectiva, pudiendo establecerse el número de aciertos y consecuentemente su porcentaje equivalente.

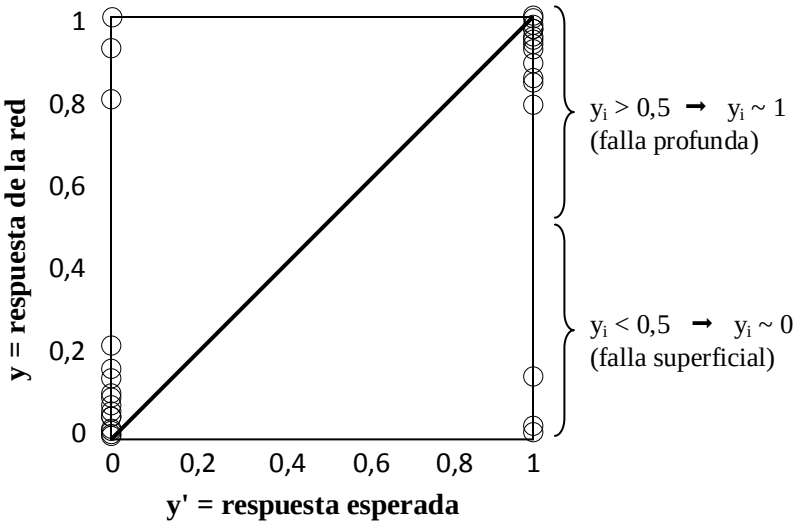

Figura 5: Hipótesis asumida para la estimación del tipo de falla

4. RESULTADOS Y DISCUSIÓN

En el Apéndice 1 se presenta una tabla con los valores de del tipo de falla calculados mediante el *SLOPE/W* de *GeoStudio* para los 729 casos, en la misma tabla se incluyen los valores estimados a través de las redes neuronales artificiales diseñadas en el presente estudio. En el Apéndice 2 se incluyen tres tablas con los pesos de las conexiones de las redes diseñadas en el presente estudio, la primera correspondiente a la predicción del tipo de falla y las otras dos correspondientes a la predicción del factor de seguridad.

4.1. Predicción del tipo de falla

Las Tablas 4 y 5, muestran los resultados del cálculo del MSE y de las predicciones fallidas, respectivamente, en la estimación del tipo de falla a través de las redes neuronales, tanto para la fase de entrenamiento como para la fase de simulación.

Tabla 4: MSE del grupo de redes para la estimación del tipo de falla

# Neuronas	Función TANSIG		Función LOGSIG	
	Entrenamiento	Simulación	Entrenamiento	Simulación
5	0.0056	0.0585	0.0076	0.0597
10	**0.0001**	**0.0406**	0.0023	0.0495
15	0.0020	0.0510	0.0019	0.0356

Tabla 5: Porcentaje de aciertos para la estimación del tipo de falla

# Neuronas capa oculta	Función TANSIG		Función LOGSIG	
	Entrenamiento	Simulación	Entrenamiento	Simulación
5	434/437 = 99.3%	269/292 = 92.1%	433/437 = 99.1%	269/292 = 92.1%
10	**437/437 = 100.0%**	**279/292 = 95.5%**	436/437 = 99.8%	271/292 = 92.8%
15	436/437 = 99.8%	271/292 = 92.8%	436/437 = 99.8%	276/292 = 94.5%

Una comparación de los valores del tipo de falla calculados a través del *SLOPE/W* de *GeoStudio* (valores *T'*), con los valores obtenidos a partir del modelo de la red neuronal con mejores resultados (valores *T*), se representa en la Fig. 6 para las fases de entrenamiento y simulación.

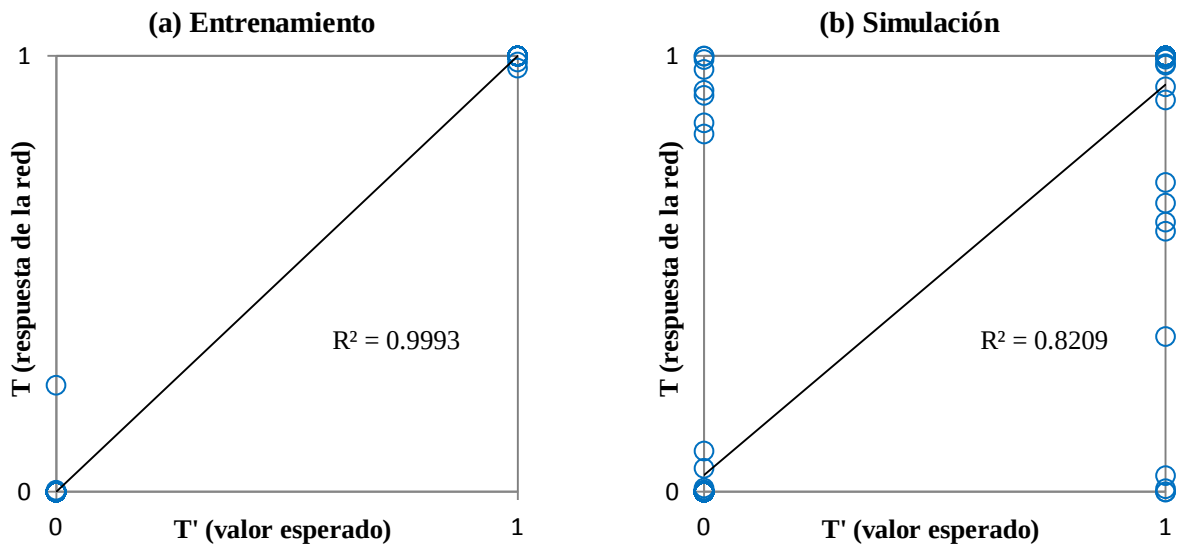

Figura 6: Comparación de *T* vs *T'* en las fases de entrenamiento (a) y simulación (b)

Los resultados mostrados en las Tablas 4 y 5 y la Fig. 6 permiten establecer de manera preliminar las siguientes conclusiones con respecto a la estimación del tipo de falla:

- De manera general, el porcentaje de aciertos así como los valores del MSE en la fase de entrenamiento son bastante satisfactorios, lo que significa que el diseño de la red ha sido adecuado.
- De manera general, el porcentaje de aciertos así como los valores del MSE en la fase de simulación son aceptables, lo que significa que la red entrenada tiene una precisión media en la predicción del tipo de falla.
- Utilizando la función de transferencia tangente-hiperbólica, el diseño de una red con 10 neuronas en la capa oculta produjo mejores resultados.
- Utilizando la función de transferencia sigmoidea, el diseño de una red con 15 neuronas en la capa oculta produjo mejores resultados.

- Bien sea en la fase de entrenamiento o en la simulación, no se aprecia de manera contundente que exista una función de activación con mejores resultados.
- Tomando en consideración el porcentaje de aciertos, la red neuronal artificial que mejor desempeño ha mostrado es la que se diseñó con 10 neuronas en la capa oculta y la función de activación tangente-hiperbólica.
- En la comparación de *T* vs *T'*, la correlación lineal es bastante buena en la fase de entrenamiento (R^2 = 0,9993), sin embargo en la fase de simulación la correlación lineal es más bien aceptable (R^2 = 0,8209) evidenciándose errores significativos tanto en la predicción del tipo de falla superficial (T = 0) como profunda (T = 1).

4.2. Predicción del factor de seguridad

La Tabla 6, muestra los resultados del cálculo del MSE en la estimación del factor de seguridad a través de las redes neuronales, tanto para la fase de entrenamiento como para la fase de simulación. Una comparación de los valores del factor de seguridad calculados mediante el *SLOPE/W* de *GeoStudio* (valores *FS'*), con los valores estimados del factor de seguridad a partir del modelo de la red neuronal con mejores resultados (valores *FS*), se representa en la Fig. 7 para el entrenamiento y la simulación.

Tabla 6: MSE del grupo de redes para la estimación del factor de seguridad

# Neuronas capa oculta	Función TANSIG		Función LOGSIG	
	Entrenamiento	Simulación	Entrenamiento	Simulación
5	0.0376	0.0573	0.0364	0.0614
10	0.0117	0.0254	0.0126	0.0224
15	**0.0053**	**0.0175**	0.0061	0.0178

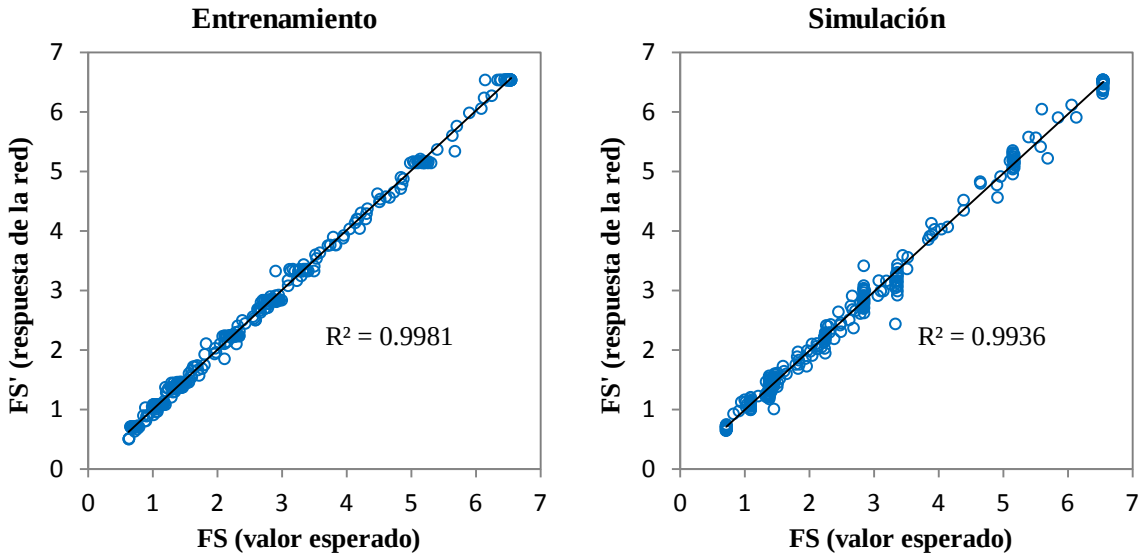

Figura 7: Comparación de *FS* vs *FS'* en las fase de entrenamiento (a) y simulación (b)

En el presente estudio, también fueron diseñadas dos redes neuronales adicionales para la predicción del factor de seguridad *FS*, esta vez considerando el conocimiento previo sobre el tipo de falla específico (superficial $T = 0$ o profunda $T = 1$); estas redes conservan las mismas características que en casos anteriores, con la salvedad de que en la capa oculta se utilizaron 6 neuronas, y dados los resultados anteriores se utilizó únicamente la función de activación tangente-hiperbólica (*TANSIG*). Los resultados del desempeño de estas redes se presentan en la Tabla 7 y en las Fig. 8 y 9.

Tabla 7: MSE del grupo de redes para la estimación de FS

# Neuronas capa oculta	T = 0		T = 1	
	Entrenamiento	Simulación	Entrenamiento	Simulación
6	$1{,}6 \times 10^{-6}$	$2{,}6 \times 10^{-6}$	0,0054	0,0257

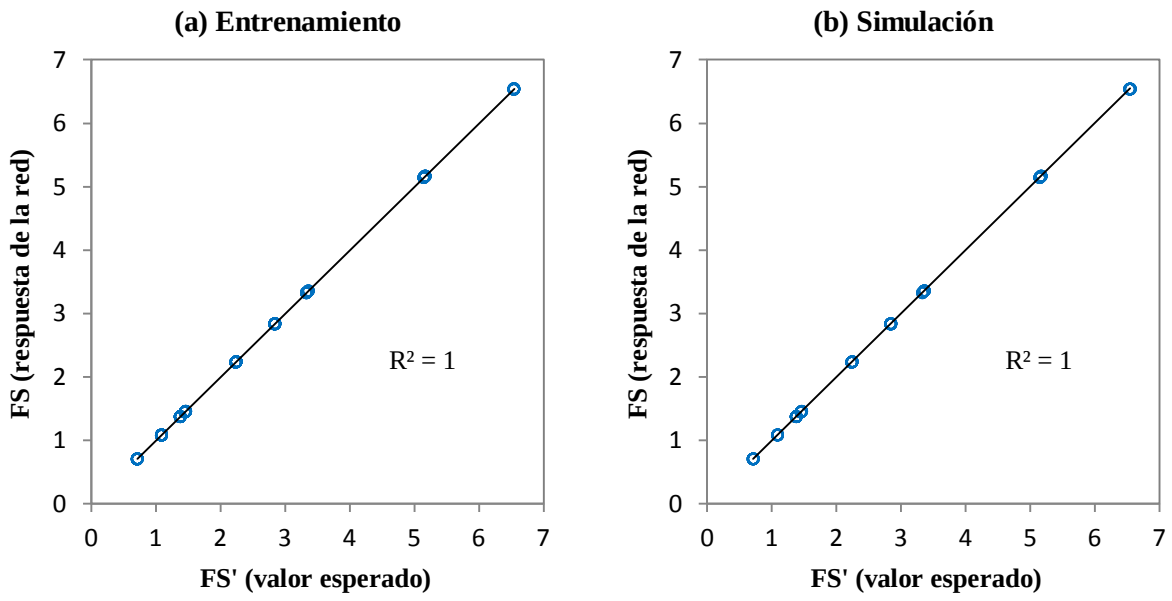

Figura 8: Comparación de *FS* vs *FS'* para T=0, entrenamiento (a) y simulación (b)

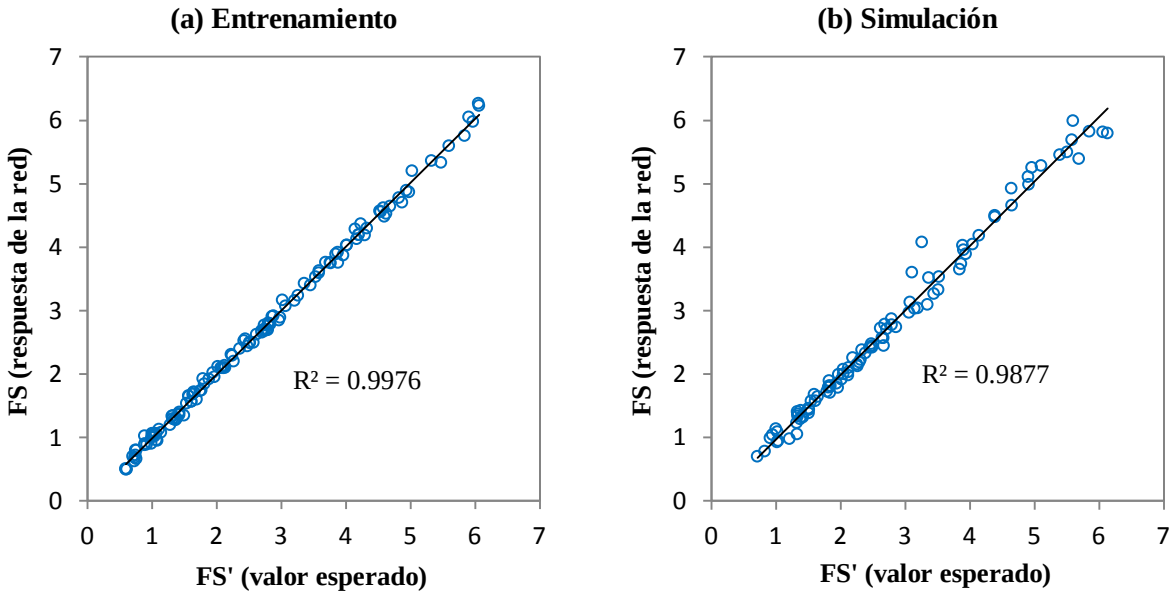

Figura 9: Comparación de *FS* vs *FS'* para T=1, entrenamiento (a) y simulación (b)

Los resultados presentados en la Tablas 6 y en la Fig. 7 permiten establecer de manera preliminar las siguientes conclusiones con respecto a la estimación del factor de seguridad:

- De manera general, los valores del MSE en la fase de entrenamiento son bastante aceptables, lo cual significa que el diseño de la red ha sido adecuado.
- De manera general, los valores del MSE en la fase de simulación son bastante aceptables, lo cual significa que la red entrenada tiene una precisión relativamente alta en la predicción del factor de seguridad.
- En la fase de entrenamiento, bien sea utilizando la función de transferencia tangente-hiperbólica o la función sigmoidea, el diseño de una red con 15 neuronas en la capa oculta produjo mejores resultados.
- En la fase de simulación, bien sea utilizando la función de transferencia tangente-hiperbólica o la función sigmoidea, el diseño de una red con 15 neuronas en la capa oculta produjo mejores resultados.
- Tanto en la fase de entrenamiento como en la fase de simulación, puede apreciarse que el uso de la función de transferencia tangente-hiperbólica apenas produjo mejores resultados respecto de la sigmoidea.
- Tomando en consideración los valores del MSE, la red neuronal artificial que mejor desempeño ha mostrado es la que se diseñó con 15 neuronas en la capa oculta y la función de activación tangente-hiperbólica.
- En la comparación de *FS* vs *FS'*, la correlación lineal es bastante buena en la fase de entrenamiento (R^2 = 0,9981) al igual que en la fase de simulación (R^2 = 0,9936).

Los resultados presentados en la Tablas 7 y en las Fig. 8 y 9 permiten establecer de manera preliminar las siguientes conclusiones con respecto a la estimación del factor de seguridad:

- En la predicción de *FS*, utilizando únicamente los datos en los que el valor de *T* es conocido e igual a cero (falla superficial), el desempeño de la red neuronal es casi perfecto con valores del *MSE* menores a 10^{-5} tanto en el entrenamiento como en la simulación.
- Por otro lado, en la predicción de *FS*, utilizando únicamente los datos en los que el valor de *T* es conocido e igual a uno (falla profunda), el desempeño es aún bueno, pero menor al alcanzado mediante la utilización de todos los datos ($T = 0$ y $T = 1$).

4.3. Estudio paramétrico

Dado que la red neuronal es capaz de generalizar, un método de partición de los pesos de las conexiones entre neuronas propuesto por Garson (1991), y adoptado por otros autores (por ejemplo: Goh, 1995; Sakellariou & Ferentinou, 2005), se utilizó en este estudio con el fin de determinar la importancia relativa de los diversos parámetros de entrada (H, φ'_e, n_e, c'_n, φ'_n, n_n) en las salidas (*T* o *FS*). Este método implica la partición de los pesos de las conexiones entre las capas oculta y de salida de cada nodo oculto, en componentes relativos asociados con cada nodo de entrada. En la predicción del tipo de falla (ver Fig. 4), la red neuronal de arquitectura 6-10-1 fue la que tuvo el mejor desempeño; w_{jk} representa los pesos de las conexiones entre las capas de entrada y oculta, y w_{ij} representa los pesos de las conexiones entre las capas de oculta y de salida. El método se realiza siguiendo los pasos siguientes:

- Para cada neurona de la capa oculta j, multiplicar el valor absoluto del peso w_{ij} por el valor absoluto del peso w_{jk}. Haciendo esto para cada variable de entrada k, se obtiene la matriz P_{jk}.
- Al dividir P_{jk} para la suma de todas las variables de entrada ($\Sigma\ P_{jk}$) se obtiene Q_{jk} para cada neurona oculta.
- Para cada neurona oculta j, calcular S_k como resultado de la suma de todos los Q_{jk} calculados en el paso anterior.
- Al dividir S_k para la suma de todas las variables de entrada ($\Sigma\ S_{jk}$) se obtiene w_k; expresado en porcentaje, este último valor representa la importancia relativa de la distribución de todos los pesos atribuidos a las variables de entrada.

El mismo procedimiento se llevó a cabo para obtener los porcentajes de la importancia relativa de los parámetros de entrada en la estimación del factor de seguridad. Los resultados del estudio paramétrico para la predicción del tipo de falla T se presentan en la Fig. 10. Se puede observar con claridad que los parámetros más dominantes en la predicción del tipo de falla T, son H, φ'_e, c'_n y n_n, que corresponden a la altura de la presa, el ángulo de rozamiento efectivo del material del espaldón, la cohesión efectiva del núcleo y la inclinación del núcleo; lógicamente los demás parámetros (n_e y φ'_n), son también importantes.

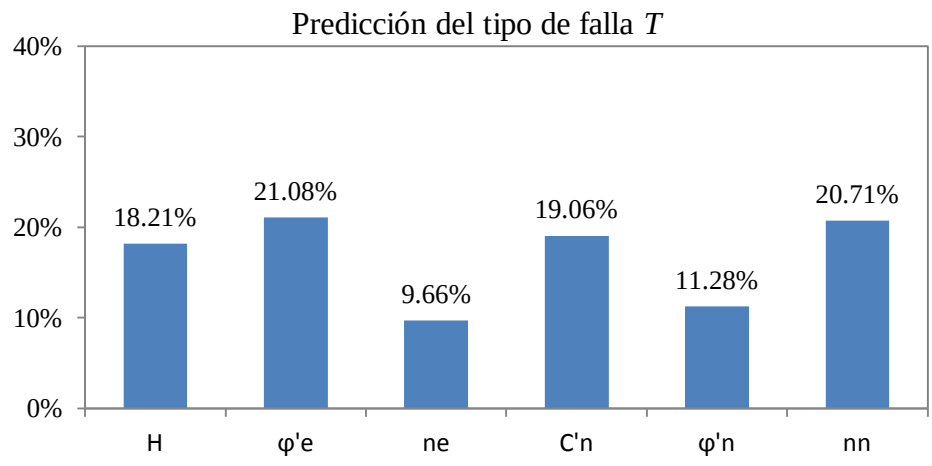

Figura 8: Importancia relativa de los parámetros de entrada en la predicción de T

Por otro lado, en la predicción del factor de seguridad *FS*, es necesario distinguir el tipo de red, así en las redes que se entrenaron utilizando todos los 729 datos, es decir tanto casos de falla superficial como profunda, el parámetro de entrada predominante fue n_n, es decir la inclinación del núcleo, seguido en importancia por los parámetros φ'_e, n_e y c'_n, los parámetros H y φ'_n tuvieron menor importancia en este análisis.

En las redes entrenadas utilizando los casos en los que el tipo de falla es superficial (505 casos), los parámetros predominantes en la predicción del factor de seguridad son φ'_e y n_e, que corresponden al ángulo de rozamiento efectivo y la inclinación del espaldón, y con una menor importancia está la altura de la presa H; las características del núcleo (c'_n, φ'_n y n_n) no tienen ninguna importancia en la predicción de *FS* en este tipo de redes. Esto se explica debido a que en el tipo de falla superficial, el factor de seguridad se determina mediante el producto entre la inclinación del espaldón y la tangente del ángulo de rozamiento efectivo. Finalmente, en las redes entrenadas utilizando los casos en los que el tipo de falla es profundo (224 casos), la

cohesión del núcleo c'_n es el parámetro predominante en la predicción del factor de seguridad, seguido de n_e, y n_n, y luego con menor importancia H, φ'_e y φ'_n.

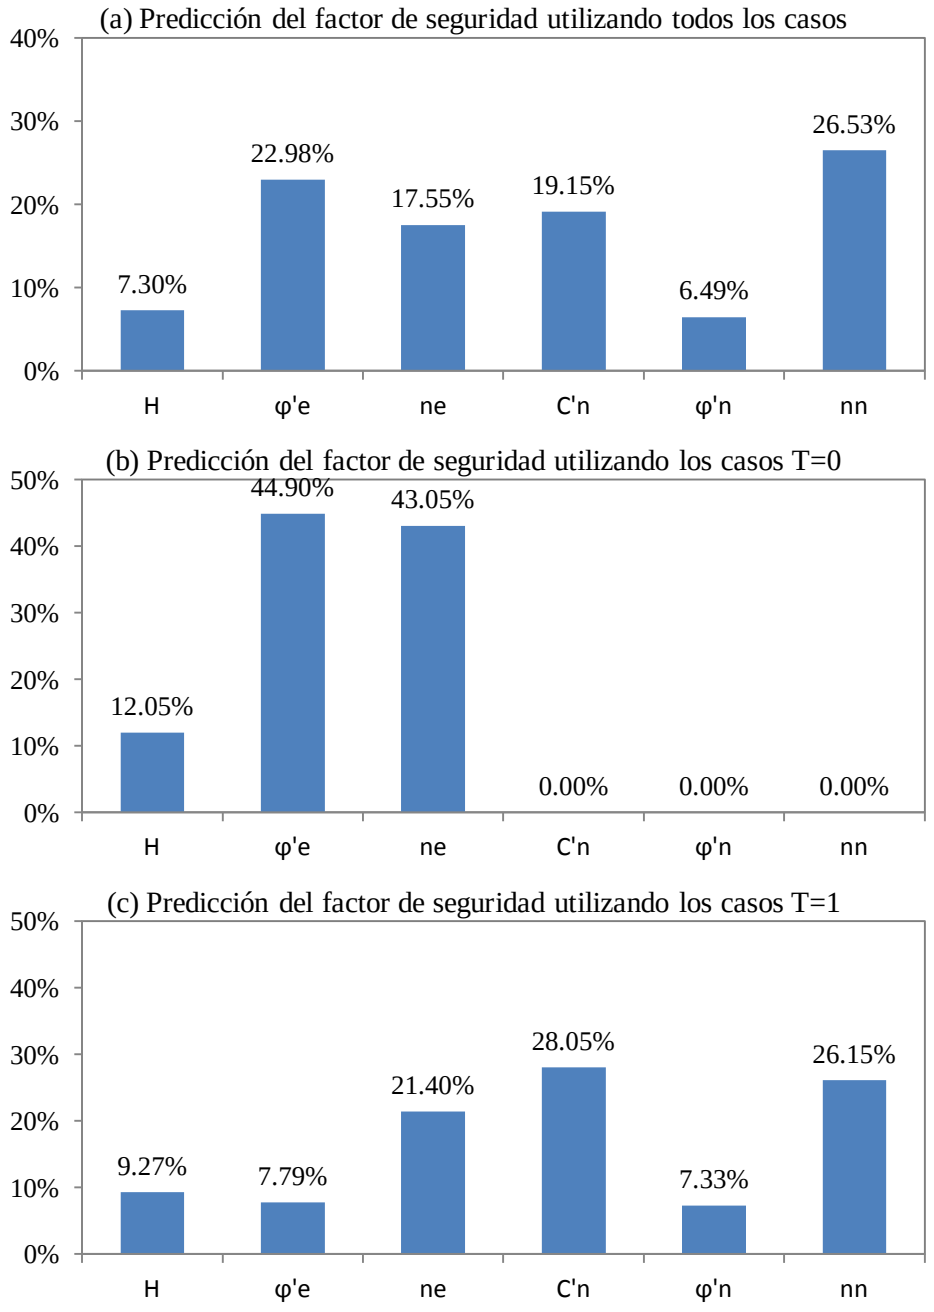

Figura 8: Importancia relativa de los parámetros de entrada en la predicción de FS

4.4. Conclusiones generales

En la predicción mediante redes neuronales artificiales, tanto del tipo de falla como del factor de seguridad, la función de transferencia tangente-hiperbólica ha sido la que ha permitido obtener los mejores resultados.

Las redes neuronales artificiales diseñadas en el presente estudio para la predicción del tipo de falla, tienen en general, un excelente desempeño en la fase de entrenamiento. No obstante, en la fase de simulación de la muestra que no forma parte del conjunto de datos de entrenamiento, las redes tienen menor eficacia.

En base a la fase de simulación del tipo de falla con los datos que no formaron parte del entrenamiento (292 datos), tomando como referencia la red neuronal artificial con mejor desempeño, es decir la red diseñada con 10 neuronas en la capa oculta y una función de activación tangente-hiperbólica, se podría concluir que la red entrenada en el presente estudio (con 437 datos) tiene un gran porcentaje de acierto (95,5 %).

El ranking de importancia de los parámetros que influyen en la predicción del tipo de falla estimado en el presente estudio mediante redes neuronales, implica que su estimación es un fenómeno de dimensiones múltiples en el que influyen casi con la misma importancia (cercana al 20 %) todos los parámetros, con excepción de la inclinación de los espaldones y el ángulo de rozamiento efectivo del material del núcleo que tienen una importancia menor (cercana al 10 %).

Razón por la cual, en el análisis de estabilidad de presas heterogéneas, deben tenerse muy en cuenta todos los seis parámetros considerados en el estudio.

En la predicción del factor de seguridad, es claro que los desempeños de las redes dependen del tipo de datos de entrada. Así las redes entrenadas únicamente con datos correspondientes al tipo de falla superficial, tuvieron un desempeño casi perfecto.

En el ranking de importancia de los parámetros que influyen en la predicción del factor de seguridad utilizando en el entrenamiento y simulación únicamente el tipo de falla superficial, predomina la influencia de las características geométricas y geotécnicas del espaldón (cercanas al 44 %), siendo también influyente la altura de la presa con una importancia menor (cerca al 12 %). Las características del núcleo han tenido una importancia nula en esta predicción.

Por otro lado, si en el entrenamiento y simulación de la red se utilizan únicamente como datos de entrada los casos en los que el fallo afecta al núcleo, predominan en la predicción del factor de seguridad, la cohesión e inclinación del núcleo, seguidos en importancia por la inclinación del espaldón, y con importancias menores al 10%, la altura de la presa y los ángulos de rozamiento interno de los dos materiales.

5. REFERENCIAS

1. Bishop, A. W. (1955). The use of the slip circle in the stability analysis of slopes. *Géotechnique, 5*, 7-17.

2. Bishop, C. M. (Ed.). (1995). *Neural networks for pattern recognition* (1st ed.). Oxford, United Kingdom: Clarendon Press.
3. Cho, S. E. (2009). Probabilistic stability analyses of slopes using the ANN-based response surface. *Computers and Geotechnics, 36*(5), 787-797.
4. Comité Nacional Español de Grandes Presas (Ed.). (2015). *Guía técnica de seguridad de presas nro. 2: Criterios para proyectos de presas y sus obras anejas* (1st ed.). Madrid: Gráficas Rito.
5. Duncan, J. M. (1996). State of the art: Limit equilibrium and finite-element analysis of slopes. *Journal of Geotechnical Engineering, 122*(7), 577-596.
6. Ellis, G., Yao, C., Zhao, R., & Penumadu, D. (1995). Stress-strain modeling of sands using artificial neural networks. *Journal of Geotechnical Engineering, 121*(5), 429-435.
7. Erzin, Y., & Cetin, T. (2012). The use of neural networks for the prediction of the critical factor of safety of an artificial slope subjected to earthquake forces. *Scientia Iranica, 19*(2), 188-194.
8. Erzin, Y., & Cetin, T. (2013). The prediction of the critical factor of safety of homogeneous finite slopes using neural networks and multiple regressions. *Computers & Geosciences, 51*, 305-313.
9. Farrokhzad, F., JanAliZadeh, A., & Barari, A. (2008). Prediction of slope stability using artificial neural network (case study: Noabad, mazandaran, iran). *International Conference on Case Histories in Geotechnical Engineering, Paper 41,* Arlington, VA, USA.
10. Fellenius, W. (1936). Calculation of the stability of earth dams. *International Congress on Large Dams. 2d,* Washington, D.C. , *4* 445-463.

11. Flood, I., & Kartam, N. (1994). Neural networks in civil engineering. I: Principles and understanding. *Journal of Computing in Civil Engineering, 8*(2), 131-148.
12. Garson, G. D. (1991). Interpreting neural-network connection weights. *AI Expert, 6*(4), 46-51.
13. Goh, A. T. C. (1995). Back-propagation neural networks for modelling complex systems. *Artificial Intelligence Eng., 9*, 143–151.
14. Hagan, M. T., & Menhaj, M. B. (1994). Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks, 5*(6), 989-993.
15. Haykin, S. (Ed.). (1994). *Neural network: A comprehensive foundation* (1st ed.). New York, USA: Macmillan College Publishing Company, Inc.
16. International Commission on Large Dams. (1973). *Lessons from dam incidents*
17. Janbu, N. (1968). Slope stability computations. *Soil Mech, and found. Engrg. Rep., 23.8*, 66.
18. Kohonen, T. (Ed.). (1989). *Self-organization and associative memory*. New York: Springer Verlag.
19. Krahn, J. (Ed.). (2004). *Seepage modeling with SEEP/W: An engineering methodology* (First Edition ed.). Alberta, Canada: GEO-SLOPE/W International Ltd.
20. Kuo, Y. L., Jaksa, M. B., Lyamin, A. V., & Kaggwa, W. S. (2009). ANN-based model for predicting the bearing capacity of strip footing on multi-layered cohesive soil. *Computers and Geotechnics, 36*(3), 503-516.
21. Lee, S. J., Lee, S. R., & Kim, Y. S. (2003). An approach to estimate unsaturated shear strength using artificial neural network and hyperbolic formulation. *Computers and Geotechnics, 30*(6), 489-503.

22. Lowe, J. (1967). Stability analysis of embankments. *Soil Mech, and found. Div., 93(4)*, 1-33.

23. Lowe, J., & Karafiath, L. (1960). Stability of earth dams upon draw-down. *1st Pan-Am. Conf. on Soil Mech. and found. Engrg.* Mexico City. , *2* 537-552.

24. Lu, P., & Rosenbaum, M. S. (2003). Artificial neural networks and grey systems for the prediction of slope stability . *Natural Hazards, 30*(3), 389-398.

25. Morgenstern, N. R., & Price, V. (1965). The analysis of the stability of general slip surfaces. *Geotechniquc, 15*, 79-93.

26. Pande, G. N., & Pietruszczak, S. (1995). Numerical models in geomechanics. *Proc. 5Th Int. Symp. on Num. Models in Geomechanics*, Davos, Switzerland.

27. Sakellariou, M. G., & Ferentinou, M. D. (2005). A study of slope stability prediction using neural networks. *Geotechnical & Geological Engineering, 23*(4), 419-445.

28. Siriwardane, H. J., & Zaman, M. M. (1994). Computer methods and advances in geomechanics. *Proc. 8Th Int. Conf. of Computer Met. and Advances in Geomech.* Morgantown, USA. 22-28.

29. Sonmez, H., Gokceoglu, C., Nefeslioglu, H. A., & Kayabasi, A. (2006). Estimation of rock modulus: For intact rocks with an artificial neural network and for rock masses with a new empirical equation. *International Journal of Rock Mechanics and Mining Sciences, 43*(2), 224-235.

30. Spencer, E. (1967). A method of analysis of stability of the embankments assuming parallel interslice forces. *Geotechnique, 17(1)*, 11-26.

Predicción de la estabilidad de presas heterogéneas mediante redes neuronales artificiales

(Apéndice)

Autor: César Costa Costa

Directores: Miguel Ángel Toledo Municio

Rafael Morán Moya

APÉNDICE 1

T y FS calculados mediante SLOPE/W de GeoStudio y estimados mediante las RNA

Nro.	Variables de entrada						Cálculos SLOPE/W		Estimación RNA	
	H (m)	φ'_e (^{0})	n_e (m/m)	c'_n (Kpa)	φ'_n (^{0})	n_n (m/m)	T'	FS'	T	FS
1	30	30	1.22	0	15	0.45	0	0.705	0	0.708
2	30	30	1.22	0	15	0.95	1	0.506	1	0.607
3	30	30	1.22	0	30	0.45	0	0.705	0	0.708
4	30	30	1.22	0	30	0.95	0	0.705	0	0.708
5	30	30	1.22	0	40	0.45	0	0.705	0	0.708
6	30	30	1.22	0	40	0.95	0	0.705	0	0.708
7	30	30	1.22	100	15	0.45	0	0.705	0	0.708
8	30	30	1.22	100	15	0.95	0	0.705	0	0.708
9	30	30	1.22	100	30	0.45	0	0.705	0	0.708
10	30	30	1.22	100	30	0.95	0	0.705	0	0.708
11	30	30	1.22	100	40	0.45	0	0.705	0	0.708
12	30	30	1.22	100	40	0.95	0	0.705	0	0.708
13	30	30	1.22	500	15	0.45	0	0.705	0	0.708
14	30	30	1.22	500	15	0.95	0	0.705	0	0.708
15	30	30	1.22	500	30	0.45	0	0.705	0	0.708
16	30	30	1.22	500	30	0.95	0	0.705	0	0.708
17	30	30	1.22	500	40	0.45	0	0.705	0	0.708
18	30	30	1.22	500	40	0.95	0	0.705	0	0.708
19	30	30	1.88	0	15	0.45	0	1.082	0	1.082
20	30	30	1.88	0	15	0.95	1	1.018	1	1.095
21	30	30	1.88	0	15	1.45	1	0.728	1	0.739
22	30	30	1.88	0	30	0.45	0	1.082	0	1.082
23	30	30	1.88	0	30	0.95	0	1.082	0	1.082
24	30	30	1.88	0	30	1.45	0	1.082	0	1.082
25	30	30	1.88	0	40	0.45	0	1.082	0	1.082
26	30	30	1.88	0	40	0.95	0	1.082	0	1.082
27	30	30	1.88	0	40	1.45	0	1.082	0	1.082
28	30	30	1.88	100	15	0.45	0	1.082	0	1.082
29	30	30	1.88	100	15	0.95	0	1.082	0	1.082
30	30	30	1.88	100	15	1.45	0	1.082	0	1.082
31	30	30	1.88	100	30	0.45	0	1.082	0	1.082

32	30	30	1.88	100	30	0.95	0	1.082	0	1.082
33	30	30	1.88	100	30	1.45	0	1.082	0	1.082
34	30	30	1.88	100	40	0.45	0	1.082	0	1.082
35	30	30	1.88	100	40	0.95	0	1.082	0	1.082
36	30	30	1.88	100	40	1.45	0	1.082	0	1.082
37	30	30	1.88	500	15	0.45	0	1.082	0	1.082
38	30	30	1.88	500	15	0.95	0	1.082	0	1.082
39	30	30	1.88	500	15	1.45	0	1.082	0	1.082
40	30	30	1.88	500	30	0.45	0	1.082	0	1.082
41	30	30	1.88	500	30	0.95	0	1.082	0	1.082
42	30	30	1.88	500	30	1.45	0	1.082	0	1.082
43	30	30	1.88	500	40	0.45	0	1.082	0	1.082
44	30	30	1.88	500	40	0.95	0	1.082	0	1.082
45	30	30	1.88	500	40	1.45	0	1.082	0	1.082
46	30	30	2.38	0	15	0.45	0	1.375	0	1.375
47	30	30	2.38	0	15	0.95	0	1.375	0	1.375
48	30	30	2.38	0	15	1.45	1	1.086	1	1.136
49	30	30	2.38	0	15	1.95	1	0.822	1	0.788
50	30	30	2.38	0	30	0.45	0	1.375	0	1.375
51	30	30	2.38	0	30	0.95	0	1.375	0	1.375
52	30	30	2.38	0	30	1.45	0	1.375	0	1.375
53	30	30	2.38	0	30	1.95	0	1.375	0	1.375
54	30	30	2.38	0	40	0.45	0	1.375	0	1.375
55	30	30	2.38	0	40	0.95	0	1.375	0	1.375
56	30	30	2.38	0	40	1.45	0	1.375	0	1.375
57	30	30	2.38	0	40	1.95	0	1.375	0	1.375
58	30	30	2.38	100	15	0.45	0	1.375	0	1.375
59	30	30	2.38	100	15	0.95	0	1.375	0	1.375
60	30	30	2.38	100	15	1.45	0	1.375	0	1.375
61	30	30	2.38	100	15	1.95	0	1.375	0	1.375
62	30	30	2.38	100	30	0.45	0	1.375	0	1.375
63	30	30	2.38	100	30	0.95	0	1.375	0	1.375
64	30	30	2.38	100	30	1.45	0	1.375	0	1.375
65	30	30	2.38	100	30	1.95	0	1.375	0	1.375
66	30	30	2.38	100	40	0.45	0	1.375	0	1.375
67	30	30	2.38	100	40	0.95	0	1.375	0	1.375
68	30	30	2.38	100	40	1.45	0	1.375	0	1.375
69	30	30	2.38	100	40	1.95	0	1.375	0	1.375
70	30	30	2.38	500	15	0.45	0	1.375	0	1.375
71	30	30	2.38	500	15	0.95	0	1.375	0	1.375
72	30	30	2.38	500	15	1.45	0	1.375	0	1.375
73	30	30	2.38	500	15	1.95	0	1.375	0	1.375

74	30	30	2.38	500	30	0.45	0	1.375	0	1.375
75	30	30	2.38	500	30	0.95	0	1.375	0	1.375
76	30	30	2.38	500	30	1.45	0	1.375	0	1.375
77	30	30	2.38	500	30	1.95	0	1.375	0	1.375
78	30	30	2.38	500	40	0.45	0	1.375	0	1.375
79	30	30	2.38	500	40	0.95	0	1.375	0	1.375
80	30	30	2.38	500	40	1.45	0	1.375	0	1.375
81	30	30	2.38	500	40	1.95	0	1.375	0	1.375
82	30	50	1.22	0	15	0.45	0	1.447	0	1.447
83	30	50	1.22	0	15	0.95	1	0.670	1	0.754
84	30	50	1.22	0	30	0.45	0	1.447	0	1.447
85	30	50	1.22	0	30	0.95	1	1.068	1	1.063
86	30	50	1.22	0	40	0.45	0	1.447	0	1.447
87	30	50	1.22	0	40	0.95	1	1.330	1	1.376
88	30	50	1.22	100	15	0.45	0	1.447	0	1.447
89	30	50	1.22	100	15	0.95	0	1.447	1	1.447
90	30	50	1.22	100	30	0.45	0	1.447	0	1.447
91	30	50	1.22	100	30	0.95	0	1.447	0	1.447
92	30	50	1.22	100	40	0.45	0	1.447	0	1.447
93	30	50	1.22	100	40	0.95	0	1.447	0	1.447
94	30	50	1.22	500	15	0.45	0	1.447	0	1.447
95	30	50	1.22	500	15	0.95	0	1.447	0	1.447
96	30	50	1.22	500	30	0.45	0	1.447	0	1.447
97	30	50	1.22	500	30	0.95	0	1.447	0	1.447
98	30	50	1.22	500	40	0.45	0	1.447	0	1.447
99	30	50	1.22	500	40	0.95	0	1.447	0	1.447
100	30	50	1.88	0	15	0.45	0	2.232	0	2.232
101	30	50	1.88	0	15	0.95	1	1.688	1	1.629
102	30	50	1.88	0	15	1.45	1	0.942	1	1.049
103	30	50	1.88	0	30	0.45	0	2.232	0	2.232
104	30	50	1.88	0	30	0.95	1	2.126	1	2.015
105	30	50	1.88	0	30	1.45	1	1.545	1	1.531
106	30	50	1.88	0	40	0.45	0	2.232	0	2.232
107	30	50	1.88	0	40	0.95	0	2.232	0	2.232
108	30	50	1.88	0	40	1.45	1	1.961	1	1.962
109	30	50	1.88	100	15	0.45	0	2.232	0	2.232
110	30	50	1.88	100	15	0.95	0	2.232	0	2.232
111	30	50	1.88	100	15	1.45	1	2.108	1	2.129
112	30	50	1.88	100	30	0.45	0	2.232	0	2.232
113	30	50	1.88	100	30	0.95	0	2.232	0	2.232
114	30	50	1.88	100	30	1.45	0	2.232	0	2.232
115	30	50	1.88	100	40	0.45	0	2.232	0	2.232

116	30	50	1.88	100	40	0.95	0	2.232	0	2.232
117	30	50	1.88	100	40	1.45	0	2.232	0	2.232
118	30	50	1.88	500	15	0.45	0	2.232	0	2.232
119	30	50	1.88	500	15	0.95	0	2.232	0	2.232
120	30	50	1.88	500	15	1.45	0	2.232	0	2.232
121	30	50	1.88	500	30	0.45	0	2.232	0	2.232
122	30	50	1.88	500	30	0.95	0	2.232	0	2.232
123	30	50	1.88	500	30	1.45	0	2.232	0	2.232
124	30	50	1.88	500	40	0.45	0	2.232	0	2.232
125	30	50	1.88	500	40	0.95	0	2.232	0	2.232
126	30	50	1.88	500	40	1.45	0	2.232	0	2.232
127	30	50	2.38	0	15	0.45	0	2.838	0	2.838
128	30	50	2.38	0	15	0.95	1	2.484	1	2.424
129	30	50	2.38	0	15	1.45	1	1.588	1	1.685
130	30	50	2.38	0	15	1.95	1	0.995	1	1.143
131	30	50	2.38	0	30	0.45	0	2.838	0	2.838
132	30	50	2.38	0	30	0.95	0	2.838	0	2.838
133	30	50	2.38	0	30	1.45	1	2.287	1	2.192
134	30	50	2.38	0	30	1.95	1	1.750	1	1.761
135	30	50	2.38	0	40	0.45	0	2.838	0	2.838
136	30	50	2.38	0	40	0.95	0	2.838	0	2.838
137	30	50	2.38	0	40	1.45	1	2.711	1	2.742
138	30	50	2.38	0	40	1.95	1	2.325	0	2.387
139	30	50	2.38	100	15	0.45	0	2.838	0	2.838
140	30	50	2.38	100	15	0.95	0	2.838	0	2.838
141	30	50	2.38	100	15	1.45	1	2.613	1	2.729
142	30	50	2.38	100	15	1.95	1	2.407	1	2.354
143	30	50	2.38	100	30	0.45	0	2.838	0	2.838
144	30	50	2.38	100	30	0.95	0	2.838	0	2.838
145	30	50	2.38	100	30	1.45	0	2.838	0	2.838
146	30	50	2.38	100	30	1.95	0	2.838	0	2.838
147	30	50	2.38	100	40	0.45	0	2.838	0	2.838
148	30	50	2.38	100	40	0.95	0	2.838	0	2.838
149	30	50	2.38	100	40	1.45	0	2.838	0	2.838
150	30	50	2.38	100	40	1.95	0	2.838	0	2.838
151	30	50	2.38	500	15	0.45	0	2.838	0	2.838
152	30	50	2.38	500	15	0.95	0	2.838	0	2.838
153	30	50	2.38	500	15	1.45	0	2.838	0	2.838
154	30	50	2.38	500	15	1.95	0	2.838	0	2.838
155	30	50	2.38	500	30	0.45	0	2.838	0	2.838
156	30	50	2.38	500	30	0.95	0	2.838	0	2.838
157	30	50	2.38	500	30	1.45	0	2.838	0	2.838

158	30	50	2.38	500	30	1.95	0	2.838	0	2.838
159	30	50	2.38	500	40	0.45	0	2.838	0	2.838
160	30	50	2.38	500	40	0.95	0	2.838	0	2.838
161	30	50	2.38	500	40	1.45	0	2.838	0	2.838
162	30	50	2.38	500	40	1.95	0	2.838	0	2.838
163	30	70	1.22	0	15	0.45	0	3.328	0	3.328
164	30	70	1.22	0	15	0.95	1	1.013	1	0.933
165	30	70	1.22	0	30	0.45	0	3.328	0	3.328
166	30	70	1.22	0	30	0.95	1	1.503	1	1.391
167	30	70	1.22	0	40	0.45	0	3.328	0	3.328
168	30	70	1.22	0	40	0.95	1	1.852	1	1.807
169	30	70	1.22	100	15	0.45	0	3.328	0	3.328
170	30	70	1.22	100	15	0.95	1	1.934	1	1.784
171	30	70	1.22	100	30	0.45	0	3.328	0	3.328
172	30	70	1.22	100	30	0.95	1	2.498	1	2.513
173	30	70	1.22	100	40	0.45	0	3.328	0	3.328
174	30	70	1.22	100	40	0.95	1	2.899	1	2.980
175	30	70	1.22	500	15	0.45	0	3.328	0	3.328
176	30	70	1.22	500	15	0.95	0	3.328	0	3.328
177	30	70	1.22	500	30	0.45	0	3.328	0	3.328
178	30	70	1.22	500	30	0.95	0	3.328	0	3.328
179	30	70	1.22	500	40	0.45	0	3.328	0	3.328
180	30	70	1.22	500	40	0.95	0	3.328	0	3.328
181	30	70	1.88	0	15	0.45	0	5.145	0	5.145
182	30	70	1.88	0	15	0.95	1	3.189	1	3.046
183	30	70	1.88	0	15	1.45	1	1.406	1	1.420
184	30	70	1.88	0	30	0.45	0	5.145	0	5.145
185	30	70	1.88	0	30	0.95	1	3.838	1	3.657
186	30	70	1.88	0	30	1.45	1	2.105	1	2.063
187	30	70	1.88	0	40	0.45	0	5.145	0	5.145
188	30	70	1.88	0	40	0.95	1	4.293	1	4.141
189	30	70	1.88	0	40	1.45	1	2.639	1	2.578
190	30	70	1.88	100	15	0.45	0	5.145	0	5.145
191	30	70	1.88	100	15	0.95	1	3.886	1	4.034
192	30	70	1.88	100	15	1.45	1	2.503	1	2.568
193	30	70	1.88	100	30	0.45	0	5.145	0	5.145
194	30	70	1.88	100	30	0.95	1	4.565	1	4.538
195	30	70	1.88	100	30	1.45	1	3.246	1	3.256
196	30	70	1.88	100	40	0.45	0	5.145	0	5.145
197	30	70	1.88	100	40	0.95	0	5.145	0	5.145
198	30	70	1.88	100	40	1.45	1	3.862	1	3.744
199	30	70	1.88	500	15	0.45	0	5.145	0	5.145

200	30	70	1.88	500	15	0.95	0	5.145	0	5.145
201	30	70	1.88	500	15	1.45	0	5.145	0	5.145
202	30	70	1.88	500	30	0.45	0	5.145	0	5.145
203	30	70	1.88	500	30	0.95	0	5.145	0	5.145
204	30	70	1.88	500	30	1.45	0	5.145	0	5.145
205	30	70	1.88	500	40	0.45	0	5.145	0	5.145
206	30	70	1.88	500	40	0.95	0	5.145	0	5.145
207	30	70	1.88	500	40	1.45	0	5.145	0	5.145
208	30	70	2.38	0	15	0.45	0	6.540	0	6.539
209	30	70	2.38	0	15	0.95	1	4.787	1	4.819
210	30	70	2.38	0	15	1.45	1	2.785	1	2.876
211	30	70	2.38	0	15	1.95	1	1.355	1	1.492
212	30	70	2.38	0	30	0.45	0	6.540	0	6.539
213	30	70	2.38	0	30	0.95	1	5.342	1	5.472
214	30	70	2.38	0	30	1.45	1	3.602	1	3.580
215	30	70	2.38	0	30	1.95	1	2.184	1	2.263
216	30	70	2.38	0	40	0.45	0	6.540	0	6.539
217	30	70	2.38	0	40	0.95	1	6.057	1	5.821
218	30	70	2.38	0	40	1.45	1	4.203	1	4.196
219	30	70	2.38	0	40	1.95	1	2.855	1	2.962
220	30	70	2.38	100	15	0.45	0	6.540	0	6.539
221	30	70	2.38	100	15	0.95	1	5.390	1	5.462
222	30	70	2.38	100	15	1.45	1	3.764	1	3.877
223	30	70	2.38	100	15	1.95	1	2.709	1	2.716
224	30	70	2.38	100	30	0.45	0	6.540	0	6.539
225	30	70	2.38	100	30	0.95	0	6.540	0	6.539
226	30	70	2.38	100	30	1.45	1	4.578	1	4.522
227	30	70	2.38	100	30	1.95	1	3.636	1	3.583
228	30	70	2.38	100	40	0.45	0	6.540	0	6.539
229	30	70	2.38	100	40	0.95	0	6.540	0	6.539
230	30	70	2.38	100	40	1.45	1	5.211	1	5.023
231	30	70	2.38	100	40	1.95	1	4.376	1	4.229
232	30	70	2.38	500	15	0.45	0	6.540	0	6.539
233	30	70	2.38	500	15	0.95	0	6.540	0	6.539
234	30	70	2.38	500	15	1.45	0	6.540	0	6.539
235	30	70	2.38	500	15	1.95	0	6.540	1	6.539
236	30	70	2.38	500	30	0.45	0	6.540	0	6.539
237	30	70	2.38	500	30	0.95	0	6.540	0	6.539
238	30	70	2.38	500	30	1.45	0	6.540	0	6.539
239	30	70	2.38	500	30	1.95	0	6.540	0	6.539
240	30	70	2.38	500	40	0.45	0	6.540	0	6.539
241	30	70	2.38	500	40	0.95	0	6.540	0	6.539

242	30	70	2.38	500	40	1.45	0	6.540	0	6.539
243	30	70	2.38	500	40	1.95	0	6.540	0	6.539
244	80	30	1.22	0	15	0.45	0	0.711	0	0.709
245	80	30	1.22	0	15	0.95	1	0.515	1	0.588
246	80	30	1.22	0	30	0.45	0	0.711	0	0.709
247	80	30	1.22	0	30	0.95	0	0.711	0	0.709
248	80	30	1.22	0	40	0.45	0	0.711	0	0.709
249	80	30	1.22	0	40	0.95	0	0.711	0	0.709
250	80	30	1.22	100	15	0.45	0	0.711	0	0.709
251	80	30	1.22	100	15	0.95	0	0.711	0	0.709
252	80	30	1.22	100	30	0.45	0	0.711	0	0.709
253	80	30	1.22	100	30	0.95	0	0.711	0	0.709
254	80	30	1.22	100	40	0.45	0	0.711	0	0.709
255	80	30	1.22	100	40	0.95	0	0.711	0	0.709
256	80	30	1.22	500	15	0.45	0	0.711	0	0.709
257	80	30	1.22	500	15	0.95	0	0.711	0	0.709
258	80	30	1.22	500	30	0.45	0	0.711	0	0.709
259	80	30	1.22	500	30	0.95	0	0.711	0	0.709
260	80	30	1.22	500	40	0.45	0	0.711	0	0.709
261	80	30	1.22	500	40	0.95	0	0.711	0	0.709
262	80	30	1.88	0	15	0.45	0	1.087	0	1.087
263	80	30	1.88	0	15	0.95	1	1.008	1	0.990
264	80	30	1.88	0	15	1.45	1	0.710	1	0.698
265	80	30	1.88	0	30	0.45	0	1.087	0	1.087
266	80	30	1.88	0	30	0.95	0	1.087	0	1.087
267	80	30	1.88	0	30	1.45	0	1.087	0	1.087
268	80	30	1.88	0	40	0.45	0	1.087	0	1.087
269	80	30	1.88	0	40	0.95	0	1.087	0	1.087
270	80	30	1.88	0	40	1.45	0	1.087	0	1.087
271	80	30	1.88	100	15	0.45	0	1.087	0	1.087
272	80	30	1.88	100	15	0.95	0	1.087	0	1.087
273	80	30	1.88	100	15	1.45	0	1.087	0	1.087
274	80	30	1.88	100	30	0.45	0	1.087	0	1.087
275	80	30	1.88	100	30	0.95	0	1.087	0	1.087
276	80	30	1.88	100	30	1.45	0	1.087	0	1.087
277	80	30	1.88	100	40	0.45	0	1.087	0	1.087
278	80	30	1.88	100	40	0.95	0	1.087	0	1.087
279	80	30	1.88	100	40	1.45	0	1.087	0	1.087
280	80	30	1.88	500	15	0.45	0	1.087	0	1.087
281	80	30	1.88	500	15	0.95	0	1.087	0	1.087
282	80	30	1.88	500	15	1.45	0	1.087	0	1.087
283	80	30	1.88	500	30	0.45	0	1.087	0	1.087

284	80	30	1.88	500	30	0.95	0	1.087	0	1.087
285	80	30	1.88	500	30	1.45	0	1.087	0	1.087
286	80	30	1.88	500	40	0.45	0	1.087	0	1.087
287	80	30	1.88	500	40	0.95	0	1.087	0	1.087
288	80	30	1.88	500	40	1.45	0	1.087	0	1.087
289	80	30	2.38	0	15	0.45	0	1.374	0	1.374
290	80	30	2.38	0	15	0.95	0	1.374	0	1.374
291	80	30	2.38	0	15	1.45	1	1.073	1	1.026
292	80	30	2.38	0	15	1.95	1	0.808	1	0.740
293	80	30	2.38	0	30	0.45	0	1.374	0	1.374
294	80	30	2.38	0	30	0.95	0	1.374	0	1.374
295	80	30	2.38	0	30	1.45	0	1.374	0	1.374
296	80	30	2.38	0	30	1.95	0	1.374	0	1.374
297	80	30	2.38	0	40	0.45	0	1.374	0	1.374
298	80	30	2.38	0	40	0.95	0	1.374	0	1.374
299	80	30	2.38	0	40	1.45	0	1.374	0	1.374
300	80	30	2.38	0	40	1.95	0	1.374	0	1.374
301	80	30	2.38	100	15	0.45	0	1.374	0	1.374
302	80	30	2.38	100	15	0.95	0	1.374	0	1.374
303	80	30	2.38	100	15	1.45	0	1.374	0	1.374
304	80	30	2.38	100	15	1.95	0	1.374	0	1.374
305	80	30	2.38	100	30	0.45	0	1.374	0	1.374
306	80	30	2.38	100	30	0.95	0	1.374	0	1.374
307	80	30	2.38	100	30	1.45	0	1.374	0	1.374
308	80	30	2.38	100	30	1.95	0	1.374	0	1.374
309	80	30	2.38	100	40	0.45	0	1.374	0	1.374
310	80	30	2.38	100	40	0.95	0	1.374	0	1.374
311	80	30	2.38	100	40	1.45	0	1.374	0	1.374
312	80	30	2.38	100	40	1.95	0	1.374	0	1.374
313	80	30	2.38	500	15	0.45	0	1.374	0	1.374
314	80	30	2.38	500	15	0.95	0	1.374	0	1.374
315	80	30	2.38	500	15	1.45	0	1.374	0	1.374
316	80	30	2.38	500	15	1.95	0	1.374	0	1.374
317	80	30	2.38	500	30	0.45	0	1.374	0	1.374
318	80	30	2.38	500	30	0.95	0	1.374	0	1.374
319	80	30	2.38	500	30	1.45	0	1.374	0	1.374
320	80	30	2.38	500	30	1.95	0	1.374	0	1.374
321	80	30	2.38	500	40	0.45	0	1.374	0	1.374
322	80	30	2.38	500	40	0.95	0	1.374	0	1.374
323	80	30	2.38	500	40	1.45	0	1.374	0	1.374
324	80	30	2.38	500	40	1.95	0	1.374	0	1.374
325	80	50	1.22	0	15	0.45	1	1.381	1	1.411

326	80	50	1.22	0	15	0.95	1	0.633	1	0.723
327	80	50	1.22	0	30	0.45	0	1.460	0	1.460
328	80	50	1.22	0	30	0.95	1	1.032	1	1.016
329	80	50	1.22	0	40	0.45	0	1.460	0	1.460
330	80	50	1.22	0	40	0.95	1	1.302	1	1.316
331	80	50	1.22	100	15	0.45	0	1.460	0	1.460
332	80	50	1.22	100	15	0.95	1	1.050	1	1.011
333	80	50	1.22	100	30	0.45	0	1.460	0	1.460
334	80	50	1.22	100	30	0.95	0	1.460	0	1.460
335	80	50	1.22	100	40	0.45	0	1.460	0	1.460
336	80	50	1.22	100	40	0.95	0	1.460	0	1.460
337	80	50	1.22	500	15	0.45	0	1.460	0	1.460
338	80	50	1.22	500	15	0.95	0	1.460	0	1.460
339	80	50	1.22	500	30	0.45	0	1.460	0	1.460
340	80	50	1.22	500	30	0.95	0	1.460	0	1.460
341	80	50	1.22	500	40	0.45	0	1.460	0	1.460
342	80	50	1.22	500	40	0.95	0	1.460	0	1.460
343	80	50	1.88	0	15	0.45	0	2.242	0	2.242
344	80	50	1.88	0	15	0.95	1	1.665	1	1.562
345	80	50	1.88	0	15	1.45	1	0.910	1	0.986
346	80	50	1.88	0	30	0.45	0	2.242	0	2.242
347	80	50	1.88	0	30	0.95	1	2.112	1	1.987
348	80	50	1.88	0	30	1.45	1	1.507	1	1.443
349	80	50	1.88	0	40	0.45	0	2.242	0	2.242
350	80	50	1.88	0	40	0.95	0	2.242	0	2.242
351	80	50	1.88	0	40	1.45	1	1.934	1	1.858
352	80	50	1.88	100	15	0.45	0	2.242	0	2.242
353	80	50	1.88	100	15	0.95	0	2.242	1	2.242
354	80	50	1.88	100	15	1.45	1	1.379	1	1.432
355	80	50	1.88	100	30	0.45	0	2.242	0	2.242
356	80	50	1.88	100	30	0.95	0	2.242	0	2.242
357	80	50	1.88	100	30	1.45	1	2.040	1	2.006
358	80	50	1.88	100	40	0.45	0	2.242	0	2.242
359	80	50	1.88	100	40	0.95	0	2.242	0	2.242
360	80	50	1.88	100	40	1.45	0	2.242	0	2.242
361	80	50	1.88	500	15	0.45	0	2.242	0	2.242
362	80	50	1.88	500	15	0.95	0	2.242	0	2.242
363	80	50	1.88	500	15	1.45	0	2.242	0	2.242
364	80	50	1.88	500	30	0.45	0	2.242	0	2.242
365	80	50	1.88	500	30	0.95	0	2.242	0	2.242
366	80	50	1.88	500	30	1.45	0	2.242	0	2.242
367	80	50	1.88	500	40	0.45	0	2.242	0	2.242

368	80	50	1.88	500	40	0.95	0	2.242	0	2.242
369	80	50	1.88	500	40	1.45	0	2.242	0	2.242
370	80	50	2.38	0	15	0.45	0	2.836	0	2.836
371	80	50	2.38	0	15	0.95	1	2.446	1	2.424
372	80	50	2.38	0	15	1.45	1	1.573	1	1.605
373	80	50	2.38	0	15	1.95	1	0.966	1	1.065
374	80	50	2.38	0	30	0.45	0	2.836	0	2.836
375	80	50	2.38	0	30	0.95	0	2.836	0	2.836
376	80	50	2.38	0	30	1.45	1	2.258	1	2.131
377	80	50	2.38	0	30	1.95	1	1.724	1	1.640
378	80	50	2.38	0	40	0.45	0	2.836	0	2.836
379	80	50	2.38	0	40	0.95	0	2.836	0	2.836
380	80	50	2.38	0	40	1.45	1	2.691	1	2.695
381	80	50	2.38	0	40	1.95	1	2.306	1	2.233
382	80	50	2.38	100	15	0.45	0	2.836	0	2.836
383	80	50	2.38	100	15	0.95	0	2.836	0	2.836
384	80	50	2.38	100	15	1.45	1	1.964	1	1.999
385	80	50	2.38	100	15	1.95	1	1.541	1	1.580
386	80	50	2.38	100	30	0.45	0	2.836	0	2.836
387	80	50	2.38	100	30	0.95	0	2.836	0	2.836
388	80	50	2.38	100	30	1.45	1	2.663	1	2.698
389	80	50	2.38	100	30	1.95	1	2.380	1	2.336
390	80	50	2.38	100	40	0.45	0	2.836	0	2.836
391	80	50	2.38	100	40	0.95	0	2.836	0	2.836
392	80	50	2.38	100	40	1.45	0	2.836	0	2.836
393	80	50	2.38	100	40	1.95	0	2.836	0	2.836
394	80	50	2.38	500	15	0.45	0	2.836	0	2.836
395	80	50	2.38	500	15	0.95	0	2.836	0	2.836
396	80	50	2.38	500	15	1.45	0	2.836	0	2.836
397	80	50	2.38	500	15	1.95	0	2.836	0	2.836
398	80	50	2.38	500	30	0.45	0	2.836	0	2.836
399	80	50	2.38	500	30	0.95	0	2.836	0	2.836
400	80	50	2.38	500	30	1.45	0	2.836	0	2.836
401	80	50	2.38	500	30	1.95	0	2.836	0	2.836
402	80	50	2.38	500	40	0.45	0	2.836	0	2.836
403	80	50	2.38	500	40	0.95	0	2.836	0	2.836
404	80	50	2.38	500	40	1.45	0	2.836	0	2.836
405	80	50	2.38	500	40	1.95	0	2.836	0	2.836
406	80	70	1.22	0	15	0.45	1	2.812	1	2.797
407	80	70	1.22	0	15	0.95	1	0.909	1	0.886
408	80	70	1.22	0	30	0.45	0	3.360	0	3.360
409	80	70	1.22	0	30	0.95	1	1.414	1	1.326

410	80	70	1.22	0	40	0.45	0	3.360	0	3.360
411	80	70	1.22	0	40	0.95	1	1.785	1	1.732
412	80	70	1.22	100	15	0.45	0	3.360	1	3.360
413	80	70	1.22	100	15	0.95	1	1.317	1	1.236
414	80	70	1.22	100	30	0.45	0	3.360	0	3.360
415	80	70	1.22	100	30	0.95	1	1.821	1	1.821
416	80	70	1.22	100	40	0.45	0	3.360	0	3.360
417	80	70	1.22	100	40	0.95	1	2.208	1	2.260
418	80	70	1.22	500	15	0.45	0	3.360	0	3.360
419	80	70	1.22	500	15	0.95	1	2.802	1	2.824
420	80	70	1.22	500	30	0.45	0	3.360	0	3.360
421	80	70	1.22	500	30	0.95	1	3.360	0	3.524
422	80	70	1.22	500	40	0.45	0	3.360	0	3.360
423	80	70	1.22	500	40	0.95	0	3.360	0	3.360
424	80	70	1.88	0	15	0.45	0	5.168	0	5.168
425	80	70	1.88	0	15	0.95	1	3.174	1	3.015
426	80	70	1.88	0	15	1.45	1	1.351	1	1.320
427	80	70	1.88	0	30	0.45	0	5.168	0	5.168
428	80	70	1.88	0	30	0.95	1	3.769	1	3.684
429	80	70	1.88	0	30	1.45	1	2.029	1	1.939
430	80	70	1.88	0	40	0.45	0	5.168	0	5.168
431	80	70	1.88	0	40	0.95	1	4.203	1	4.193
432	80	70	1.88	0	40	1.45	1	2.561	1	2.441
433	80	70	1.88	100	15	0.45	0	5.168	0	5.168
434	80	70	1.88	100	15	0.95	1	3.437	1	3.354
435	80	70	1.88	100	15	1.45	1	1.954	1	1.792
436	80	70	1.88	100	30	0.45	0	5.168	0	5.168
437	80	70	1.88	100	30	0.95	1	4.040	1	4.052
438	80	70	1.88	100	30	1.45	1	2.484	1	2.451
439	80	70	1.88	100	40	0.45	0	5.168	0	5.168
440	80	70	1.88	100	40	0.95	1	4.491	1	4.594
441	80	70	1.88	100	40	1.45	1	3.056	1	2.975
442	80	70	1.88	500	15	0.45	0	5.168	0	5.168
443	80	70	1.88	500	15	0.95	1	4.653	1	4.682
444	80	70	1.88	500	15	1.45	1	3.509	1	3.334
445	80	70	1.88	500	30	0.45	0	5.168	0	5.168
446	80	70	1.88	500	30	0.95	0	5.168	0	5.168
447	80	70	1.88	500	30	1.45	1	4.306	1	4.323
448	80	70	1.88	500	40	0.45	0	5.168	0	5.168
449	80	70	1.88	500	40	0.95	0	5.168	0	5.168
450	80	70	1.88	500	40	1.45	1	4.909	1	4.994
451	80	70	2.38	0	15	0.45	0	6.536	0	6.541

452	80	70	2.38	0	15	0.95	1	4.877	1	4.976
453	80	70	2.38	0	15	1.45	1	2.703	1	2.791
454	80	70	2.38	0	15	1.95	1	1.306	1	1.379
455	80	70	2.38	0	30	0.45	0	6.536	0	6.541
456	80	70	2.38	0	30	0.95	1	5.605	1	5.594
457	80	70	2.38	0	30	1.45	1	3.540	1	3.528
458	80	70	2.38	0	30	1.95	1	2.119	1	2.106
459	80	70	2.38	0	40	0.45	0	6.536	0	6.541
460	80	70	2.38	0	40	0.95	1	6.059	1	5.901
461	80	70	2.38	0	40	1.45	1	4.138	1	4.166
462	80	70	2.38	0	40	1.95	1	2.788	1	2.781
463	80	70	2.38	100	15	0.45	0	6.536	0	6.541
464	80	70	2.38	100	15	0.95	1	5.102	1	5.291
465	80	70	2.38	100	15	1.45	1	3.071	1	3.139
466	80	70	2.38	100	15	1.95	1	1.819	1	1.900
467	80	70	2.38	100	30	0.45	0	6.536	0	6.541
468	80	70	2.38	100	30	0.95	1	5.847	1	5.831
469	80	70	2.38	100	30	1.45	1	3.900	1	3.963
470	80	70	2.38	100	30	1.95	1	2.711	1	2.730
471	80	70	2.38	100	40	0.45	0	6.536	0	6.541
472	80	70	2.38	100	40	0.95	1	6.275	1	6.050
473	80	70	2.38	100	40	1.45	1	4.537	1	4.622
474	80	70	2.38	100	40	1.95	1	3.408	1	3.450
475	80	70	2.38	500	15	0.45	0	6.536	0	6.541
476	80	70	2.38	500	15	0.95	0	6.536	1	6.541
477	80	70	2.38	500	15	1.45	1	4.647	1	4.665
478	80	70	2.38	500	15	1.95	1	3.926	1	3.872
479	80	70	2.38	500	30	0.45	0	6.536	0	6.541
480	80	70	2.38	500	30	0.95	0	6.536	0	6.541
481	80	70	2.38	500	30	1.45	1	5.503	1	5.504
482	80	70	2.38	500	30	1.95	1	4.903	1	4.935
483	80	70	2.38	500	40	0.45	0	6.536	0	6.541
484	80	70	2.38	500	40	0.95	0	6.536	0	6.541
485	80	70	2.38	500	40	1.45	1	6.129	1	5.803
486	80	70	2.38	500	40	1.95	1	5.686	1	5.400
487	130	30	1.22	0	15	0.45	0	0.711	0	0.711
488	130	30	1.22	0	15	0.95	1	0.502	1	0.593
489	130	30	1.22	0	30	0.45	0	0.711	0	0.711
490	130	30	1.22	0	30	0.95	0	0.711	0	0.711
491	130	30	1.22	0	40	0.45	0	0.711	0	0.711
492	130	30	1.22	0	40	0.95	0	0.711	0	0.711
493	130	30	1.22	100	15	0.45	0	0.711	0	0.711

494	130	30	1.22	100	15	0.95	0	0.711	0	0.711
495	130	30	1.22	100	30	0.45	0	0.711	0	0.711
496	130	30	1.22	100	30	0.95	0	0.711	0	0.711
497	130	30	1.22	100	40	0.45	0	0.711	0	0.711
498	130	30	1.22	100	40	0.95	0	0.711	0	0.711
499	130	30	1.22	500	15	0.45	0	0.711	0	0.711
500	130	30	1.22	500	15	0.95	0	0.711	0	0.711
501	130	30	1.22	500	30	0.45	0	0.711	0	0.711
502	130	30	1.22	500	30	0.95	0	0.711	0	0.711
503	130	30	1.22	500	40	0.45	0	0.711	0	0.711
504	130	30	1.22	500	40	0.95	0	0.711	0	0.711
505	130	30	1.88	0	15	0.45	0	1.087	0	1.087
506	130	30	1.88	0	15	0.95	1	1.030	1	0.954
507	130	30	1.88	0	15	1.45	1	0.708	1	0.707
508	130	30	1.88	0	30	0.45	0	1.087	0	1.087
509	130	30	1.88	0	30	0.95	0	1.087	0	1.087
510	130	30	1.88	0	30	1.45	0	1.087	0	1.087
511	130	30	1.88	0	40	0.45	0	1.087	0	1.087
512	130	30	1.88	0	40	0.95	0	1.087	0	1.087
513	130	30	1.88	0	40	1.45	0	1.087	0	1.087
514	130	30	1.88	100	15	0.45	0	1.087	0	1.087
515	130	30	1.88	100	15	0.95	0	1.087	0	1.087
516	130	30	1.88	100	15	1.45	1	1.032	1	0.881
517	130	30	1.88	100	30	0.45	0	1.087	0	1.087
518	130	30	1.88	100	30	0.95	0	1.087	0	1.087
519	130	30	1.88	100	30	1.45	0	1.087	0	1.087
520	130	30	1.88	100	40	0.45	0	1.087	0	1.087
521	130	30	1.88	100	40	0.95	0	1.087	0	1.087
522	130	30	1.88	100	40	1.45	0	1.087	0	1.087
523	130	30	1.88	500	15	0.45	0	1.087	0	1.087
524	130	30	1.88	500	15	0.95	0	1.087	0	1.087
525	130	30	1.88	500	15	1.45	0	1.087	0	1.087
526	130	30	1.88	500	30	0.45	0	1.087	0	1.087
527	130	30	1.88	500	30	0.95	0	1.087	0	1.087
528	130	30	1.88	500	30	1.45	0	1.087	0	1.087
529	130	30	1.88	500	40	0.45	0	1.087	0	1.087
530	130	30	1.88	500	40	0.95	0	1.087	0	1.087
531	130	30	1.88	500	40	1.45	0	1.087	0	1.087
532	130	30	2.38	0	15	0.45	0	1.377	0	1.377
533	130	30	2.38	0	15	0.95	1	1.372	0	1.297
534	130	30	2.38	0	15	1.45	1	1.070	1	0.996
535	130	30	2.38	0	15	1.95	1	0.806	1	0.754

536	130	30	2.38	0	30	0.45	0	1.377	0	1.377
537	130	30	2.38	0	30	0.95	0	1.377	0	1.377
538	130	30	2.38	0	30	1.45	0	1.377	0	1.377
539	130	30	2.38	0	30	1.95	0	1.377	0	1.377
540	130	30	2.38	0	40	0.45	0	1.377	0	1.377
541	130	30	2.38	0	40	0.95	0	1.377	0	1.377
542	130	30	2.38	0	40	1.45	0	1.377	0	1.377
543	130	30	2.38	0	40	1.95	0	1.377	0	1.377
544	130	30	2.38	100	15	0.45	0	1.377	0	1.377
545	130	30	2.38	100	15	0.95	0	1.377	0	1.377
546	130	30	2.38	100	15	1.45	1	1.323	1	1.058
547	130	30	2.38	100	15	1.95	1	1.205	1	0.985
548	130	30	2.38	100	30	0.45	0	1.377	0	1.377
549	130	30	2.38	100	30	0.95	0	1.377	0	1.377
550	130	30	2.38	100	30	1.45	0	1.377	0	1.377
551	130	30	2.38	100	30	1.95	0	1.377	0	1.377
552	130	30	2.38	100	40	0.45	0	1.377	0	1.377
553	130	30	2.38	100	40	0.95	0	1.377	0	1.377
554	130	30	2.38	100	40	1.45	0	1.377	0	1.377
555	130	30	2.38	100	40	1.95	0	1.377	0	1.377
556	130	30	2.38	500	15	0.45	0	1.377	0	1.377
557	130	30	2.38	500	15	0.95	0	1.377	0	1.377
558	130	30	2.38	500	15	1.45	0	1.377	0	1.377
559	130	30	2.38	500	15	1.95	0	1.377	0	1.377
560	130	30	2.38	500	30	0.45	0	1.377	0	1.377
561	130	30	2.38	500	30	0.95	0	1.377	0	1.377
562	130	30	2.38	500	30	1.45	0	1.377	0	1.377
563	130	30	2.38	500	30	1.95	0	1.377	0	1.377
564	130	30	2.38	500	40	0.45	0	1.377	0	1.377
565	130	30	2.38	500	40	0.95	0	1.377	0	1.377
566	130	30	2.38	500	40	1.45	0	1.377	0	1.377
567	130	30	2.38	500	40	1.95	0	1.377	0	1.377
568	130	50	1.22	0	15	0.45	1	1.364	1	1.419
569	130	50	1.22	0	15	0.95	1	0.690	1	0.729
570	130	50	1.22	0	30	0.45	0	1.459	0	1.459
571	130	50	1.22	0	30	0.95	1	1.024	1	1.035
572	130	50	1.22	0	40	0.45	0	1.459	0	1.459
573	130	50	1.22	0	40	0.95	1	1.292	1	1.345
574	130	50	1.22	100	15	0.45	0	1.459	0	1.459
575	130	50	1.22	100	15	0.95	1	0.898	1	0.916
576	130	50	1.22	100	30	0.45	0	1.459	0	1.459
577	130	50	1.22	100	30	0.95	1	1.334	1	1.343

578	130	50	1.22	100	40	0.45	0	1.459	0	1.459
579	130	50	1.22	100	40	0.95	0	1.459	0	1.459
580	130	50	1.22	500	15	0.45	0	1.459	0	1.459
581	130	50	1.22	500	15	0.95	0	1.459	0	1.459
582	130	50	1.22	500	30	0.45	0	1.459	0	1.459
583	130	50	1.22	500	30	0.95	0	1.459	0	1.459
584	130	50	1.22	500	40	0.45	0	1.459	0	1.459
585	130	50	1.22	500	40	0.95	0	1.459	0	1.459
586	130	50	1.88	0	15	0.45	0	2.242	0	2.242
587	130	50	1.88	0	15	0.95	1	1.657	1	1.567
588	130	50	1.88	0	15	1.45	1	0.906	1	0.998
589	130	50	1.88	0	30	0.45	0	2.242	0	2.242
590	130	50	1.88	0	30	0.95	1	2.114	1	2.037
591	130	50	1.88	0	30	1.45	1	1.499	1	1.464
592	130	50	1.88	0	40	0.45	0	2.242	0	2.242
593	130	50	1.88	0	40	0.95	0	2.242	0	2.242
594	130	50	1.88	0	40	1.45	1	1.928	1	1.878
595	130	50	1.88	100	15	0.45	0	2.242	0	2.242
596	130	50	1.88	100	15	0.95	1	1.832	1	1.712
597	130	50	1.88	100	15	1.45	1	1.206	1	1.277
598	130	50	1.88	100	30	0.45	0	2.242	0	2.242
599	130	50	1.88	100	30	0.95	0	2.242	0	2.242
600	130	50	1.88	100	30	1.45	1	1.841	1	1.818
601	130	50	1.88	100	40	0.45	0	2.242	0	2.242
602	130	50	1.88	100	40	0.95	0	2.242	0	2.242
603	130	50	1.88	100	40	1.45	0	2.242	0	2.242
604	130	50	1.88	500	15	0.45	0	2.242	0	2.242
605	130	50	1.88	500	15	0.95	0	2.242	0	2.242
606	130	50	1.88	500	15	1.45	0	2.242	0	2.242
607	130	50	1.88	500	30	0.45	0	2.242	0	2.242
608	130	50	1.88	500	30	0.95	0	2.242	0	2.242
609	130	50	1.88	500	30	1.45	0	2.242	0	2.242
610	130	50	1.88	500	40	0.45	0	2.242	0	2.242
611	130	50	1.88	500	40	0.95	0	2.242	0	2.242
612	130	50	1.88	500	40	1.45	0	2.242	0	2.242
613	130	50	2.38	0	15	0.45	0	2.842	0	2.842
614	130	50	2.38	0	15	0.95	1	2.447	1	2.472
615	130	50	2.38	0	15	1.45	1	1.575	1	1.608
616	130	50	2.38	0	15	1.95	1	0.958	1	1.079
617	130	50	2.38	0	30	0.45	0	2.842	0	2.842
618	130	50	2.38	0	30	0.95	0	2.842	0	2.842
619	130	50	2.38	0	30	1.45	1	2.251	1	2.160

620	130	50	2.38	0	30	1.95	1	1.720	1	1.656
621	130	50	2.38	0	40	0.45	0	2.842	0	2.842
622	130	50	2.38	0	40	0.95	0	2.842	0	2.842
623	130	50	2.38	0	40	1.45	1	2.687	1	2.740
624	130	50	2.38	0	40	1.95	1	2.298	1	2.237
625	130	50	2.38	100	15	0.45	0	2.842	0	2.842
626	130	50	2.38	100	15	0.95	1	2.632	1	2.613
627	130	50	2.38	100	15	1.45	1	1.808	1	1.796
628	130	50	2.38	100	15	1.95	1	1.326	1	1.413
629	130	50	2.38	100	30	0.45	0	2.842	0	2.842
630	130	50	2.38	100	30	0.95	0	2.842	0	2.842
631	130	50	2.38	100	30	1.45	1	2.505	1	2.505
632	130	50	2.38	100	30	1.95	1	2.143	1	2.120
633	130	50	2.38	100	40	0.45	0	2.842	0	2.842
634	130	50	2.38	100	40	0.95	0	2.842	0	2.842
635	130	50	2.38	100	40	1.45	0	2.842	0	2.842
636	130	50	2.38	100	40	1.95	1	2.780	1	2.801
637	130	50	2.38	500	15	0.45	0	2.842	0	2.842
638	130	50	2.38	500	15	0.95	0	2.842	0	2.842
639	130	50	2.38	500	15	1.45	0	2.842	0	2.842
640	130	50	2.38	500	15	1.95	1	2.680	0	2.791
641	130	50	2.38	500	30	0.45	0	2.842	0	2.842
642	130	50	2.38	500	30	0.95	0	2.842	0	2.842
643	130	50	2.38	500	30	1.45	0	2.842	0	2.842
644	130	50	2.38	500	30	1.95	0	2.842	0	2.842
645	130	50	2.38	500	40	0.45	0	2.842	0	2.842
646	130	50	2.38	500	40	0.95	0	2.842	0	2.842
647	130	50	2.38	500	40	1.45	0	2.842	0	2.842
648	130	50	2.38	500	40	1.95	0	2.842	0	2.842
649	130	70	1.22	0	15	0.45	1	2.791	1	2.826
650	130	70	1.22	0	15	0.95	1	0.888	1	0.882
651	130	70	1.22	0	30	0.45	1	3.102	1	3.609
652	130	70	1.22	0	30	0.95	1	1.390	1	1.330
653	130	70	1.22	0	40	0.45	1	3.255	0	4.085
654	130	70	1.22	0	40	0.95	1	1.741	1	1.741
655	130	70	1.22	100	15	0.45	0	3.358	1	3.358
656	130	70	1.22	100	15	0.95	1	1.136	1	1.105
657	130	70	1.22	100	30	0.45	0	3.358	0	3.358
658	130	70	1.22	100	30	0.95	1	1.642	1	1.649
659	130	70	1.22	100	40	0.45	0	3.358	0	3.358
660	130	70	1.22	100	40	0.95	1	2.037	1	2.080
661	130	70	1.22	500	15	0.45	0	3.358	1	3.358

662	130	70	1.22	500	15	0.95	1	2.102	1	2.103
663	130	70	1.22	500	30	0.45	0	3.358	0	3.358
664	130	70	1.22	500	30	0.95	1	2.659	1	2.575
665	130	70	1.22	500	40	0.45	0	3.358	0	3.358
666	130	70	1.22	500	40	0.95	1	3.080	1	3.064
667	130	70	1.88	0	15	0.45	0	5.168	1	5.168
668	130	70	1.88	0	15	0.95	1	3.141	1	3.039
669	130	70	1.88	0	15	1.45	1	1.343	1	1.306
670	130	70	1.88	0	30	0.45	0	5.168	0	5.168
671	130	70	1.88	0	30	0.95	1	3.756	1	3.762
672	130	70	1.88	0	30	1.45	1	2.011	1	1.922
673	130	70	1.88	0	40	0.45	0	5.168	0	5.168
674	130	70	1.88	0	40	0.95	1	4.197	1	4.291
675	130	70	1.88	0	40	1.45	1	2.533	1	2.419
676	130	70	1.88	100	15	0.45	0	5.168	0	5.168
677	130	70	1.88	100	15	0.95	1	3.341	1	3.101
678	130	70	1.88	100	15	1.45	1	1.605	1	1.582
679	130	70	1.88	100	30	0.45	0	5.168	0	5.168
680	130	70	1.88	100	30	0.95	1	3.935	1	3.899
681	130	70	1.88	100	30	1.45	1	2.316	1	2.221
682	130	70	1.88	100	40	0.45	0	5.168	0	5.168
683	130	70	1.88	100	40	0.95	1	4.384	1	4.505
684	130	70	1.88	100	40	1.45	1	2.855	1	2.747
685	130	70	1.88	500	15	0.45	0	5.168	0	5.168
686	130	70	1.88	500	15	0.95	1	4.042	1	4.014
687	130	70	1.88	500	15	1.45	1	2.664	1	2.452
688	130	70	1.88	500	30	0.45	0	5.168	0	5.168
689	130	70	1.88	500	30	0.95	1	4.641	1	4.933
690	130	70	1.88	500	30	1.45	1	3.440	1	3.272
691	130	70	1.88	500	40	0.45	0	5.168	0	5.168
692	130	70	1.88	500	40	0.95	0	5.168	0	5.168
693	130	70	1.88	500	40	1.45	1	4.036	1	4.006
694	130	70	2.38	0	15	0.45	0	6.549	0	6.543
695	130	70	2.38	0	15	0.95	1	4.901	1	5.116
696	130	70	2.38	0	15	1.45	1	2.701	1	2.771
697	130	70	2.38	0	15	1.95	1	1.283	1	1.364
698	130	70	2.38	0	30	0.45	0	6.549	0	6.543
699	130	70	2.38	0	30	0.95	1	5.577	1	5.697
700	130	70	2.38	0	30	1.45	1	3.519	1	3.540
701	130	70	2.38	0	30	1.95	1	2.103	1	2.077
702	130	70	2.38	0	40	0.45	0	6.549	0	6.543
703	130	70	2.38	0	40	0.95	1	5.987	1	5.966

704	130	70	2.38	0	40	1.45	1	4.139	1	4.190
705	130	70	2.38	0	40	1.95	1	2.778	1	2.734
706	130	70	2.38	100	15	0.45	0	6.549	0	6.543
707	130	70	2.38	100	15	0.95	1	4.957	1	5.261
708	130	70	2.38	100	15	1.45	1	2.914	1	2.855
709	130	70	2.38	100	15	1.95	1	1.607	1	1.688
710	130	70	2.38	100	30	0.45	0	6.549	0	6.543
711	130	70	2.38	100	30	0.95	1	5.765	1	5.836
712	130	70	2.38	100	30	1.45	1	3.765	1	3.754
713	130	70	2.38	100	30	1.95	1	2.473	1	2.482
714	130	70	2.38	100	40	0.45	0	6.549	0	6.543
715	130	70	2.38	100	40	0.95	1	6.239	1	6.060
716	130	70	2.38	100	40	1.45	1	4.386	1	4.482
717	130	70	2.38	100	40	1.95	1	3.165	1	3.203
718	130	70	2.38	500	15	0.45	0	6.549	0	6.543
719	130	70	2.38	500	15	0.95	1	5.595	1	5.998
720	130	70	2.38	500	15	1.45	1	3.899	1	3.842
721	130	70	2.38	500	15	1.95	1	2.925	1	2.876
722	130	70	2.38	500	30	0.45	0	6.549	0	6.543
723	130	70	2.38	500	30	0.95	0	6.549	0	6.543
724	130	70	2.38	500	30	1.45	1	4.714	1	4.868
725	130	70	2.38	500	30	1.95	1	3.880	1	3.956
726	130	70	2.38	500	40	0.45	0	6.549	0	6.543
727	130	70	2.38	500	40	0.95	0	6.549	0	6.543
728	130	70	2.38	500	40	1.45	1	5.371	1	5.323
729	130	70	2.38	500	40	1.95	1	4.628	1	4.578

APÉNDICE 2

Tabla A2.1: Pesos sinápticos de la red neuronal artificial para la predicción del tipo de falla

w_{jk}

0.95156	2.35360	0.48357	0.31173	-0.71608	1.16700
1.16940	-0.68365	-1.49390	0.05464	-0.73847	0.06283
1.37300	-2.78250	-0.56490	-1.94100	-1.11320	0.35887
-0.86939	0.95063	0.48943	3.72810	-0.41728	-2.71240
0.41120	2.72640	0.49994	-4.79100	-1.79340	-0.62580
-1.22690	1.13110	-0.36003	0.45548	0.24606	-0.72787
-0.18510	0.80678	-1.85880	-0.58444	-1.53500	5.55960
0.28890	0.84176	-0.67260	-3.48700	-0.49807	3.63140
-2.49590	-1.11400	0.01712	-1.71620	1.08380	-1.89250
2.38890	-1.54020	0.13147	-0.06680	0.52903	-0.79972

w_{ij}

5.02680
2.36140
-5.16300
-4.55710
8.41380
3.58620
6.95320
5.07370
-5.64880
4.00740

b_j

-1.27640
-1.79620
2.06910
0.62092
-2.45860
0.50008
2.21150
-1.16640
2.24040
2.24860

b_i

-0.38714

Tabla A2.2: Pesos sinápticos de la red neuronal artificial para la predicción del factor de seguridad utilizando todos los casos

w_{jk}

-0.022125	-0.118450	-0.663950	0.299060	-0.295190	0.942980
-1.681100	1.180100	0.411790	-1.142300	-0.187370	0.480570
0.008694	-0.427760	-0.341440	0.043526	0.059883	-0.722840
-0.074382	-0.305280	0.578090	0.461590	0.336240	-1.101900
0.002920	-0.257620	-0.083990	0.087440	0.081447	-2.167400
0.036347	0.603540	0.659670	0.012209	0.108590	-0.335360
-0.071797	-0.854060	-0.250630	0.269560	0.196860	-1.279200
-0.083714	-1.023300	0.286610	0.718500	0.599320	-0.697560
0.167010	1.415600	0.420210	-0.335750	0.223740	-0.215180
0.052018	-1.350200	-1.618000	-0.072026	-0.043003	0.250280
-0.063100	-0.207190	-0.821410	0.877450	-0.351370	1.183300
1.906900	-1.278700	-0.361050	0.937460	0.205930	-0.608350
0.171510	-0.076950	0.095176	-2.173100	0.069884	-0.281900
-0.065938	-1.711700	-1.155100	0.208460	0.188990	-1.061900
0.688770	-0.736070	-0.262670	3.394400	0.108980	-0.332660

w_{ij}

-1.381400
1.294400
-1.886400
-1.107500
0.845610
2.078900
1.773100
0.462860
0.224100
1.273200
0.792430
1.150400
-2.130200
-1.614800
-1.866400

b_j

-0.307010
-1.943700
-0.485920
0.021988
-1.014800
-1.309400
0.566870
0.672220
1.088300
0.967200
-0.581500
1.786200
-0.140830
1.016200
-1.607300

b_i

-0.106890

Tabla A2.3: Pesos sinápticos de la red neuronal artificial para la predicción del factor de seguridad utilizando los casos de falla superficial

w_{jk}	-0.05853	1.82830	2.40010	-0.00001	0.00001	0.00001	w_{ij}	1.33910	b_j	2.5966	b_i	0.64239
	0.36579	1.22150	0.05519	0.00003	0.00004	-0.00001		-1.01840		-0.6063		
	-0.06120	-1.00750	0.85585	-0.00001	-0.00001	0.00000		-1.59570		0.2633		
	0.13779	-0.01189	1.10480	0.00000	0.00000	-0.00002		0.94797		1.1464		
	-0.05699	-1.22890	-1.85110	0.00000	0.00000	0.00000		-3.17100		2.7639		
	0.79227	1.45190	0.17944	0.00009	0.00010	-0.00005		0.26351		-0.6201		

Tabla A2.4: Pesos sinápticos de la red neuronal artificial para la predicción del factor de seguridad utilizando los casos de falla profunda

w_{jk}	-0.10717	-0.82445	0.63337	-0.65529	-0.07608	-0.97104	w_{ij}	-0.52991	b_j	-1.0185	b_i	0.10883
	1.20360	0.15933	0.25981	-2.08800	0.09559	-0.34862		-0.44013		0.1387		
	-0.07708	-0.39730	-0.80447	-0.13913	-0.07780	1.45220		-1.93930		1.8213		
	0.03437	0.05015	1.16150	0.69006	0.25240	-1.46640		1.40160		1.7519		
	0.03733	-0.03819	-0.75744	-0.56865	-0.50058	0.22935		-0.50677		1.0567		
	0.35604	0.02076	0.16113	0.93880	-0.12441	-0.36762		-0.69769		-0.6464		