6. Aplicación de redes neuronales en el cálculo de sobretensiones y tasa de contorneamientos

6.1. INTRODUCCIÓN

Este capítulo presenta los resultados obtenidos al analizar el comportamiento de líneas aéreas de distribución frente al rayo empleando redes neuronales. El cálculo de la tasa de contorneamientos se realizará de manera estadística aplicando el método de Monte Carlo, siguiendo el procedimiento que se ha comentado en el capítulo anterior.

La aplicación del método de Monte Carlo en el análisis estadístico de sobretensiones atmosféricas en líneas aéreas de distribución puede ser una tarea muy laboriosa debido al elevado número de parámetros que intervienen en una sobretensión. Además, la duración de esta tarea puede ser muy larga si los algoritmos de cálculos de sobretensiones son muy sofisticados. Debido a esto, en este capítulo se ha desarrollado una aproximación basada en el empleo de redes neuronales.

Una red neuronal es un procesador paralelo que puede ser entrenado para reproducir un determinado comportamiento natural o artificial. La principal ventaja del empleo de una red neuronal frente a un algoritmo tradicional podría estar por tanto en la velocidad de cálculo si el algoritmo es muy sofisticado. Esto sería todavía más evidente si el número de casos a calcular fuese muy elevado, lo que puede ocurrir con fenómenos como el rayo. Sin embargo, es necesario tener en cuenta que al tiempo de cálculo mediante red neuronal es necesario añadir el tiempo de entrenamiento, y además que actualmente no existe un consenso total sobre el algoritmo de cálculo más adecuado para obtener sobretensiones inducidas en una línea de distribución por descargas que caen a tierra en sus cercanías. Solo cuando la red neuronal fuese entrenada con datos de campo las ventajas frente a cualquier algoritmo tradicional serían evidentes.

Este capítulo se ha dividido en tres partes.

- La sección 2 presenta una introducción a las redes neuronales y muy especialmente al modelo “Backpropagation” empleado en este estudio.

- En la sección 3 se detalla el proceso de entrenamiento de redes neuronales que se ha seguido y los resultados obtenidos con los distintos estudios realizados, concretamente la aplicación de una red neuronal en la clasificación de descargas atmosféricas y en el cálculo de sobretensiones originadas por estas descargas. El cálculo de las sobretensiones inducidas por descargas a tierra se ha realizado mediante la fórmula de Rusck y mediante el método de Chowdhuri.

- Finalmente, la última sección presenta el estudio de validación que se basará fundamentalmente en el cálculo de la tasa de contorneamientos mediante las redes neuronales desarrolladas anteriormente y mediante los algoritmos de cálculo empleados en el entrenamiento.

6.2. INTRODUCCIÓN A LAS REDES NEURONALES

6.2.1. Conceptos generales

6.2.1.1. Definición

Existen numerosas formas de definir lo que es una red neuronal, como por ejemplo

Red neuronal artificial es una nueva forma de computación, inspirada en modelos biológicos.

Red neuronal artificial es un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles.

Red neuronal artificial es un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas.

Redes neuronales artificiales son redes interconectadas masivamente, en paralelo, de elementos simples (usualmente adaptativos) y con organización jerárquica las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

En las redes neuronales biológicas, las células (neuronas) corresponden a los elementos de proceso anteriores. Las interconexiones se realizan por medio de las ramas de salida (axones) que producen un número variable de conexiones (sinapsis) con otras neuronas (o quizás con otras partes como músculos y glándulas). Las redes neuronales son sistemas con elementos de proceso muy interconectados.

La compleja operación de las redes neuronales es el resultado de abundantes lazos de realimentación junto con no linealidades de los elementos de proceso y cambios adaptativos de sus parámetros, que pueden definir incluso fenómenos dinámicos muy complicados.

La programación de una red se puede realizar de dos formas

- alterando las estructuras de interconexión entre las células
- cambiando las fuerzas de estas interconexiónes.

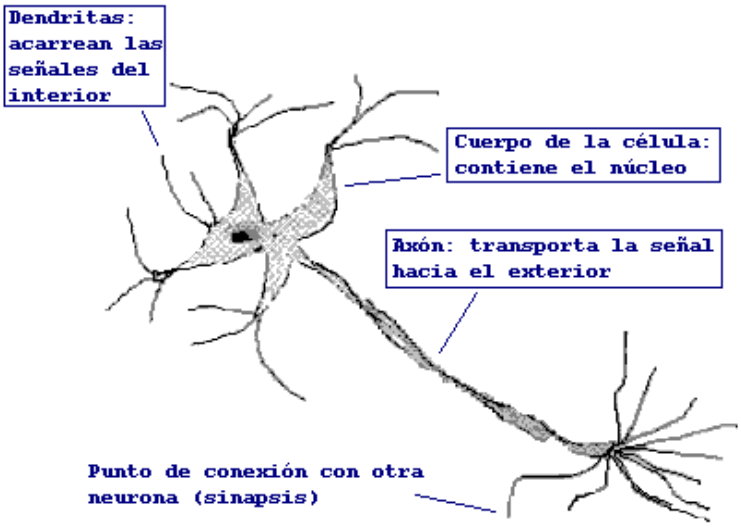

Figura 6.1. Forma general de una neurona.

Parece que existen bastantes estrategias claras sobre como cambiar las fuerzas en la dirección correcta, mientras que los cambios en las interconexiones son mas difíciles de definir, porque suelen tener efectos radicales en el comportamiento de la red, especialmente en lo concerniente a la operación secuencial y las funciones jerárquicas.

6.2.1.2. Aplicaciones

Las redes neuronales forman una teoría computacional emergente que puede utilizarse en gran número y variedad de aplicaciones. Se pueden desarrollar redes neuronales en un periodo de tiempo razonable y pueden realizarse tareas concretas mejor que con otras tecnologías convencionales, incluyendo los sistemas expertos. Cuando se implementan mediante hardware (redes neuronales con chips VLSI), presentan una alta tolerancia a fallos del sistema y proporcionan un grado de paralelismo en el proceso de datos muy grande. Esto hace posible insertar redes neuronales de bajo coste en sistemas existentes y recientemente desarrollados.

Hay muchos tipos diferentes de redes neuronales, cada uno de los cuales tiene una aplicación particular más apropiada. A continuación se muestran algunos ejemplos

- obtención de modelos de retina (Biología)
- identificación de candidatos para posiciones específicas (Empresa)
- previsión del tiempo (Medio ambiente)
- valoración del riesgo de los créditos (Finanzas)
- identificación de falsificaciones (Finanzas)
- inspección de calidad (Manufacturación)
- control de producción en líneas de proceso (Manufacturación)
- lectores de rayos X (Medicina)
- clasificación de las señales de radar (Militar)
- creación de armas inteligentes (Militar).

Este trabajo está enfocado hacia el campo de reconocimiento de patrones, es decir, se introducen una serie de variables de entrada (intensidad, velocidad,...) y se obtienen varias variables de salida como por ejemplo la tensión inducida en una línea. Serán estas variables de salida las que tendrán que ser estimadas en la fase de aprendizaje de la red neuronal. Para este estudio se empleará el modelo de red neuronal Backpropagation, la cual será descrita en el apartado 6.2.2.

6.2.1.3. Tipos de redes neuronales en el reconocimiento de patrones

Dentro del campo de reconocimiento de patrones, existen actualmente varios modelos de redes neuronales. Entre los más importantes se pueden mencionar los siguientes

1) Self-Organizing-Map (SOM)/Topology-Preserving-Map (TPM)
   - aparecen entre los años 1980-1984
   - realizan mapas de características comunes de los datos aprendidos
   - una limitación importante es la necesidad de un largo proceso de entrenamiento
   - creadas por Teuvo Kohonen.

2) Backpropagation
   - aparece en el año 1985 (aunque se conocía desde 1974)
   - es la red más popular
   - se han llevado a cabo numerosas aplicaciones con éxito
   - utiliza un aprendizaje sencillo
   - es potente
   - tiene como limitaciones un largo tiempo de aprendizaje y la necesidad de una cantidad considerable de ejemplos
   - creada por Paul Werbos, David Parker y David Rumelhart.

3) Máquinas de Boltzman y Cauchy
   - aparecen entre los años 1985-1986
   - son un tipo de redes bastante simples
   - representación de patrones de manera óptima
   - necesitan un tiempo muy largo de aprendizaje
   - creada por Jeffrey Hinton, Terry Sejnowski, Harold Szu.

4) Teoría de la resonancia adaptativa (ART)
   - aparece en el año 1986
   - es sofisticada pero poco utilizada
   - como limitaciones tiene la sensibilidad a la translación, distorsión y escala
   - creada por Gail Carpenter y Stephen Grossberg.

6.2.1.4. Elementos de una red neuronal

Una red neuronal es un procesador paralelo que intenta reproducir el comportamiento de una neurona biológica. Cualquier modelo de red neuronal consta de dispositivos elementales de proceso, las neuronas. Cada neurona está caracterizada en cualquier instante por un valor numérico denominado valor o estado de activación $a_i(t)$; asociado a cada unidad, existe una función de salida o de transferencia f_i, que transforma el estado actual de activación en una señal de salida y_i. Dicha señal es enviada a través de los canales de comunicación unidireccionales a otras unidades de la red; en estos canales la señal se modifica de acuerdo con la sinapsis (el peso w_{ji}) asociada a cada uno de ellos según una determinada regla. Las señales moduladas que han llegado a la señal j-ésima se combinan entre ellas, generando así la entrada neta o total

$$\mathrm{Net}_j = \sum_i y_i w_{ji} \tag{6.1}$$

Una función de activación F, determina el nuevo estado de activación $a_j(t+1)$ de la neurona, teniendo en cuenta la entrada total calculada y el anterior estado de activación $a_j(t)$.

La dinámica que rige la actualización de los estados de las unidades (evolución de la red neuronal) puede ser de dos tipos: modo asíncrono y modo síncrono. En el primer caso, las neuronas evalúan su estado continuamente, según les va llegando información, y lo hacen de forma independiente. En el caso síncrono, la información también llega de forma continua, pero los cambios se realizan simultáneamente, como si existiera un reloj interno que decidiera cuando deben cambiar su estado. Los sistemas biológicos se encuentran probablemente entre ambas posibilidades.

Es importante resaltar el concepto general de aprendizaje. Se puede considerar que el conocimiento en una red neuronal artificial se encuentra representado en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones. En realidad puede decirse que se aprende modificando los valores de los pesos de la red. Al igual que el funcionamiento de una red depende del número de neuronas de las que disponga y de como estén conectadas entre sí, cada modelo dispone de sus propias técnicas de aprendizaje.

6.2.1.5. Estructura de una red neuronal artificial

Una vez definidos los componentes más importantes de una red neuronal: Unidades de procesamiento (la neurona artificial), estado de activación de cada neurona, patrón de conexión entre neuronas, regla de propagación, función de transferencia, regla de activación, y regla de aprendizaje; será importante destacar que una red se puede organizar también en función de: Número de niveles o capas, número de neuronas por nivel, patrones de conexión, y flujo de información.

6.2.1.6. Características de las redes neuronales artificiales

Existen cuatro aspectos que caracterizan una red neuronal: la arquitectura, el mecanismo de aprendizaje, el tipo de asociación realizada entre la información de entrada y de salida, y por último, la forma de representación de estas informaciones.

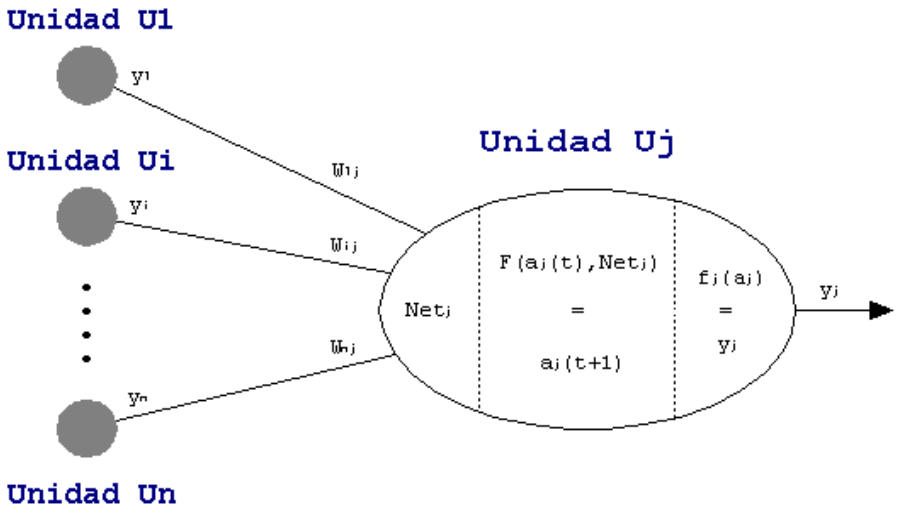

Figura 6.2. Entradas y salidas de una neurona U_j.

a) Arquitectura

La arquitectura o topología de una red neuronal, consiste en la organización y disposición de las neuronas formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y salida de la red. En este sentido los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

Cuando se realiza una clasificación de la red en términos topológicos, se suele distinguir entre las redes con una sola capa o nivel de neuronas y las redes con múltiples capas (2, 3, etc.).

b) Mecanismo de aprendizaje

El aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua creación y destrucción de conexiones. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero.

Durante el proceso de aprendizaje los pesos de las conexiones de la red sufren modificaciones, por tanto se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables

$$\frac{dw_{ij}}{dt} = 0 \tag{6.2}$$

Un aspecto importante en el aprendizaje de las redes neuronales es conocer como se modifican los valores de los pesos, es decir, cuales son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información.

Estos criterios determinan lo que se conoce como regla de aprendizaje de la red. De forma general se suelen considerar dos tipos de reglas: las que responden a lo que habitualmente se conoce aprendizaje supervisado, y las correspondientes a un aprendizaje no supervisado. La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo (supervisor) que controle el proceso de aprendizaje de la red.

Otro criterio que se puede utilizar para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual o si el aprendizaje supone la desconexión de la red, es decir, su inhabilitación hasta que el proceso termine. En el primer caso, se trataría de un aprendizaje ON LINE, mientras que el segundo es lo que se conoce como aprendizaje OFF LINE.

Cuando el aprendizaje es OFF LINE, se distingue entre una fase de aprendizaje o entrenamiento y una fase de operación o funcionamiento, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de test o prueba que serán utilizados en la correspondiente fase. En las redes con aprendizaje OFF LINE, los pesos de las conexiones permanecen fijos después que termina la etapa de entrenamiento de la red. Debido precisamente a su carácter estático, estos sistemas no presentan problemas de estabilidad en su funcionamiento.

En las redes con aprendizaje ON LINE no se distingue entre fase de entrenamiento y de operación, de tal forma que los pesos varían dinámicamente siempre que se presente una nueva información del sistema. En este tipo de redes, debido al carácter dinámico de las mismas, el estudio de la estabilidad suele ser un aspecto fundamental del estudio.

c) Tipo de asociación entre las informaciones de entrada y salida

Existen dos formas primarias de realizar la asociación entre entrada/salida que se corresponden con la naturaleza de la información almacenada en la red. Una primera sería la denominada heteroasociación, que se refiere al caso en que la red aprende parejas de datos

$$\left[(A_1, B_1), (A_2, B_2), ..., (A_n, B_n)\right] \tag{6.3}$$

de tal forma que cuando se le presenta una información de entrada A_i, deberá responder generando la correspondiente salida asociada B_i. La segunda se conoce como autoasociación, donde la red aprende ciertas informaciones $A_1, A_2, ..., A_n$, de tal forma que cuando se le presenta una información de entrada realizará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de la entrada.

Estos dos mecanismos de asociación dan lugar a dos tipos de redes neuronales: las redes heteroasociativas y las autoasociativas. Una red heteroasociativa podría considerarse aquella que computa cierta función, que en la mayoría de los casos no podrá expresarse analíticamente, entre un conjunto de entradas y un conjunto de salidas, correspondiendo a cada posible entrada una determinada salida. Por otra parte, una red asociativa es una red cuya principal misión es reconstruir una determinada información de entrada que se presenta incompleta o distorsionada (le asocia el dato almacenado más parecido).

En realidad estos dos tipos de modelos de redes no son diferentes en principio, porque una red heteroasociativa puede ser siempre reducida a una autoasociativa mediante la concatenación de una información de entrada y su salida (respuesta) asociada, para obtener la información de entrada de la red autoasociativa equivalente.

d) Representación de la información de entrada y salida

Las redes neuronales pueden también clasificarse en función de la forma en que se representan las informaciones de entrada y las respuestas o datos de salida. Así, en un gran número de redes, tanto los datos de entrada como los de salida son de naturaleza analógica, es decir, son valores reales continuos, normalmente normalizados, y su valor absoluto será menor que la unidad. Cuando esto ocurre, las funciones de activación de las neuronas serán también continuas, de tipo lineal o sigmoidal.

Otras redes, por el contrario, sólo admiten valores discretos o binarios {0,1} en su entrada, generando también unas respuestas a la salida de tipo binario. En este caso, las funciones de activación de las neuronas serán del tipo escalón.

La Tabla 6.1 muestra los modelos de red neuronal más conocidos dentro del campo de aplicación del reconocimiento de patrones y las características más relevantes de cada uno según la clasificación que se ha desarrollado.

Tabla 6.1. Características de los modelos de redes neuronales.

MODELO DE RED	TOPOLOGÍA	APRENDIZAJE			ASOCIACIÓN	INFORMACIÓN DE ENTRADA Y SALIDA
		ON LINE/ OFF LINE	SUPERVISADO/ NO SUPERVISADO	REGLA		
TPM	2 capas Feedforward Conexiones laterales	Off	No supervisado	Competitivo	Heteroasociación	Analógica
Backpropagation	n capas Feedforward	Off	Supervisado	Corrección error	Heteroasociación	Analógica
Boltzman Machine	1 capa Conexiones laterales 3 capas Feedforward	Off	Supervisado	Estocástico, Hebbiano, Corrección error	Heteroasociación	Binaria
Cauchy Machine	1 capa Conexiones laterales 3 capas Feedforward	Off	No supervisado	Estocástico	Heteroasociación	E: analógica S: binaria
ART	2 capas Feedforward /Feedback Conexiones laterales	On	No supervisado	Competitivo	Heteroasociación	Analógica

6.2.2. Modelo de red neuronal Backpropagation

6.2.2.1. Introducción

El algoritmo de propagación hacia atrás, o retropropagación (Backpropagation), es una regla de aprendizaje que se puede aplicar en modelos de redes con más de dos capas. De forma simplificada, el funcionamiento de una red Backpropagation consiste en el aprendizaje de un conjunto predefinido de pares de entradas-salidas dados como ejemplo, empleando un ciclo propagación-adaptación de dos fases: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, este estímulo se va propagando a través de todas las capas superiores hasta generar una salida, el resultado obtenido en las neuronas de salida se compara con la salida que se desea obtener y se calcula un valor del error para cada neurona de

salida. A continuación, estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo el porcentaje de error aproximado a la participación de la neurona intermedia de la salida original. Este proceso se repite capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada.

En la etapa de entrenamiento, este tipo de red neuronal es capaz de adaptar los pesos de las neuronas de las capas intermedias con el objetivo de minimizar el error entre un conjunto de patrones dados como ejemplo y sus salidas estimadas. En la etapa de validación, se aplica esa misma relación a nuevos patrones de entrada no utilizados durante el proceso de entrenamiento. Esta es una de las características más importantes de las redes neuronales. Se entiende como capacidad de generalización a la facilidad que tiene una red neuronal de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento. En general, la red debe encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan las entradas de entrenamiento, y que pueda aplicar, además, a entradas no presentadas durante la etapa de aprendizaje para clasificarlas según las características que compartan con los ejemplos de entrenamiento.

6.2.2.2. Proceso de aprendizaje de la red neuronal

6.2.2.2.1. Algoritmo de entrenamiento

En una red Backpropagation existe una capa de entrada con n neuronas, una capa de salida con m neuronas y al menos una capa oculta de neuronas internas. Cada neurona de una capa (excepto las de entrada) recibe entrada de todas las neuronas de la capa anterior y envía su salida a todas las neuronas de la capa posterior (excepto las de salida). No hay conexiones hacia atrás (feedback) ni conexiones laterales entre neuronas de la misma capa. La figura 6.3 muestra la estructura general.

A continuación se presentan los pasos y fórmulas a utilizar para aplicar el algoritmo de entrenamiento.

1) Se inicializan los pesos de la red con valores pequeños aleatorios.

2) Se presenta un patrón de entrada, X_p ($x_{p1},x_{p2},...,x_{pn}$), y se especifica la salida deseada que debe generar la red ($d_1,d_2,...,d_m$). Si por ejemplo la red es utilizada como un clasificador todas las salidas serán cero, salvo una, que será la de la clase a la que pertenece el patrón de entrada.

3) Se calcula la salida actual de la red. Para ello se presentan las entradas a la red y se va calculando la salida que presenta cada capa hasta llegar a la capa de salida ($y_1,y_2,...,y_m$). Los pasos serían los siguientes

   - se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada; para una neurona j oculta

$$net_{pj}^{(h)} = \sum_i w_{ji}^{(h)} x_{pi} + \theta_j^{(h)} \qquad (6.4)$$

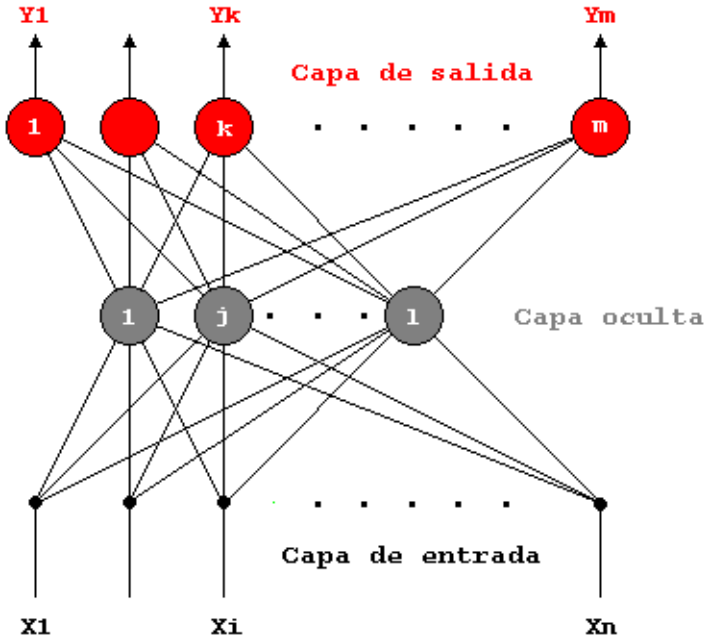

Figura 6.3. Modelo de arquitectura de una red Backpropagation.

en donde el índice h se refiere a magnitudes de la capa oculta (hidden), el subíndice p, al p-ésimo vector de entrenamiento, j a la j-ésima neurona oculta, y θ es el umbral de activación de la neurona y puede ser opcional; el índice i se varía entre 1 y el número de neuronas de la capa de entrada.

- se calculan las salidas de las neuronas ocultas

$$y_{pj} = f_j^{(h)}(net_{pj}^{(h)}) \tag{6.5}$$

- se realizan los mismos cálculos para obtener las salidas de las neuronas de salida (output)

$$net_{pk}^{(o)} = \sum_j w_{kj}^{(o)} y_{pj} + \theta_k^{(o)} \tag{6.6}$$

$$y_{pk} = f_k^{(o)}(net_{pk}^{(o)}) \tag{6.7}$$

donde el índice j varía entre 1 y el número de neuronas de la capa oculta.

4) Se calculan los términos de error de las salidas de todas las neuronas. Si la neurona k está en la capa de salida el error es

$$\delta_{pk}^{(o)} = (d_{pk} - y_{pk})\, f_k^{(o)'}(net_{pk}^{(o)}) \tag{6.8}$$

siendo $f_k^{(o)'}(net_{pk}^{(o)})$ la tasa de cambio o pendiente de la función de transferencia. Si la neurona j no es de salida el error es

$$\delta_{pj}^{(h)} = f_j^{(h)'}(net_{pj}^{(h)}) \sum_k \delta_{pk}^{(o)} w_{kj}^{(o)} \tag{6.9}$$

valor que depende de todos los términos de error de la capa de salida.

Los umbrales internos de las neuronas se adaptan de forma similar, considerando que están conectados con pesos desde entradas auxiliares de valor constante.

5) Se actualizan los pesos. Para ello, se utiliza el algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la siguiente forma

   - para los pesos de las neuronas de la capa de salida

$$w_{kj}^{(o)}(t+1) = w_{kj}^{(o)}(t) + \Delta w_{kj}^{(o)}(t+1) \tag{6.10}$$

$$\Delta w_{kj}^{(o)}(t+1) = \alpha \delta_{pk}^{(o)} y_{pj} \tag{6.11}$$

   - para los pesos de las neuronas de una capa oculta

$$w_{ji}^{(h)}(t+1) = w_{ji}^{(h)}(t) + \Delta w_{ji}^{(h)}(t+1) \tag{6.12}$$

$$\Delta w_{ji}^{(h)}(t+1) = \alpha \delta_{pj}^{(h)} x_{pi} \tag{6.13}$$

   siendo α la tasa de aprendizaje (amplitud de paso).

   A mayor tasa de aprendizaje, mayor es la modificación de los pesos en cada iteración, con lo que el aprendizaje será en general más rápido. Aunque, por otro lado, puede dar lugar a oscilaciones. Para filtrar esas oscilaciones se añade en las expresiones anteriores el término constante β (momento) que determina el efecto en t+1 del cambio de los pesos en el instante t

$$\ldots + \beta \left[w_{ji}(t) - w_{ji}(t-1) \right] \tag{6.14}$$

6) El proceso se repite hasta que el error

$$E_p = \frac{1}{2} \sum_{k=1}^{m} \left[(d_{pk} - y_{pk}) \right]^2 \tag{6.15}$$

   resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

6.2.2.2.2. Variables significativas del entrenamiento

A continuación se describen las variables más importantes que actúan en el algoritmo de aprendizaje. La variación de dichas variables puede alterar de manera considerable los resultados del entrenamiento, y por tanto el funcionamiento de la red neuronal.

- Número de neuronas de la capa oculta: Generalmente un aumento de neuronas ocultas aumenta la eficacia del aprendizaje. Sin embargo, hay que tener en cuenta que existe un margen óptimo en el número de neuronas ocultas, es decir, fuera de ese intervalo los resultados pueden empeorar. Con un error elevado en la salida, un aumento del número de neuronas ocultas puede hacer que disminuya dicho error. De todas formas la tendencia es tener el menor número posible de ellas ya que el proceso de aprendizaje es más rápido.

- Número de capas ocultas: Un aumento del número de capas de neuronas ocultas se traduce en un cambio en la estructura de la red, pudiéndose obtener resultados diferentes. Generalmente con una capa oculta es suficiente. En una red neuronal sin capas ocultas normalmente solo se pueden tener relaciones lineales entre la entrada y la salida.

- Condiciones iniciales: Una mejora en las condiciones iniciales de pesos y umbrales da la posibilidad de que se alcance un mínimo global y no uno local. Diferentes condiciones iniciales pueden hacer que se alcancen diferentes mínimos, y por tanto diferentes resultados.

- Número de iteraciones: Un número elevado de ellas significa un entrenamiento lento. Mediante control de los otros parámetros se puede conseguir que la red entrene con un número más reducido de iteraciones. Recuérdese que el objetivo del entrenamiento de una red neuronal es adaptar los pesos y los umbrales de las neuronas para así minimizar el error entre un conjunto de patrones dados como ejemplo y sus salidas estimadas. La figura 6.4 muestra un ejemplo de superficie de error típico con una función de transferencia sigmoidal logística.

- Patrones de entrada y salida: Un aumento del número de patrones de entrada y salida hace que la red tenga un mejor aprendizaje, y que por tanto cuando se muestren a la red datos desconocidos (diferentes de los utilizados en el entrenamiento) el error en el cálculo de las salidas sea más pequeño. Sin embargo, cuanto mayor sea el número de datos más largo es el proceso de aprendizaje de la red neuronal. Es muy importante hacer un estudio previo de los datos para evitar confusiones a la red neuronal. Cuanto más definidos estén los datos más rápido aprenderá la red.

- Tasa de aprendizaje: La tasa de aprendizaje es la encargada de acelerar el proceso de aprendizaje. Se suelen escoger valores pequeños, empezando con una tasa constante. Lógicamente es deseable que, hasta alcanzar el mínimo, el entrenamiento sea rápido mientras que en el entorno del mínimo sea lento para poder alcanzarlo plenamente. Por este motivo se utiliza una tasa de aprendizaje variable, adaptativa a lo largo del proceso de entrenamiento.

- Momento: Contrarresta las posibles inestabilidades que se crean en la variación de los pesos, y es importante porque reduce la posibilidad de caer en un mínimo local, además puede acelerar enormemente el proceso.

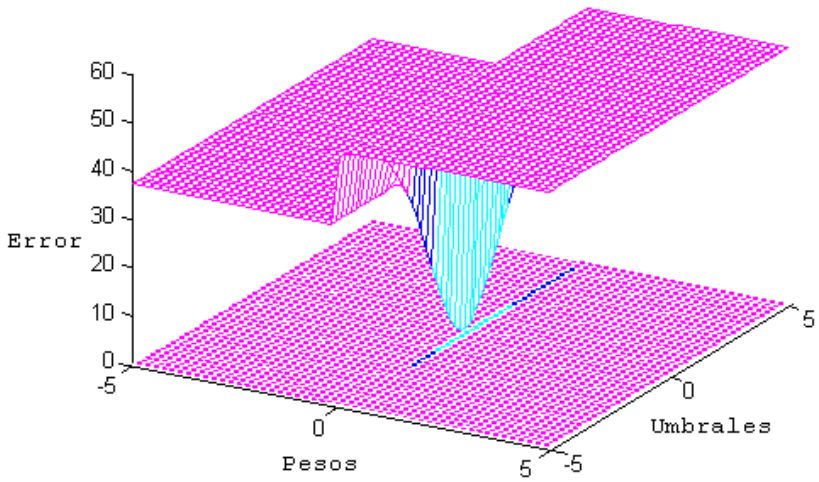

Figura 6.4. Superficie del error.

- Función de transferencia: La función de transferencia o función de activación es la encargada de representar las salidas en función de las entradas a cada neurona. Para el modelo de red Backpropagation dicha función debe ser derivable. Las figuras 6.5, 6.6 y 6.7 muestran algunas de las funciones de transferencia más utilizadas con este modelo. Las dos sigmoidales han de ser adaptadas a las salidas, es decir, los datos de salida han de ser normalizados. También es muy importante normalizar las entradas netas, y una vez normalizadas elegir su mejor intervalo. A continuación se explican más detalladamente estas técnicas.

6.2.2.2.3. Técnicas para la mejora del entrenamiento

A continuación se comentan una serie de técnicas interesantes que pueden mejorar en algunos casos la eficacia del entrenamiento de una red neuronal.

a) Variación de la pendiente de la función de transferencia

La función de transferencia lineal responde a la expresión

$$f(x) = a \cdot x + b \tag{6.16}$$

donde *a* es la pendiente, *x* es la entrada neta de la neurona y *b* es el umbral de la neurona. Variando la pendiente se puede conseguir una mejor adaptación de las salidas de la red neuronal. En la figura 6.8 se puede observar como varía la función de transferencia al variar la pendiente.

Con la función sigmoidal, para la mayoría de los valores del estímulo de entrada (variable independiente), el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. De hecho, cuando la pendiente es elevada, esta función tiende a la función escalón. Sin embargo, la importancia de la función sigmoidal es que su derivada es siempre positiva y cercana a cero para los valores grandes positivos o negativos; además, toma su valor máximo cuando x es 0. Esto hace que se puedan utilizar las reglas de aprendizaje definidas para la funcion escalón, con la ventaja, respecto a esta función, de que la derivada está definida en todo el intervalo. La función sigmoidal logística responde a la expresión

$$f(x) = \frac{c}{1 + \exp\{-a(x + b)\}} + d \tag{6.17}$$

Con d=0 y c=1 se tiene una función sigmoidal que toma los valores asintóticos 0 y 1. Ajustando estos parámetros se pueden obtener salidas deseadas por el usuario.

La función de transferencia sigmoidal tangencial hiperbólica es similar a la anterior, aunque en este caso la salida también puede ser negativa. Esta función responde a la expresión

$$f(x) = c \cdot \left(\frac{\exp\{2a(x + b)\} - 1}{\exp\{2a(x + b)\} + 1} \right) + d \tag{6.18}$$

Con d=0 y c=1 se tiene una función sigmoidal que toma los valores asintóticos -1 y 1.

Las figuras 6.9 y 6.10 muestran la importancia de adaptar la pendiente de estas funciones. Al disminuir la pendiente hay más probabilidad de que las salidas no sean las asintóticas.

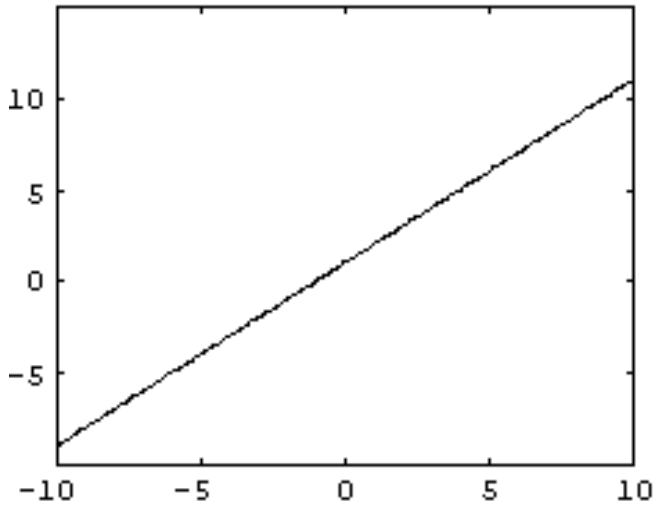

Figura 6.5. Función de transferencia lineal.

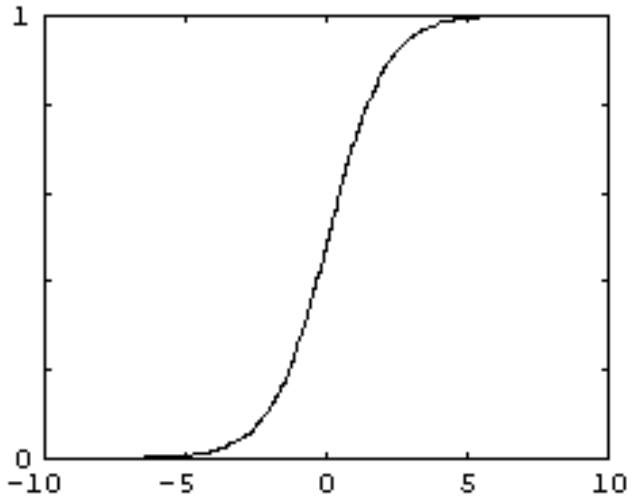

Figura 6.6. Función de transferencia sigmoidal logística.

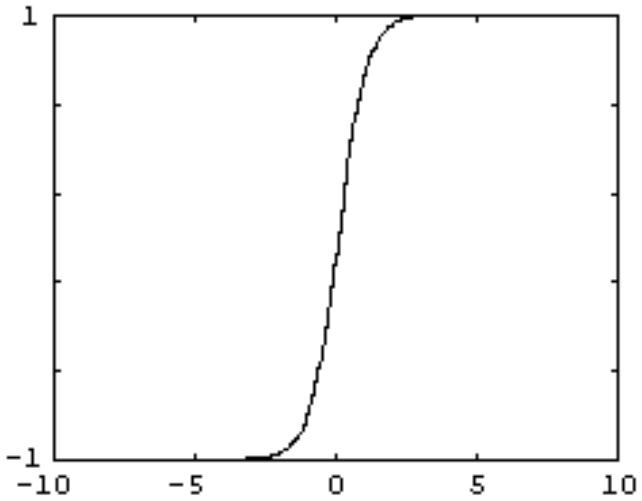

Figura 6.7. Función de transferencia sigmoidal tangencial hiperbólica.

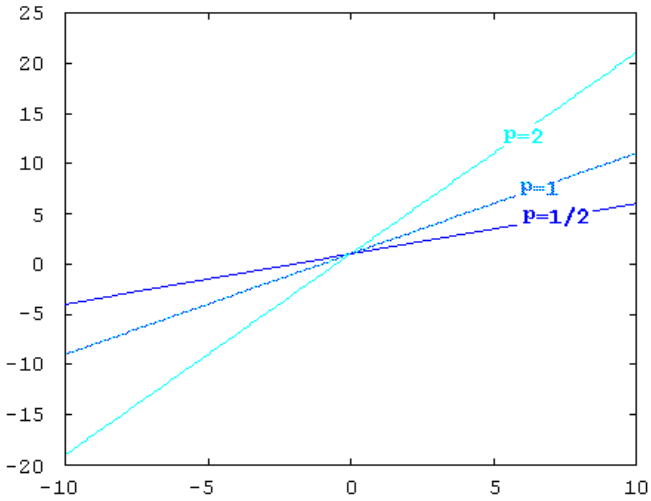

Figura 6.8. Función de transferencia lineal. Variación de la pendiente.

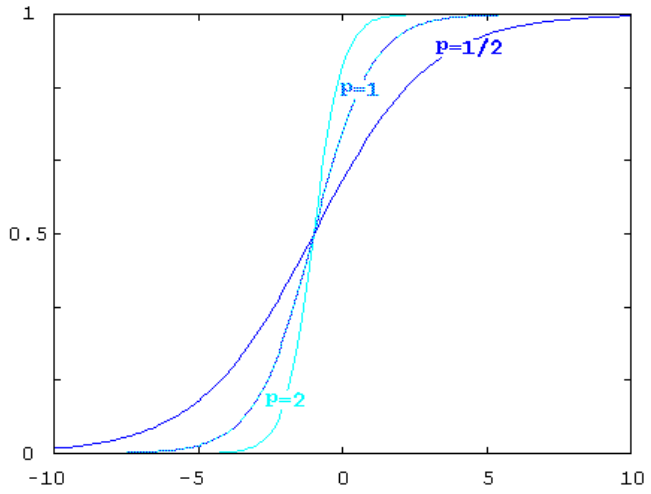

Figura 6.9. Función de transferencia log-sigmoidal. Variación de la pendiente.

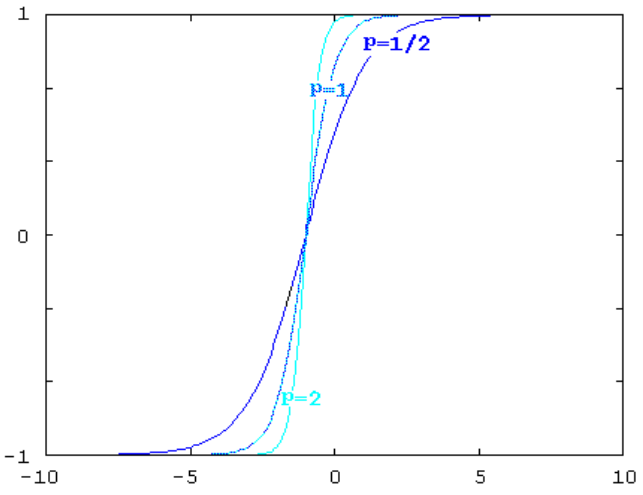

Figura 6.10. Función de transferencia tan-sigmoidal. Variación de la pendiente.

b) Intervalo de las entradas netas

El mínimo error que alcanza la red durante el entrenamiento en algunos casos depende considerablemente del intervalo escogido para las entradas netas de las neuronas. En ambas funciones de transferencia, sigmoidal logística y sigmoidal tangencial, las salidas están acotadas entre 0 y 1 o entre -1 y 1 respectivamente, por tanto habrá un intervalo máximo a partir del cual las salidas o bien no variarán o bien empeorarán. En el caso de utilizar una función lineal, dado que la salida no está acotada, el intervalo de las entradas netas no tiene límite de apertura.

Veamos algunos ejemplos. La figura 6.11 muestra la función de transferencia sigmoidal logística con un umbral (variable b) igual a 1. Para conseguir que la función proporcione valores entre 0 y 1, las entradas han de tener un valor cercano al 0. Se puede observar que los valores de salida comienzan a ser asintóticos a partir de unos valores de entrada entre -5 y 5. No obstante este intervalo no tiene porque ser el mejor, puesto que esto depende de los datos de entrada y del umbral de activación de la neurona. Las figuras 6.12 y 6.13 muestran los diferentes intervalos de salida según se escojan los intervalos {0,1} o {-1,1} para las entradas. Dará mejores resultados un intervalo {-1,1}, porque es mayor. También hay que tener en cuenta que adaptando el umbral se puede obtener cualquier salida dentro del intervalo {0,1}. La figura 6.14 muestra que un cambio en el umbral de la neurona (por ejemplo, b=3), desplaza la gráfica de la función de transferencia a lo largo del eje de abcisas.

Las directrices a seguir para el correcto ajuste del intervalo de las entradas netas pueden ser

1) Normalizar las entradas netas simétricamente, es decir, tomando como extremos 1 y -1

2) Aumentar el intervalo de dichas entradas hasta obtener un error mínimo.

c) Normalización de los datos

A continuación se comentan algunos de los métodos más utilizados para normalizar datos.

Método 1: MÁXIMO

Supóngase que los datos que se quieren normalizar se encuentran dentro del vector DATOS(i), con i=1,...,n. El procedimiento a seguir es el siguiente:

1) Se busca el máximo del vector DATOS(i)

2) Se normalizan los datos según la relación

$$DATOS_norm(i) = DATOS(i)/Max \tag{6.19}$$

Los datos normalizados caen dentro del intervalo {0,1} en el caso de que los datos originales sean positivos, si también son negativos caerán dentro del intervalo {-1,1}.

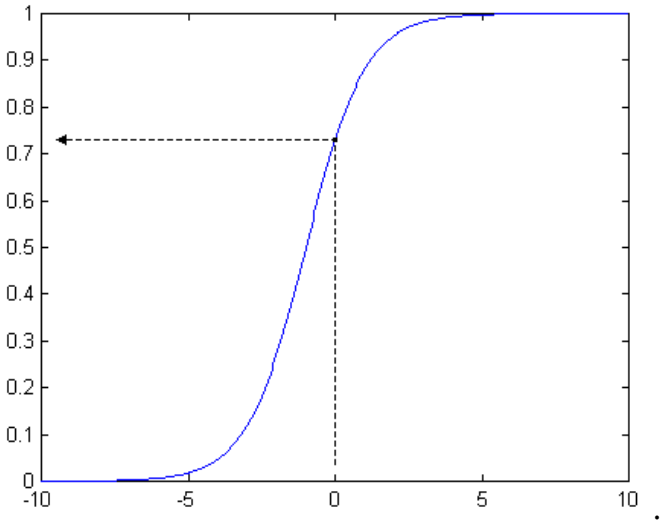

Figura 6.11. Función de transferencia log-sigmoidal (completa/b=1).

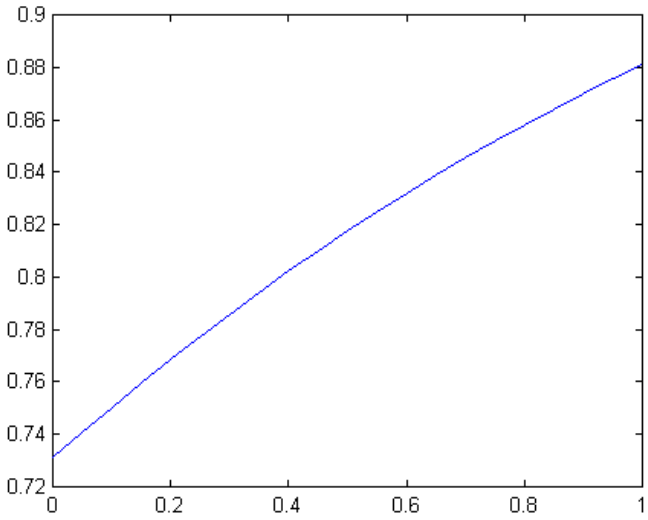

Figura 6.12. Función de transferencia log-sigmoidal (intervalo {0,1}/b=1).

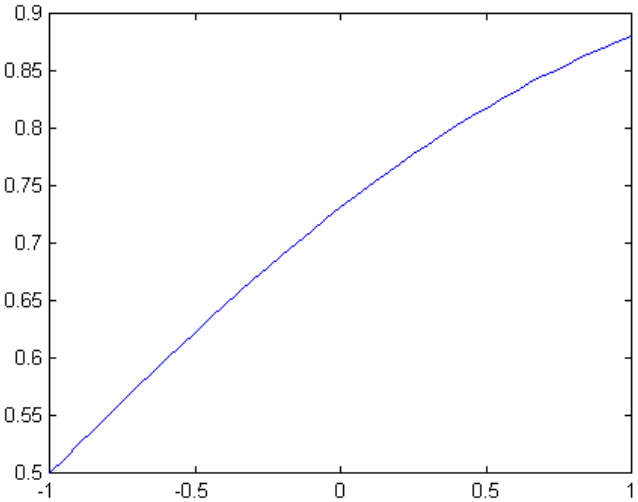

Figura 6.13. Función de transferencia log-sigmoidal (intervalo {-1,1}/b=1).

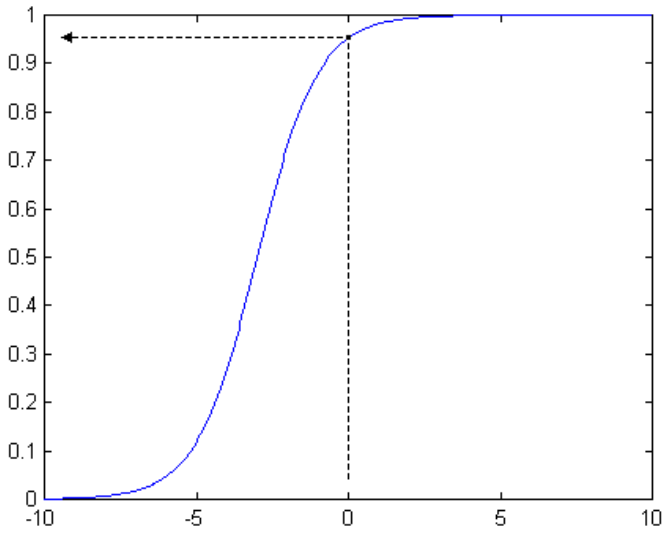

Figura 6.14. Función de transferencia log-sigmoidal (completa/b=3).

Método 2: MÍNIMO-MÁXIMO

El procedimiento a seguir es bastante parecido al anterior:

1) Se busca el máximo y el mínimo del vector DATOS(i)

2) Se normalizan los datos según la relación

$$DATOS_norm(i) = \frac{DATOS(i) - Min}{Max - Min} \tag{6.20}$$

Estos datos normalizados caen dentro del intervalo {0,1} sean cuales sean los datos originales. No obstante es importante destacar que en los datos normalizados siempre habrá un valor que será 0 y otro que será 1.

Método 3: MEDIA-DESVIACIÓN TIPO

Con este método se pueden obtener datos normalizados dentro del intervalo {-1,1} o dentro del intervalo {0,1}. Inicialmente se calcula

$$DATOS_norm(i) = \frac{DATOS(i) - \mu}{\sigma} \tag{6.21}$$

Los datos normalizados caen dentro del intervalo {-k1,k2}. Nótese que k1 y k2 son números reales positivos, y que μ y σ son la media y la desviación tipo de los datos de entrada, respectivamente. Para que los datos normalizados caigan dentro del intervalo {-1,1}, se dividen por el mayor de k1 o k2. Para que los datos normalizados caigan dentro del intervalo {0,1} se hace lo siguiente:

1) A los datos normalizados se les suma el mayor de k1 y k2. Ahora estos datos caen dentro del intervalo {0,k3}, siendo k3=k1+k2.

2) Los datos normalizados se dividen por k3, obteniéndose así el intervalo de {0,1}.

6.2.2.3. Proceso de validación de la red neuronal

Una vez que la red neuronal ha sido entrenada, se procede a su validación, es decir, se presentan datos diferentes de los utilizados en el proceso de aprendizaje. El objetivo es estudiar la respuesta de la red neuronal frente a datos que no han sido utilizados durante el entrenamiento. Para visualizar la validación de la red se dispone de gráficos similares a los realizados durante el entrenamiento. La figura 6.15 muestra un ejemplo de validación de una red neuronal Backpropagation.

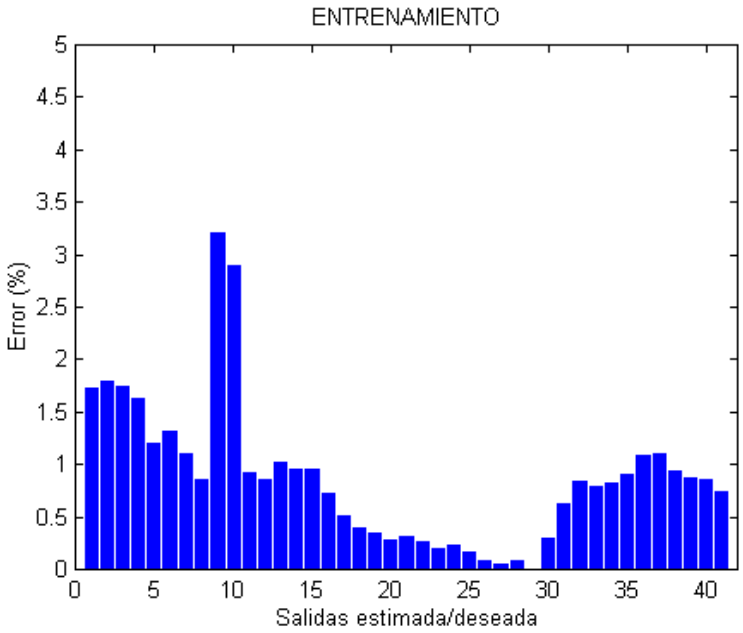

a) Error porcentual en las salidas de la red neuronal

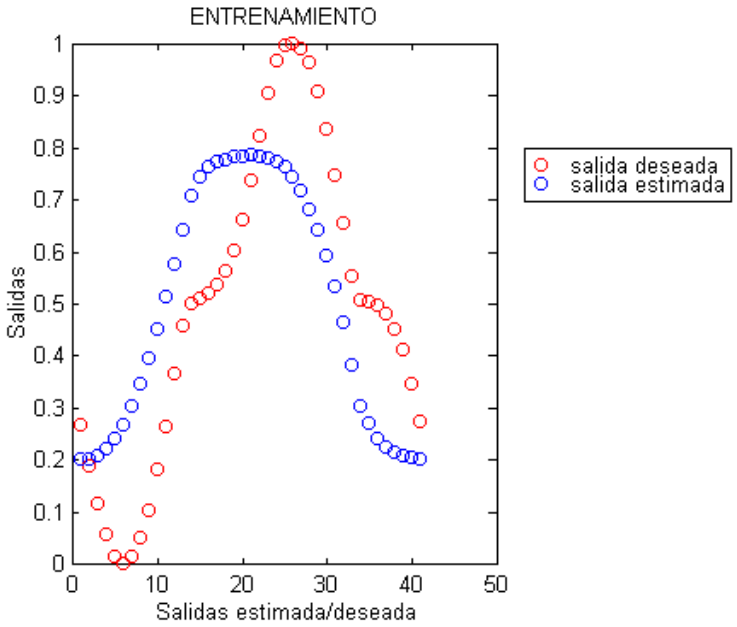

b) Salidas calculadas vs. salidas deseadas

Figura 6.15. Validación de una red neuronal.

6.3. ENTRENAMIENTO DE REDES NEURONALES EN EL CÁLCULO DE SOBRETENSIONES POR RAYOS

6.3.1. Introducción

El objetivo del entrenamiento es minimizar la diferencia entre la salida real y la calculada por la red neuronal mediante el ajuste de los parámetros de la red. Como resultado se obtiene la configuración de la red mediante pesos (W) y umbrales (B).

A continuación se resume la estrategia general seguida en el entrenamiento

1) Se empieza con una capa oculta y un número determinado de neuronas ocultas. Se fijan los valores de 0.25 para la tasa de aprendizaje y 0.9 para el momento. Se utiliza la función de transferencia sigmoidal logística para todas las neuronas tanto de las capas ocultas como de la capa de salida.

   Dentro de este apartado se distinguen las siguientes fases

   - se intentan encontrar unas buenas condiciones iniciales de pesos y umbrales con el objetivo de estimar un primer comportamiento de la red neuronal

   - con las condiciones iniciales anteriores se ajusta el intervalo de las entradas netas y la pendiente de la función de transferencia.

2) Se varía el número de neuronas de la primera capa oculta

3) En caso de ser necesario se añade una segunda capa oculta y se varía el número de neuronas de esta capa

4) Con la arquitectura elegida se terminan de ajustar los parámetros de la tasa de aprendizaje y el momento.

Los valores son normalizados según el método media-desviación tipo, ver apartado 6.2.2.2.3.

El entrenamiento de la red neuronal en el cálculo de sobretensiones originadas por el rayo se realizará de dos formas diferentes según se tenga en cuenta la función de probabilidad que sigue la velocidad de retorno del rayo: distribución uniforme y velocidad en función de la intensidad de pico de la descarga, ver expresión (3.10).

Antes de mostrar el entrenamiento de la red neuronal en el cálculo de sobretensiones originadas por el rayo, se muestra un ejemplo de red neuronal trabajando como clasificador de tipos de impacto del rayo en una línea sin cable de tierra con una altura media de sus conductores de 10 m, ver figura 4.2. No se estudiará el clasificador para líneas con cable de tierra porque siguiendo el mismo ejemplo, tal como muestra la figura 4.4, la probabilidad de que un rayo impacte en un conductor de fase es muy reducida, por lo que el clasificador de descargas se convierte en el estudiado en el caso de líneas sin cable de tierra, aunque con la diferencia de que los impactos pueden ser a tierra o al cable de tierra, en lugar de a los conductores de fase.

6.3.2. Clasificador de descargas atmosféricas. Líneas sin cable de tierra

El objetivo es comprobar que la red neuronal puede funcionar como clasificador y distinguir entre descargas a la línea y descargas a tierra. Además se comprobará que las pautas del entrenamiento a seguir posteriormente son adecuadas. Esta tarea se ha realizado exclusivamente con una línea cuyos conductores se encuentran todos a una altura media de 10 m.

Las variables de entrada y salida de la red neuronal son las siguientes

- Entradas (variables independientes): Intensidad máxima de la descarga (variable I), distancia perpendicular entre la línea y la descarga (variable y)

- Salida de la red neuronal (variable dependiente): Tipo de descarga, directa / indirecta (variable t).

La red neuronal se ha entrenado con un total de 300 patrones generados de forma aleatoria. Cada patrón esta formado por un valor para cada entrada (I,y) y el correspondiente valor para la salida (t).

a) Intensidad de la descarga

   Los valores de la intensidad de la descarga se generan siguiendo el procedimiento visto en el apartado 5.3.1 del capítulo 5.

b) Distancia perpendicular entre la línea y la descarga

   El valor de esta distancia se genera de forma aleatoria, entre 0 m y 500 m, utilizando una distribución uniforme.

c) Tipo de descarga

   Se utiliza el Modelo Electrogeométrico, ver expresión (4.2), para saber si una descarga, caracterizada por los parámetros que componen la entrada de la red neuronal (I,y), es directa a la línea (t = 1) o directa a tierra (t = 0). La figura 6.16 visualiza la clasificación de descargas de acuerdo con el Modelo Electrogeométrico descrito en el capítulo 4, sección 4.2.

Entrenamiento

La Tabla 6.2 muestra una pequeña parte de los datos utilizados en el entrenamiento. El proceso seguido se detalla a continuación.

1) Se fijan los parámetros iniciales de la red neuronal

   - 1 capa de neuronas ocultas
   - 4 neuronas en la capa oculta
   - funciones de transferencia: log-sigmoidal
   - tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
   - momento β=0.9.

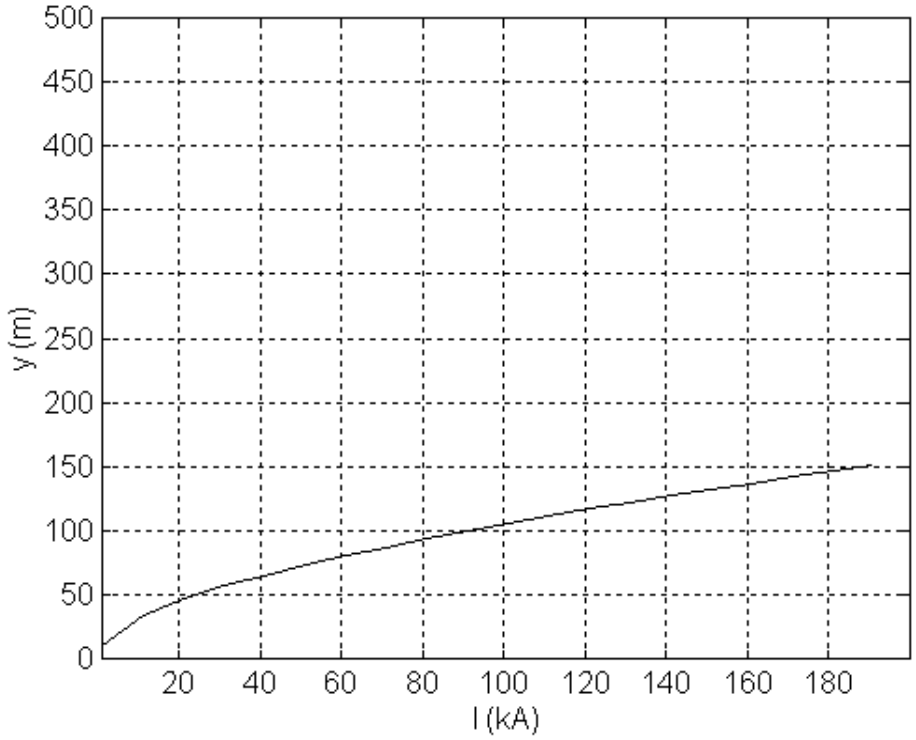

a) Modelo Electrogeométrico. Vista bidimensional.

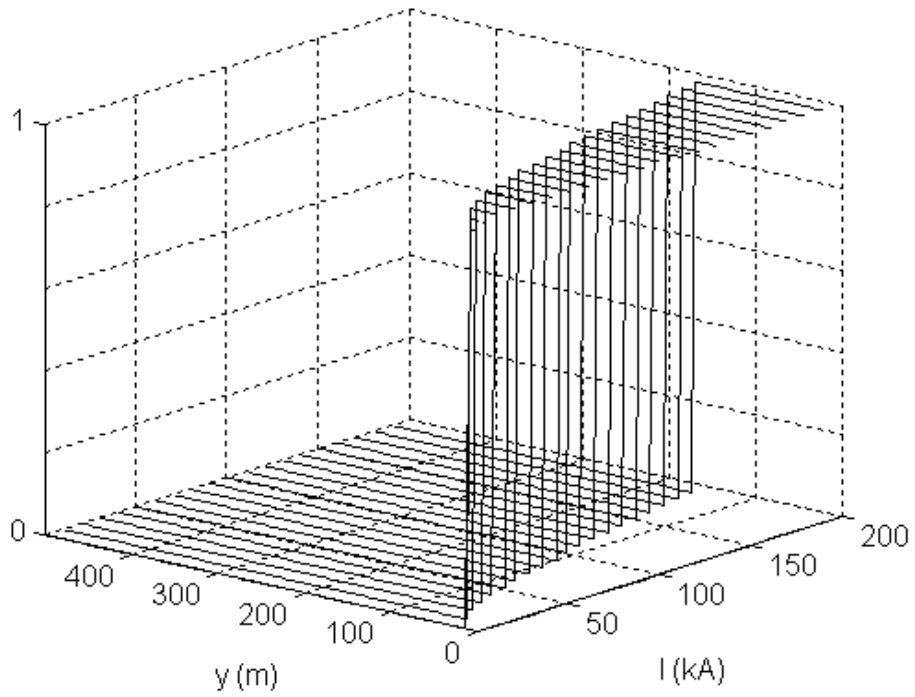

b) Modelo Electrogeométrico. Vista tridimensional.

Figura 6.16. Clasificador de descargas atmosféricas de acuerdo con el modelo electrogeométrico (h = 10 m)

Tabla 6.2. Datos del entrenamiento.

ENTRADAS		**SALIDA**
Intensidad (kA)	**Distancia línea - descarga (m)**	**Tipo descarga**
43	68	0
8	27	1
34	416	0
30	114	0
11	21	1
74	433	0
41	66	0
37	497	0
14	374	0
42	242	0
30	4	1
3	219	0
57	340	0
10	299	0
16	467	0
9	331	0
17	119	0
11	5	1
54	481	0
9	98	0
13	69	0
47	288	0
8	499	0
11	235	0
16	292	0
17	254	0
22	366	0
18	397	0
31	39	1
7	246	0
20	395	0
38	178	0
16	329	0
25	9	1
16	203	0
66	388	0
47	232	0
53	36	1
23	123	0
18	128	0
24	112	0
18	160	0
36	16	1
33	449	0
58	18	1
41	310	0
6	435	0
23	427	0
6	82	0
38	117	0
16	269	0

a) Estudio previo. Se pretenden conseguir unas buenas condiciones iniciales para el estudio del intervalo de las entradas netas y el de la pendiente de la función de transferencia. Tras varios entrenamientos, se han escogido las condiciones iniciales de pesos y umbrales que dan el mínimo error global. Los dos próximos estudios se realizarán con 1000 iteraciones.

b) Ajuste del intervalo de las entradas netas de la función de transferencia. Se aumenta el intervalo de dichas entradas hasta que se alcanza un mínimo. Solo ajustando el intervalo de las entradas netas se consiguen muy buenos resultados. Recuérdese que todavía no se han ajustado los parámetros principales de la red. Se acepta que las entradas de la red neuronal se encuentren dentro del intervalo [-32,32].

c) Ajuste de la pendiente de la función de transferencia. Se varía la pendiente de la función de transferencia hasta encontrar el mínimo error. Es importante destacar que aunque hay dos funciones de transferencia, las pendientes de dichas funciones se variarán por igual. Del estudio se deduce que una variación de la pendiente no disminuye el error.

2) Se varía el número de neuronas de la capa oculta. Se han realizado 2 estudios con cada estructura diferente, uno a 1000 iteraciones para buscar unas buenas condiciones iniciales, y otro más largo, a 10000 iteraciones, para encontrar un buen mínimo. Se ha llegado a la conclusión de que un aumento de neuronas ocultas (de 4 a 6) no sólo mejora los resultados sino que además acelera enormemente el proceso. Por ejemplo, mientras que con 4 neuronas ocultas el mínimo global se encuentra a más de 100000 iteraciones, con 6 neuronas ocultas un error bastante más pequeño se consigue en menos de 1000 iteraciones.

3) Se añade una capa más de neuronas ocultas y se mantiene constante el número de neuronas de la primera capa. En este caso, con una capa más de neuronas ocultas el entrenamiento se ralentiza considerablemente. Además, no se consiguen mejores resultados.

4) Del estudio anterior se concluye que una estructura de red neuronal aceptable es la siguiente

- primera capa oculta: 6 neuronas
- funciones de transferencia: log-sigmoidal.

A continuación se intentarán ajustar los parámetros propios de la fase del aprendizaje tales como el momento y la tasa de aprendizaje. Es importante resaltar que con estos ajustes (incluido el del momento) el error puede disminuir, aunque de forma poco sensible.

a) Tasa de aprendizaje. El entrenamiento se realiza con una tasa de aprendizaje variable, ya que después de realizar una serie de pruebas con diferentes valores de este parámetro se admite que una tasa de aprendizaje constante empeora los resultados. Además se llega también a la conclusión de que el valor adoptado durante el entrenamiento por los diferentes parámetros que componen la tasa de aprendizaje variable es óptimo.

b) Ajuste del momento. El valor actual (0.9) es aceptable.

5) La estructura final de la red escogida, ver figura 6.17, con todos sus parámetros ajustados es la siguiente

- 1 capa de 6 neuronas ocultas
- funciones de transferencia: log-sigmoidal
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento: β=0.9.

Los resultados del entrenamiento con esta red se exponen en la figura 6.18. Se puede observar que el ajuste es muy bueno. No solo la red neuronal no se confunde en ninguno de los casos sino que además ningún error supera el 5%. La Tabla 6.3 muestra los patrones del entrenamiento que han superado el 1 % de error. Se puede ver que tan solo 5 patrones, de una cantidad total de 300, han superado este error.

Validación

A continuación se valida la red neuronal analizando su comportamiento con datos que no han sido utilizados en el proceso de entrenamiento. La validación de esta red neuronal se realiza con 2000 patrones. En los gráficos de la figura 6.19 se puede observar el error cometido en el cálculo de las salidas y el ajuste de las salidas con los valores de los pesos y umbrales óptimos conseguidos en el entrenamiento de la red neuronal. De estos gráficos se deduce que tan solo unos pocos patrones, 13, son confundidos por la red neuronal. Esto significa que la red clasifica correctamente en más de un 99 % de los casos. La Tabla 6.4 muestra las salidas calculadas para estos patrones.

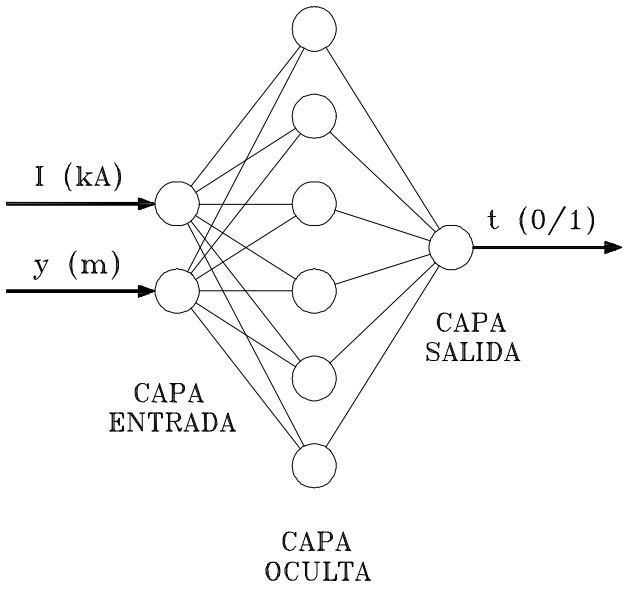

Figura 6.17. Arquitectura de red neuronal.

Tabla 6.3. Resultados del entrenamiento.

ENTRADAS		SALIDA DESEADA	SALIDA CALCULADA	
Intensidad (kA)	**Distancia línea - descarga (m)**	**Tipo descarga**	**Tipo descarga**	**Error (%)**
43	68	0	0.0155	1.55
41	66	0	0.0234	2.34
7	38	0	0.0292	2.91
36	55	1	0.9797	2.03
23	45	1	0.9623	3.77

Tabla 6.4. Resultados de la validación.

ENTRADAS		SALIDA DESEADA	SALIDA CALCULADA	
Intensidad (kA)	**Distancia línea - descarga (m)**	**Tipo descarga**	**Tipo descarga**	**Error (%)**
13	37	0	0.9551	95.50
9	36	0	0.6519	65.19
12	37	0	0.9005	90.04
7	29	0	0.9976	99.76
8	35	0	0.6960	69.60
38	62	1	0.1242	87.57
157	141	0	1.0000	99.99
24	49	1	0.4525	54.74
104	111	0	0.9699	96.99
32	57	1	0.1364	86.36
3	25	0	0.9987	99.87
35	59	1	0.2095	79.04
39	64	1	0.0352	96.48

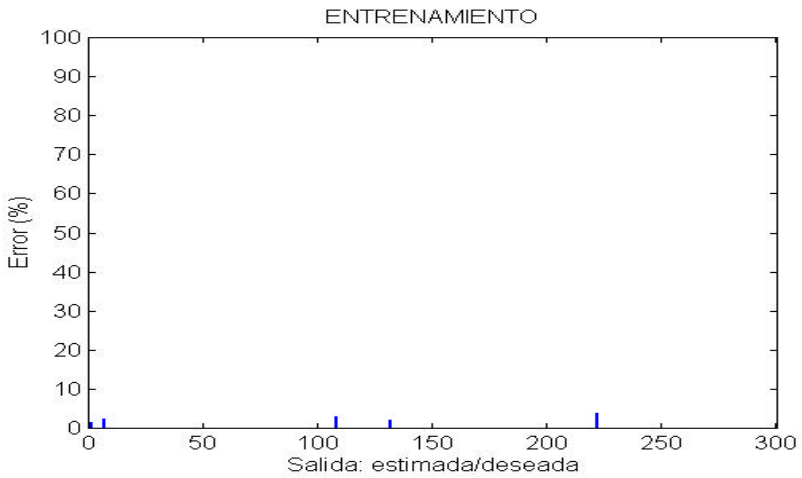

a. Error porcentual en las salidas.

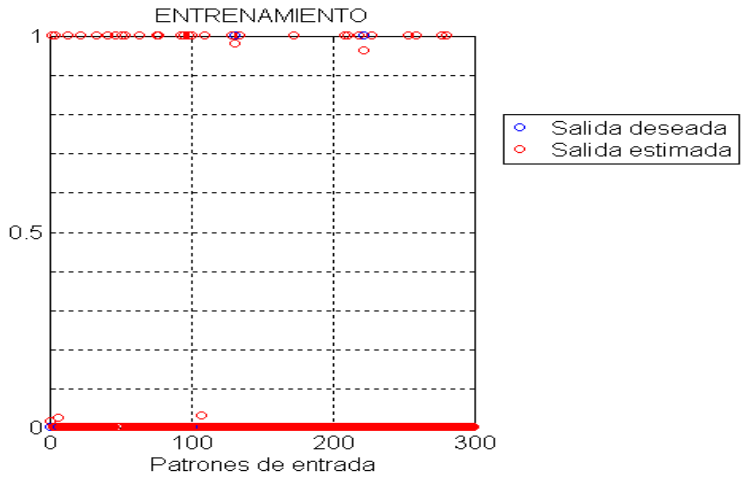

b. Ajuste de las salidas.

Figura 6.18. Entrenamiento de la red neuronal.

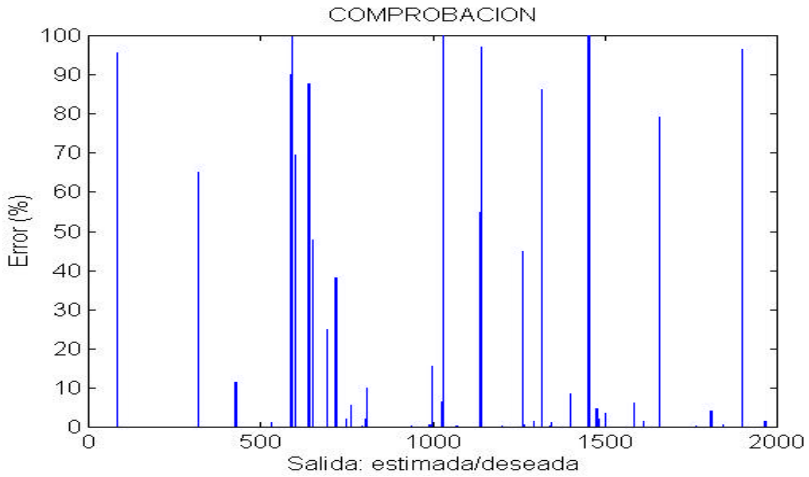

a. Error porcentual en las salidas.

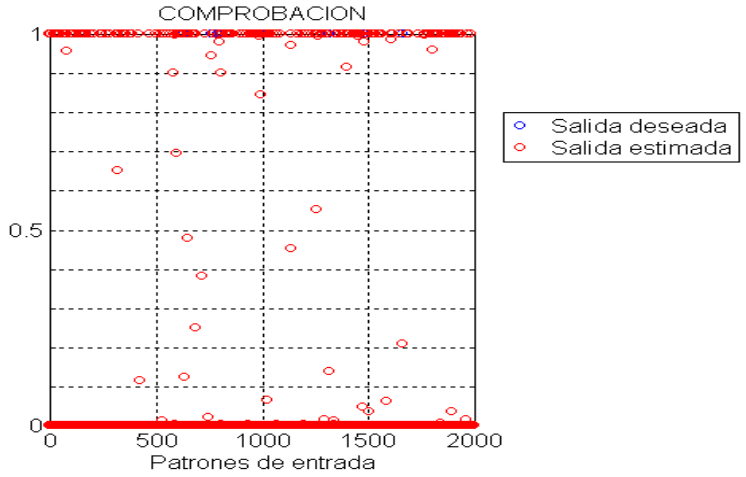

b. Ajuste de las salidas.

Figura 6.19. Validación de la red neuronal.

6.3.3. Cálculo de sobretensiones en líneas sin cable de tierra. Velocidad de retorno del rayo con distribución uniforme

6.3.3.1. Método de Rusck

El objetivo es desarrollar una red neuronal que permita calcular sobretensiones originadas por el rayo en líneas sin apantallar, y de acuerdo con el modelo de Rusck cuando se trata de descargas a tierra. Las pautas que se van a seguir en este entrenamiento son las mismas que se comentaron en la aplicación anterior. En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas (variables independientes): Intensidad máxima de la descarga (variable I), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), altura de la línea (variable h)

- Salidas (variables dependientes): Tipo de descarga, directa / indirecta (variable t), sobretensión que aparece en la línea (variable V).

La figura 6.20 muestra la geometría general para dos configuraciones de línea, horizontal y vertical. Sin embargo, con el método de Rusck solamente es necesario especificar una altura media para los conductores de fase como entrada de la red neuronal. Además, este conductor equivalente se encontraría situado en el eje del poste, es decir x = 0. Por tanto, en este estudio no se tendrá en cuenta el tipo de configuración de la línea, horizontal o vertical, en los datos de entrada de la red neuronal.

La red neuronal se ha entrenado con un total de 2500 patrones diferentes calculados de forma aleatoria. Cada patrón esta formado por un valor para cada entrada (I,y,v,h) y el correspondiente valor para cada salida (t,V). A continuación se comenta como se genera cada valor de las variables de entrada.

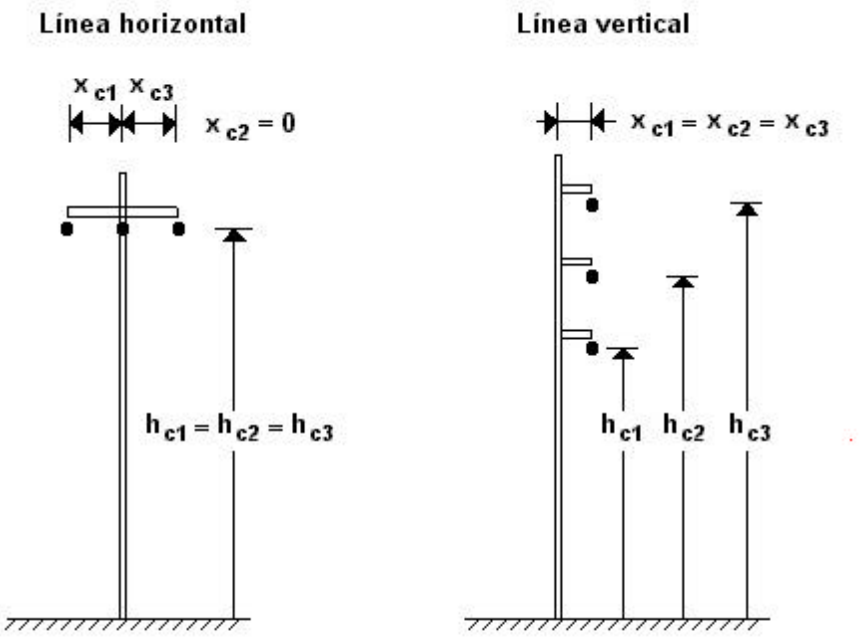

Figura 6.20. Geometría de la línea.

a) Intensidad de la descarga

Los valores de la intensidad de la descarga se generan siguiendo el procedimiento visto en el apartado 5.3.1 del capítulo 5.

b) Distancia perpendicular entre la línea y la descarga

El valor de esta distancia se genera de forma aleatoria, entre 0 m y 500 m, considerando una distribución uniforme.

c) Velocidad de retorno del rayo

El valor de la velocidad de retorno del rayo se genera de forma aleatoria, entre 30000 km/s y 150000 km/s, suponiendo una distribución uniforme.

d) Altura de la línea

Se han utilizado los valores de 5 m, 8 m, 11 m, 14 m y 17 m, en el entrenamiento de la red neuronal. Con los dos valores extremos, 5 m y 17 m, se cubre la totalidad de líneas de distribución.

e) Tipo de descarga

Se utiliza la expresión (4.2) para saber si una descarga, caracterizada por los parámetros que componen la entrada de la red neuronal (I,y,v,h), es directa (t = 1) o indirecta (t = 0).

f) Sobretensión que aparece en la línea

Se utiliza la expresión (4.6) para calcular la tensión que aparece en la línea si la descarga es directa a los conductores de fase, y la expresión (4.20) si la descarga es directa a tierra.

Entrenamiento

La Tabla 6.5 muestra una parte de los datos utilizados en el entrenamiento. El proceso seguido se detalla a continuación.

1) Se fijan los siguientes parámetros

- 1 capa de neuronas ocultas
- 4 neuronas en la capa oculta
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento β=0.9.

Una diferencia muy importante respecto a la aplicación estudiada en el apartado anterior son las funciones de transferencia utilizadas con esta red neuronal. Puesto que la salida más importante de la red neuronal es la que calcula las tensiones, se ha escogido como función de transferencia global la denominada función de aproximación (función tan-sigmoidal en las diferentes capas ocultas y función lineal en la capa de salida). Se ha demostrado que esta arquitectura de red neuronal es capaz de aproximar cualquier función con un número finito de discontinuidades y precisión arbitraria. Cuanto más compleja sea la función más neuronas serán necesarias para poder aproximarla.

Tabla 6.5. Datos del entrenamiento.

ENTRADAS				SALIDAS	
Altura (m)	**Intensidad (kA)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**Tipo descarga**	**Tensión (kV)**
5	1	0	30000	1	207.23
5	1	0	150000	1	207.23
5	1	500	30000	0	0.32
5	1	500	150000	0	0.41
5	200	0	30000	1	41446.53
8	63	300	141534	0	68.51
8	56	474	134736	0	37.96
8	19	67	77057	0	81.18
8	53	203	78053	0	74.01
8	34	335	149545	0	33.26
8	152	214	68439	0	198.40
11	139	242	124134	0	247.97
11	41	416	139549	0	43.90
11	44	480	59657	0	34.82
11	78	145	60652	0	201.87
11	41	277	132145	0	64.45
11	58	156	51039	0	136.95
11	30	489	131538	0	26.85
11	34	240	34022	0	50.38
11	27	376	82476	0	28.01
11	59	33	127945	1	13596.17
11	6	61	66066	0	39.88
11	10	471	37615	0	7.26
11	92	55	142365	1	21228.74
11	35	494	86894	0	27.93
11	29	95	145569	0	137.88
11	38	90	40431	0	153.91
11	33	69	132751	0	207.96
11	14	205	86288	0	27.15
11	17	179	110321	0	40.86
11	40	400	56453	0	37.70
11	61	49	147171	1	14033.48
11	33	446	61259	0	27.89
11	18	69	130003	0	114.46
11	10	222	32269	0	16.57
14	20	175	122137	0	63.23
14	59	328	56836	0	85.53
14	46	307	43630	0	69.79
14	21	207	93298	0	52.57
14	21	330	132746	0	35.36
14	78	440	73465	0	87.18
14	36	204	56447	0	84.85
17	48	143	102262	0	214.07
17	49	159	87842	0	191.18
17	19	94	67014	0	118.80
17	24	296	67621	0	48.89
17	12	386	104471	0	19.74
17	12	124	79831	0	59.17
17	31	134	67439	0	135.80
17	13	402	55616	0	18.71

a) Estudio previo. Tanto éste como los próximos estudios se realizarán con 1000 iteraciones. Por ahora, el objetivo es conseguir unas buenas condiciones iniciales para el estudio del intervalo de las entradas netas y el de la pendiente de las funciones de transferencia. Se guardan los pesos y los umbrales que dan el mínimo error. Se comprueba que en este punto todavía existe un error considerable en el cálculo de las salidas.

b) Ajuste del intervalo de las entradas netas de las funciones de transferencia. A diferencia del ejemplo anterior, en este caso se concluye que aumentando el intervalo de dichas entradas no se modifica en absoluto el mínimo alcanzado.

c) Ajuste de la pendiente de la función de transferencia. Se varían por separado las pendientes de las funciones de transferencia. En este caso, una variación en el valor de dichas pendientes disminuye notablemente el mínimo conseguido. Se mantienen como valores óptimos un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.1 para la función lineal. Se observa claramente que la capa de neuronas tan-sigmoidales es la que actúa como clasificador, y la capa de neuronas lineales es la que termina adaptando las tensiones.

2) Variación del número de neuronas de la primera capa oculta. Se han realizado 2 estudios con cada estructura diferente, uno a 1000 iteraciones para buscar unas buenas condiciones iniciales, y otro más largo, a 10000 iteraciones, para encontrar un buen mínimo. En este caso, se ha aumentado hasta 10 el número de neuronas y los resultados apenas han mejorado.

3) Variación del número de neuronas de la segunda capa oculta. Se añade una capa más de neuronas ocultas y se mantiene constante en 4 el número de neuronas de la primera capa. Se comienzan a conseguir mejores resultados con el aumento del número de neuronas de esta segunda capa. A la vista de los resultados conseguidos se prefiere aumentar el número de neuronas de la primera capa oculta para así poder aumentar el número de neuronas de la segunda capa. Se prueban diferentes estructuras, la que mejor se adapta tiene 14 neuronas en la primera capa oculta y 12 neuronas en la segunda capa oculta.

4) Del estudio anterior se concluye que la estructura de red neuronal ajustada es la siguiente

- primera capa oculta: 14 neuronas
- segunda capa oculta: 12 neuronas
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida).

A continuación se intentarán ajustar los parámetros propios de la fase del aprendizaje tales como el momento y la tasa de aprendizaje. Tal como se comentó durante el entrenamiento del ejemplo, con estos ajustes el error disminuirá poco.

a) Tasa de aprendizaje. Se comprueba que una tasa de aprendizaje adaptativa va mejor que una constante, y que los parámetros actuales son aceptables.

b) Ajuste del momento. Se comprueba que el valor actual (0.9) es aceptable.

5) La estructura final de la red con todos sus parámetros ajustados es la siguiente, ver figura 6.21

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento: β=0.9.

Los resultados del entrenamiento con esta red se muestran en la figura 6.22. Los gráficos se han calculado con las salidas normalizadas porque muestran de manera más clara el error cometido por la red neuronal en el entrenamiento. Debido a la enorme diferencia entre los valores extremos de las tensiones, esta red neuronal ha funcionado mucho mejor con datos normalizados. Se puede observar que el ajuste es muy bueno. Por un lado, el error cometido en los valores calculados de las salidas que actúan como clasificador no supera en ningún caso el 1 %. En el cálculo de las tensiones, el error cometido no supera el 2 %, estando en la mayoría de los casos por debajo del 1 %.

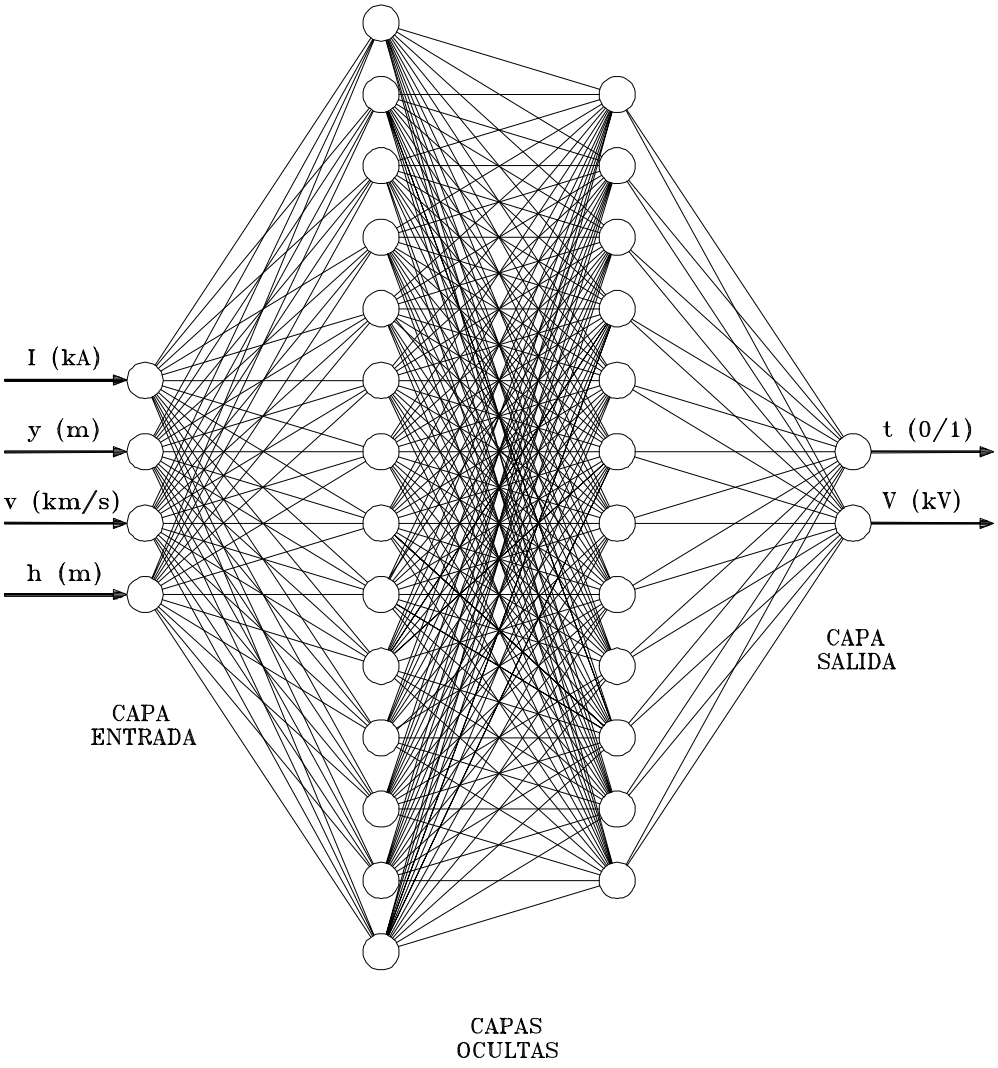

Figura 6.21. Arquitectura de la red neuronal (Método de Rusck con líneas sin apantallar).

Validación

La validación de esta red neuronal se realiza con 6000 patrones que no han intervenido en el proceso de entrenamiento. Se han utilizado 1000 patrones para cada altura de la línea (5 m, 8 m, 10 m, 11 m, 14 m y17 m). La altura de 10 m no ha sido utilizada durante el entrenamiento de la red neuronal.

Los gráficos de las figuras 6.23, 6.24, y 6.25 muestran para tres alturas diferentes el error cometido en el cálculo de ambas salidas y el ajuste de las salidas con los valores de los pesos y umbrales óptimos conseguidos en el entrenamiento de la red neuronal. Se puede observar que en más del 99 % de los casos el error cometido en el cálculo de tensiones se encuentra por debajo del 2 %. En unos pocos casos el error puede llegar a alcanzar el 10 %, y esto ocurre cuando la red neuronal muestra confusión en la clasificación de descargas.

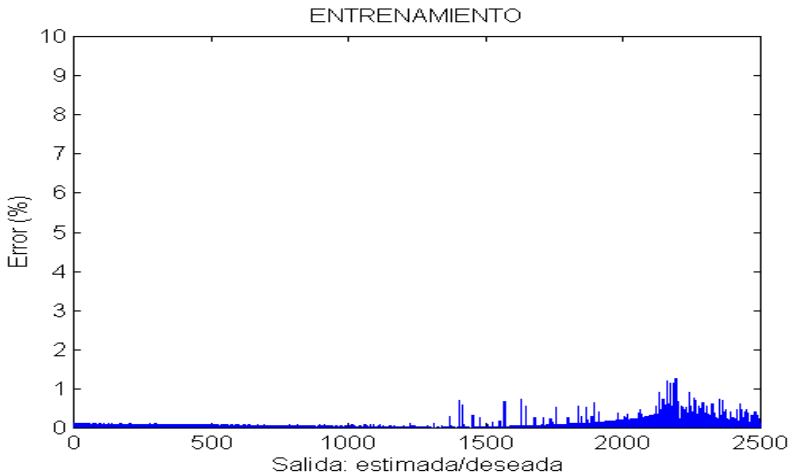

a. Error porcentual en el cálculo de sobretensiones.

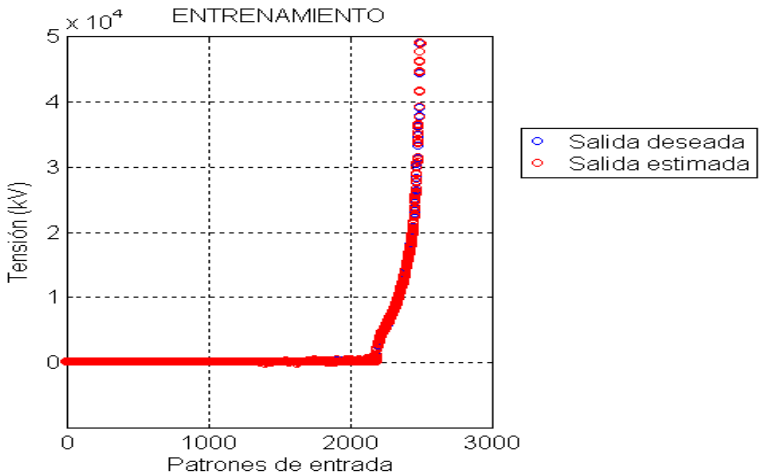

b. Ajuste de las salidas (tensiones).

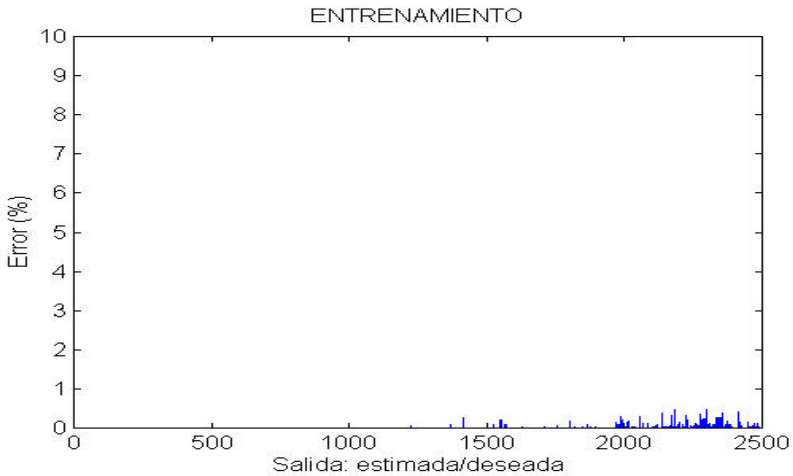

c. Error porcentual en la clasificación de descargas.

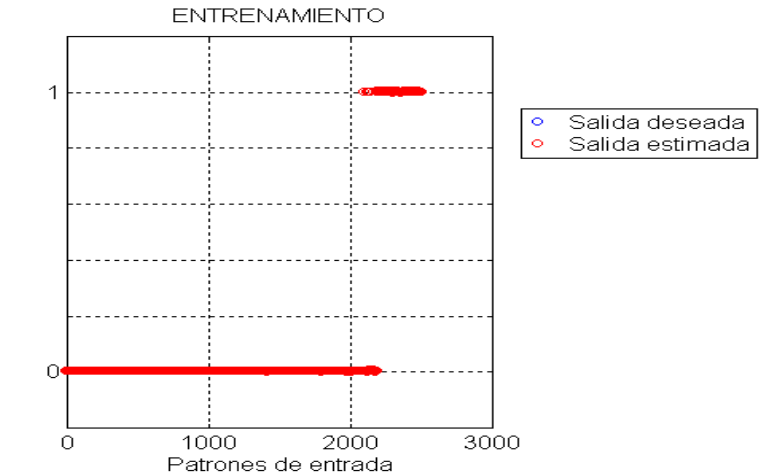

d. Ajuste del clasificador.

Figura 6.22. Entrenamiento de la red neuronal.

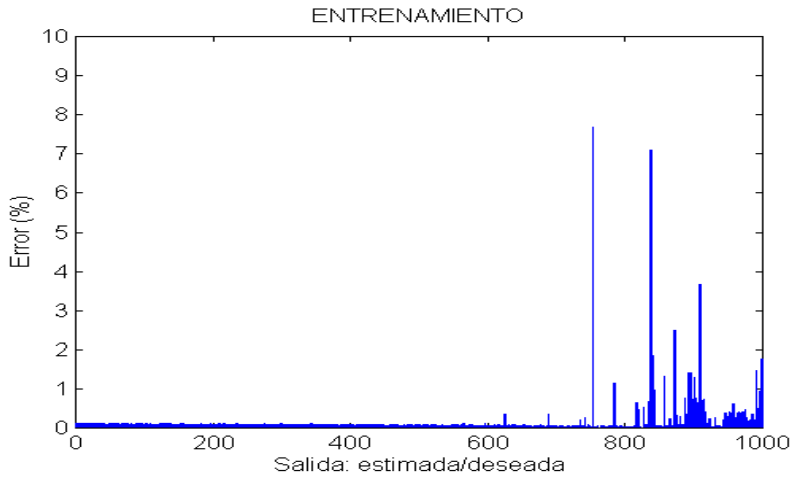

a. Error porcentual en el cálculo de sobretensiones.

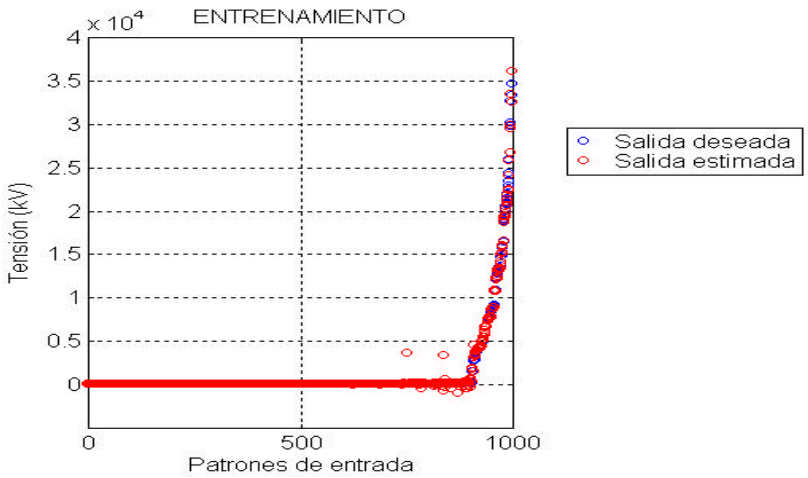

b. Ajuste de las salidas (tensiones).

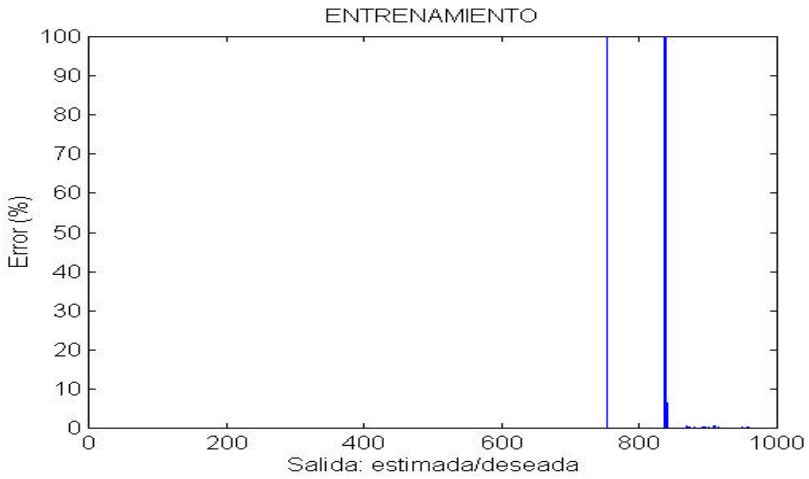

c. Error porcentual en la clasificación de descargas.

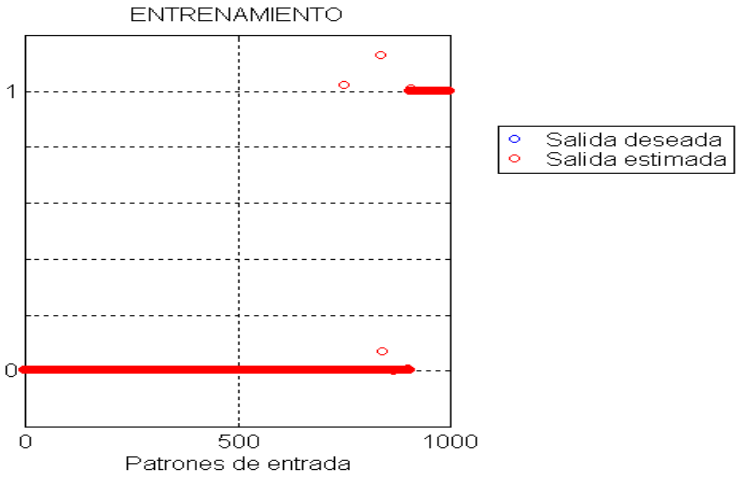

d. Ajuste del clasificador.

Figura 6.23. Validación de la red neuronal. Altura = 5 m.

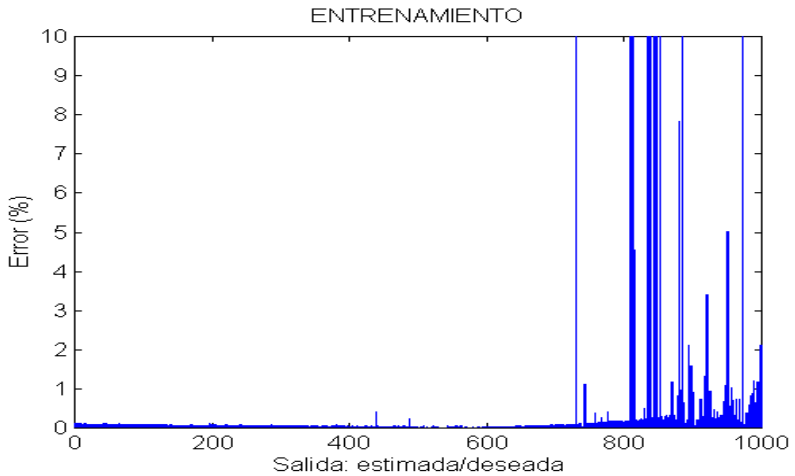

a. Error porcentual en el cálculo de sobretensiones.

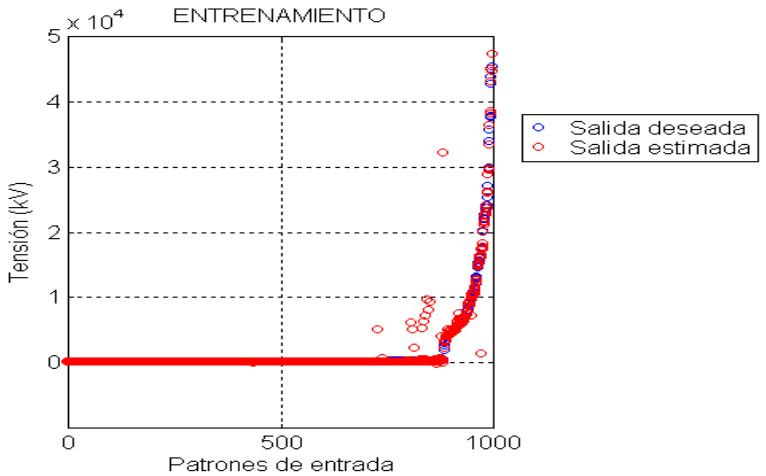

b. Ajuste de las salidas (tensiones).

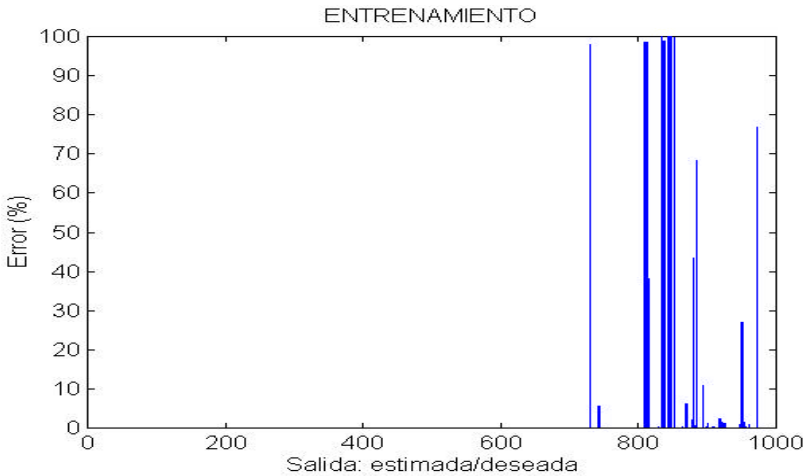

c. Error porcentual en la clasificación de descargas.

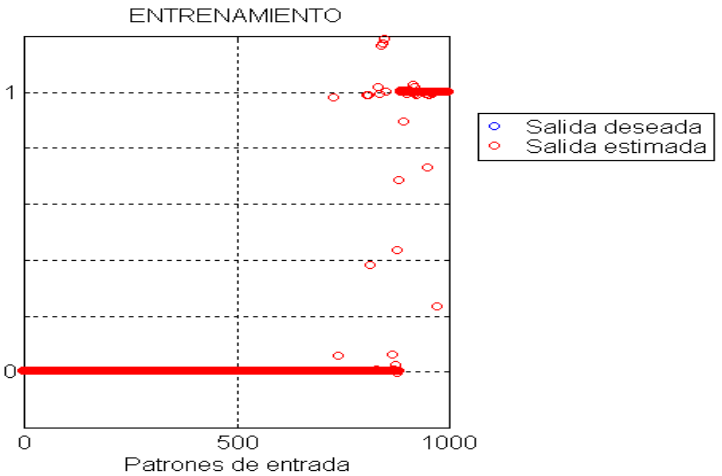

d. Ajuste del clasificador.

Figura 6.24. Validación de la red neuronal. Altura = 10 m.

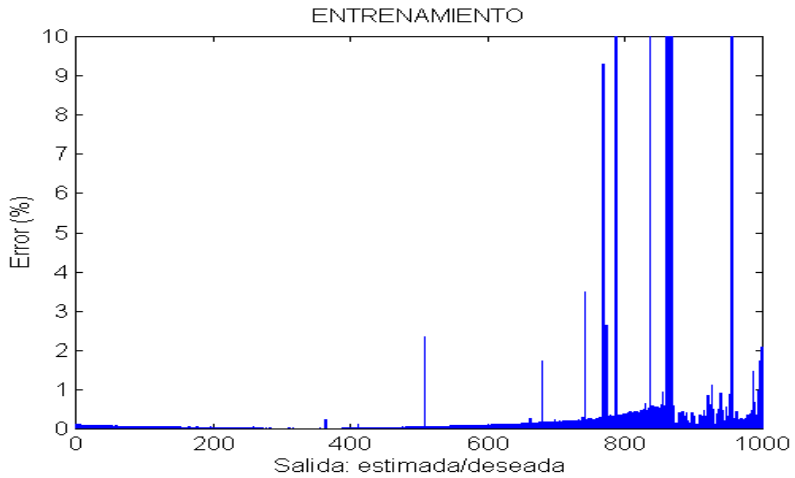

a. Error porcentual en el cálculo de sobretensiones.

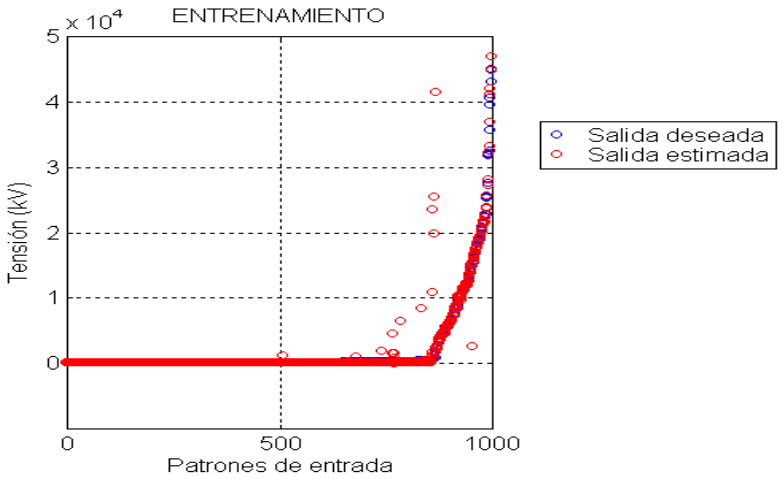

b. Ajuste de las salidas (tensiones).

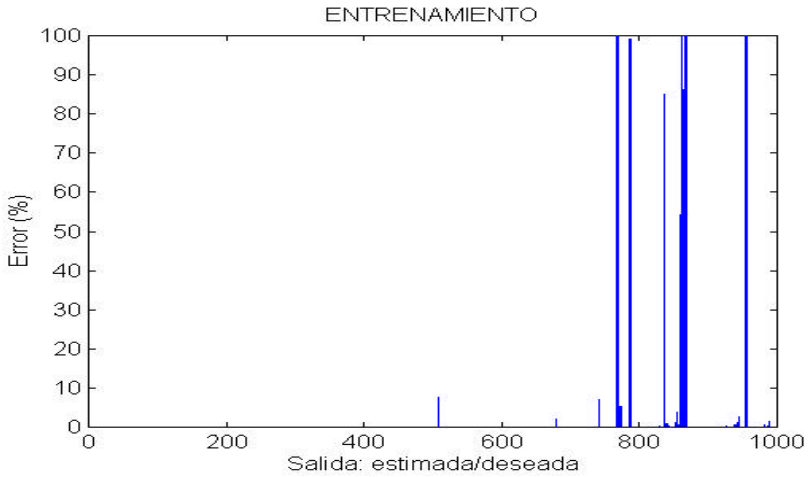

c. Error porcentual en la clasificación de descargas.

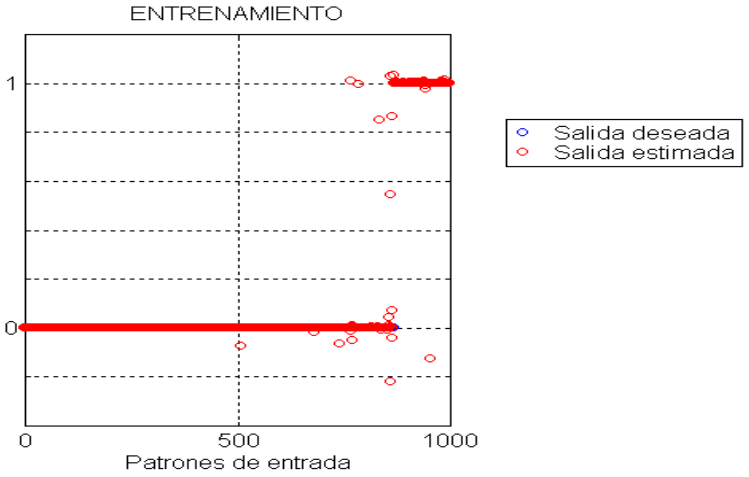

d. Ajuste del clasificador.

Figura 6.25. Validación de la red neuronal. Altura = 17 m.

6.3.3.2. Método de Chowdhuri

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), tiempo de frente de la onda de corriente del rayo (variable t_f), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3})

- Salidas: Tipo de descarga, directa / indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 2800 patrones diferentes calculados de forma aleatoria. Cada patrón esta formado por un valor para cada entrada ($I,t_f,y,v,h_{c1},h_{c2},h_{c3},x_{c1},x_{c2},x_{c3}$) y el correspondiente valor para cada salida (t,V). A continuación se comenta como se genera cada valor de las variables anteriores.

a) Intensidad y tiempo de frente

   Los valores de la intensidad y del tiempo de frente de la onda de corriente del rayo se generan siguiendo el procedimiento visto en el apartado 5.3.1 del capítulo 5.

b) Distancia perpendicular entre la línea y la descarga

   El valor de esta distancia se genera de forma aleatoria, entre 0 m y 500 m, utilizando una distribución uniforme.

c) Velocidad de retorno del rayo

   El valor de la velocidad de retorno del rayo se genera de forma aleatoria, entre 30000 km/s y 150000 km/s, utilizando una distribución uniforme.

d) Geometría de la línea

   Se han utilizado 5 configuraciones diferentes para las líneas de tipo horizontal. La altura en cada configuración ha sido de 5 m, 8 m, 11 m, 14 m y 17 m. La figura 6.20 muestra los tipos de línea utilizados en el entrenamiento.

   Se han utilizado 4 configuraciones diferentes para las líneas de tipo vertical (con tres alturas diferentes para cada conductor de fase): 5 m, 7 m, 9 m (configuración 1), 8 m, 10 m, 12 m (configuración 2), 11 m, 13 m, 15 m (configuración 3), 14 m, 16 m, 18 m (configuración 4). Para cada configuración de línea horizontal se han utilizado dos tipos de distancias al eje diferentes por parte de cada conductor: -1 m, 0 m, 1 m (distancia entre conductores más externos = 2 m), -3 m, 0 m, 3 m (distancia entre conductores más externos = 6 m). En líneas verticales se ha supuesto que los conductores se encuentran colocados en el eje de la línea, es decir, distancia al eje = 0.

   La Tabla 6.6 resume las combinaciones adoptadas en el entrenamiento de la red neuronal para las variables altura y distancia al eje.

Tabla 6.6. Variables altura y distancia al eje.

	h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)
Línea horizontal	5	5	5	-1	0	1
	5	5	5	-3	0	3
	8	8	8	-1	0	1
	8	8	8	-3	0	3
	11	11	11	-1	0	1
	11	11	11	-3	0	3
	14	14	14	-1	0	1
	14	14	14	-3	0	3
	17	17	17	-1	0	1
	17	17	17	0	0	0
Línea vertical	5	7	9	0	0	0
	8	10	12	0	0	0
	11	13	15	0	0	0
	14	16	18	0	0	0

e) Tipo de descarga

Se utiliza la expresión (4.2) para saber si una descarga, caracterizada por los parámetros que componen la entrada de la red neuronal ($I,t_f,y,v,h_{c1},h_{c2},h_{c3},x_{c1},x_{c2},x_{c3}$), es directa (t = 1) o indirecta (t = 0).

f) Sobretensión que aparece en la línea

Se utiliza la expresión (4.6) para calcular la tensión que aparece en la línea si la descarga es directa a los conductores de fase, y la expresión (4.46) si la descarga es directa a tierra.

Entrenamiento

El objetivo no es repetir todos los pasos que se realizaron en el entrenamiento de la red neuronal del apartado anterior (método de Rusck), sino verificar que la estructura final obtenida en aquel estudio es también adecuada en este estudio. La Tabla 6.7 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento β=0.9.

Tabla 6.7. Datos del entrenamiento.

ENTRADAS										SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Intensidad (kA)**	**Tiempo de frente (ms)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**Tipo descarga**	**Tensión (kV)**
5	5	5	-1	0	1	84	3.0	377	144526	0	34.69
5	5	5	-1	0	1	53	4.0	328	48847	0	115.21
5	5	5	-1	0	1	22	4.0	94	106585	0	23.07
8	8	8	-3	0	3	26	5.5	146	103137	0	29.43
8	8	8	-3	0	3	26	3.0	467	130097	0	19.69
8	8	8	-3	0	3	35	3.0	81	103224	0	87.67
11	11	11	-1	0	1	56	5.5	148	92466	0	104.59
11	11	11	-1	0	1	14	4.0	81	128948	0	24.54
11	11	11	-1	0	1	38	6.0	1	40498	1	9433.73
11	11	11	-1	0	1	32	6.5	66	132818	0	34.19
14	14	14	-1	0	1	30	4.0	330	148007	0	26.25
14	14	14	-1	0	1	36	2.0	417	70709	0	203.89
14	14	14	-1	0	1	7	3.5	426	71680	0	25.14
14	14	14	-1	0	1	21	8.0	112	94621	0	36.44
17	17	17	-3	0	3	12	4.0	319	78217	0	46.82
17	17	17	-3	0	3	47	6.0	316	78665	0	120.53
17	17	17	-3	0	3	46	6.0	206	110840	0	79.47
5	7	9	0	0	0	19	2.5	185	81739	0	65.51
5	7	9	0	0	0	31	5.0	288	116289	0	23.95
5	7	9	0	0	0	26	3.5	166	50056	0	131.66
8	10	12	0	0	0	10	2.5	20	35702	1	2541.86
8	10	12	0	0	0	13	1.5	327	98577	0	52.52
8	10	12	0	0	0	30	3.0	453	66939	0	101.95
8	10	12	0	0	0	30	7.0	282	136151	0	16.40
11	13	15	0	0	0	25	2.5	215	84226	0	131.32
11	13	15	0	0	0	18	7.0	313	91809	0	24.96
11	13	15	0	0	0	71	1.5	477	119058	0	192.61
11	13	15	0	0	0	61	2.5	145	37554	0	1091.42

El entrenamiento de esta red neuronal queda reducido a los siguientes pasos

1) Se realiza un estudio previo con el objetivo de conseguir unas buenas condiciones iniciales para el estudio posterior de la pendiente de las funciones de transferencia. Se guardan los pesos y los umbrales que dan el mínimo error. Se comprueba que en general existe un error considerable en el cálculo de las salidas.

2) Ajuste de la pendiente de las funciones de transferencia. Se varían por separado las pendientes de las funciones de transferencia. Una variación en el valor de dichas pendientes disminuye notablemente el error conseguido. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.1 para la función lineal.

3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas, y se comprueba que esta estructura entrena correctamente, siendo los errores de cálculo de las salidas muy pequeños. La figura 6.26 muestra la arquitectura de la red, mientras que la figura 6.27 muestra los resultados del entrenamiento obtenidos con esta red. Se puede observar que el ajuste es similar al que se obtuvo con el método de Rusck. Por un lado, el error cometido en los valores calculados de las salidas que actúan como clasificador no supera en ningún caso el 1 %. En el cálculo de las tensiones, en más de un 90 % de los datos el error cometido no supera el 1 %.

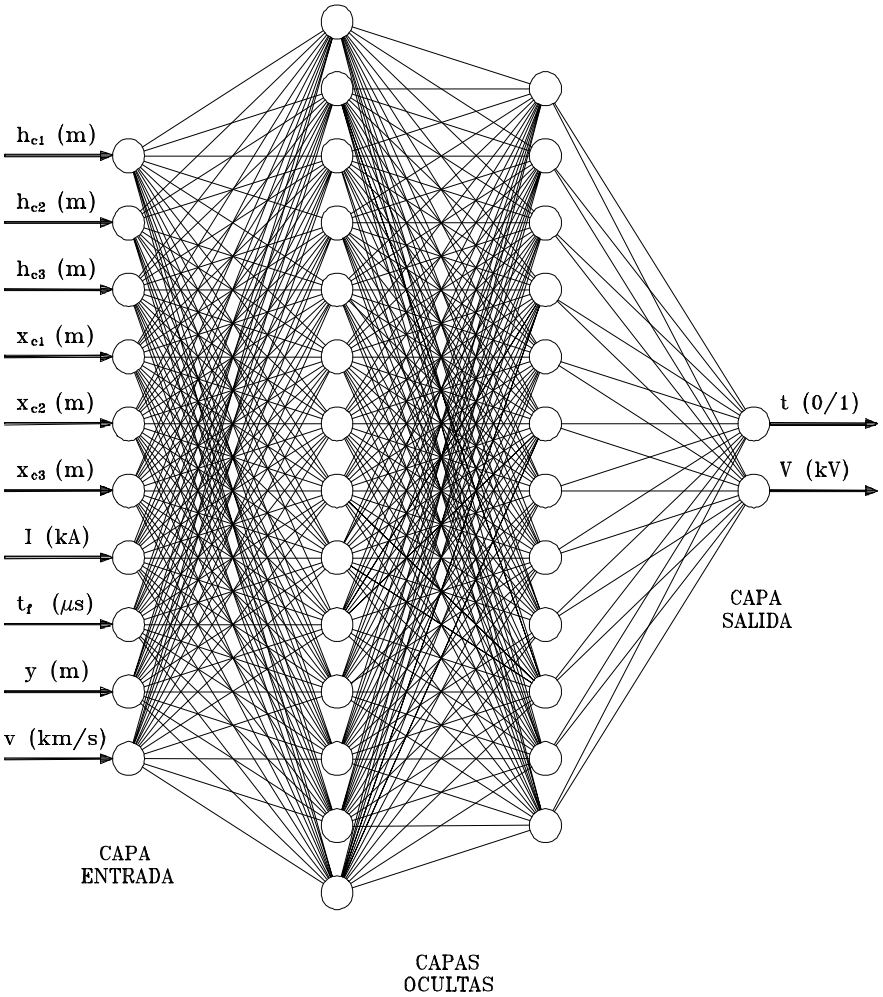

Figura 6.26. Arquitectura de la red neuronal (Método de Chowdhuri con líneas sin apantallar).

Validación

La validación de esta red neuronal se ha realizado con 6000 patrones que no han intervenido en el proceso de entrenamiento. Se han utilizado 1000 patrones para cada una de las configuraciones de línea mostradas en la Tabla 6.8.

Los gráficos de las figuras 6.28, 6.29, y 6.30 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Las conclusiones de este estudio son similares a las que se obtuvieron con el método de Rusck. En general el error cometido en el cálculo de tensiones se encuentra por debajo del 2 %, aunque cuando la red neuronal presenta confusión en la clasificación de descargas el error es mayor.

Tabla 6.8. Variables altura y distancia al eje de la línea.

	h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)
Línea horizontal	5	5	5	-1.5	0	1.5
	10	10	10	-2	0	2
	17	17	17	-3	0	3
Línea vertical	5	7	9	0	0	0
	10	12	14	0	0	0
	14	16	18	0	0	0

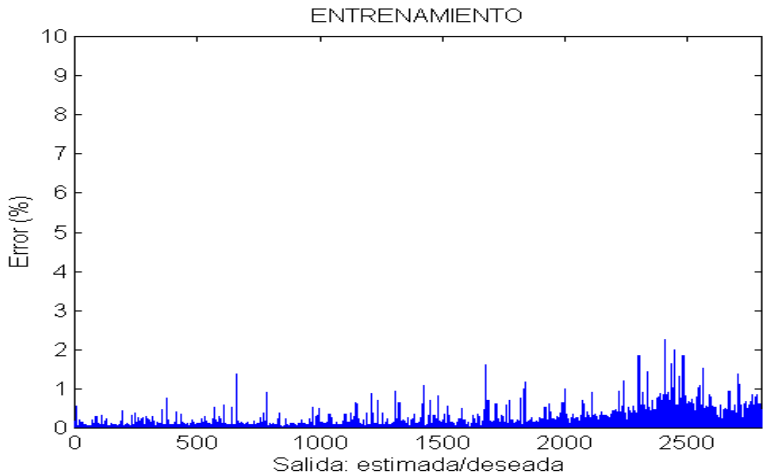

a. Error porcentual en el cálculo de sobretensiones.

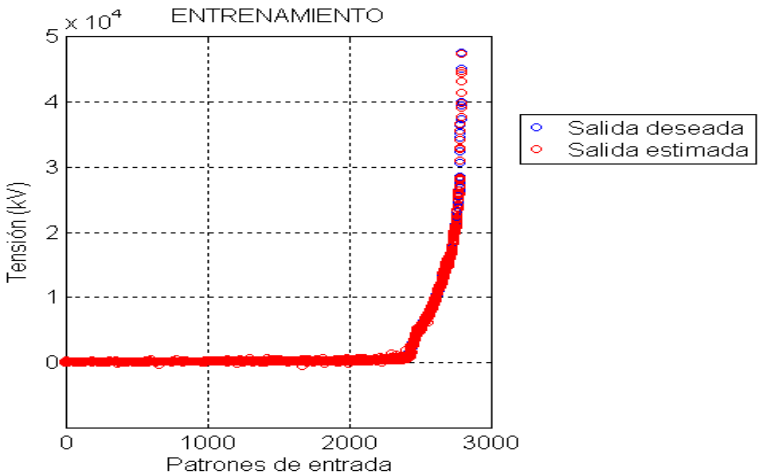

b. Ajuste de las salidas (tensiones).

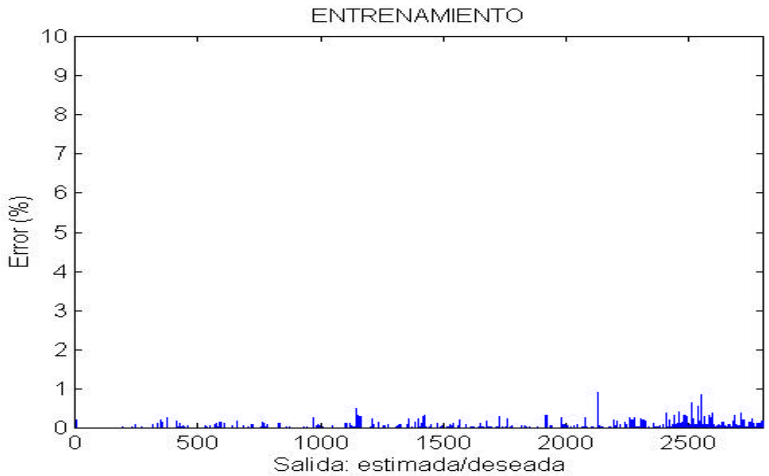

c. Error porcentual en la clasificación de descargas.

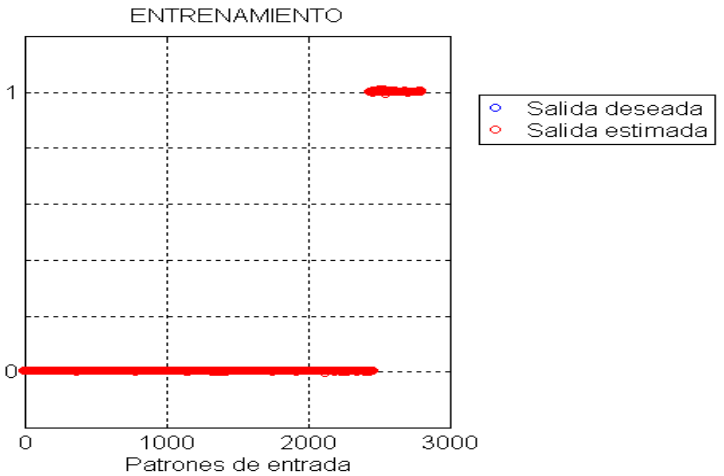

d. Ajuste del clasificador.

Figura 6.27. Entrenamiento de la red neuronal.

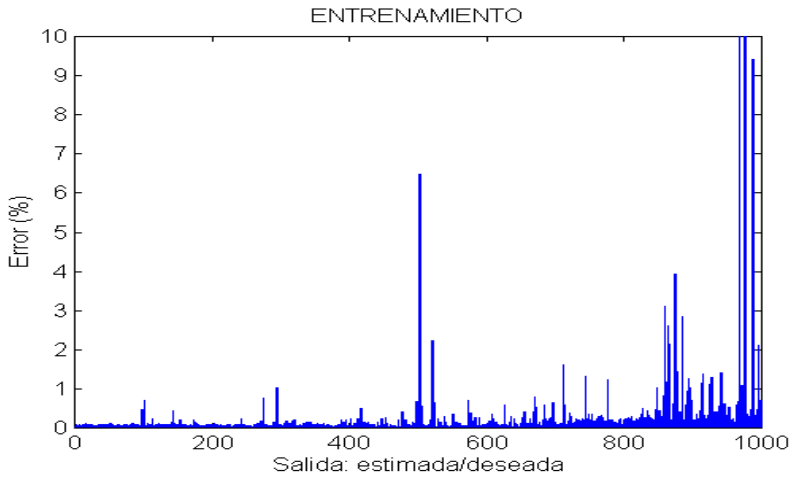

a. Error porcentual en el cálculo de sobretensiones.

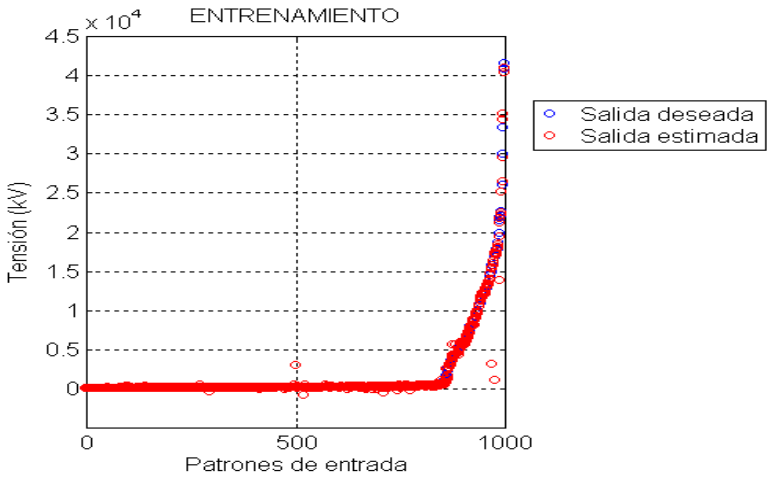

b. Ajuste de las salidas (tensiones).

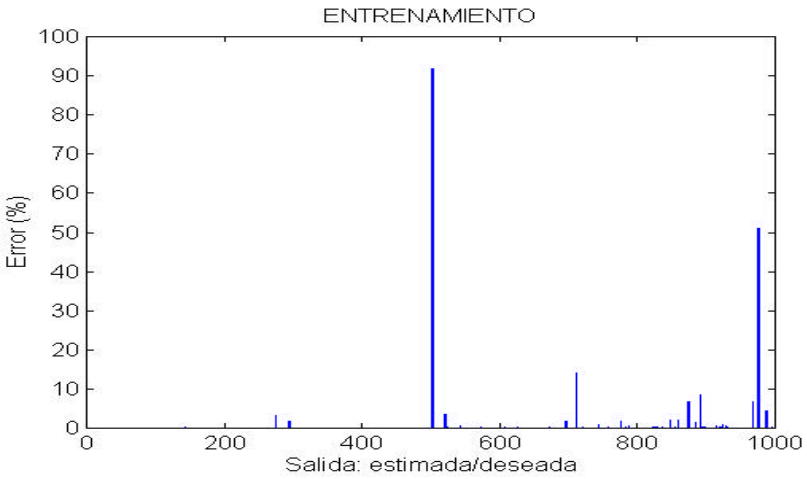

c. Error porcentual en la clasificación de descargas.

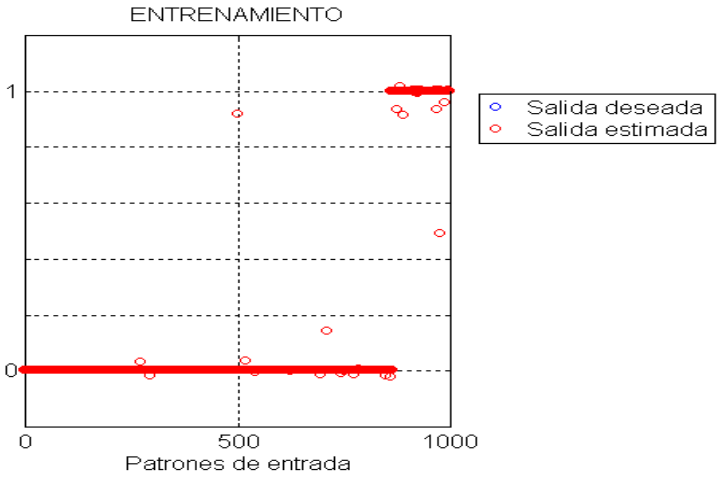

d. Ajuste del clasificador.

Figura 6.28. Validación de la red neuronal. Línea horizontal, altura = 10 m, distancia entre conductores más externos = 4 m.

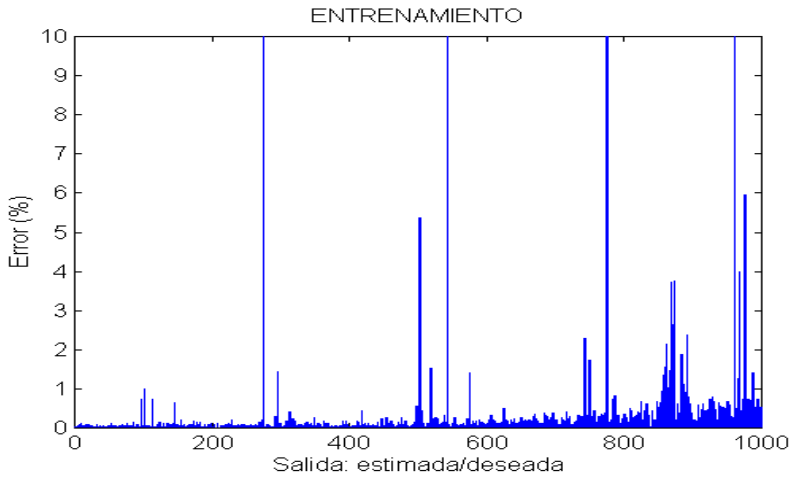

a. Error porcentual en el cálculo de sobretensiones.

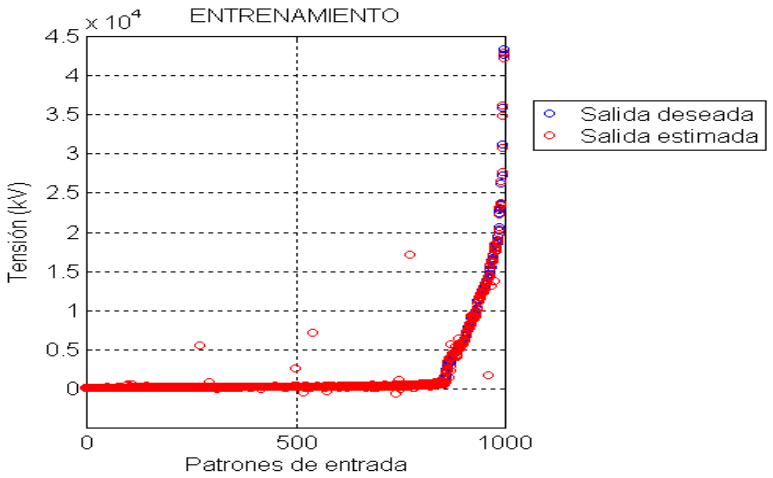

b. Ajuste de las salidas (tensiones).

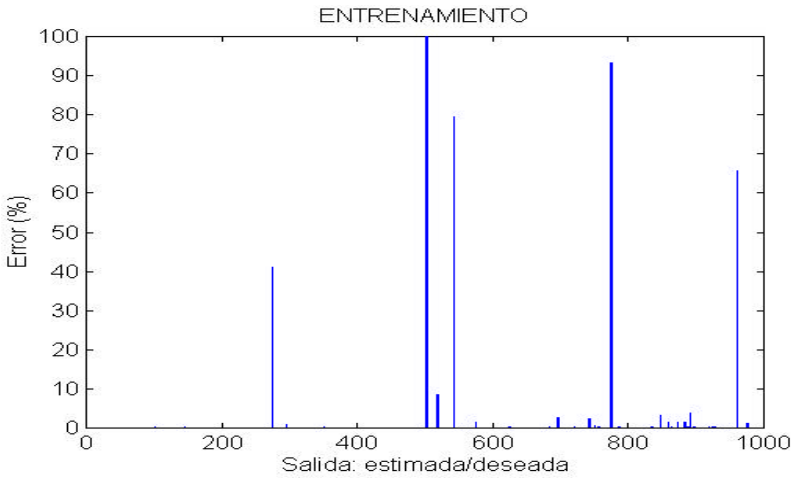

c. Error porcentual en la clasificación de descargas.

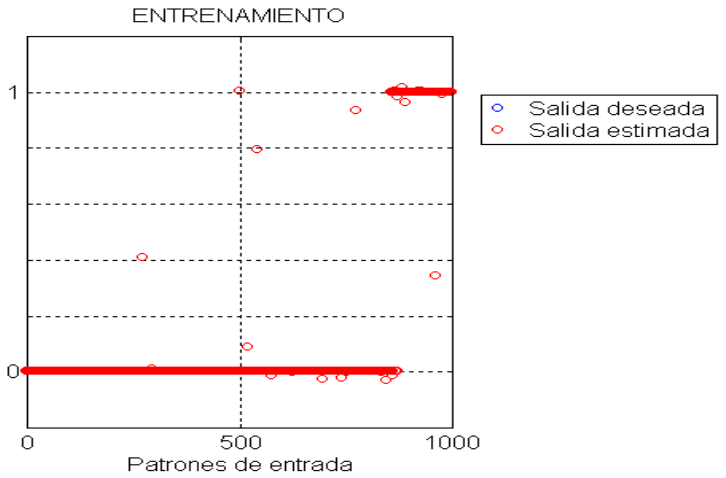

d. Ajuste del clasificador.

Figura 6.29. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m.

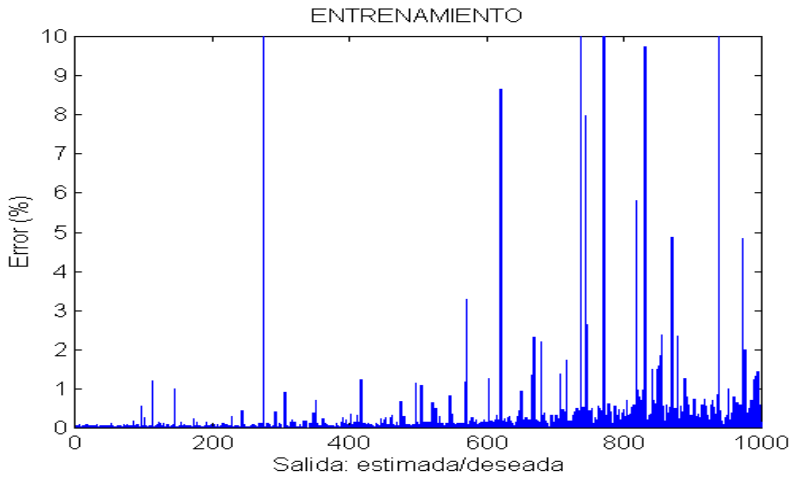

a. Error porcentual en el cálculo de sobretensiones.

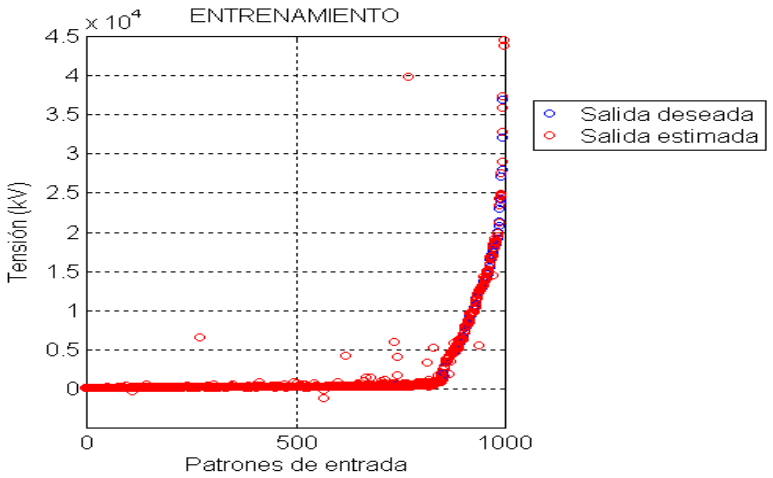

b. Ajuste de las salidas (tensiones).

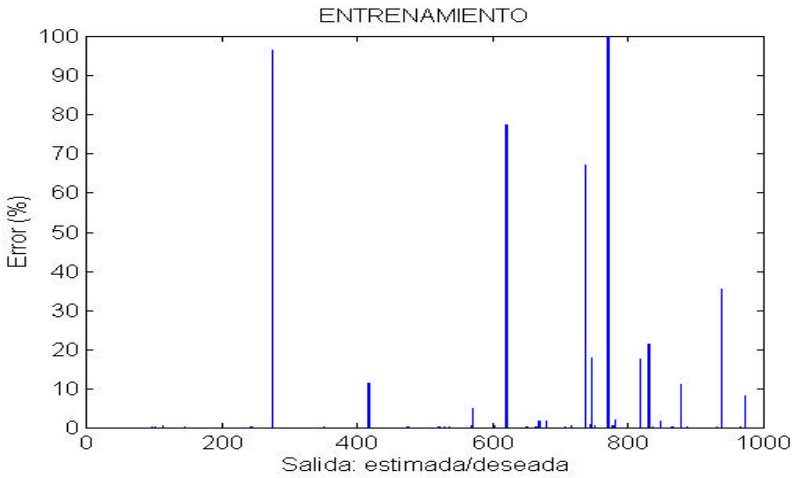

c. Error porcentual en la clasificación de descargas.

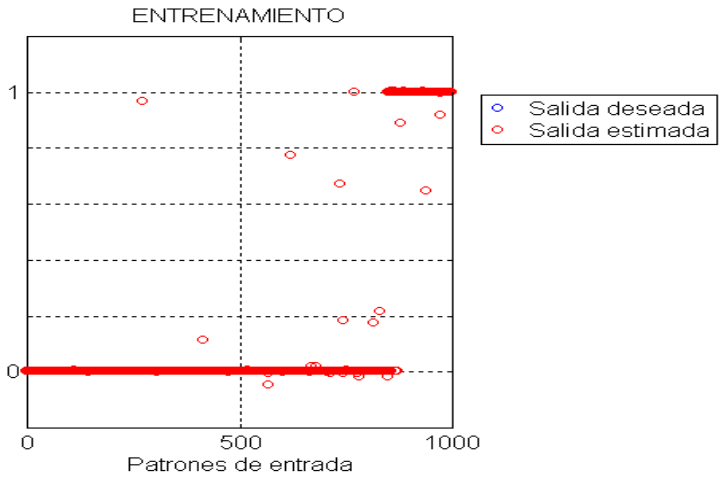

d. Ajuste del clasificador.

Figura 6.30. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m

6.3.4. Cálculo de sobretensiones en líneas con cable de tierra. Velocidad de retorno del rayo con distribución uniforme

6.3.4.1. Método de Rusck

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), altura del cable de tierra (variable h_{ct}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3}), resistencia de puesta a tierra de los postes (variable R)

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 8640 patrones diferentes calculados de forma aleatoria. Cada patrón esta formado por un valor para cada entrada (I,y,v,h_{c1},h_{c2},h_{c3}, h_{ct},x_{c1},x_{c2},x_{c3},R) y el correspondiente valor para cada salida (t,V). A continuación se comenta como se genera cada valor de las variables anteriores.

a) Intensidad

   La intensidad de la descarga se calcula siguiendo el procedimiento visto en el apartado 5.3.1 del capítulo 5.

b) Distancia perpendicular entre la línea y la descarga

   El valor de esta distancia se genera de forma aleatoria, entre 0 m y 500 m, considerando una distribución uniforme.

c) Velocidad de retorno del rayo

   El valor de la velocidad de retorno del rayo se genera de forma aleatoria, entre 30000 km/s y 150000 km/s, suponiendo una distribución uniforme.

d) Geometría de la línea

   Tanto para las líneas de tipo horizontal como las de tipo vertical se han utilizado las configuraciones comentadas en el apartado 6.3.3, ver figura 6.31. La única diferencia es que la red neuronal se ha entrenado con dos valores diferentes de distancias al eje en el caso de la línea vertical, 0.5 m y 1.5 m, respectivamente, en lugar de estar los conductores colocados sobre el eje de la línea. Esto ha sido así porque en una línea vertical la distancia al eje de los conductores es la distancia horizontal entre conductores y cable de tierra.

   El cable de tierra se encuentra situado sobre el eje de la línea, esto es $x_{ct} = 0$, y su altura dependerá de la altura de los conductores, aunque se han utilizado dos alturas diferentes del cable de tierra para cada altura diferente de la línea. Las Tablas 6.9 y 6.10 resumen las combinaciones adoptadas en el entrenamiento de la red neuronal.

Tabla 6.9. Variables altura de los conductores, altura del cable de tierra, distancia al eje de los conductores y resistencia de puesta a tierra. Línea horizontal.

h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)	h_{ct} (m)	R (W)
5	5	5	-1	0	1	6.5	10
5	5	5	-1	0	1	6.5	40
5	5	5	-1	0	1	6.5	70
5	5	5	-1	0	1	8.0	10
5	5	5	-1	0	1	8.0	40
5	5	5	-1	0	1	8.0	70
5	5	5	-3	0	3	6.5	10
5	5	5	-3	0	3	6.5	40
5	5	5	-3	0	3	6.5	70
5	5	5	-3	0	3	8.0	10
5	5	5	-3	0	3	8.0	40
5	5	5	-3	0	3	8.0	70
8	8	8	-1	0	1	9.5	10
8	8	8	-1	0	1	9.5	40
8	8	8	-1	0	1	9.5	70
8	8	8	-1	0	1	11.0	10
8	8	8	-1	0	1	11.0	40
8	8	8	-1	0	1	11.0	70
8	8	8	-3	0	3	9.5	10
8	8	8	-3	0	3	9.5	40
8	8	8	-3	0	3	9.5	70
8	8	8	-3	0	3	11.0	10
8	8	8	-3	0	3	11.0	40
8	8	8	-3	0	3	11.0	70
11	11	11	-1	0	1	12.5	10
11	11	11	-1	0	1	12.5	40
11	11	11	-1	0	1	12.5	70
11	11	11	-1	0	1	14.0	10
11	11	11	-1	0	1	14.0	40
11	11	11	-1	0	1	14.0	70
11	11	11	-3	0	3	12.5	10
11	11	11	-3	0	3	12.5	40
11	11	11	-3	0	3	12.5	70
11	11	11	-3	0	3	14.0	10
11	11	11	-3	0	3	14.0	40
11	11	11	-3	0	3	14.0	70
14	14	14	-1	0	1	15.5	10
14	14	14	-1	0	1	15.5	40
14	14	14	-1	0	1	15.5	70
14	14	14	-1	0	1	17.0	10
14	14	14	-1	0	1	17.0	40
14	14	14	-1	0	1	17.0	70
14	14	14	-3	0	3	15.5	10
14	14	14	-3	0	3	15.5	40
14	14	14	-3	0	3	15.5	70
14	14	14	-3	0	3	17.0	10
14	14	14	-3	0	3	17.0	40
14	14	14	-3	0	3	17.0	70
17	17	17	-1	0	1	18.5	10
17	17	17	-1	0	1	18.5	40
17	17	17	-1	0	1	18.5	70
17	17	17	-1	0	1	20.0	10
17	17	17	-1	0	1	20.0	40
17	17	17	-1	0	1	20.0	70
17	17	17	-3	0	3	18.5	10
17	17	17	-3	0	3	18.5	40
17	17	17	-3	0	3	18.5	70
17	17	17	-3	0	3	20.0	10
17	17	17	-3	0	3	20.0	40
17	17	17	-3	0	3	20.0	70

Tabla 6.10. Variables altura de los conductores, altura del cable de tierra, distancia al eje de los conductores y resistencia de puesta a tierra. Línea vertical.

h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)	h_{ct} (m)	R (Ω)
5	7	9	0.5	0.5	0.5	10.5	10
5	7	9	0.5	0.5	0.5	10.5	40
5	7	9	0.5	0.5	0.5	10.5	70
5	7	9	0.5	0.5	0.5	12.0	10
5	7	9	0.5	0.5	0.5	12.0	40
5	7	9	0.5	0.5	0.5	12.0	70
5	7	9	1.5	1.5	1.5	10.5	10
5	7	9	1.5	1.5	1.5	10.5	40
5	7	9	1.5	1.5	1.5	10.5	70
5	7	9	1.5	1.5	1.5	12.0	10
5	7	9	1.5	1.5	1.5	12.0	40
5	7	9	1.5	1.5	1.5	12.0	70
8	10	12	0.5	0.5	0.5	13.5	10
8	10	12	0.5	0.5	0.5	13.5	40
8	10	12	0.5	0.5	0.5	13.5	70
8	10	12	0.5	0.5	0.5	15.0	10
8	10	12	0.5	0.5	0.5	15.0	40
8	10	12	0.5	0.5	0.5	15.0	70
8	10	12	1.5	1.5	1.5	13.5	10
8	10	12	1.5	1.5	1.5	13.5	40
8	10	12	1.5	1.5	1.5	13.5	70
8	10	12	1.5	1.5	1.5	15.0	10
8	10	12	1.5	1.5	1.5	15.0	40
8	10	12	1.5	1.5	1.5	15.0	70
11	13	15	0.5	0.5	0.5	16.5	10
11	13	15	0.5	0.5	0.5	16.5	40
11	13	15	0.5	0.5	0.5	16.5	70
11	13	15	0.5	0.5	0.5	18.0	10
11	13	15	0.5	0.5	0.5	18.0	40
11	13	15	0.5	0.5	0.5	18.0	70
11	13	15	1.5	1.5	1.5	16.5	10
11	13	15	1.5	1.5	1.5	16.5	40
11	13	15	1.5	1.5	1.5	16.5	70
11	13	15	1.5	1.5	1.5	18.0	10
11	13	15	1.5	1.5	1.5	18.0	40
11	13	15	1.5	1.5	1.5	18.0	70
14	16	18	0.5	0.5	0.5	19.5	10
14	16	18	0.5	0.5	0.5	19.5	40
14	16	18	0.5	0.5	0.5	19.5	70
14	16	18	0.5	0.5	0.5	21.0	10
14	16	18	0.5	0.5	0.5	21.0	40
14	16	18	0.5	0.5	0.5	21.0	70
14	16	18	1.5	1.5	1.5	19.5	10
14	16	18	1.5	1.5	1.5	19.5	40
14	16	18	1.5	1.5	1.5	19.5	70
14	16	18	1.5	1.5	1.5	21.0	10
14	16	18	1.5	1.5	1.5	21.0	40
14	16	18	1.5	1.5	1.5	21.0	70

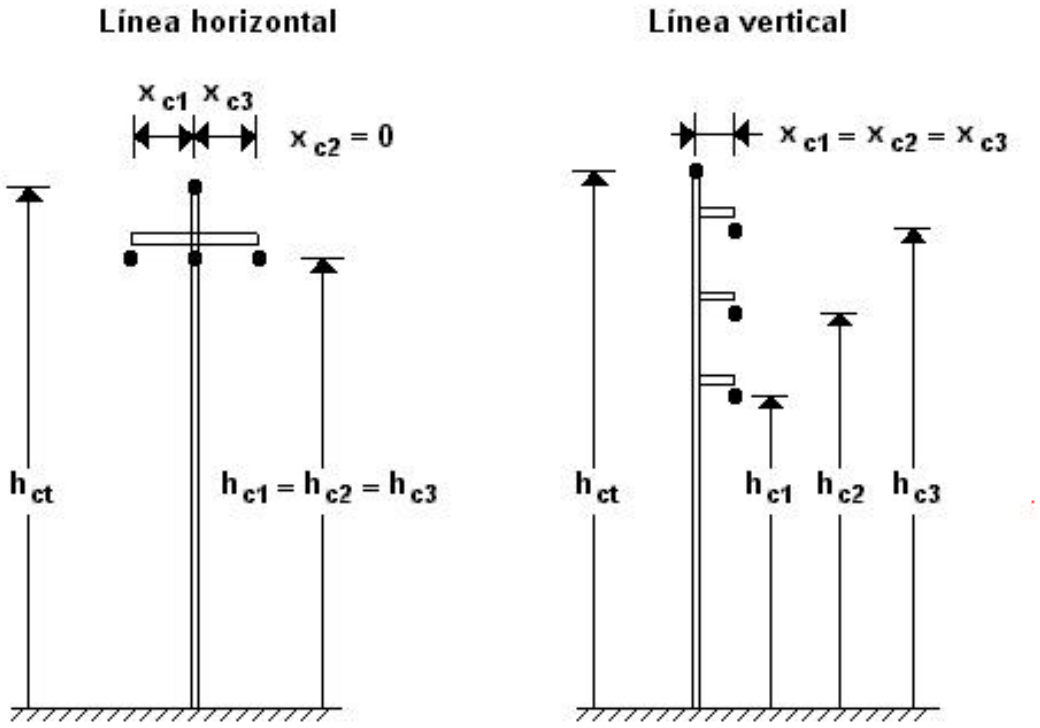

Figura 6.31. Geometría de la línea.

e) Resistencia de puesta a tierra

Se han utilizado tres valores constantes con cada configuración de línea diferente, 10 Ω, 40 Ω y 70 Ω, respectivamente, ver Tablas 6.9 y 6.10.

f) Tipo de descarga

Al igual que en los apartados anteriores, se utiliza el Modelo Electrogeométrico para saber si una descarga, caracterizada por los parámetros que componen la entrada de la red neuronal ($I,y,v,h_{c1},h_{c2},h_{c3},h_{ct},x_{c1},x_{c2},x_{c3},R$), es directa al cable de tierra (t = 2), directa a los conductores de fase (t = 1) o indirecta (t = 0).

g) Sobretensión que aparece en la línea

Se utiliza la expresión (4.17) para calcular la tensión que aparece en la línea si la descarga es directa al cable de tierra, la expresión (4.6) si la descarga es directa a los conductores de fase, y la expresión (4.20) si la descarga es directa a tierra, esta última corregida por el factor de apantallamiento, ver expresión (4.26).

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en el apartado 6.3.3, método de Chowdhuri, verificándose de esta manera que la estructura final obtenida cuando la línea no tenía instalado un cable de tierra es también adecuada en este estudio. La Tabla 6.11 muestra una parte de los datos utilizados en el entrenamiento.

Tabla 6.11. Datos del entrenamiento.

ENTRADAS											SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Altura cable de tierra (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Resistencia puesta a tierra (W)**	**Intensidad (kA)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**Tipo descarga**	**Tensión (kV)**
5	5	5	6.5	-1	0	1	10	38	27	67302	2	217.06
5	5	5	6.5	-1	0	1	10	46	176	82717	0	32.36
5	5	5	6.5	-1	0	1	10	50	484	105755	0	13.45
8	8	8	9.5	-1	0	1	10	42	144	57624	0	53.68
8	8	8	9.5	-1	0	1	10	70	50	102486	2	385.25
8	8	8	9.5	-1	0	1	10	52	114	44807	0	82.67
11	11	11	12.5	-1	0	1	70	22	419	79720	0	14.68
11	11	11	12.5	-1	0	1	70	54	312	39058	0	45.40
11	11	11	12.5	-1	0	1	70	29	65	58285	0	120.15
14	14	14	15.5	-1	0	1	70	15	269	117063	0	21.61
14	14	14	15.5	-1	0	1	70	6	486	65281	0	3.95
14	14	14	15.5	-1	0	1	70	18	392	110143	0	17.58
14	14	14	15.5	-1	0	1	70	25	456	52464	0	18.23
17	17	17	20.0	-3	0	3	40	23	320	110411	0	33.25
17	17	17	20.0	-3	0	3	40	33	359	82567	0	40.44
17	17	17	20.0	-3	0	3	40	28	325	105604	0	40.29
5	7	9	12.0	0.5	0.5	0.5	10	122	125	83891	0	229.72
5	7	9	12.0	0.5	0.5	0.5	10	24	262	44443	0	19.82
5	7	9	12.0	0.5	0.5	0.5	10	59	250	81682	0	54.80
8	10	12	13.5	1.5	1.5	1.5	40	31	162	69564	0	55.04
8	10	12	13.5	1.5	1.5	1.5	40	18	141	88791	0	38.93
8	10	12	13.5	1.5	1.5	1.5	40	36	145	115639	0	78.91
11	13	15	18.0	0.5	0.5	0.5	70	19	455	35518	0	15.01
11	13	15	18.0	0.5	0.5	0.5	70	29	348	131650	0	37.63
11	13	15	18.0	0.5	0.5	0.5	70	40	399	125241	0	44.07
14	16	18	21.0	0.5	0.5	0.5	40	95	137	87428	0	331.19
14	16	18	21.0	0.5	0.5	0.5	40	23	273	47980	0	36.85
14	16	18	21.0	0.5	0.5	0.5	40	55	261	85219	0	99.70

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento β=0.9.

El entrenamiento de esta red neuronal consta de los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.

2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.3 para la función lineal.

3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.32 muestra la arquitectura de la red, mientras que la figura 6.33 muestra los resultados del entrenamiento obtenidos con esta red. Se puede observar que el ajuste es similar al que se obtuvo en el apartado 6.3.3, con línea sin cable de tierra. Tanto en el clasificador como en el cálculo de las tensiones en más de un 90 % de los datos el error cometido no supera el 5 %.

Validación

La validación de esta red neuronal se ha realizado con 6000 patrones que no han intervenido en el proceso de entrenamiento. Se han utilizado 1000 patrones para cada configuración de línea, ver Tabla 6.12.

Los gráficos de las figuras 6.34, 6.35, y 6.36 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Se puede observar que en la mayoría de los casos el error cometido en el cálculo de sobretensiones no supera el 3%. Además, en más del 99 % de los casos la red neuronal no presenta confusiones al clasificar las descargas.

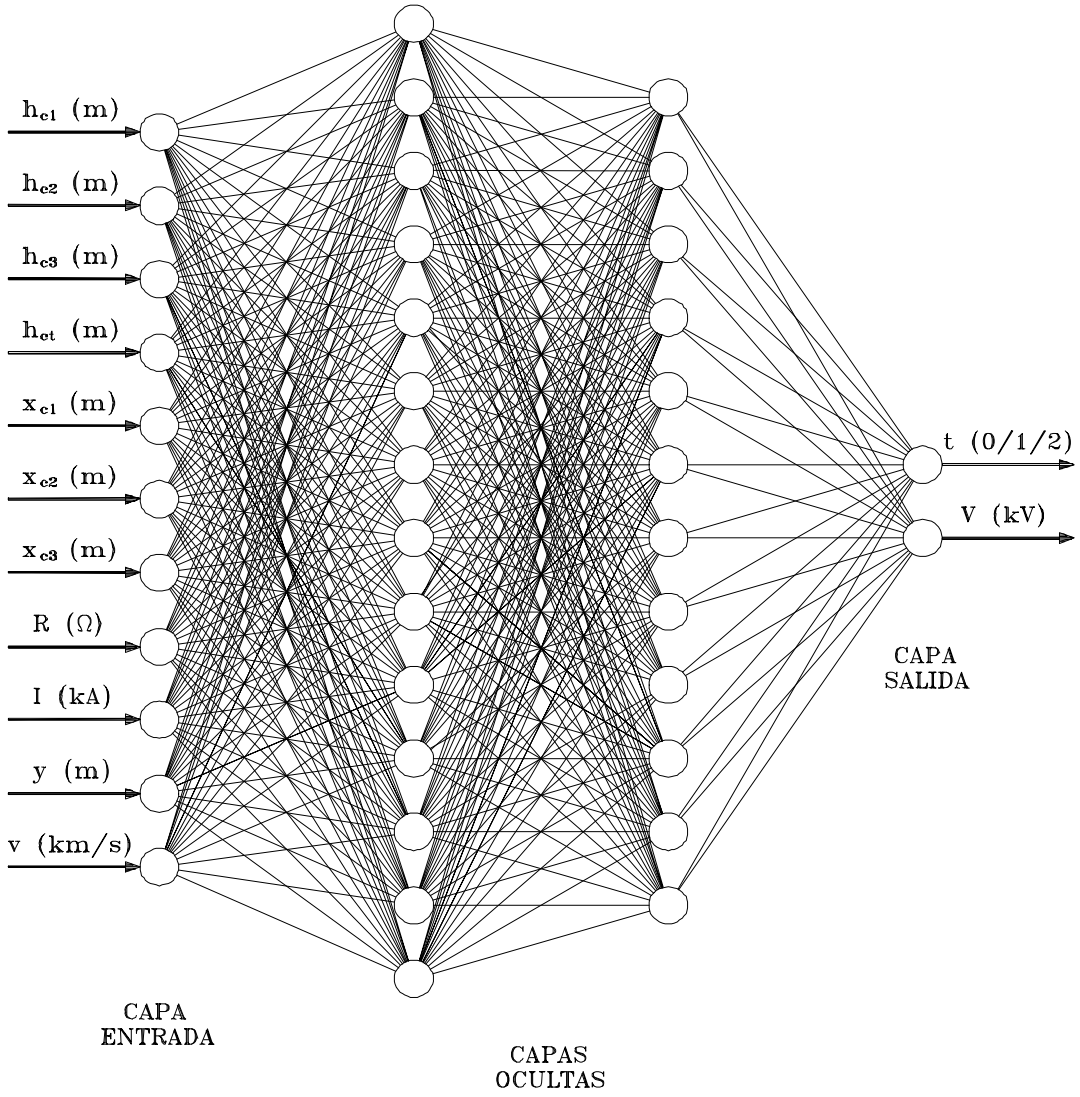

Figura 6.32. Arquitectura de la red neuronal (Método de Rusck con líneas apantalladas).

Tabla 6.12. Variables altura de los conductores, altura del cable de tierra, distancia al eje de los conductores y resistencia de puesta a tierra.

	h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)	h_{ct} (m)	R (W)
Línea horizontal	5	5	5	-1.5	0	1.5	6.5	30
	10	10	10	-2	0	2	11.5	50
	17	17	17	-3	0	3	18.5	10
Línea vertical	5	7	9	1	1	1	10.5	20
	10	12	14	1	1	1	15.5	50
	14	16	18	1.5	1.5	1.5	19.5	70

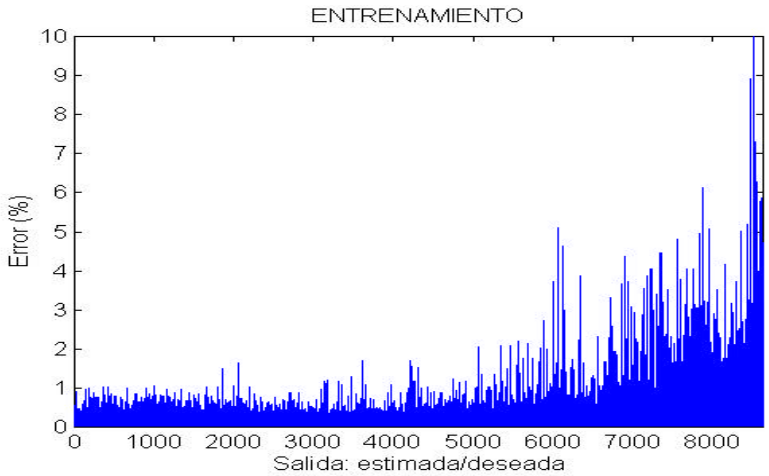

a. Error porcentual en el cálculo de sobretensiones.

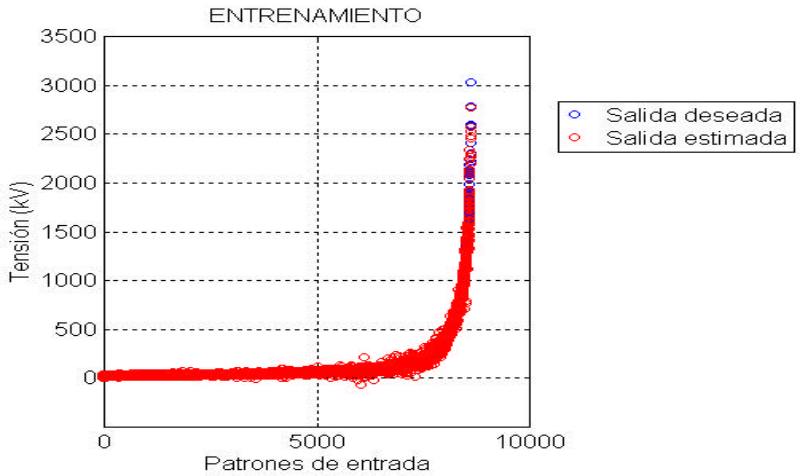

b. Ajuste de las salidas (tensiones).

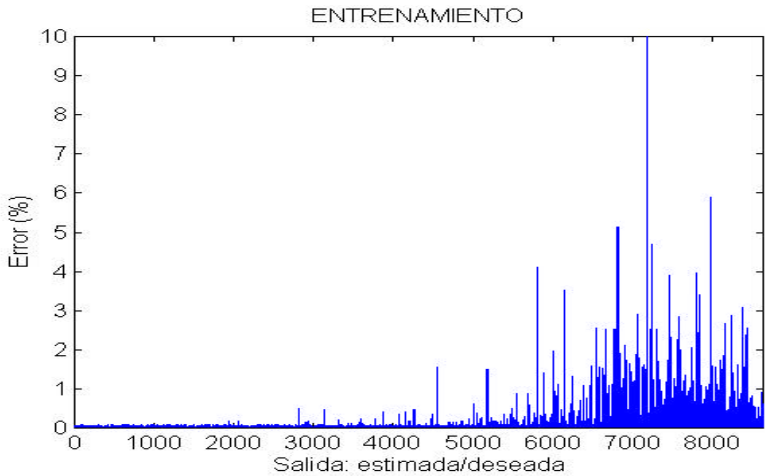

c. Error porcentual en la clasificación de descargas.

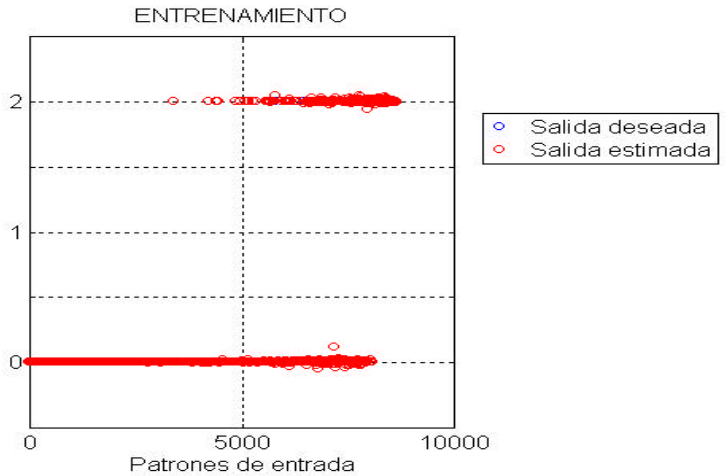

d. Ajuste del clasificador.

Figura 6.33. Entrenamiento de la red neuronal.

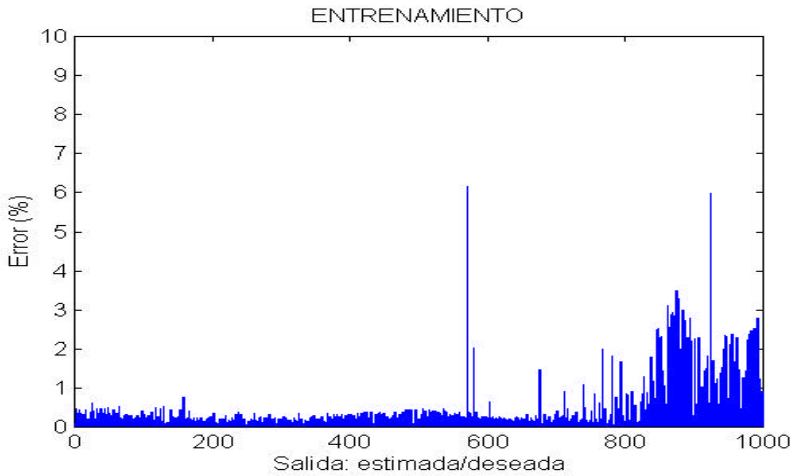

a. Error porcentual en el cálculo de sobretensiones.

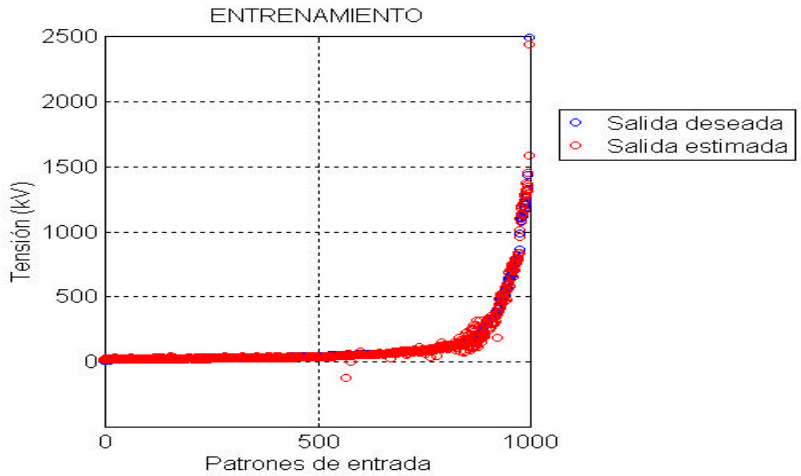

b. Ajuste de las salidas (tensiones).

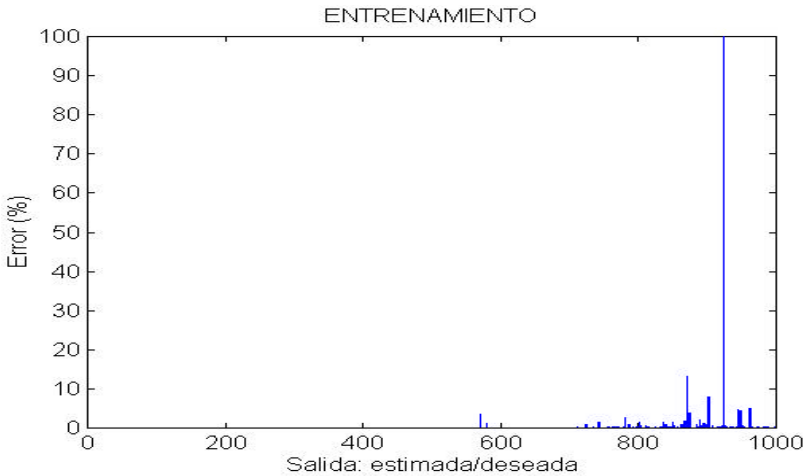

c. Error porcentual en la clasificación de descargas.

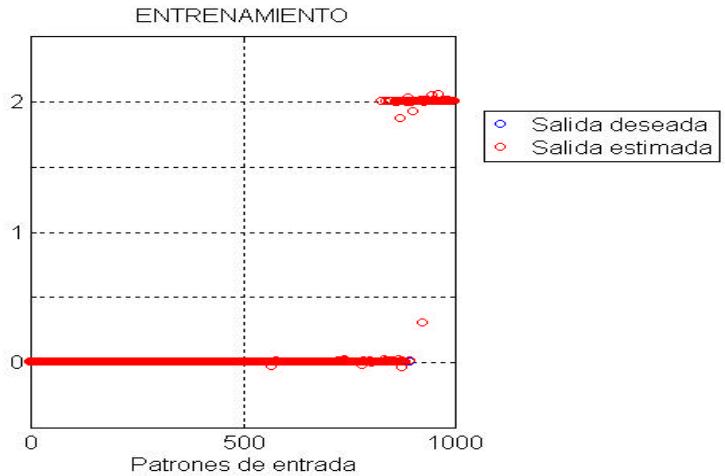

d. Ajuste del clasificador.

Figura 6.34. Validación de la red neuronal. Línea horizontal, altura conductores = 10 m, distancia entre conductores más externos = 4 m, altura cable de tierra = 11.5 m, resistencia de puesta a tierra = 50 Ω.

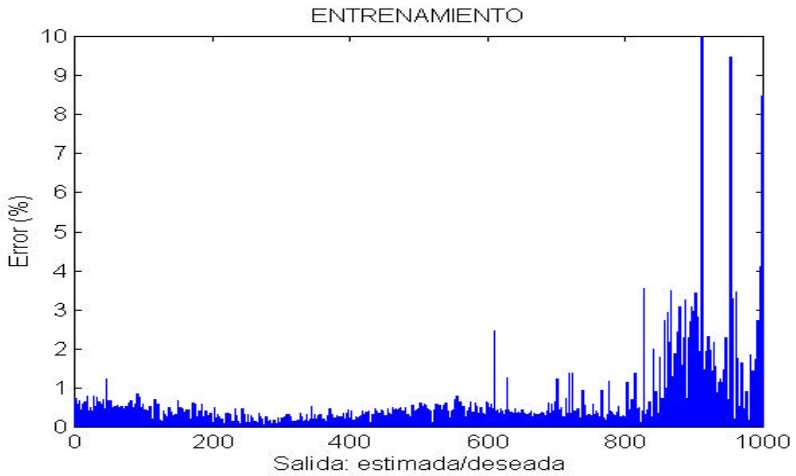

a. Error porcentual en el cálculo de sobretensiones.

b. Ajuste de las salidas (tensiones).

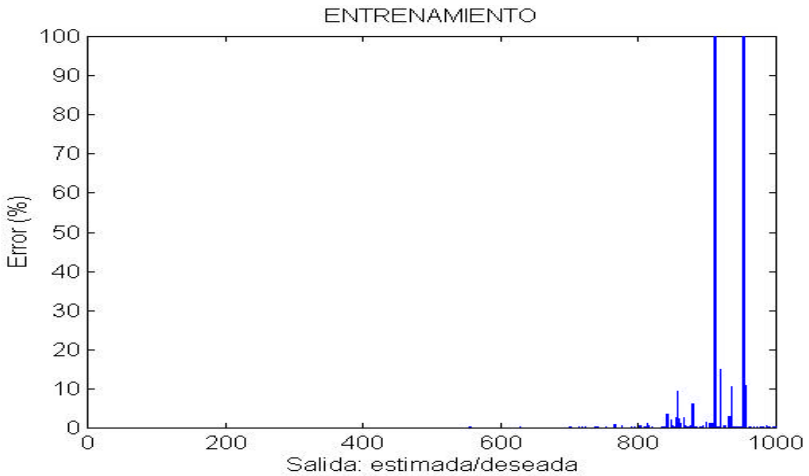

c. Error porcentual en la clasificación de descargas.

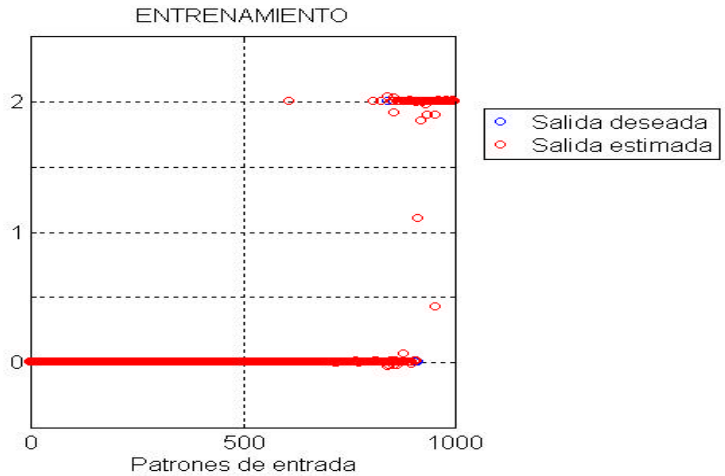

d. Ajuste del clasificador.

Figura 6.35. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m, distancia horizontal conductores - cable de tierra = 1 m, altura cable de tierra = 15.5 m, resistencia de puesta a tierra = 50 Ω.

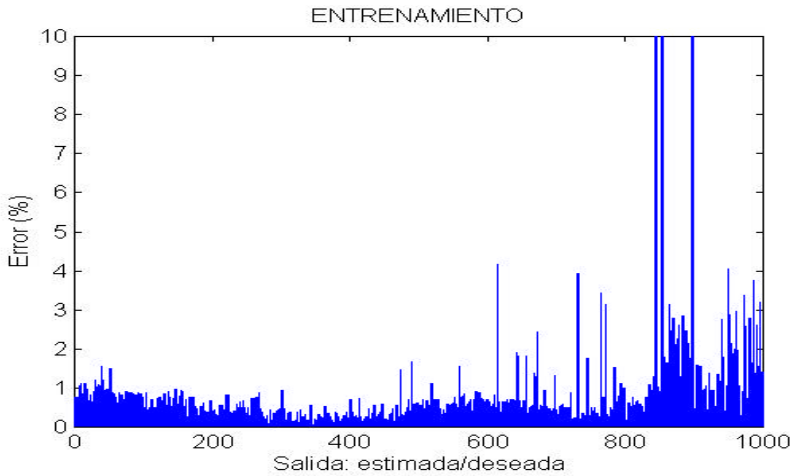

a. Error porcentual en el cálculo de sobretensiones.

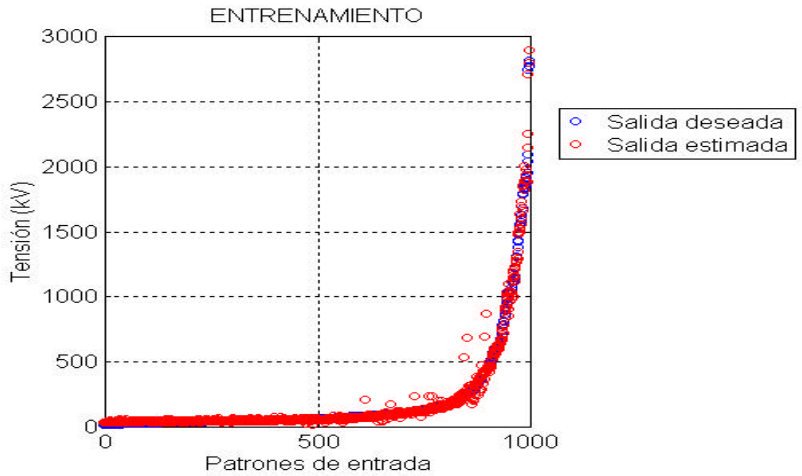

b. Ajuste de las salidas (tensiones).

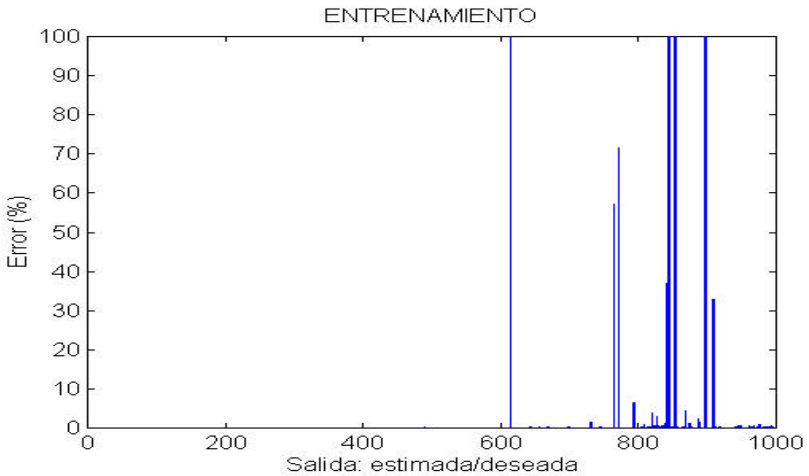

c. Error porcentual en la clasificación de descargas.

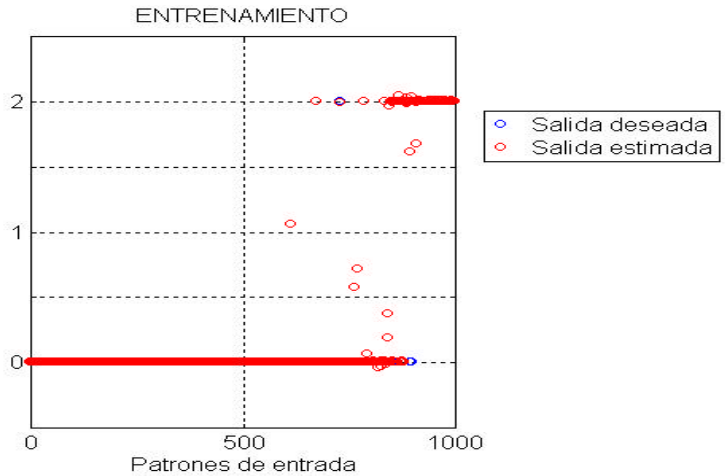

d. Ajuste del clasificador.

Figura 6.36. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m, distancia horizontal conductores - cable de tierra = 1.5 m, altura cable de tierra = 19.5 m, resistencia de puesta a tierra = 70 Ω.

6.3.4.2. Método de Chowdhuri

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), tiempo de frente de la onda de corriente del rayo (variable t_f), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), altura del cable de tierra (variable h_{ct}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3}), resistencia de puesta a tierra de los postes (variable R)

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

Este estudio se ha realizado de manera idéntica al anterior, método de Rusck. La única diferencia es que con el método de Chowdhuri la red neuronal tiene una entrada más, el tiempo de frente, cuyos valores se han generado siguiendo el procedimiento visto en el apartado 5.3.1 del capítulo 5.

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en los apartados anteriores. La Tabla 6.13 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente

- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)

- tasa de aprendizaje variable, $\alpha_0=0.25$, $\alpha_i=1.01$, $\alpha_d=0.6$

- momento $\beta=0.9$.

El entrenamiento de esta red neuronal tiene los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.

2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.3 para la función lineal.

3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.37 muestra la arquitectura de la red, mientras que la figura 6.38 muestra los resultados del entrenamiento obtenidos con esta red. Aunque los resultados del entrenamiento han sido algo peores que con el método de Rusck, se puede observar que en general el error cometido en las dos salidas, clasificador y cálculo de tensiones, no supera el 5 %.

Tabla 6.13. Datos del entrenamiento.

ENTRADAS												SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Altura cable de tierra (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Resistencia puesta a tierra (W)**	**Intensidad (kA)**	**Tiempo de frente (ms)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**Tipo descarga**	**Tensión (kV)**
5	5	5	8.0	-3	0	3	70	29	9.0	377	76350	0	12.30
5	5	5	8.0	-3	0	3	70	136	3.0	147	31777	0	776.40
5	5	5	8.0	-3	0	3	70	66	3.5	161	61855	0	135.40
8	8	8	9.5	-1	0	1	10	52	2.0	432	92757	0	83.52
8	8	8	11.0	-1	0	1	10	18	4.5	488	46634	0	37.39
8	8	8	11.0	-1	0	1	40	11	6.5	132	62081	0	18.09
11	11	11	12.5	-1	0	1	40	92	9.0	169	61182	0	134.33
11	11	11	12.5	-3	0	3	10	44	2.0	171	102868	0	144.10
11	11	11	12.5	-3	0	3	10	42	2.0	14	136539	2	243.13
14	14	14	15.5	-1	0	1	40	18	5.0	411	61905	0	41.02
14	14	14	15.5	-1	0	1	40	30	6.5	463	48117	0	70.39
14	14	14	17.0	-1	0	1	70	34	3.0	303	86004	0	97.36
14	14	14	17.0	-1	0	1	70	17	3.5	196	79542	0	54.32
17	17	17	20.0	-1	0	1	40	33	1.5	358	100006	0	143.15
17	17	17	20.0	-1	0	1	40	22	9.0	486	61462	0	33.30
17	17	17	20.0	-1	0	1	40	10	4.0	269	69497	0	37.26
5	7	9	10.5	1.5	1.5	1.5	40	23	10.5	251	33577	0	42.74
5	7	9	12.0	1.5	1.5	1.5	40	21	9.0	418	133333	0	4.28
5	7	9	12.0	1.5	1.5	1.5	70	68	6.0	115	82608	0	89.01
8	10	12	15.0	0.5	0.5	0.5	10	30	2.0	129	141703	0	57.09
8	10	12	15.0	0.5	0.5	0.5	10	150	6.0	95	38035	2	976.40
8	10	12	15.0	0.5	0.5	0.5	10	9	2.0	485	82897	0	22.21
11	13	15	16.5	0.5	0.5	0.5	40	59	1.5	279	109728	0	206.35
11	13	15	16.5	0.5	0.5	0.5	40	20	5.5	205	97807	0	27.84
11	13	15	18.0	0.5	0.5	0.5	40	22	1.5	394	78116	0	103.72
14	16	18	21.0	1.5	1.5	1.5	70	78	5.5	265	50988	0	326.07
14	16	18	21.0	1.5	1.5	1.5	70	142	8.0	450	57135	0	279.95
14	16	18	21.0	1.5	1.5	1.5	70	56	2.5	362	56223	0	364.64

Validación

La validación de esta red neuronal se ha realizado con 6000 patrones que no han intervenido en el proceso de entrenamiento. Se han utilizado las mismas 6 configuraciones de línea que se encuentran definidas en la Tabla 6.12.

Los gráficos de las figuras 6.39, 6.40, y 6.41 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Los resultados han sido similares a los obtenidos con el método de Rusck para líneas apantalladas, aunque ahora la red neuronal es algo más compleja. Los gráficos apenas muestran confusión por parte de la red neuronal en la clasificación de descargas, y además, en general el error cometido en el cálculo de las tensiones es inferior al 3 %.

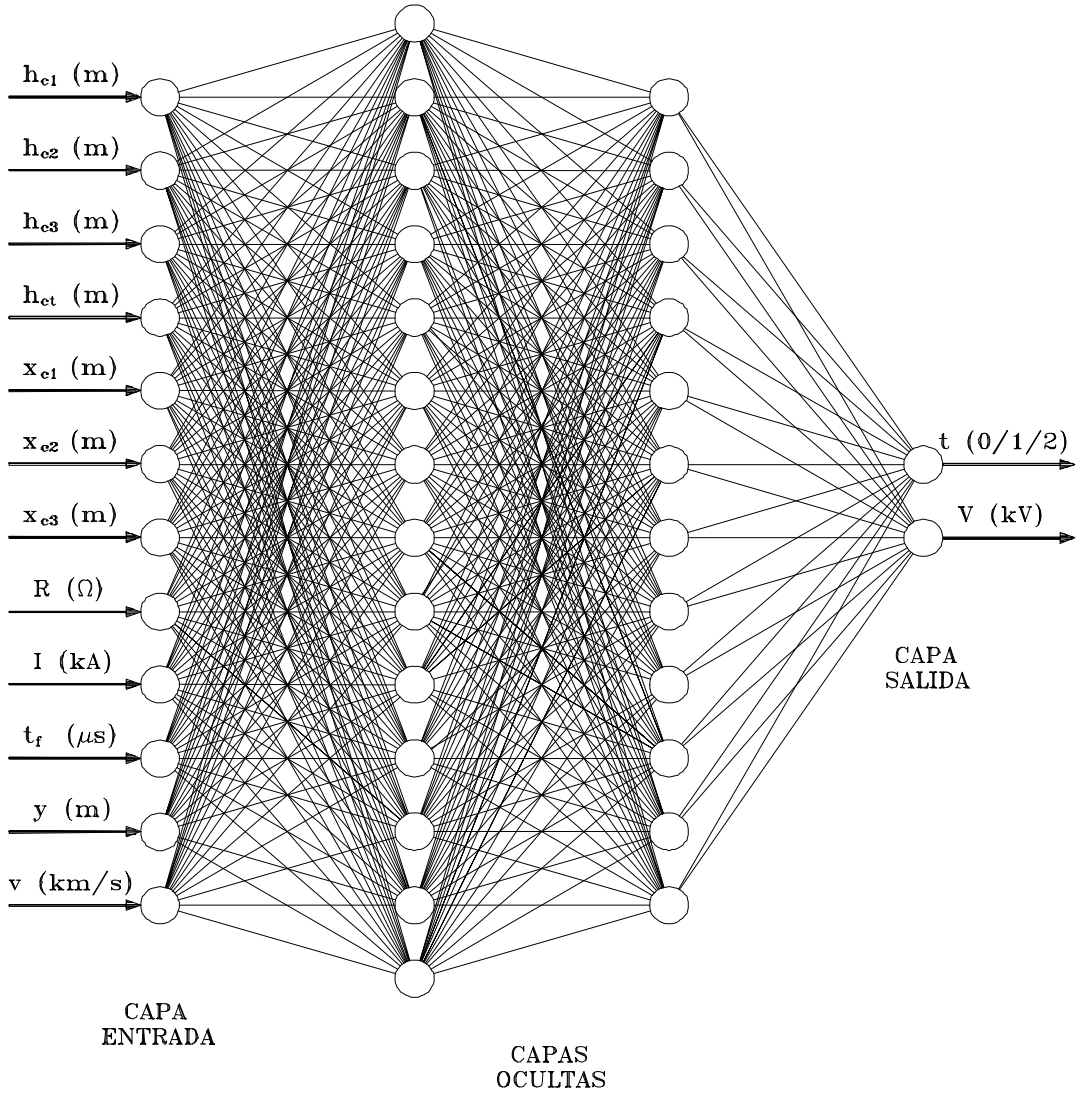

Figura 6.37. Arquitectura de la red neuronal (Método de Chowdhuri con líneas apantalladas).

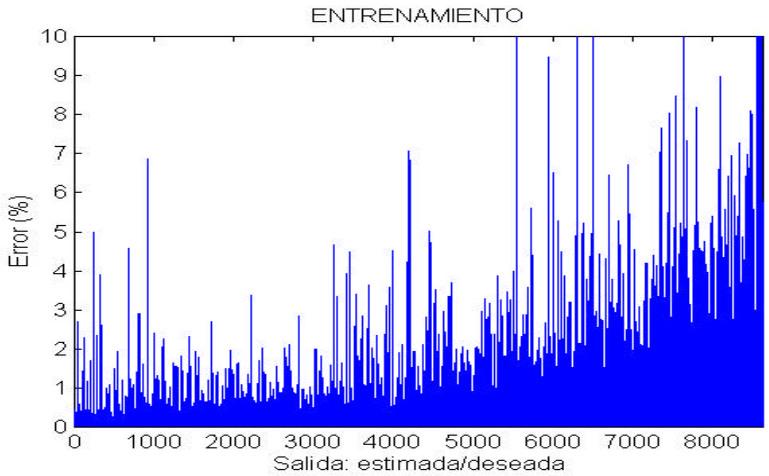

a. Error porcentual en el cálculo de sobretensiones.

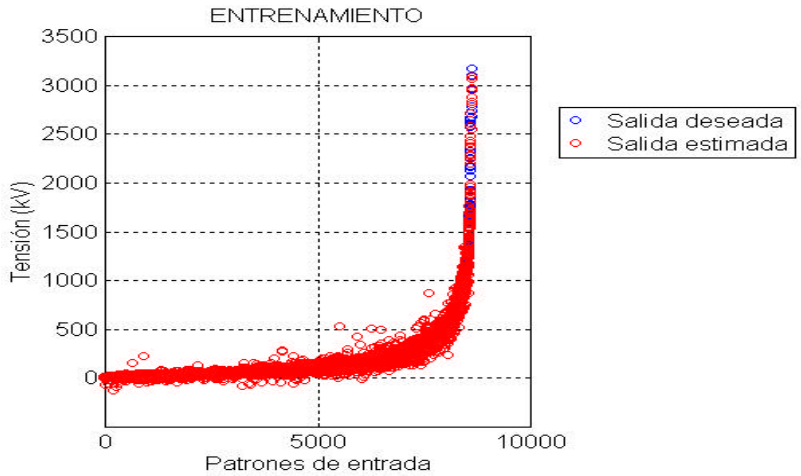

b. Ajuste de las salidas (tensiones).

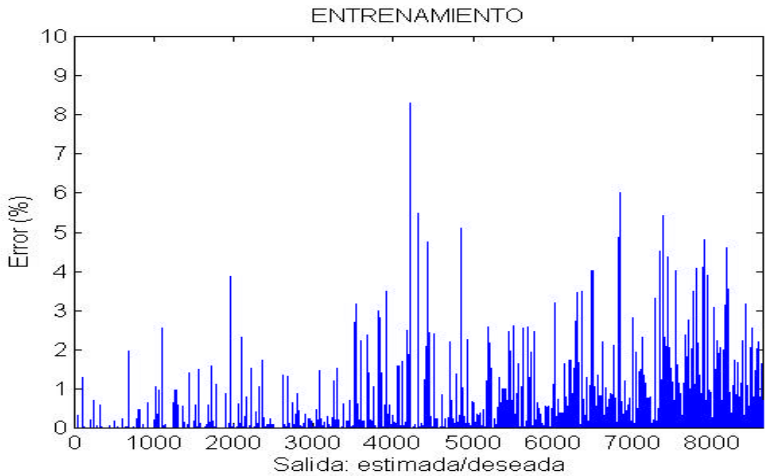

c. Error porcentual en la clasificación de descargas.

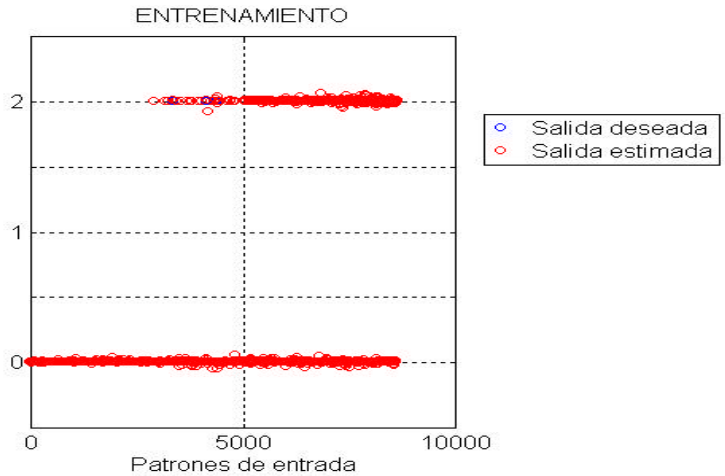

d. Ajuste del clasificador.

Figura 6.38. Entrenamiento de la red neuronal.

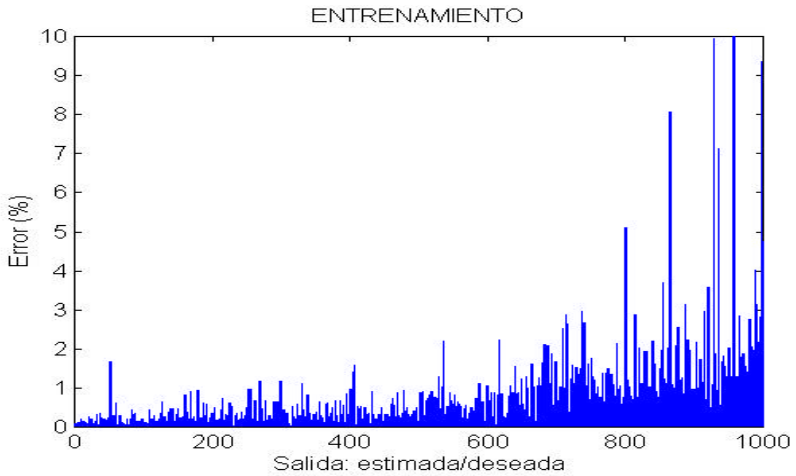

a. Error porcentual en el cálculo de sobretensiones.

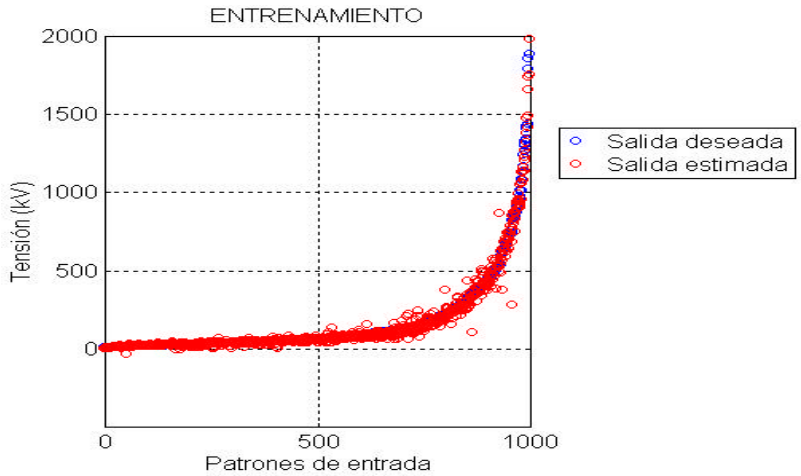

b. Ajuste de las salidas (tensiones).

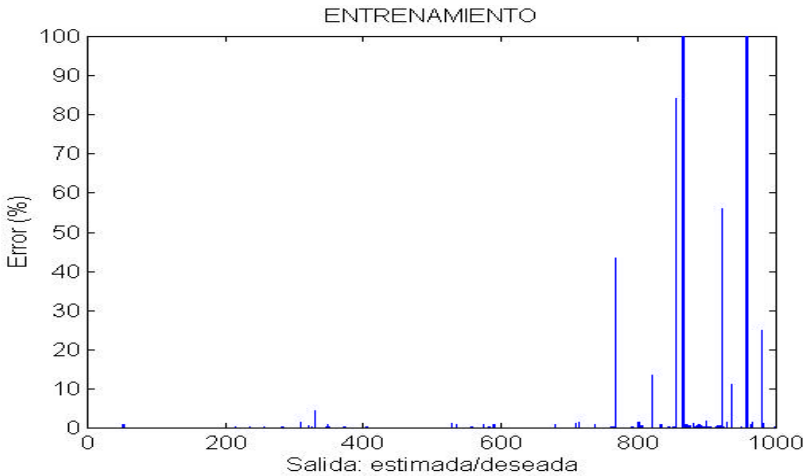

c. Error porcentual en la clasificación de descargas.

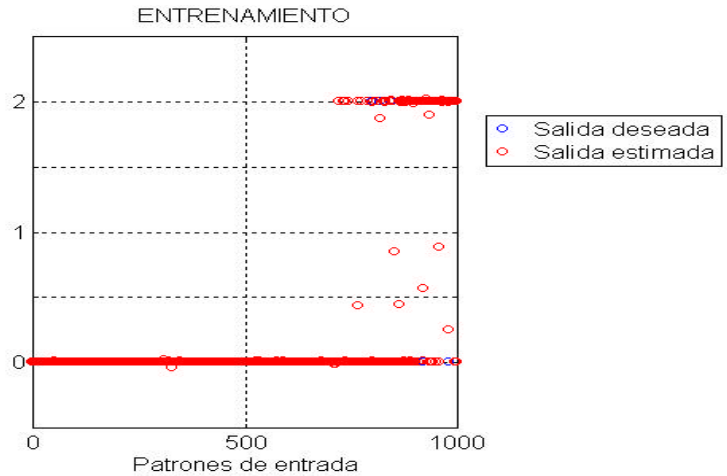

d. Ajuste del clasificador.

Figura 6.39. Validación de la red neuronal. Línea horizontal, altura conductores = 10 m, distancia entre conductores más externos = 4 m, altura cable de tierra = 11.5 m, resistencia de puesta a tierra = 50 Ω.

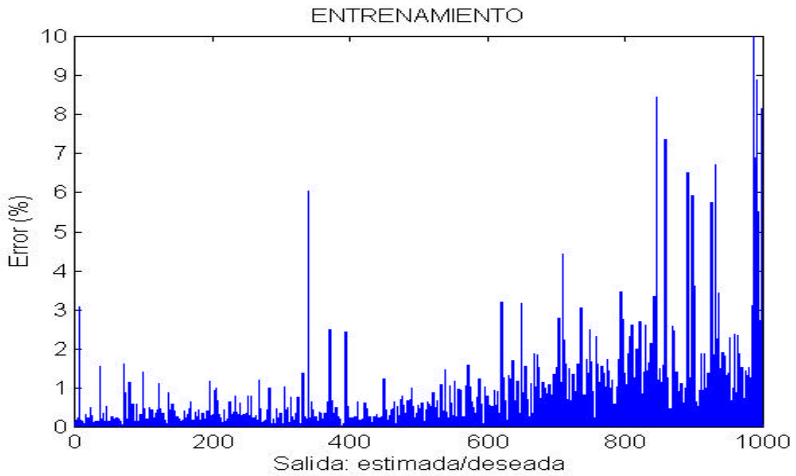

a. Error porcentual en el cálculo de sobretensiones.

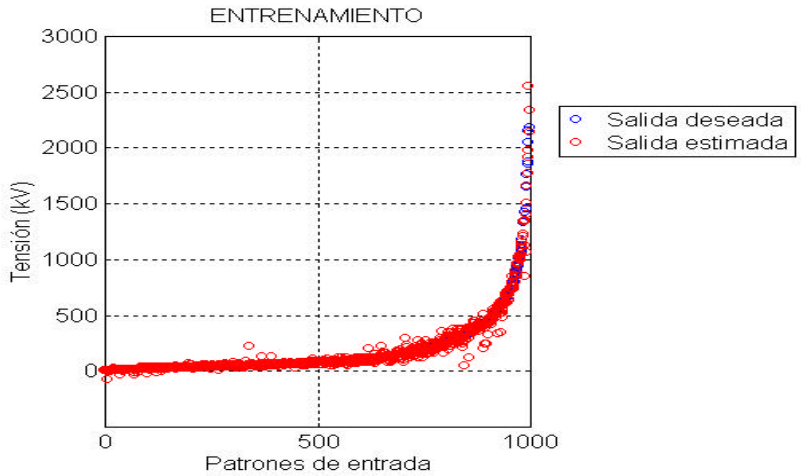

b. Ajuste de las salidas (tensiones).

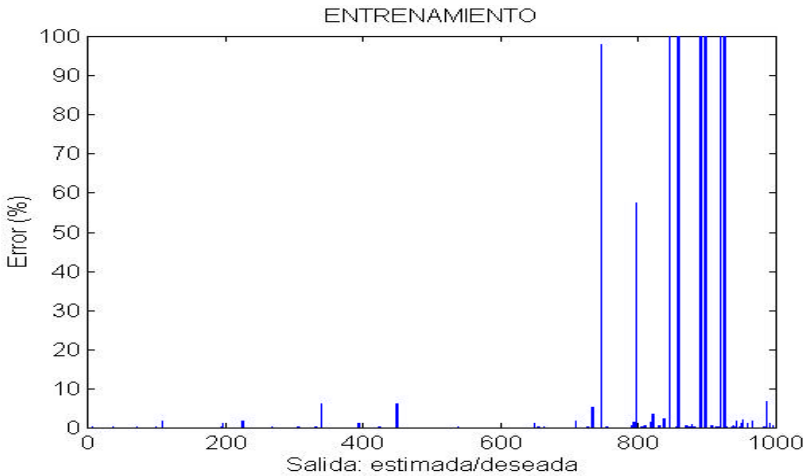

c. Error porcentual en la clasificación de descargas.

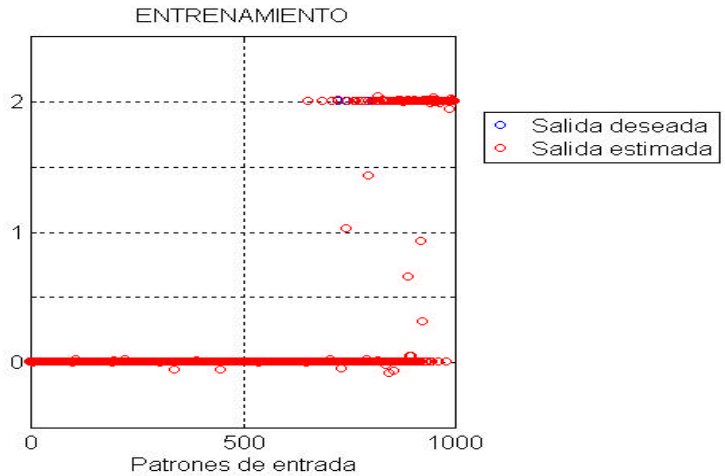

d. Ajuste del clasificador.

Figura 6.40. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m, distancia horizontal conductores - cable de tierra = 1 m, altura cable de tierra = 15.5 m, resistencia de puesta a tierra = 50 Ω.

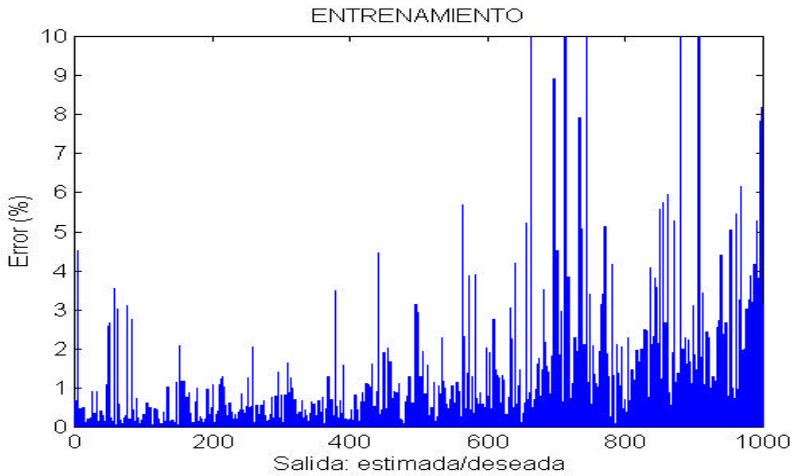

a. Error porcentual en el cálculo de sobretensiones.

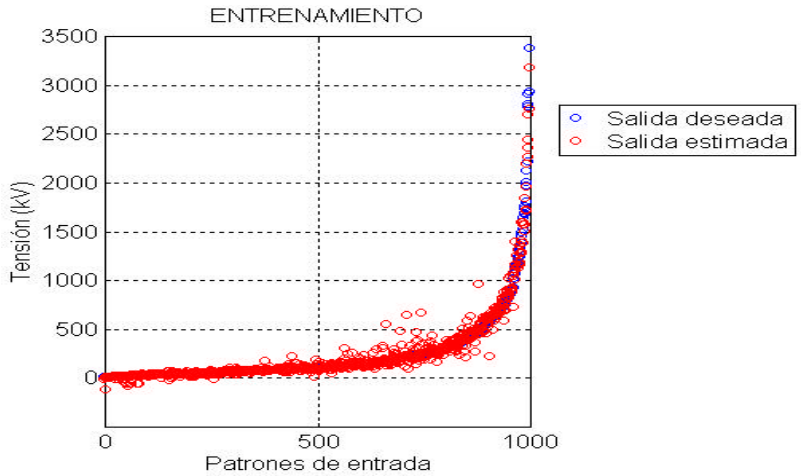

b. Ajuste de las salidas (tensiones).

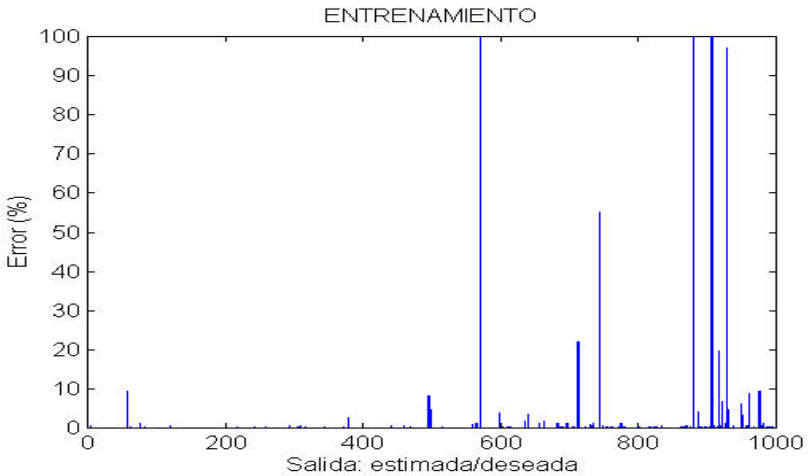

c. Error porcentual en la clasificación de descargas.

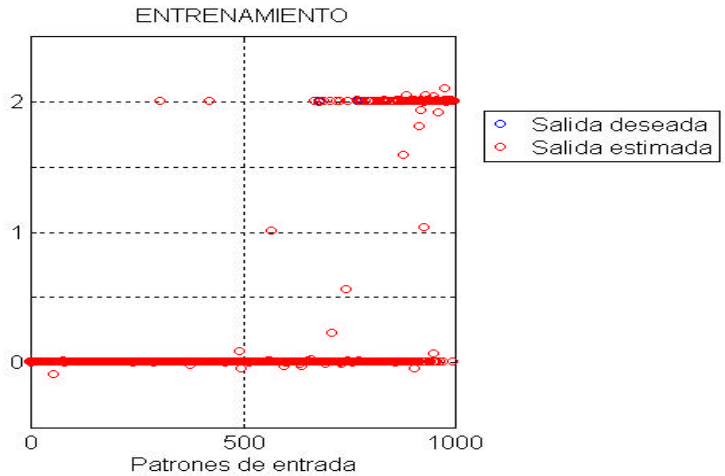

d. Ajuste del clasificador.

Figura 6.41. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m, distancia horizontal conductores - cable de tierra = 1.5 m, altura cable de tierra = 19.5 m, resistencia de puesta a tierra = 70 Ω.

6.3.5. Cálculo de sobretensiones en líneas sin cable de tierra. Velocidad de retorno del rayo en función de la intensidad máxima

6.3.5.1. Método de Rusck

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas (variables independientes): Intensidad máxima de la descarga (variable I), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), parámetro W (variable W), altura de la línea (variable h).

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 9000 patrones diferentes calculados de forma aleatoria. Este estudio se ha realizado de manera idéntica al utilizado con el método de Rusck en líneas sin apantallar y distribución de velocidad de retorno del rayo uniforme, para más detalles ver el apartado 6.3.3. La diferencia es que ahora la velocidad de retorno del rayo se calcula a partir de la intensidad de pico de la descarga. Por tanto, se añadirá una nueva entrada a la red neuronal, la que corresponde al parámetro W, ver expresión (3.10), el cual tomará cuatro valores diferentes en este entrenamiento: 50, 200, 350 y 500.

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en los apartados anteriores. La Tabla 6.14 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento β=0.9.

El entrenamiento de esta red neuronal se puede resumir en los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.
2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.1 para la función lineal.
3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.42 muestra la arquitectura de la red, y la figura 6.43 muestra los resultados del entrenamiento obtenidos con esta red. Se puede observar que en general el error cometido en las dos salidas, clasificador y cálculo de tensiones, se encuentra acotado por debajo del 10 %. Los resultados han sido algo peores que cuando se supuso que la velocidad seguía una distribución uniforme, lo cual es lógico porque la complejidad de la red neuronal ha aumentado.

Tabla 6.14. Datos de entrenamiento.

ENTRADAS					SALIDAS	
Altura (m)	**Intensidad (kA)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**W**	**Tipo descarga**	**Tensión (kV)**
5	33	180	189164	50	0	40.82
5	61	268	221982	50	0	54.27
5	39	86	197870	50	0	101.66
5	13	45	136277	50	0	57.21
5	19	376	157425	50	0	10.51
5	30	122	182746	50	0	53.11
5	19	99	155906	50	0	38.91
5	33	357	189164	50	0	20.60
5	38	346	197139	50	0	24.88
5	34	250	190863	50	0	30.39
8	57	92	111845	350	0	187.30
8	26	312	78178	350	0	23.17
8	17	130	64567	350	0	35.92
8	13	231	56773	350	0	15.28
8	19	194	67218	350	0	26.36
8	30	440	83642	350	0	19.22
8	96	417	139184	350	0	74.09
8	33	175	88060	350	0	54.53
8	38	164	93326	350	0	66.72
8	34	68	89268	350	0	144.39
11	36	354	116477	200	0	42.36
11	18	416	86204	200	0	17.17
11	23	76	95400	200	0	119.03
11	21	151	91473	200	0	54.39
11	4	457	42008	200	0	3.16
11	22	44	93466	200	1	5408.67
11	13	363	72761	200	0	13.30
11	6	96	49079	200	0	21.07
11	15	427	77999	200	0	13.25
11	25	173	100000	200	0	59.62
14	33	172	74647	500	0	94.67
14	38	161	79730	500	0	117.47
14	34	65	75699	500	1	8800.07
14	46	200	86642	500	0	115.11
14	21	117	59537	500	0	84.04
14	50	264	90453	500	0	96.56
14	40	193	81175	500	0	102.19
14	49	354	89626	500	0	70.56
14	45	428	86204	500	0	53.11
14	17	234	53620	500	0	33.27
17	50	138	211598	50	0	287.43
17	66	25	225918	50	1	17335.63
17	25	99	173205	50	0	185.40
17	58	405	219407	50	0	115.87
17	26	492	174348	50	0	38.22
17	17	311	151115	50	0	38.42
17	14	44	138325	50	1	3572.99
17	19	375	157425	50	0	36.08
17	30	253	182746	50	0	87.48
17	101	97	245354	50	1	26731.23

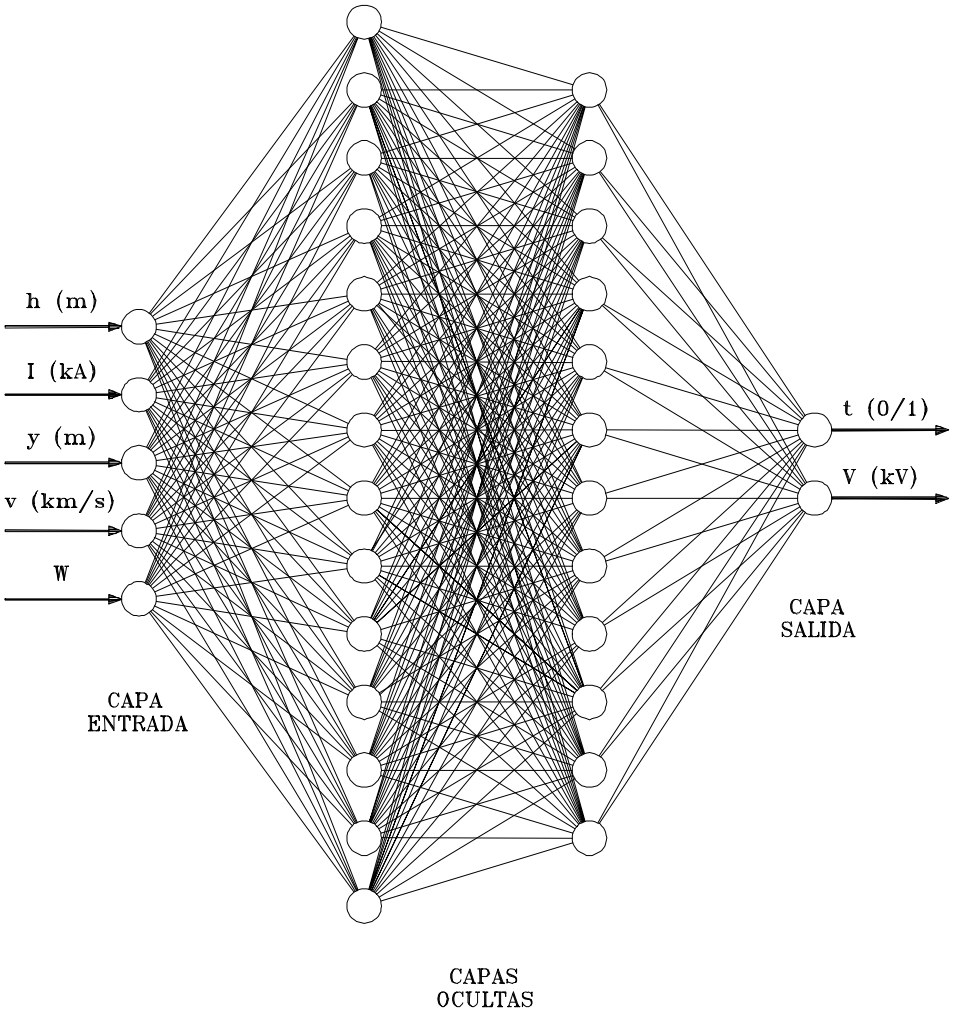

Figura 6.42. Arquitectura de la red neuronal (Método de Rusck con líneas sin apantallar).

Validación

La validación de esta red neuronal se ha realizado con 10000 patrones que no han intervenido en el proceso de entrenamiento. Se han utilizado 1000 patrones para cada combinación de la altura de la línea y del parámetro W mostrada en la Tabla 6.15. Los gráficos de las figuras 6.44, 6.45, y 6.46 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Estos resultados muestran que en la inmensa mayoría de los casos el error cometido en el cálculo de tensiones se encuentra por debajo del 3 %, y que la red neuronal apenas muestra confusión en la clasificación de descargas.

Tabla 6.15. Variables altura y parámetro W.

h (m)	W
5	50
8	200
8	500
10	350
10	500
11	50
14	200
14	500
17	350
17	200

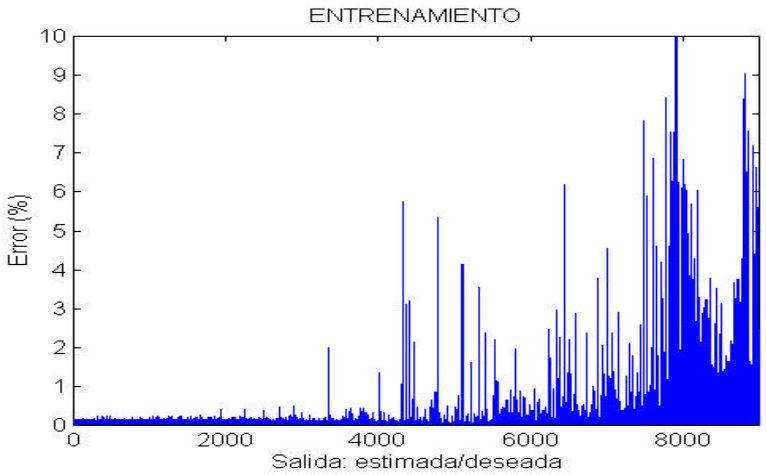

a. Error porcentual en el cálculo de sobretensiones.

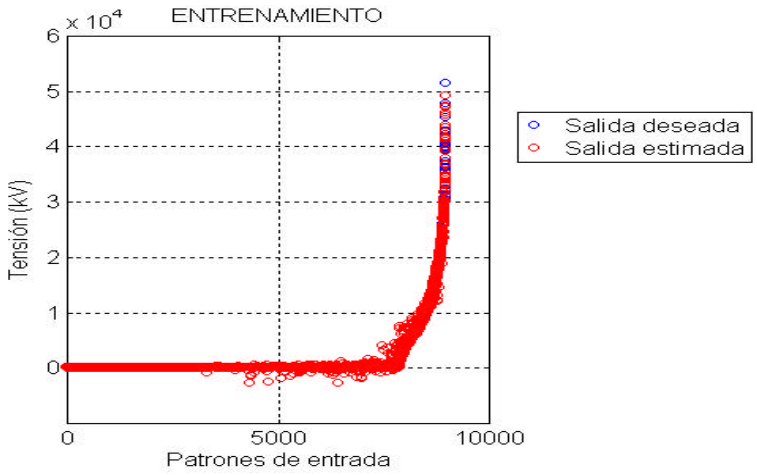

b. Ajuste de las salidas (tensiones).

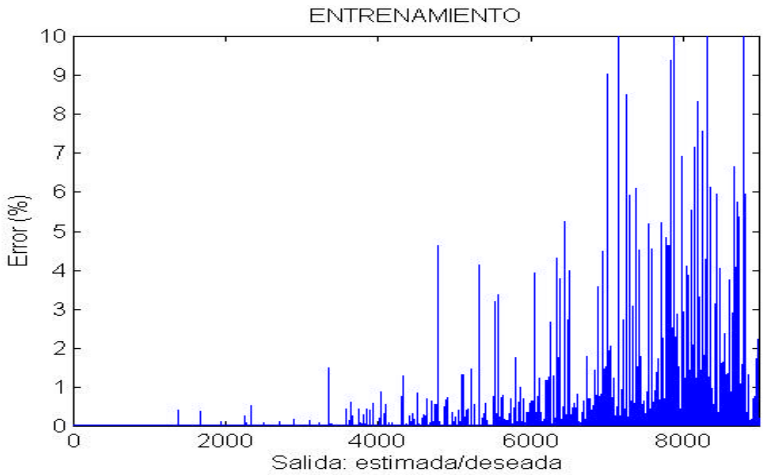

c. Error porcentual en la clasificación de descargas.

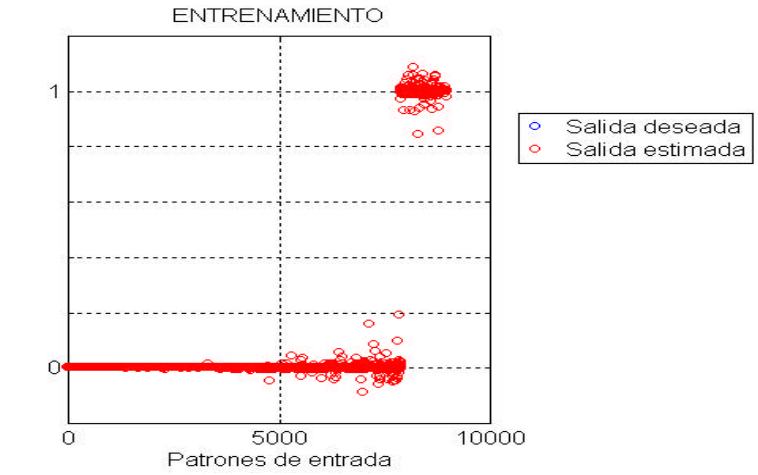

d. Ajuste del clasificador.

Figura 6.43. Entrenamiento de la red neuronal.

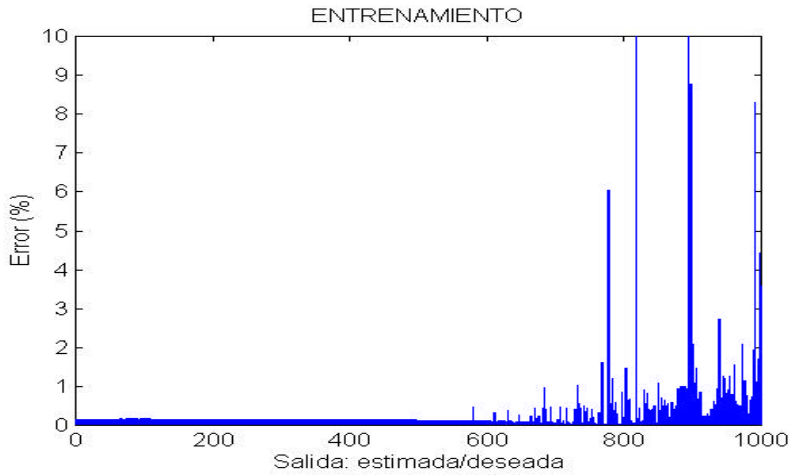

a. Error porcentual en el cálculo de sobretensiones.

b. Ajuste de las salidas (tensiones).

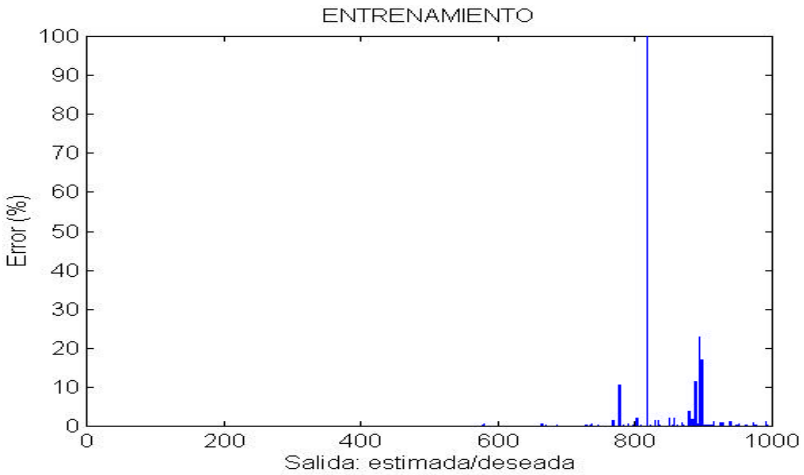

c. Error porcentual en la clasificación de descargas.

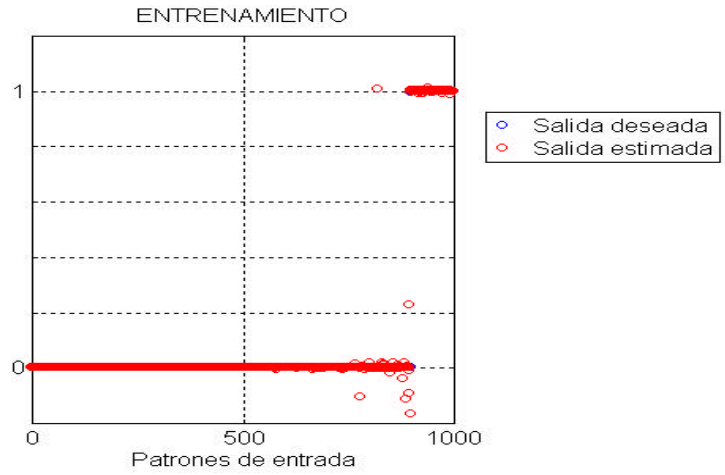

d. Ajuste del clasificador.

Figura 6.44. Validación de la red neuronal. Altura = 5 m, W = 50.

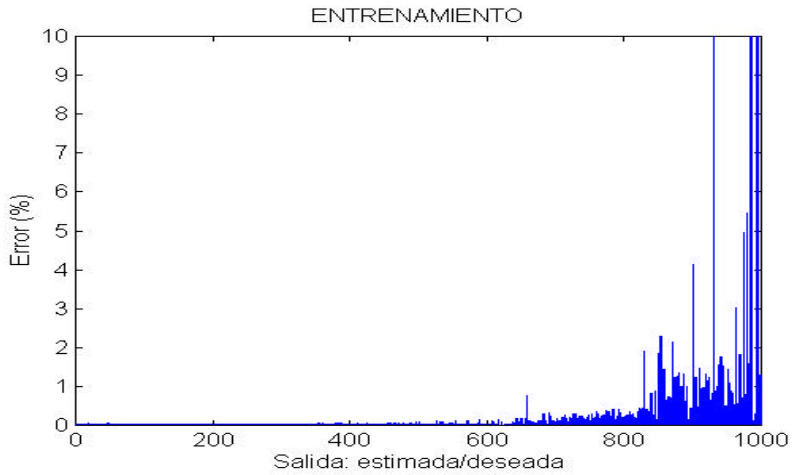

a. Error porcentual en el cálculo de sobretensiones.

b. Ajuste de las salidas (tensiones).

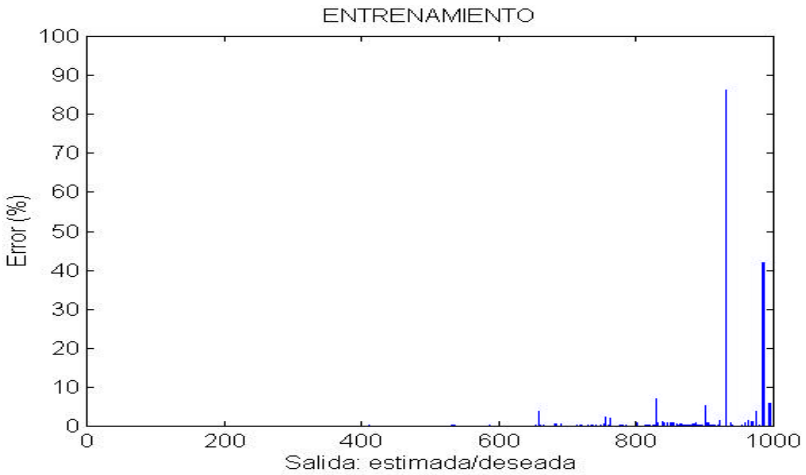

c. Error porcentual en la clasificación de descargas.

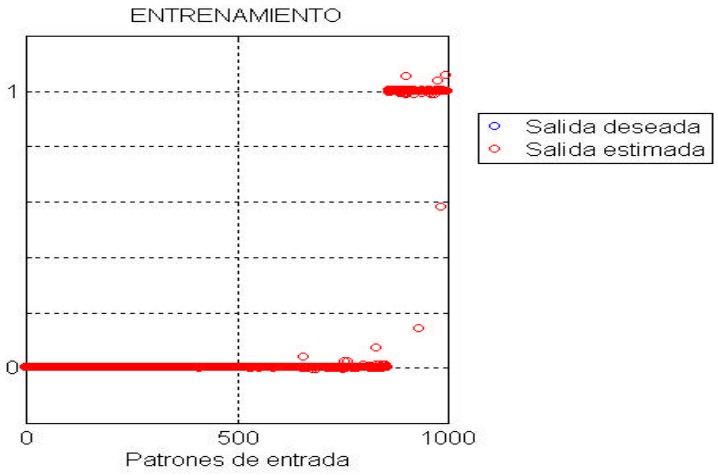

d. Ajuste del clasificador.

Figura 6.45. Validación de la red neuronal. Altura = 10 m, W = 350.

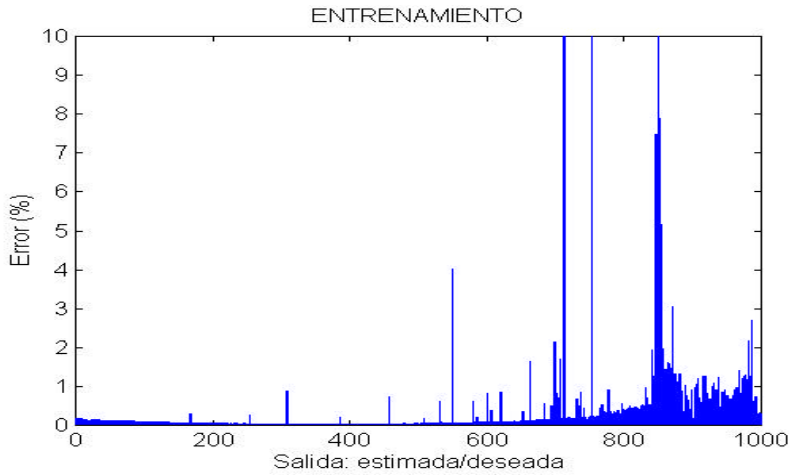

a. Error porcentual en el cálculo de sobretensiones.

b. Ajuste de las salidas (tensiones).

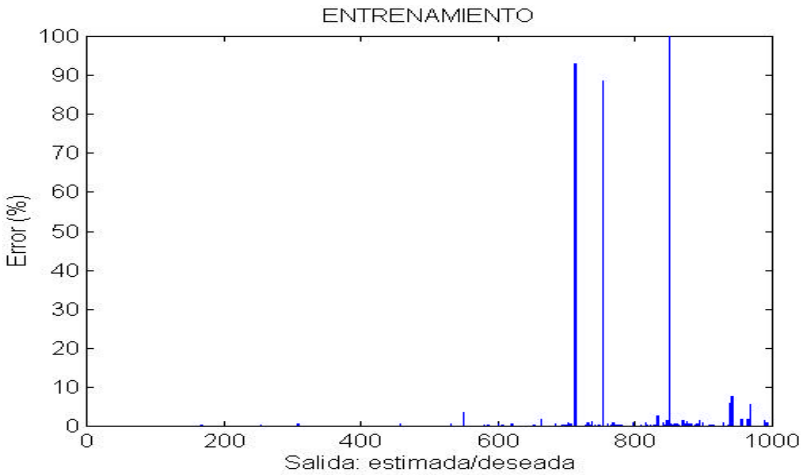

c. Error porcentual en la clasificación de descargas.

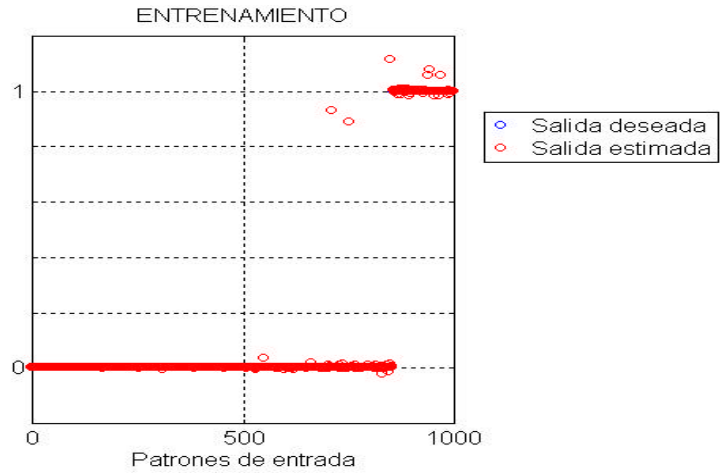

d. Ajuste del clasificador.

Figura 6.46. Validación de la red neuronal. Altura = 17 m, W = 200.

6.3.5.2. Método de Chowdhuri

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), tiempo de frente de la onda de corriente del rayo (variable t_f), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), parámetro W (variable W), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3})

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 8960 patrones diferentes calculados de forma aleatoria. Este estudio es similar al utilizado con el método de Chowdhuri en líneas sin apantallar y distribución de velocidad de retorno del rayo uniforme, para más detalles ver el apartado 6.3.3. Al igual que con el método de Rusck, la diferencia es que ahora se debe de añadir una nueva entrada a la red neuronal, la que corresponde al parámetro W, porque la velocidad de retorno del rayo se calcula a partir de la intensidad de pico de la descarga, ver expresión (3.10). La red neuronal se ha entrenado de nuevo con cuatro valores diferentes del parámetro W: 50, 200, 350 y 500.

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en los apartados anteriores. La Tabla 6.16 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente

- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)

- tasa de aprendizaje variable, $\alpha_0=0.25$, $\alpha_i=1.01$, $\alpha_d=0.6$

- momento $\beta=0.9$.

El entrenamiento de esta red neuronal tiene los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.

2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.1 para la función lineal.

3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.47 muestra la arquitectura de la red, y la figura 6.48 muestra los resultados del entrenamiento obtenidos con esta red. Tal y como ocurrió con el método de Rusck, los resultados han sido algo peores que cuando se supuso que la velocidad seguía una distribución uniforme. Ahora el error cometido en las dos salidas, clasificador y cálculo de tensiones, se encuentra acotado por debajo del 5 %.

Tabla 6.16. Datos de entrenamiento.

ENTRADAS											SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Intensidad (kA)**	**Tiempo de frente (ms)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**W**	**Tipo descarga**	**Tensión (kV)**
5	5	5	-3	0	3	83	5.0	80	131025	350	1	18791.36
5	5	5	-3	0	3	32	6.5	289	86829	350	0	19.91
5	5	5	-3	0	3	34	3.0	377	88667	350	0	38.33
8	8	8	-1	0	1	62	7.5	258	99285	500	0	44.49
8	8	8	-1	0	1	41	3.5	323	82120	500	0	77.98
8	8	8	-1	0	1	38	3.0	458	79241	500	0	72.21
11	11	11	-3	0	3	54	2.0	424	216173	50	0	10.27
11	11	11	-3	0	3	20	4.0	492	160357	50	0	7.90
11	11	11	-3	0	3	86	5.0	285	238306	50	0	15.79
14	14	14	-3	0	3	29	4.0	177	106759	200	0	71.01
14	14	14	-3	0	3	70	8.5	238	152753	200	0	32.51
14	14	14	-3	0	3	18	5.5	181	86204	200	0	45.20
17	17	17	-1	0	1	24	2.5	20	170848	50	1	6351.99
17	17	17	-1	0	1	40	2.5	153	200000	50	0	35.27
17	17	17	-1	0	1	60	3.5	493	221565	50	0	15.21
5	7	9	0	0	0	9	3.5	247	60573	200	0	29.15
5	7	9	0	0	0	29	2.5	157	105950	200	0	68.44
5	7	9	0	0	0	27	6.0	314	103464	200	0	21.19
8	10	12	0	0	0	16	1.5	315	62725	350	0	127.84
8	10	12	0	0	0	38	3.5	45	93326	350	1	9531.97
8	10	12	0	0	0	25	4.5	318	77460	350	0	57.20
8	10	12	0	0	0	80	6.5	480	129069	350	0	38.39
11	13	15	0	0	0	22	2.0	315	61588	500	0	184.52
11	13	15	0	0	0	67	9.5	15	102786	500	1	17349.94
11	13	15	0	0	0	4	7.0	402	26726	500	0	27.40
14	16	18	0	0	0	25	8.0	240	99105	200	0	36.56
14	16	18	0	0	0	15	2.5	310	79241	200	0	91.04
14	16	18	0	0	0	46	3.0	437	129152	200	0	77.82

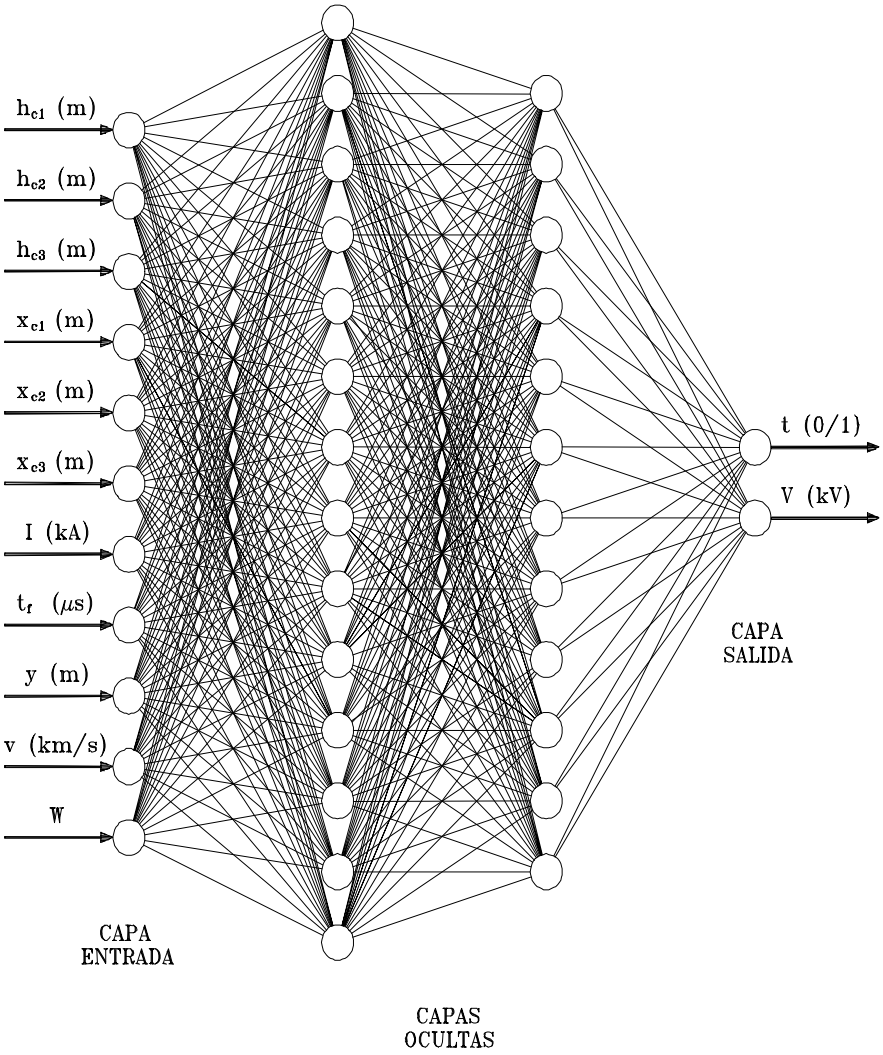

Figura 6.47. Arquitectura de la red neuronal (Método de Chowdhuri con líneas sin apantallar).

Validación

La red neuronal se ha validado con 10000 patrones que no han intervenido en el proceso de entrenamiento, con 1000 patrones para cada una de las configuraciones de línea mostradas en la Tabla 6.17. Los gráficos de las figuras 6.49, 6.50, y 6.51 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. En general, el error cometido en el cálculo de tensiones se encuentra por debajo del 3 %, y la red neuronal apenas muestra confusión en la clasificación de descargas.

Tabla 6.17. Variables altura, distancia al eje de la línea y parámetro W.

	h_{c1} (m)	**h_{c2} (m)**	**h_{c3} (m)**	**x_{c1} (m)**	**x_{c2} (m)**	**x_{c3} (m)**	**W**
Línea horizontal	5	5	5	-1.5	0	1.5	50
	10	10	10	-2	0	2	200
	10	10	10	-2	0	2	500
	17	17	17	-3	0	3	350
	17	17	17	-3	0	3	500
Línea vertical	5	7	9	0	0	0	50
	5	7	9	0	0	0	200
	10	12	14	0	0	0	500
	10	12	14	0	0	0	350
	14	16	18	0	0	0	200

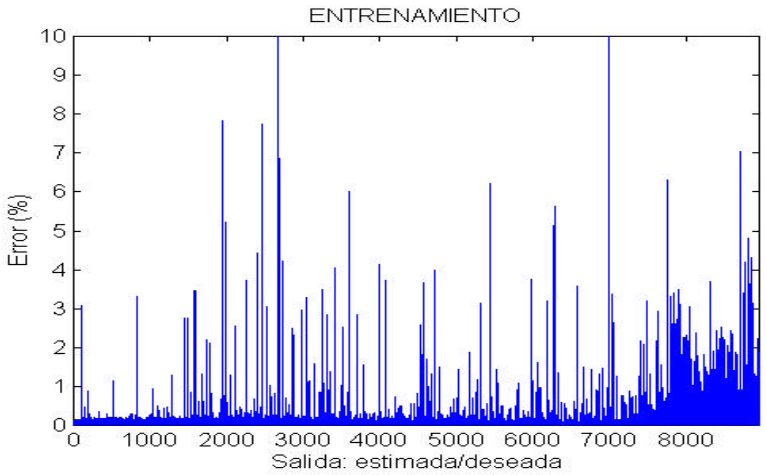

a. Error porcentual en el cálculo de sobretensiones.

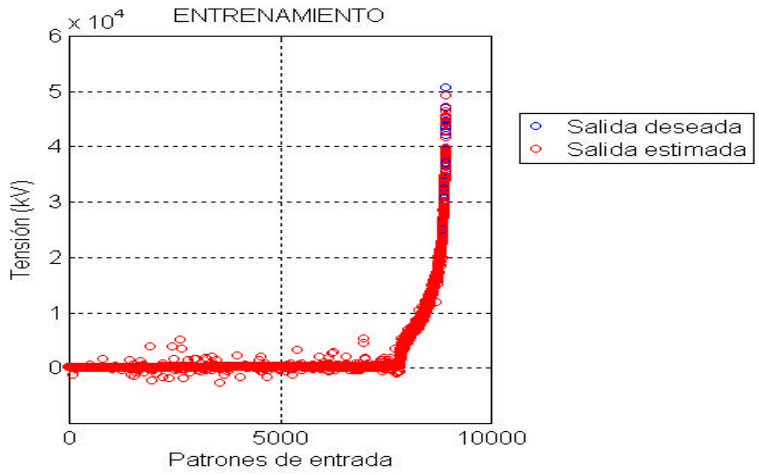

b. Ajuste de las salidas (tensiones).

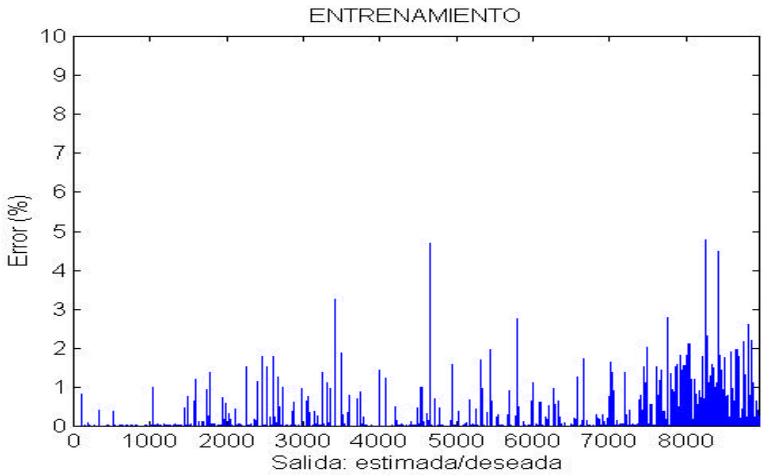

c. Error porcentual en la clasificación de descargas.

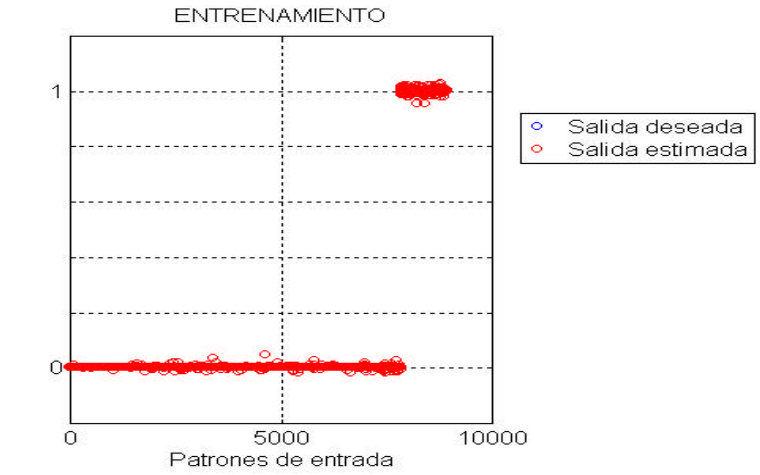

d. Ajuste del clasificador.

Figura 6.48. Entrenamiento de la red neuronal.

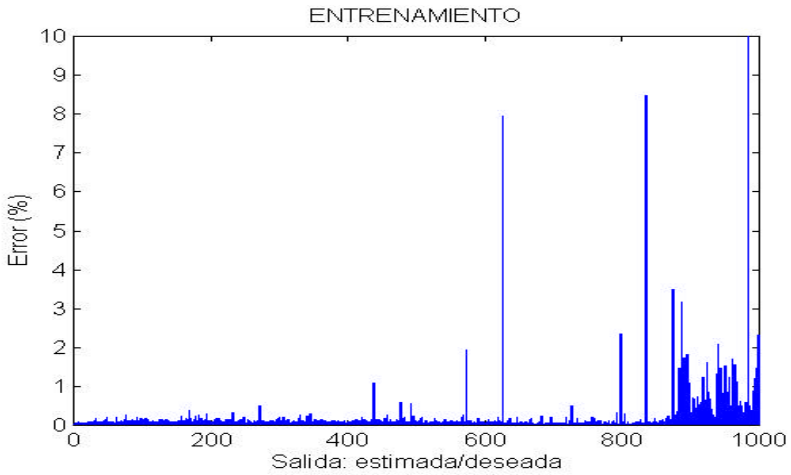

a. Error porcentual en el cálculo de sobretensiones.

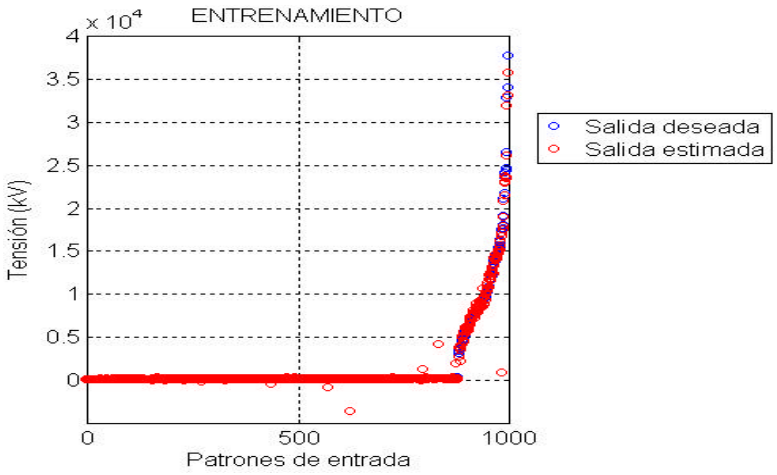

b. Ajuste de las salidas (tensiones).

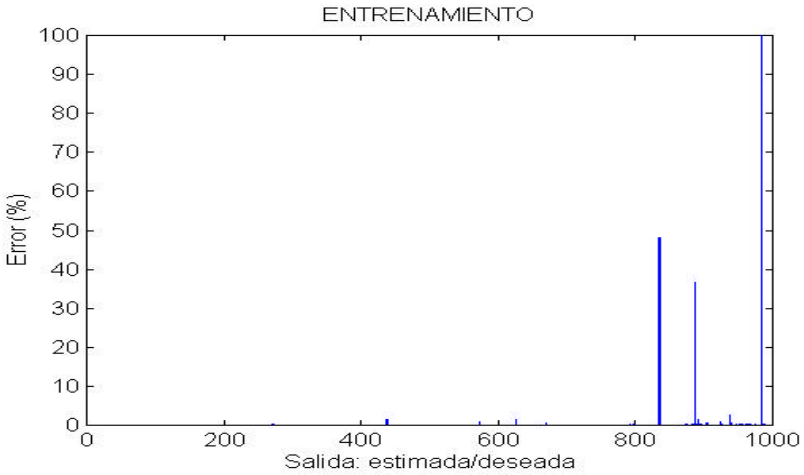

c. Error porcentual en la clasificación de descargas.

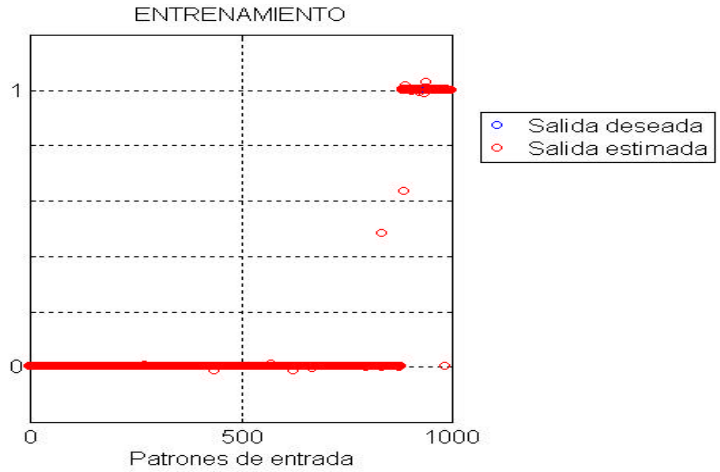

d. Ajuste del clasificador.

Figura 6.49. Validación de la red neuronal. Línea horizontal, altura = 10 m, distancia entre conductores más externos = 4 m, W = 200.

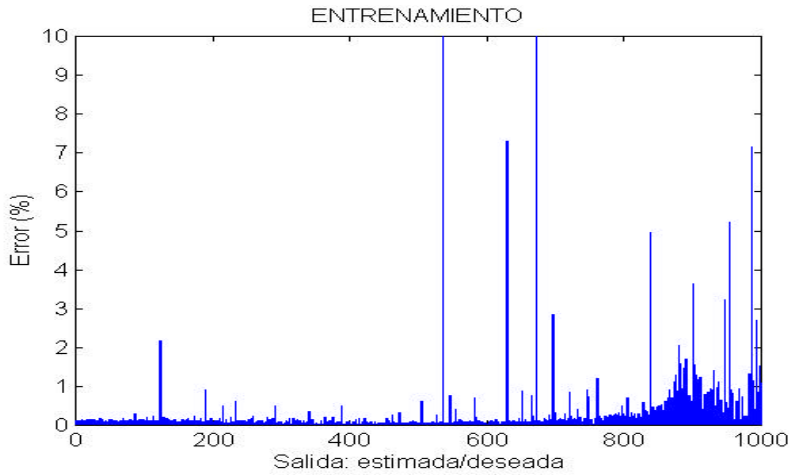

a. Error porcentual en el cálculo de sobretensiones.

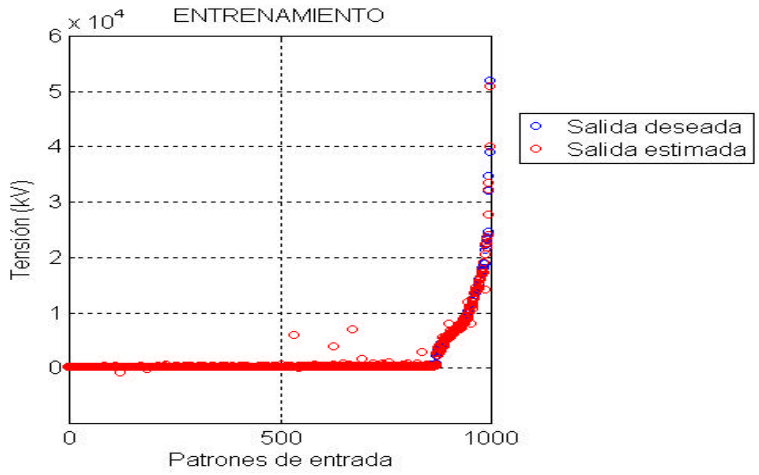

b. Ajuste de las salidas (tensiones).

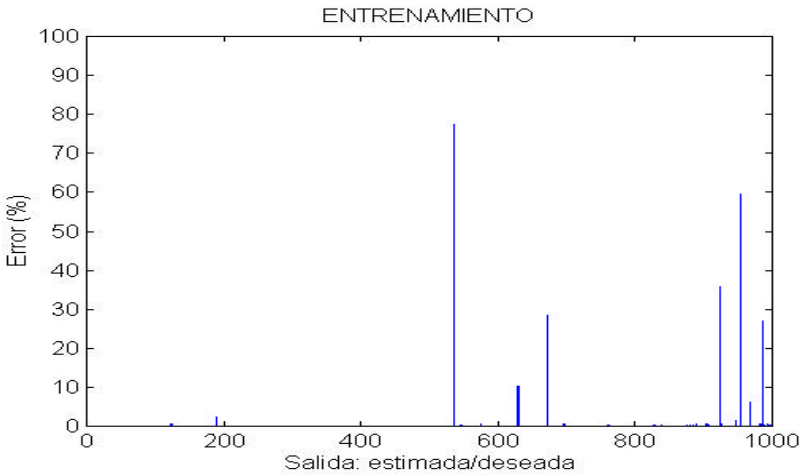

c. Error porcentual en la clasificación de descargas.

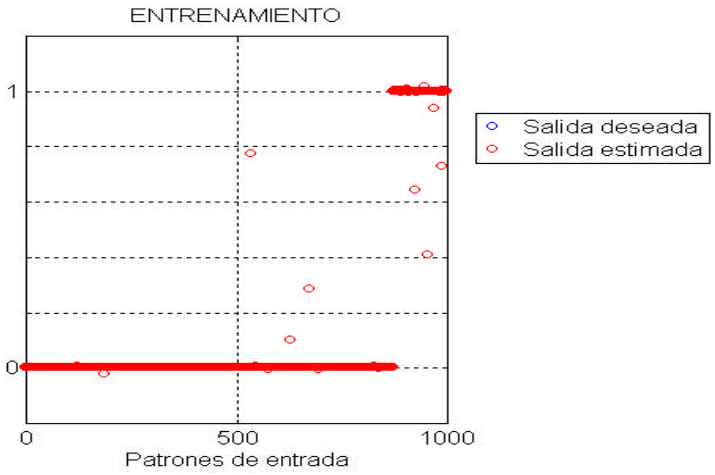

d. Ajuste del clasificador.

Figura 6.50. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m, W = 500.

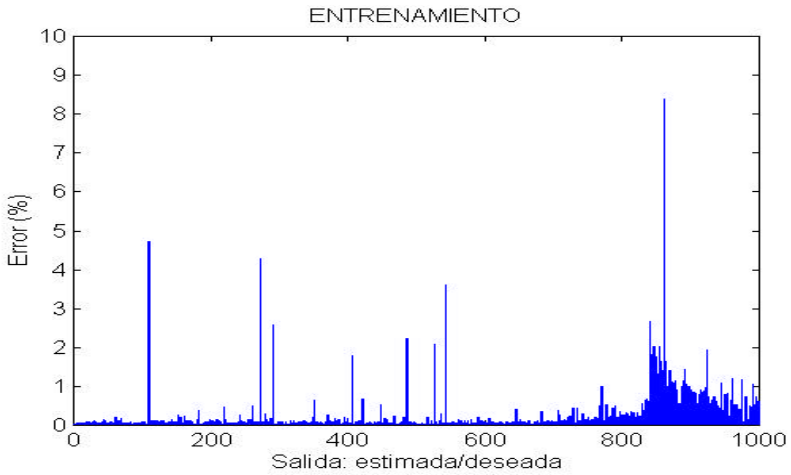

a. Error porcentual en el cálculo de sobretensiones.

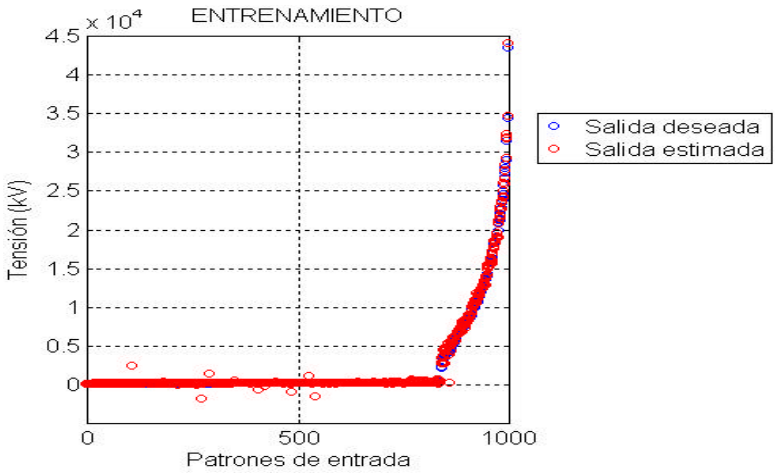

b. Ajuste de las salidas (tensiones).

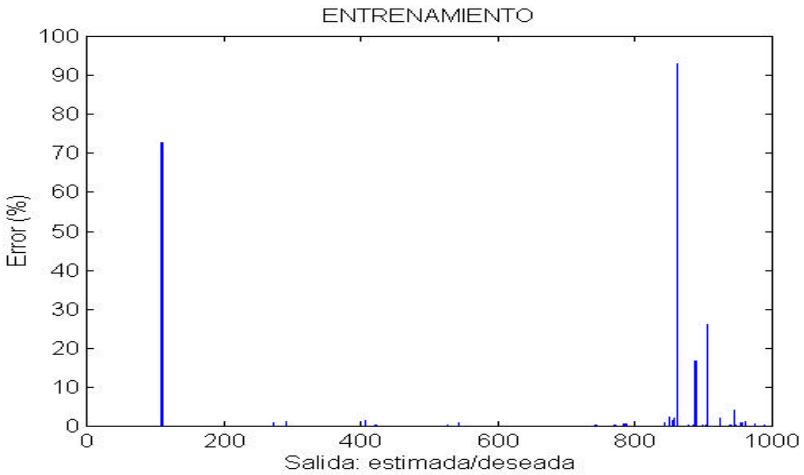

c. Error porcentual en la clasificación de descargas.

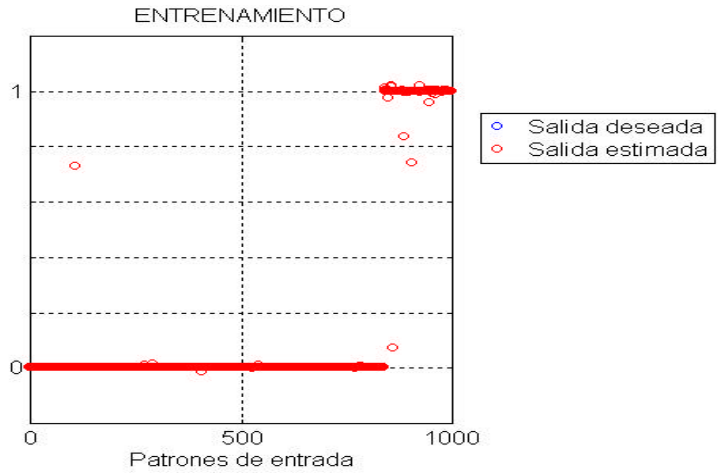

d. Ajuste del clasificador.

Figura 6.51. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m, W = 200.

6.3.6. Cálculo de sobretensiones en líneas con cable de tierra. Velocidad de retorno del rayo en función de la intensidad máxima

6.3.6.1. Método de Rusck

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), parámetro W (variable W), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), altura del cable de tierra (variable h_{ct}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3}), resistencia de puesta a tierra de los postes (variable R)

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 10800 patrones diferentes calculados de forma aleatoria. Este estudio es similar al utilizado con el método de Rusck en líneas apantalladas y distribución de velocidad de retorno del rayo uniforme, para más detalles ver el apartado 6.3.4. En este apartado el número de patrones ha sido escogido teniendo en cuenta una duración aceptable del proceso de entrenamiento. Sin embargo, es fácil darse cuenta que el número de patrones utilizados comienza a ser un problema ya que en el mismo estudio pero con distribución de velocidad uniforme se utilizaron casi 9000. La red neuronal se ha entrenado con cuatro valores diferentes del parámetro W: 50, 200, 350 y 500, los mismos que han sido utilizados para líneas sin apantallar.

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en los apartados anteriores. La Tabla 6.18 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente
- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)
- tasa de aprendizaje variable, α_0=0.25, α_i=1.01, α_d=0.6
- momento β=0.9.

El entrenamiento de esta red neuronal tiene los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.
2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.3 para la función lineal.
3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.52 muestra la arquitectura de la red, y la figura 6.53 muestra los resultados del entrenamiento obtenidos con esta red. El error cometido en las dos salidas, clasificador y cálculo de tensiones, se encuentra acotado por debajo del 10 %.

Tabla 6.18. Datos de entrenamiento.

ENTRADAS												SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Altura cable de tierra (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Resistencia puesta a tierra (W)**	**Intensidad (kA)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**W**	**Tipo descarga**	**Tensión (kV)**
5	5	5	6.5	-1.0	0.0	1.0	10	27	131	177647	50	0	31.54
5	5	5	6.5	-1.0	0.0	1.0	10	23	147	168393	50	0	23.47
5	5	5	6.5	-1.0	0.0	1.0	10	27	214	177647	50	0	19.26
8	8	8	11.0	-1.0	0.0	1.0	10	24	127	75251	350	0	38.14
8	8	8	11.0	-1.0	0.0	1.0	10	35	305	90453	350	0	24.38
8	8	8	11.0	-1.0	0.0	1.0	10	80	266	129399	350	0	69.35
11	11	11	14.0	-1.0	0.0	1.0	70	33	464	112902	200	0	22.96
11	11	11	14.0	-1.0	0.0	1.0	70	33	428	112163	200	0	24.44
11	11	11	14.0	-1.0	0.0	1.0	70	36	188	116477	200	0	61.38
14	14	14	15.5	-3.0	0.0	3.0	10	16	386	62725	350	0	13.22
14	14	14	15.5	-3.0	0.0	3.0	10	15	30	59835	350	2	83.41
14	14	14	15.5	-3.0	0.0	3.0	10	20	239	69749	350	0	27.14
14	14	14	15.5	-3.0	0.0	3.0	10	31	84	85574	350	0	123.92
17	17	17	20.0	-3.0	0.0	3.0	10	29	53	180763	50	2	166.63
17	17	17	20.0	-3.0	0.0	3.0	10	47	171	208826	50	0	154.07
17	17	17	20.0	-3.0	0.0	3.0	10	82	221	236177	50	0	220.55
5	7	9	12.0	0.5	0.5	0.5	70	15	233	79241	200	0	15.95
5	7	9	12.0	0.5	0.5	0.5	70	25	411	99105	200	0	15.38
5	7	9	12.0	0.5	0.5	0.5	70	44	372	127395	200	0	32.39
8	10	12	15.0	1.5	1.5	1.5	40	31	157	72486	500	0	61.87
8	10	12	15.0	1.5	1.5	1.5	40	23	23	62254	500	2	326.95
8	10	12	15.0	1.5	1.5	1.5	40	20	27	58835	500	2	290.62
11	13	15	16.5	1.5	1.5	1.5	70	45	352	206474	50	0	64.03
11	13	15	16.5	1.5	1.5	1.5	70	46	304	207666	50	0	76.00
11	13	15	16.5	1.5	1.5	1.5	70	28	235	179743	50	0	56.35
14	16	18	21.0	1.5	1.5	1.5	10	60	146	98198	500	0	192.08
14	16	18	21.0	1.5	1.5	1.5	10	7	342	33985	500	0	7.78
14	16	18	21.0	1.5	1.5	1.5	10	75	358	108347	500	0	100.29

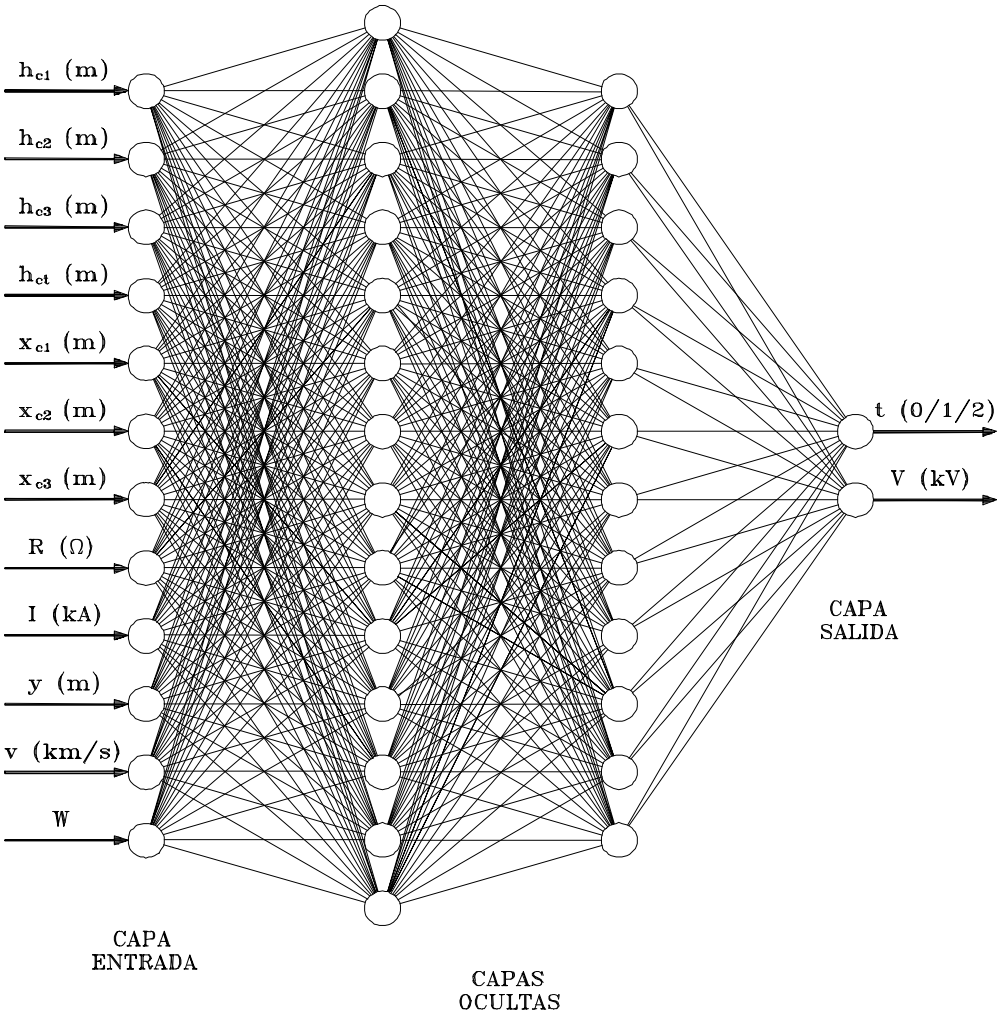

Figura 6.52. Arquitectura de la red neuronal (Método de Rusck con líneas apantalladas).

Validación

La red neuronal se ha validado con 10000 patrones que no han intervenido en el proceso de entrenamiento, con 1000 patrones para cada una de las configuraciones de línea mostradas en la Tabla 6.19. Los gráficos de las figuras 6.54, 6.55, y 6.56 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Al igual que en el entrenamiento, en general los errores correspondientes a ambas salidas de la red neuronal, clasificador y cálculo de tensiones, se encuentran por debajo del 10 %.

Tabla 6.19. Variables altura de los conductores, altura del cable de tierra, distancia al eje de los conductores, resistencia de puesta a tierra y parámetro W.

	h_{c1} (m)	h_{c2} (m)	h_{c3} (m)	h_{ct} (m)	x_{c1} (m)	x_{c2} (m)	x_{c3} (m)	R (W)	W
Línea horizontal	5	5	5	6.5	-1.5	0	1.5	30	50
	10	10	10	11.5	-2	0	2	50	200
	10	10	10	11.5	-2	0	2	50	500
	17	17	17	18.5	-3	0	3	10	350
	17	17	17	18.5	-3	0	3	10	500
Línea vertical	5	7	9	10.5	0	0	0	20	50
	5	7	9	10.5	0	0	0	20	200
	10	12	14	15.5	0	0	0	50	500
	10	12	14	15.5	0	0	0	50	350
	14	16	18	19.5	0	0	0	70	200

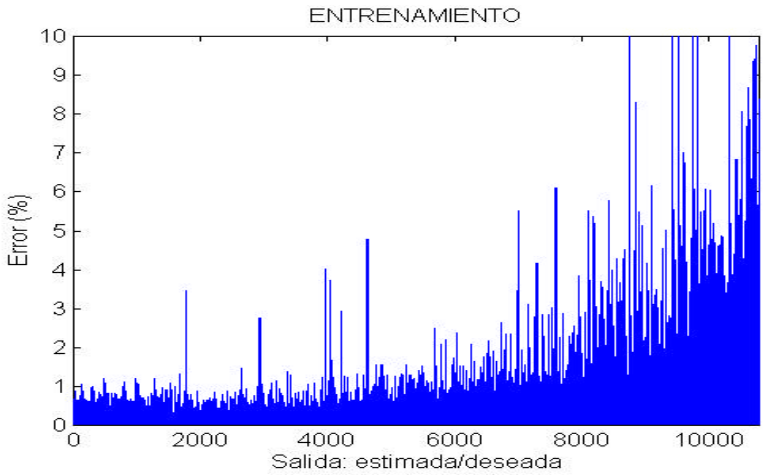

a. Error porcentual en el cálculo de sobretensiones.

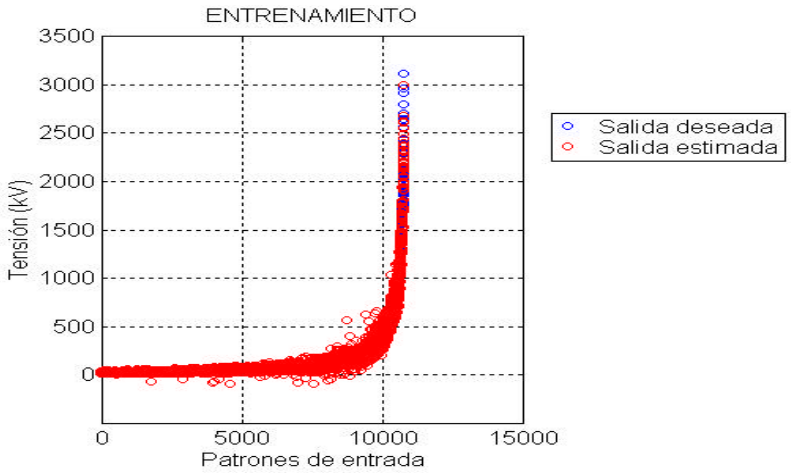

b. Ajuste de las salidas (tensiones).

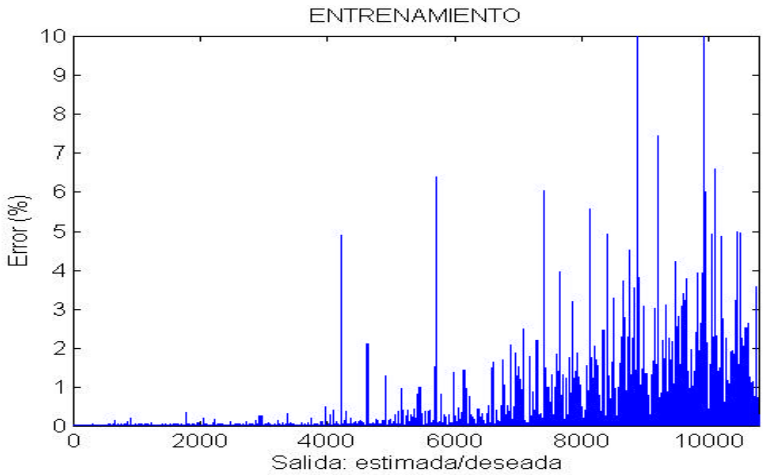

c. Error porcentual en la clasificación de descargas.

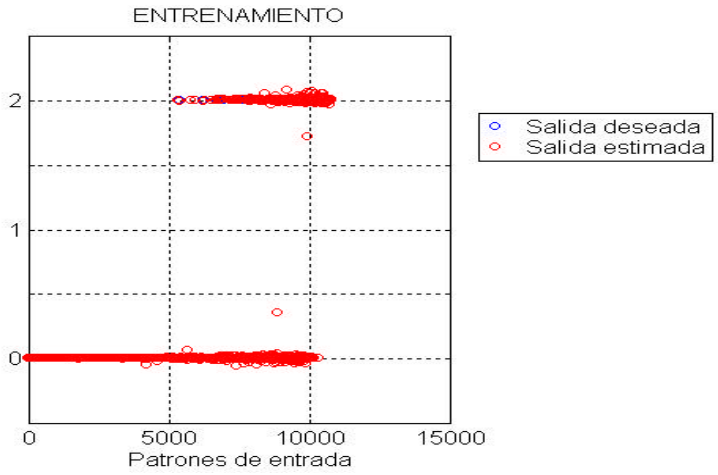

d. Ajuste del clasificador.

Figura 6.53. Entrenamiento de la red neuronal.

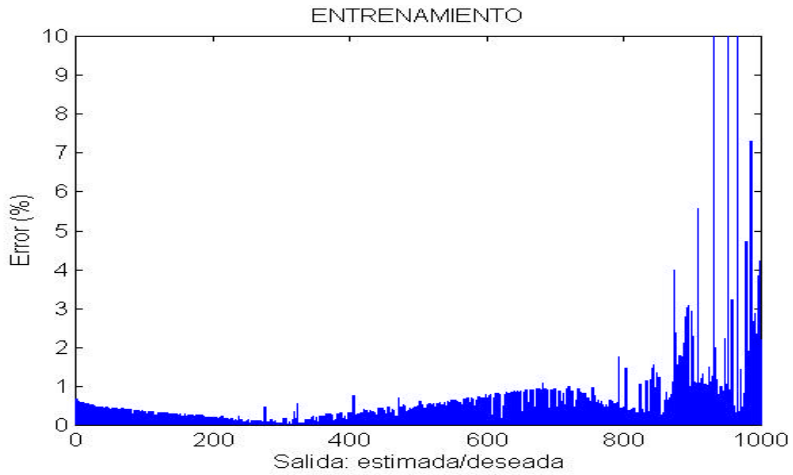

a. Error porcentual en el cálculo de sobretensiones.

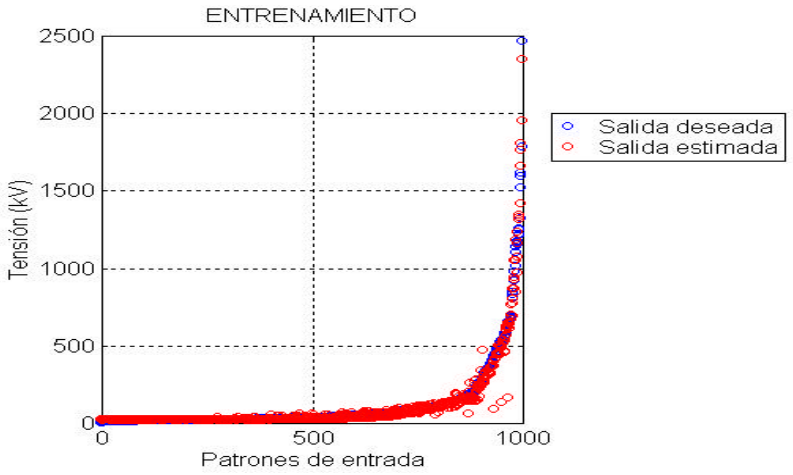

b. Ajuste de las salidas (tensiones).

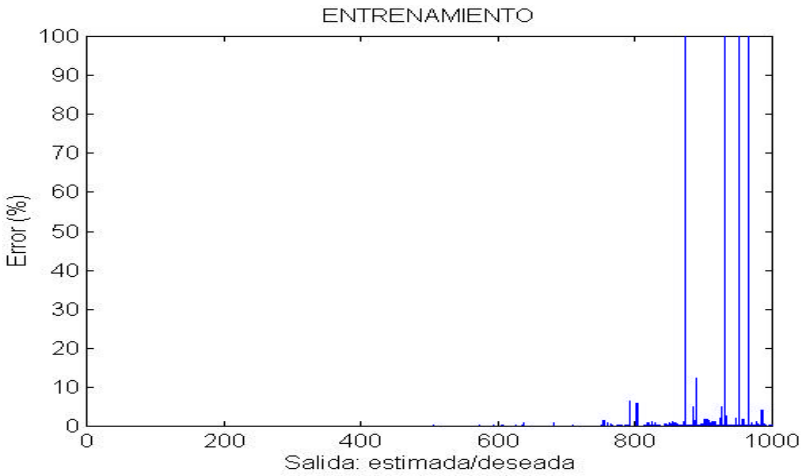

c. Error porcentual en la clasificación de descargas.

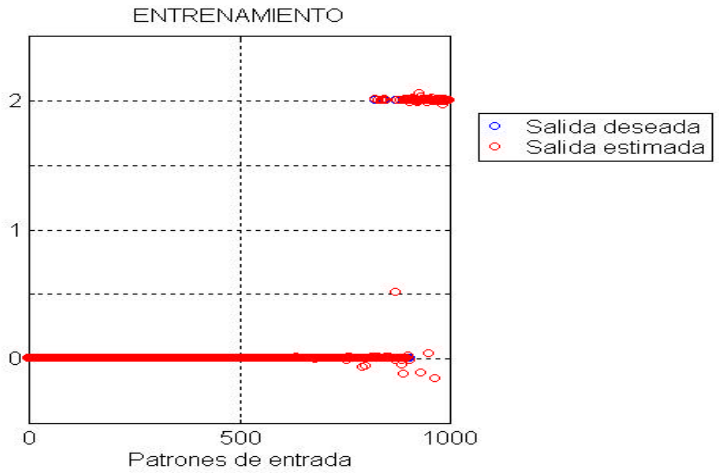

d. Ajuste del clasificador.

Figura 6.54. Validación de la red neuronal. Línea horizontal, altura conductores = 10 m, distancia entre conductores más externos = 4 m, altura cable de tierra = 11.5 m, resistencia de puesta a tierra = 50 Ω, W = 200.

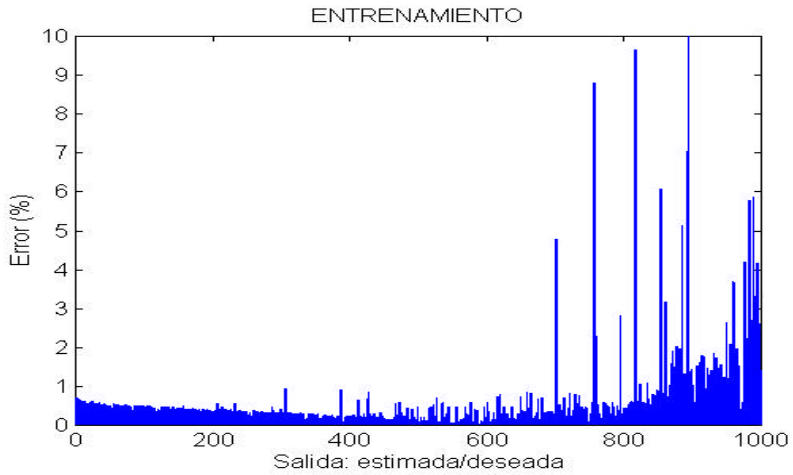

a. Error porcentual en el cálculo de sobretensiones.

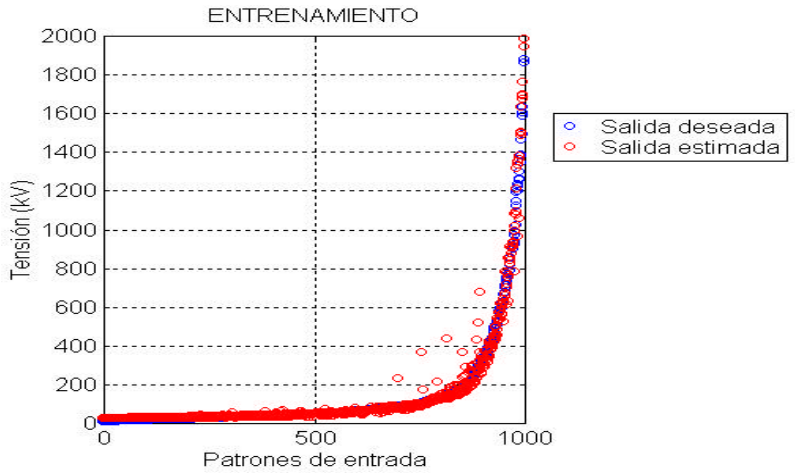

b. Ajuste de las salidas (tensiones).

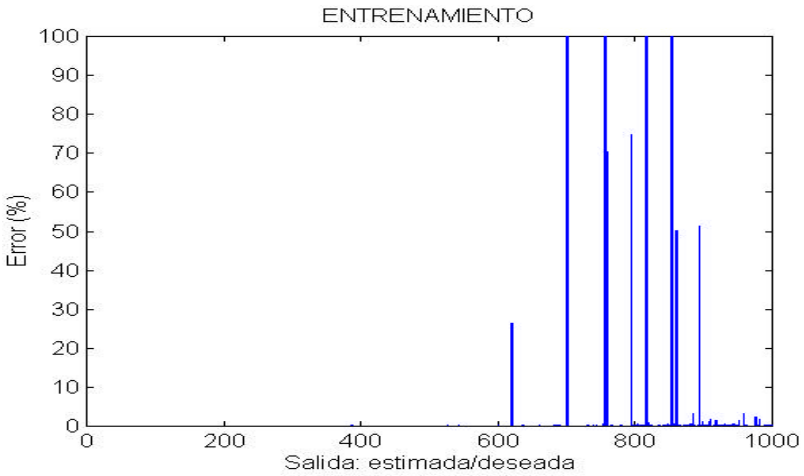

c. Error porcentual en la clasificación de descargas.

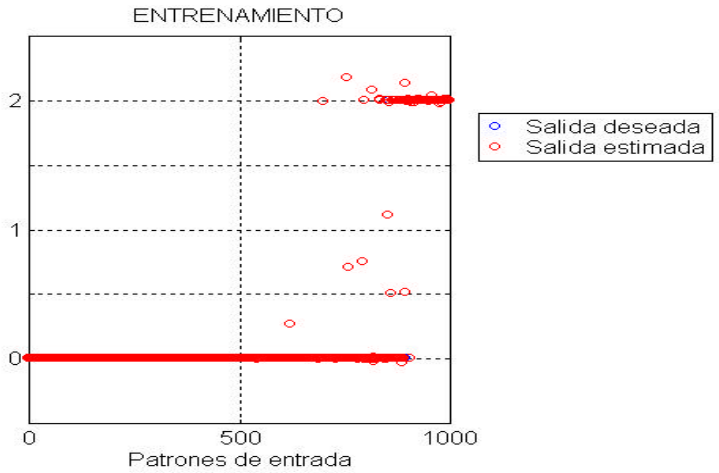

d. Ajuste del clasificador.

Figura 6.55. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m, distancia horizontal conductores - cable de tierra = 1 m, altura cable de tierra = 15.5 m, resistencia de puesta a tierra = 50 Ω, W = 500.

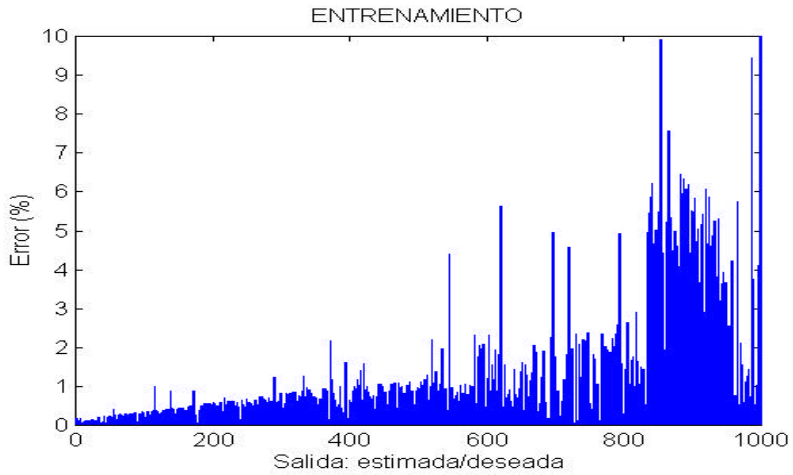

a. Error porcentual en el cálculo de sobretensiones.

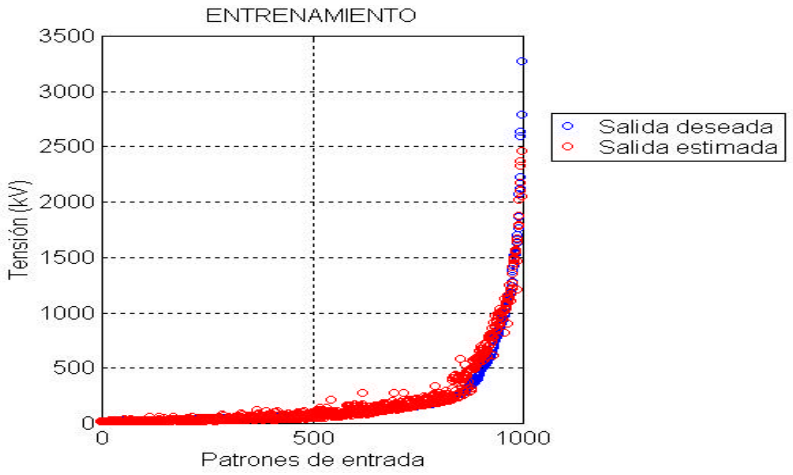

b. Ajuste de las salidas (tensiones).

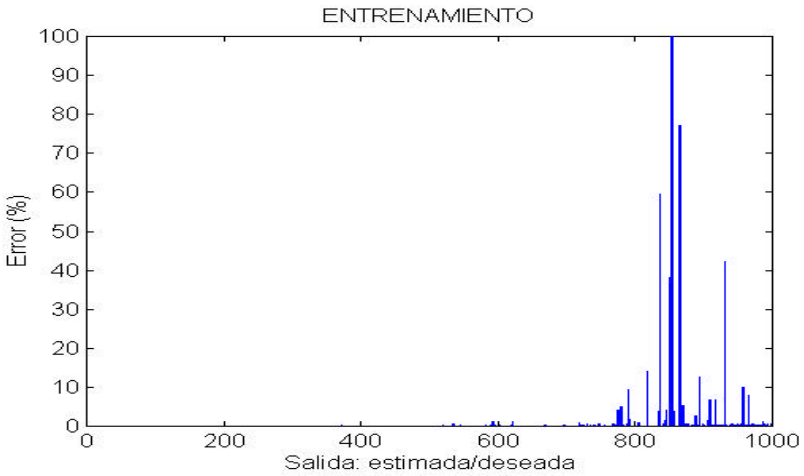

c. Error porcentual en la clasificación de descargas.

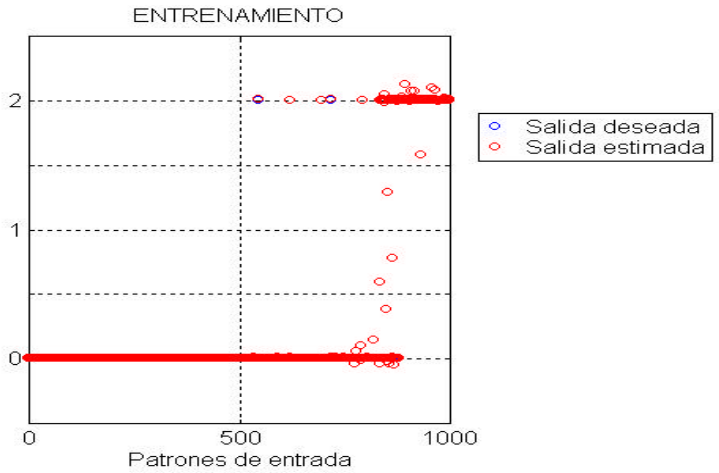

d. Ajuste del clasificador.

Figura 6.56. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m, distancia horizontal conductores - cable de tierra = 1.5 m, altura cable de tierra = 19.5 m, resistencia de puesta a tierra = 70 Ω, W = 200.

6.3.6.2. Método de Chowdhuri

En este estudio se han escogido las siguientes variables de entrada y salida de la red

- Entradas: Intensidad máxima de la descarga (variable I), tiempo de frente de la onda de corriente del rayo (variable t_f), distancia perpendicular entre la línea y la descarga (variable y), velocidad de retorno del rayo (variable v), parámetro W (variable W), altura de cada conductor de fase (variable h_{c1}, variable h_{c2}, variable h_{c3}), altura del cable de tierra (variable h_{ct}), distancia al eje de cada conductor de fase (variable x_{c1}, variable x_{c2}, variable x_{c3}), resistencia de puesta a tierra de los postes (variable R)

- Salidas: Tipo de descarga, directa al cable de tierra/directa al conductor de fase/indirecta (variable t), sobretensión que aparece en la línea (variable V).

La red neuronal se ha entrenado con un total de 10800 patrones diferentes calculados de forma aleatoria. Este estudio es similar al utilizado con el método de Chowdhuri en líneas apantalladas y distribución de velocidad de retorno del rayo uniforme, para más detalles ver el apartado 6.3.4, la única diferencia es que se ha añadido una nueva entrada, la correspondiente al parámetro W. La red neuronal se ha entrenado con cuatro valores diferentes del parámetro W: 50, 200, 350 y 500.

Entrenamiento

Para entrenar la red neuronal se seguirá la metodología utilizada en los apartados anteriores. La Tabla 6.20 muestra una parte de los datos utilizados en el entrenamiento.

La estructura de red neuronal utilizada ha sido la siguiente

- 2 capas de neuronas ocultas, con 14 y 12 neuronas respectivamente

- funciones de transferencia: tan-sigmoidal (capas ocultas), lineal (capa de salida)

- tasa de aprendizaje variable, $\alpha_0=0.25$, $\alpha_i=1.01$, $\alpha_d=0.6$

- momento $\beta=0.9$.

El entrenamiento de esta red neuronal tiene los siguientes pasos

1) Estudio previo. Se guardan los pesos y los umbrales que dan el mínimo error.

2) Ajuste de la pendiente de las funciones de transferencia. Se mantiene un valor unidad para la pendiente de la función tan-sigmoidal, y un valor de 0.3 para la función lineal.

3) Se entrena la red neuronal con la estructura comentada anteriormente y con las pendientes ajustadas hasta que el error se estabiliza. La figura 6.57 muestra la arquitectura de la red, y la figura 6.58 muestra los resultados del entrenamiento obtenidos con esta red. Se puede observar que el error cometido por el clasificador se encuentra por debajo del 5 %, y que el error cometido en el cálculo de tensiones es inferior al 10 %.

Tabla 6.20. Datos de entrenamiento.

ENTRADAS													SALIDAS	
Altura conductor 1 (m)	**Altura conductor 2 (m)**	**Altura conductor 3 (m)**	**Altura cable de tierra (m)**	**Distancia al eje conductor 1 (m)**	**Distancia al eje conductor 2 (m)**	**Distancia al eje conductor 3 (m)**	**Resistencia puesta a tierra (W)**	**Intensidad (kA)**	**Tiempo de frente (ms)**	**Distancia descarga - línea (m)**	**Velocidad (km/s)**	**W**	**Tipo descarga**	**Tensión (kV)**
5	5	5	6.5	-3.0	0.0	3.0	70	29	2.5	358	105950	200	0	25.02
5	5	5	6.5	-3.0	0.0	3.0	70	17	1.5	310	82820	200	0	35.88
5	5	5	6.5	-3.0	0.0	3.0	70	37	3.5	49	118535	200	2	636.78
8	8	8	11.0	-1.0	0.0	1.0	70	49	5.0	219	210511	50	0	7.41
8	8	8	11.0	-1.0	0.0	1.0	70	32	4.5	469	186508	50	0	3.89
8	8	8	11.0	-1.0	0.0	1.0	70	38	2.5	58	196396	50	2	627.44
11	11	11	12.5	-3.0	0.0	3.0	40	161	3.0	393	168214	350	0	67.64
11	11	11	12.5	-3.0	0.0	3.0	40	32	4.0	268	86204	350	0	57.96
11	11	11	12.5	-3.0	0.0	3.0	40	15	4.0	59	60816	350	0	72.16
14	14	14	17.0	-3.0	0.0	3.0	40	32	4.0	425	86204	350	0	59.62
14	14	14	17.0	-3.0	0.0	3.0	40	51	4.0	266	106528	350	0	83.08
14	14	14	17.0	-3.0	0.0	3.0	40	17	8.5	187	63654	350	0	32.74
14	14	14	17.0	-3.0	0.0	3.0	40	26	8.5	11	78889	350	2	343.69
17	17	17	20.0	-3.0	0.0	3.0	70	13	4.5	151	136277	50	0	17.61
17	17	17	20.0	-3.0	0.0	3.0	70	9	3.0	475	114354	50	0	14.12
17	17	17	20.0	-3.0	0.0	3.0	70	43	4.5	436	203350	50	0	10.06
5	7	9	12.0	0.5	0.5	0.5	10	38	6.0	223	93885	350	0	32.32
5	7	9	12.0	0.5	0.5	0.5	10	10	3.0	305	50000	350	0	36.38
5	7	9	12.0	0.5	0.5	0.5	10	48	3.0	251	103705	350	0	64.84
8	10	12	15.0	1.5	1.5	1.5	40	18	6.0	365	85096	200	0	18.93
8	10	12	15.0	1.5	1.5	1.5	40	34	3.0	310	114354	200	0	47.03
8	10	12	15.0	1.5	1.5	1.5	40	23	1.5	207	95400	200	0	101.39
11	13	15	16.5	0.5	0.5	0.5	10	36	5.5	360	77242	500	0	57.04
11	13	15	16.5	0.5	0.5	0.5	10	25	4.0	83	64838	500	0	114.29
11	13	15	16.5	0.5	0.5	0.5	10	53	5.5	317	92477	500	0	66.89
14	16	18	19.5	1.5	1.5	1.5	40	22	2.0	314	165831	50	0	24.67
14	16	18	19.5	1.5	1.5	1.5	40	25	3.5	266	172039	50	0	15.37
14	16	18	19.5	1.5	1.5	1.5	40	64	5.5	466	224393	50	0	11.25

Validación

Para validar esta red neuronal se ha seguido un procedimiento similar al utilizado con el método de Rusck. La red neuronal se ha validado con 10000 patrones que no han intervenido en el proceso de entrenamiento, distribuyendo 1000 para cada una de las configuraciones de línea mostradas en la Tabla 6.19. Los gráficos de las figuras 6.59, 6.60, y 6.61 muestran los resultados obtenidos para 3 de las configuraciones anteriores. Los resultados obtenidos con las otras configuraciones son similares. Los resultados de la validación muestran que los errores correspondientes a ambas salidas de la red neuronal, clasificador y cálculo de tensiones, en general se encuentran acotados por debajo del 10 %.

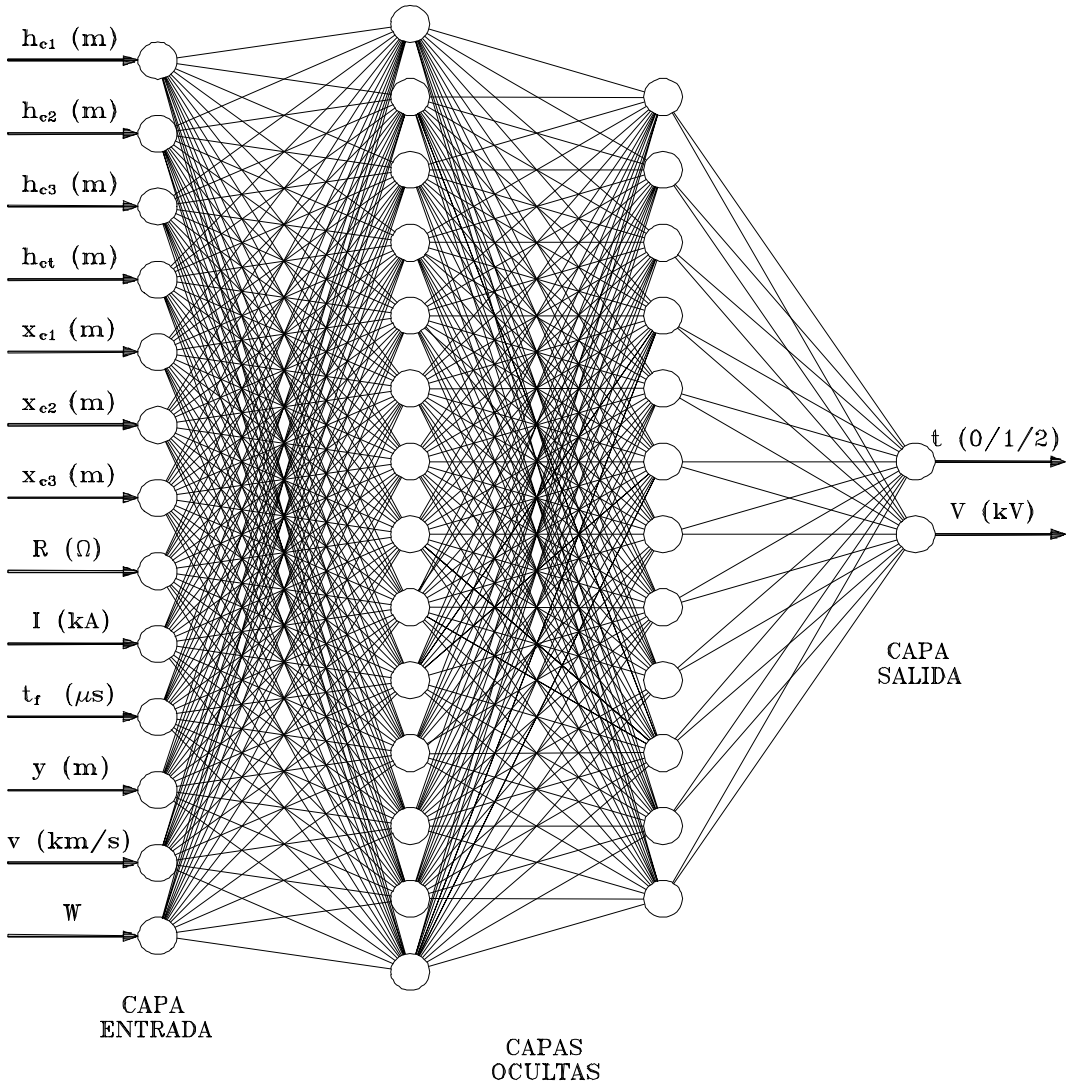

Figura 6.57. Arquitectura de la red neuronal (Método de Chowdhuri con líneas apantalladas).

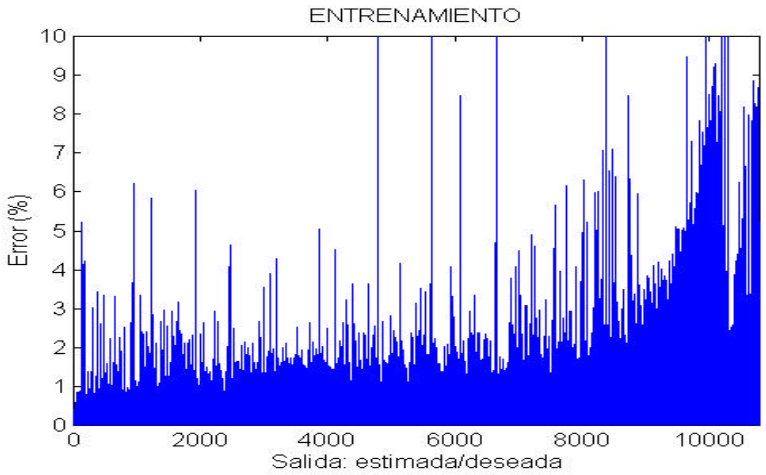

a. Error porcentual en el cálculo de sobretensiones.

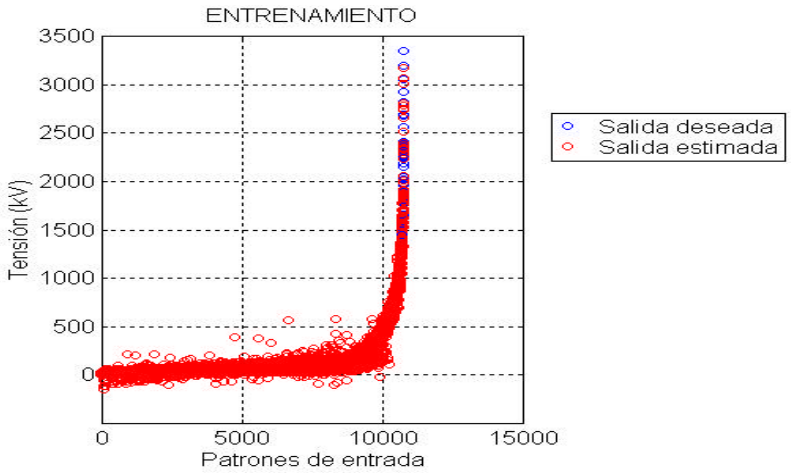

b. Ajuste de las salidas (tensiones).

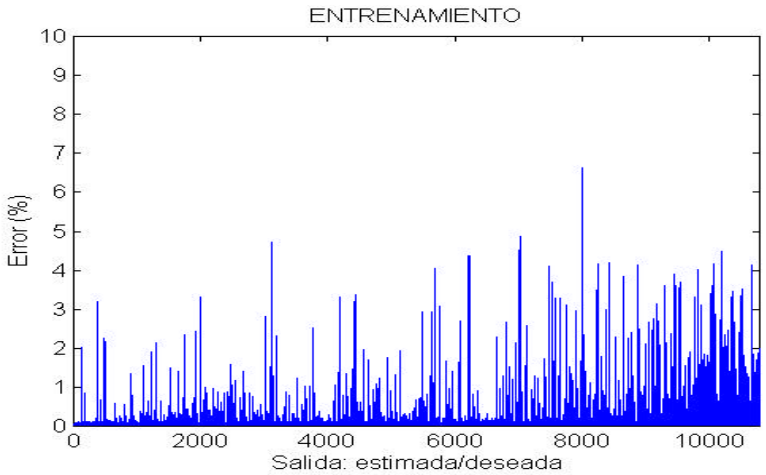

c. Error porcentual en la clasificación de descargas.

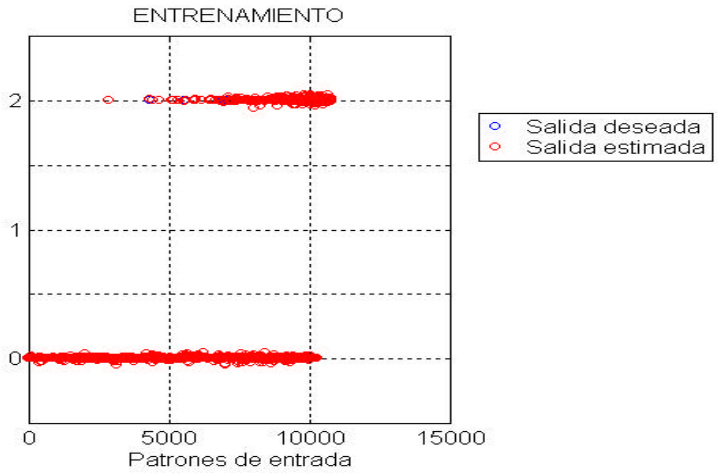

d. Ajuste del clasificador.

Figura 6.58. Entrenamiento de la red neuronal.

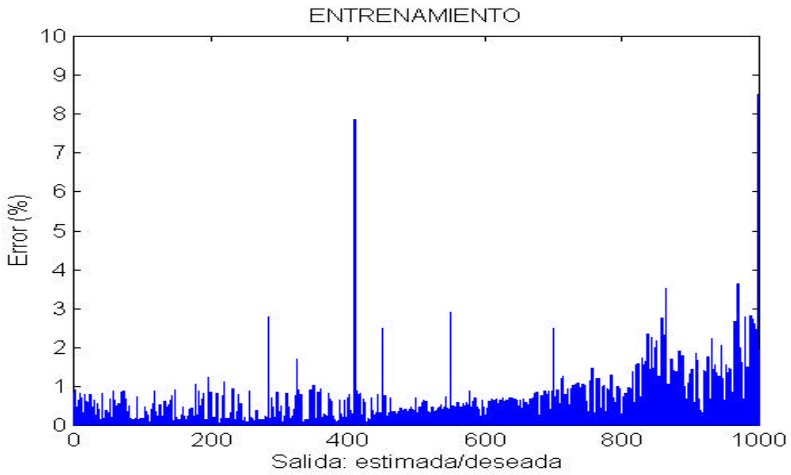

a. Error porcentual en el cálculo de sobretensiones.

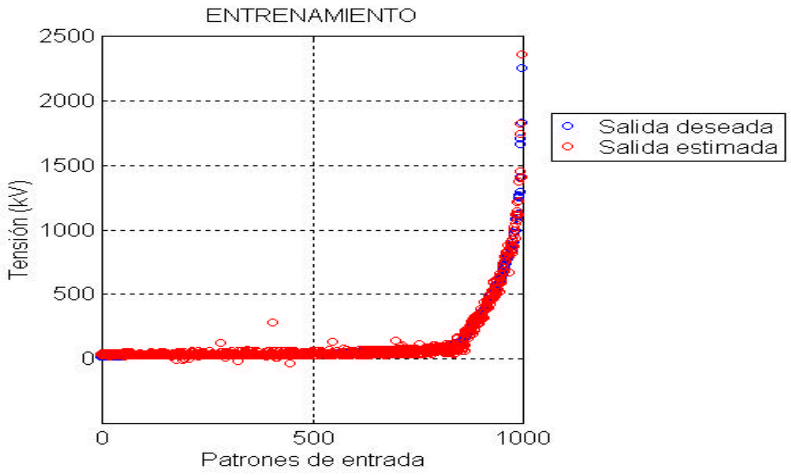

b. Ajuste de las salidas (tensiones).

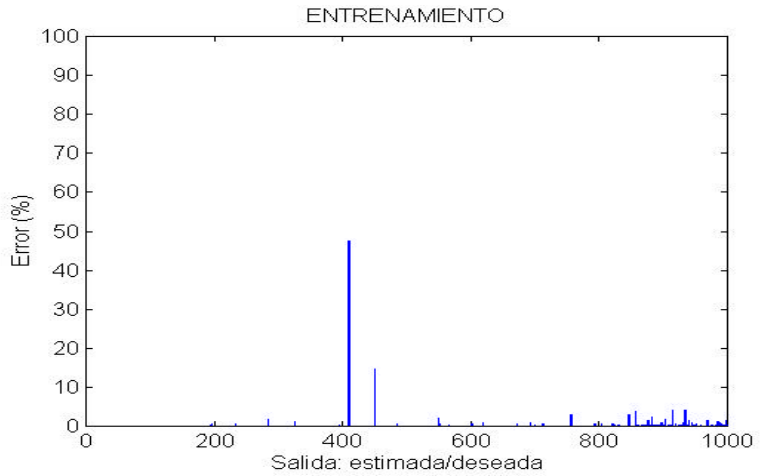

c. Error porcentual en la clasificación de descargas.

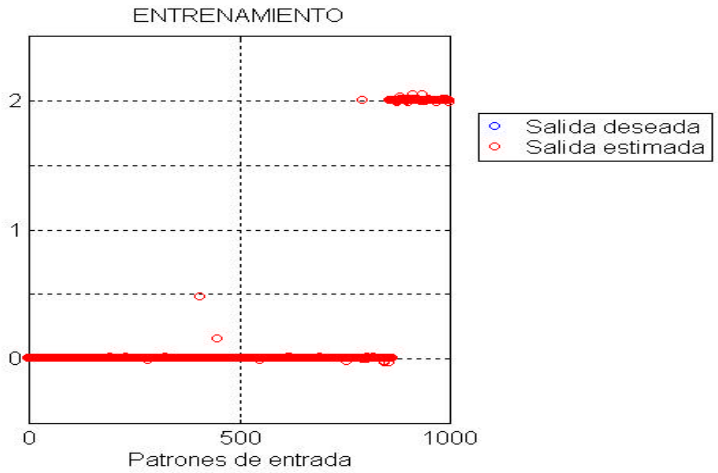

d. Ajuste del clasificador.

Figura 6.59. Validación de la red neuronal. Línea horizontal, altura conductores = 10 m, distancia entre conductores más externos = 4 m, altura cable de tierra = 11.5 m, resistencia de puesta a tierra = 50 Ω, W = 200.

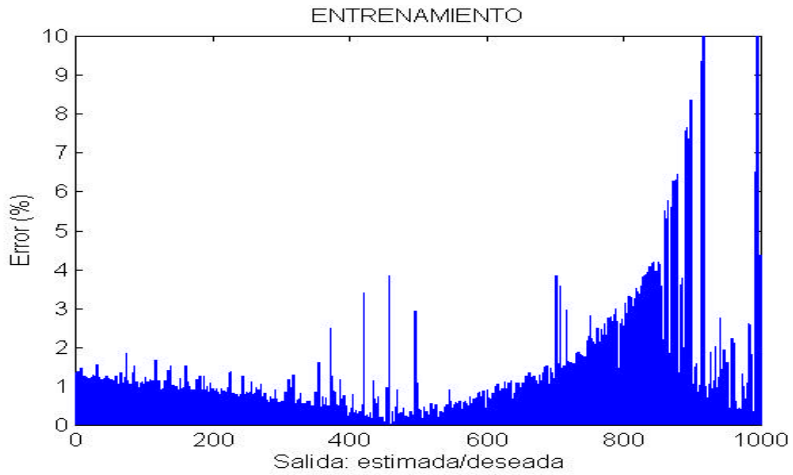

a. Error porcentual en el cálculo de sobretensiones.

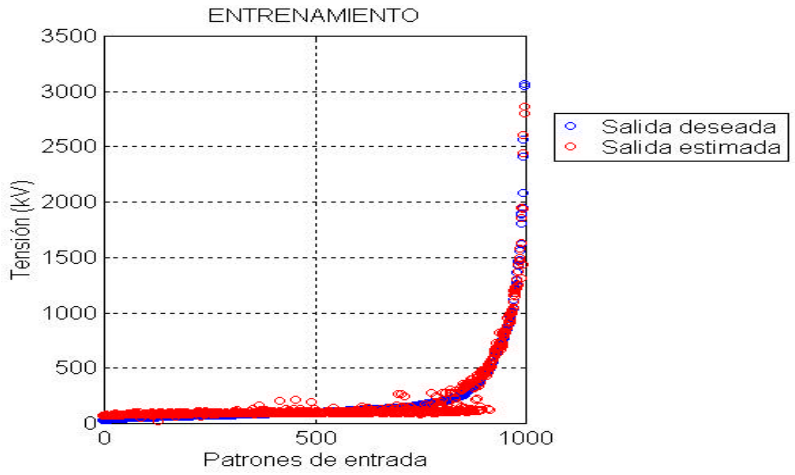

b. Ajuste de las salidas (tensiones).

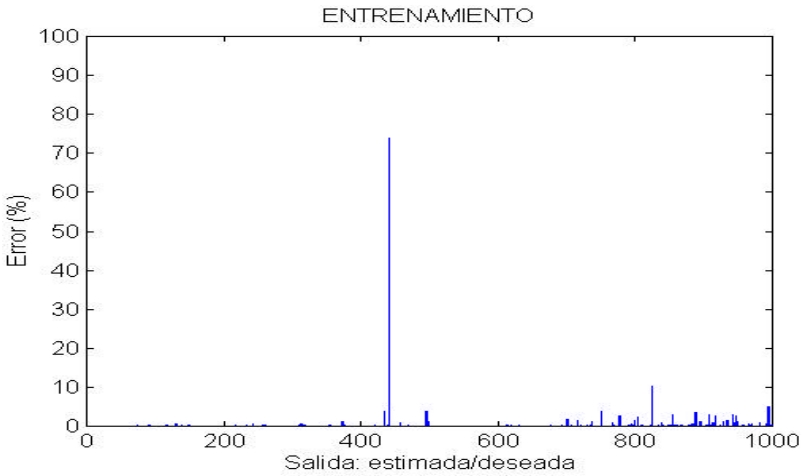

c. Error porcentual en la clasificación de descargas.

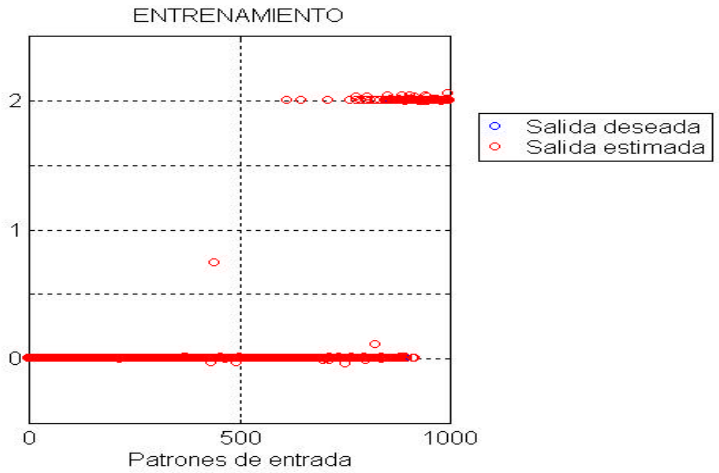

d. Ajuste del clasificador.

Figura 6.60. Validación de la red neuronal. Línea vertical, altura c1 =10 m, altura c2 =12 m, altura c3 =14 m, distancia horizontal conductores - cable de tierra = 1 m, altura cable de tierra = 15.5 m, resistencia de puesta a tierra = 50 Ω, W = 500.

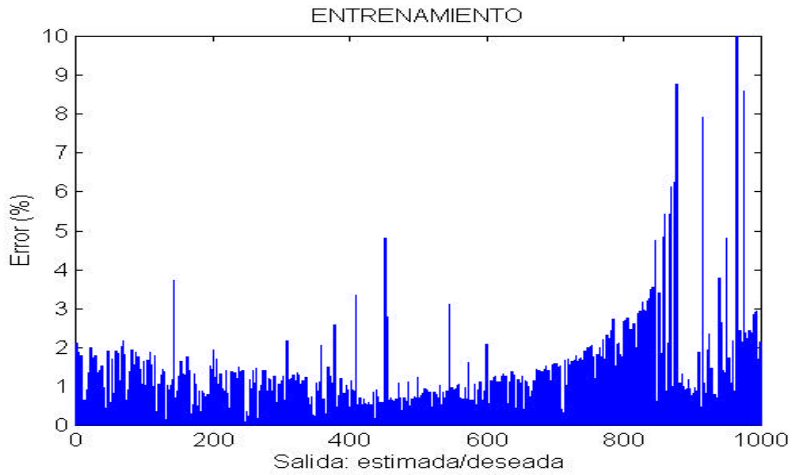

a. Error porcentual en el cálculo de sobretensiones.

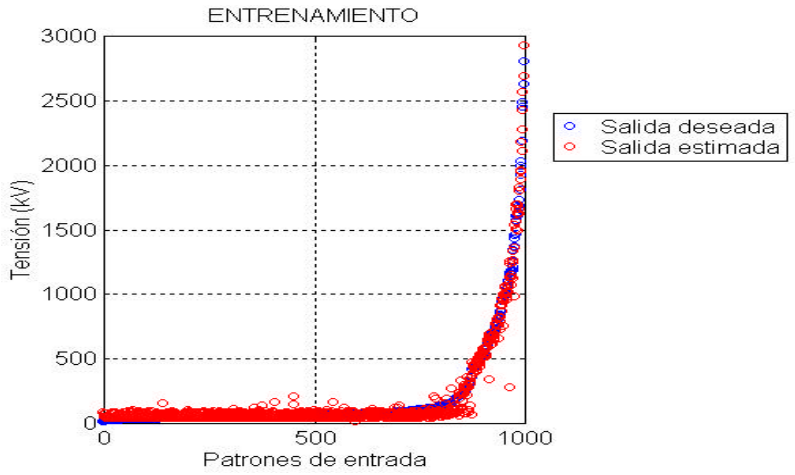

b. Ajuste de las salidas (tensiones).

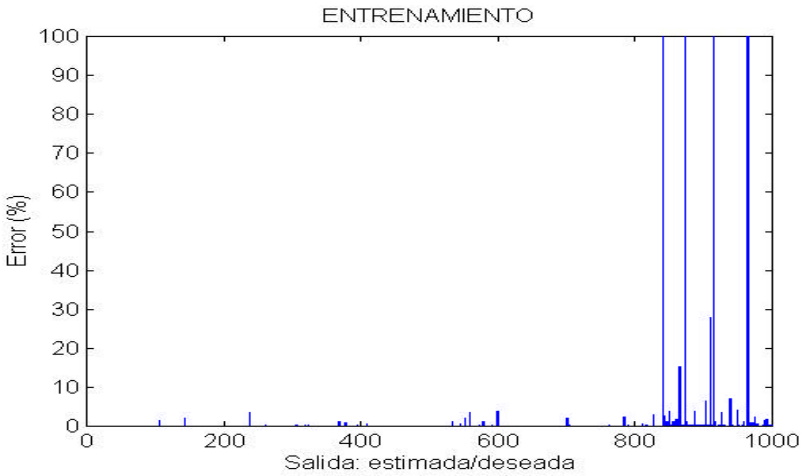

c. Error porcentual en la clasificación de descargas.

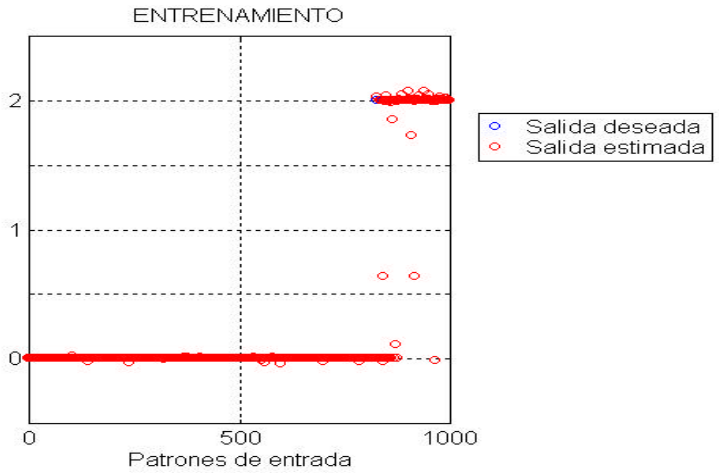

d. Ajuste del clasificador.

Figura 6.61. Validación de la red neuronal. Línea vertical, altura c1 =14 m, altura c2 =16 m, altura c3 =18 m, distancia horizontal conductores - cable de tierra = 1.5 m, altura cable de tierra = 19.5 m, resistencia de puesta a tierra = 70 Ω, W = 200.