

De manera que al contar en tiempo real con los valores de niveles en el punto PN4, por ejemplo a las 2, 3, y 4 horas, se puedan predecir los valores de los niveles que se tendrán a las 5,6 y 7 horas en el punto PN5, si el intervalo de tiempo de medición es de una hora.

3.2.3 PREPROCESAMIENTO DE LOS DATOS Y FORMACIÓN DE PATRONES

El preprocesamiento se realiza para formar y normalizar los vectores de entrada y salida de cada ejemplo. Cada pareja de ejemplos debe formarse siguiendo el mismo orden de los datos establecido en la estructura de la red. Para facilitar la formación de las parejas de datos de entrada y salida se hizo una tabla guía (ver Tabla 3.2). Con base a la Tabla 3.2, y utilizando los valores de la Tabla 3.1, se formó la Tabla 3.3. Los datos de esta tabla, normalizados, son los que se introducen al programa Backprop, eliminando las dos primeras columnas. La normalización, esto es, transformar los datos en un rango de 0 a 1, puede hacerse por distintos procedimientos. En el caso de que los niveles sean de 0 a 10, como en este ejemplo los datos simplemente fueron divididos entre 10.

3.2.4 ENTRENAMIENTO Y PREDICCIÓN

Una vez formada la tabla de patrones de datos normalizados, se puede iniciar el procedimiento iterativo de modificar los pesos; esto es, el entrenamiento. Se trata de encontrar el número adecuado de ciclos para lograr el mejor funcionamiento de la red, en su respuesta a eventos conocidos, no usados en el entrenamiento (predicción a posteriori).

Se requiere realizar varias pruebas para acercarse al número apropiado de ciclos, de acuerdo al error de predicción. Si el error de predicción es aceptable la red se puede utilizar en predicciones a priori. Esto se hizo de la siguiente manera.

El programa Backprop, permite dar un número de ciclos dado, y calcula un error de ajuste promedio para cada pareja de datos. Se hicieron corridas para 500, 1000 y 1500 ciclos. Y posteriormente con las matrices de datos obtenidas, en cada caso, se hizo la predicción de la avenida 4 de la Tabla 3.1, la cual no se introdujo en los datos de entrenamiento. La predicción del evento 4 de la Tabla 3.1 fue mejor con las matrices obtenidas para 1000 ciclos (ver Tabla 3.4).

En la tabla 3.5 se muestra una comparación de los valores obtenidos por el modelo con los valores dato. Nótese que los errores de predicción son

aceptables. Esto se debe a que el evento 4 es similar a los de entrenamiento. La capacidad de predicción de la red aumenta si es entrenada con una mayor diversidad de ejemplos.

3.2.5 USO DEL PROGRAMA DE CÓMPUTO

A continuación se presentan los pasos para el uso del programa Backprop. El programa corre en ambiente ms-dos.

1. Los datos de la Tabla 3.3 normalizados, eliminando las dos primeras columnas, se deben codificar en un archivo de texto con nombre DATA.DAT, el cual lo toma el programa automáticamente.
2. Inicialmente se debe indicar al programa si se realizará entrenamiento (0) o si se utilizará para predicción (1). Se debe empezar por el entrenamiento.
3. Posteriormente el programa pide los datos de: a) número de capas: 3 para el ejemplo. b) número de neuronas en cada capa: 3,3,3 para el ejemplo. c) valor de un coeficiente de rapidez de entrenamiento: el programa sugiere usar 0.2. d) número de ciclos: 500, para la primera prueba. Las matrices de pesos las guarda el programa en un archivo llamado WEIGHTS.DAT
4. Posteriormente se usan los mismos parámetros para una prueba de 1000 y 1500 ciclos. Para cada prueba se utiliza el programa en (1) esto es en predicción, utilizando el archivo de pesos correspondiente y como datos de entrada la Tabla 3.5 pero solo las columnas correspondientes a PN4. Estos datos se forman como en el paso 1 y también debe nombrarse el archivo como DATA.DAT (el archivo anterior puede guardarse con otro nombre). los resultados de predicción se guardan en el archivo EXIT.DAT
5. Los resultados de cada predicción se comparan con los datos, como en la Tabla 3.5. Para encontrar el número de ciclos apropiado. En el ejemplo se encontró que la mejor predicción fue para 1000 ciclos.

Puntos de medición de niveles y sus gráficas

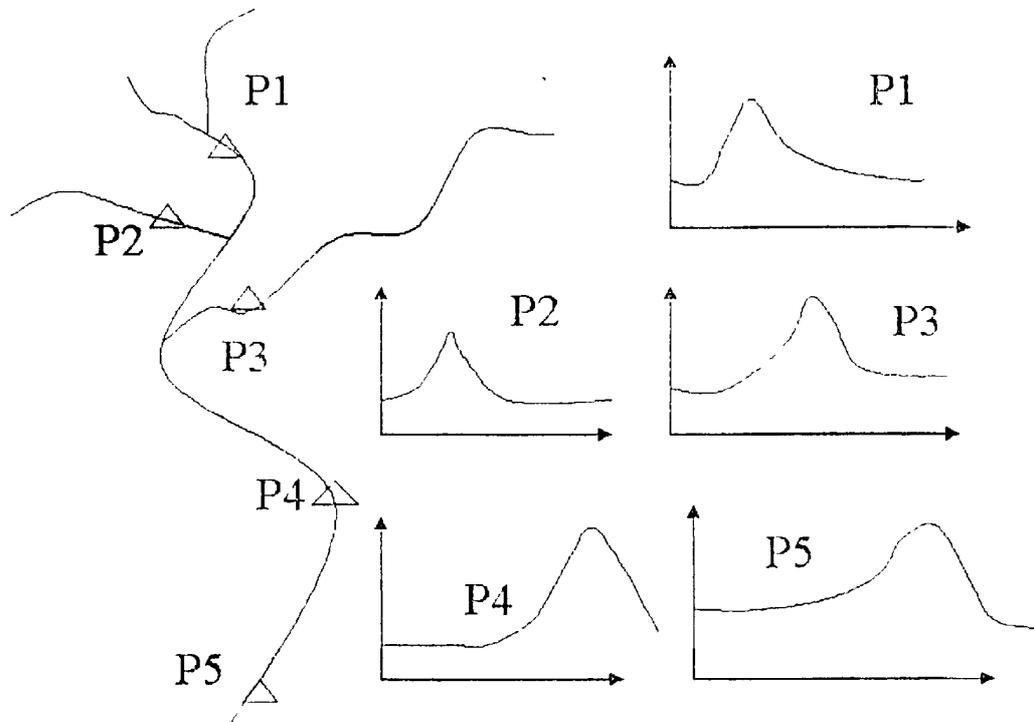


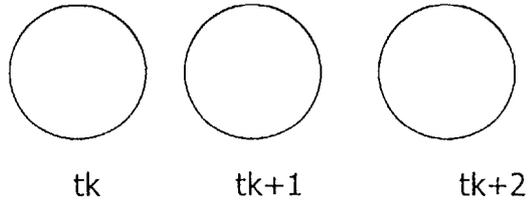
Figura 2

Figura 3.2

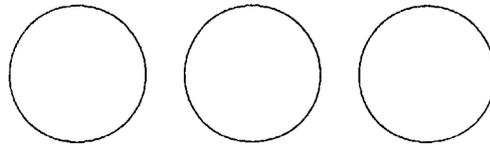
EJEMPLO NUMERICO

PATRON DE ENTRADA

PN4



PATRON INTERMEDIO



PATRON DE SALIDA

PN5

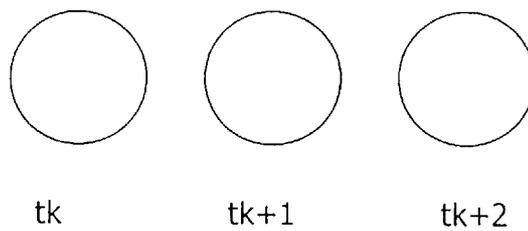


Figura 3.3

Tabla 3.1

Datos de niveles de 4 avenidas

Avenida	Puntos	t ₀	t ₁	t ₂	t ₃	t ₄	t ₄	t ₆	t ₇	t ₈	t ₉	t ₁₀
1	PN4	1	3	5	6	6	4	2	4	6	3	2
1	PN5	1	1	1	3	4	5	5	4	4	5	4
2	PN4	1	1	2	6	7	6	5	6	6	4	2
2	PN5	1	1	1	1	3	4	5	5	6	5	4
3	PN4	1	1	5	7	4	3	6	8	6	4	3
3	PN5	1	1	1	2	4	4	3	5	6	5	4
4	PN4	1	3	8	6	4	4	7	6	3	2	1
4	PN5	1	1	2	4	5	5	5	6	6	5	4

Tabla 3.2

Tabla guía para la formación de los datos de entrada al programa

Evento o avenida	Indice k	PN4 t _k	PN4 t _{k+1}	PN4 t _{k+2}	PN5 t _{k+3}	PN5 t _{k+4}	PN5 t _{k+5}
1	0	t ₀	t ₁	t ₂	t ₃	t ₄	t ₅
1	1	t ₁	t ₂	t ₃	t ₄	t ₅	t ₆
1	2	t ₂	t ₃	t ₄	t ₅	t ₆	t ₇
1	3	t ₃	t ₄	t ₅	t ₆	t ₇	t ₈
1	4	t ₄	t ₅	t ₆	t ₇	t ₈	t ₉
1	5	t ₅	t ₆	t ₇	t ₈	t ₉	t ₁₀
1	n	t _n	t _{n+1}	t _{n+2}	t _{n+3}	t _{n+4}	t _{n+5}

Tabla 3.3

Tabla de datos entrada al programa

Evento o avenida	Indice k	PN4 tk	PN4 tk+1	PN4 tk+2	PN5 tk+3	PN5 tk+4	PN5 tk+5
1	0	1	3	5	3	4	5
1	1	3	5	6	4	5	5
1	2	5	6	6	5	5	4
1	3	6	6	4	5	4	4
1	4	6	4	2	4	4	5
1	5	4	2	4	4	5	4
1	6	2	4	6	5	4	4
2	0	1	1	2	1	3	4
2	1	1	2	6	3	4	5
2	2	2	6	7	4	5	5
2	3	6	7	6	5	5	6
2	4	7	6	5	5	6	5
2	5	6	5	6	6	5	4
2	6	5	6	6	5	4	4
3	0	1	1	5	2	4	4
3	1	1	5	7	4	4	3
3	2	5	7	4	4	3	5
3	3	7	4	3	3	5	6
3	4	4	3	6	5	6	5
3	5	3	6	8	6	5	4
3	6	6	8	6	5	4	4

Tabla 3.4

Matrices de pesos obtenidas para 1000 ciclos

					M1[i, j]				
	1	2	3	4	5	6	7	8	9
1	0.124	0.012	0.083	0.467	0.223	0.432	0.367	0.446	0.667
2	0.224	0.666	0.899	0.123	0.446	0.433	0.766	0.467	0.438
3	0.334	0.123	0.445	0.693	0.968	0.331	0.669	0.444	0.633
					M2[i, j]				
	1	2	3	4	5	6	7	8	9
1	0.235	0.569	0.896	0.678	0.346	0.226	0.654	0.336	0.694
2	0.339	0.785	0.563	0.879	0.854	0.639	0.998	0.536	0.631
3	0.851	0.754	0.236	0.563	0.008	0.445	0.569	0.057	0.495

Tabla 3.5

Comparación de resultados de predicción y valores dato

Evento o avenida	Indice k	PN4 tk	PN4 tk+1	PN4 tk+2	PN5 tk+3	PN5 tk+4	PN5 tk+5	Dato o predicción
4	0	1	3	8	4	5	5	dato
					3.8	5.2	5.6	pred
4	1	3	8	6	5	5	5	dato
					4.3	4.8	5.5	pred
4	2	8	6	4	5	5	6	dato
					5.3	5.2	6.4	pred
4	3	6	6	4	5	6	6	dato
					4.5	5.7	6.8	pred
4	4	4	4	7	6	6	5	dato
					5.6	5.7	5.5	pred
4	5	4	7	6	6	5	4	dato
					5.6	5.3	4.4	pred
4	6	7	6	3	5	4	4	dato
					4.7	4.5	4.6	pred

3.3 DISEÑO DE PROPUESTA, MADRE VIEJA

Por las características Geomorfológicas de la cuenca y tomando en cuenta los sitios de mayor vulnerabilidad que se encuentran en la parte media y baja de la cuenca, un sistema de alerta temprana para los sitios de mayor riesgo se puede establecer principalmente con base a mediciones de niveles en los ríos.

3.3.1 PUNTOS DE MEDICIÓN

Los sitios que se proponen a continuación se indican en el mapa anexo con triángulos.

- Río Los Molinos. Puente de la carretera Godínez – Xepatán.
- Río Los Chocoyos. Puente de la carretera Godínez – Xepatán.
- Río Madre Vieja. Puente en el camino de la Finca Sajoma San Jorge.
- Río San Jorge . Vado en la Finca San Jorge.
- Río Santa Teresa. Vado en la finca Santa Teresa.
- Río Quixayá. Puente ruta nacional Patulul – Godínez.
- Río Los Farrales. Puente ruta nacional Patulul – Godínez.
- Río San Lázaro–Lutiyá. Puente ruta nacional Patutul–Godínez.
- Patulul. Puente ruta nacional Patulul – Godínez.
- Río Susu. Puente en la población San Juan Bautista.

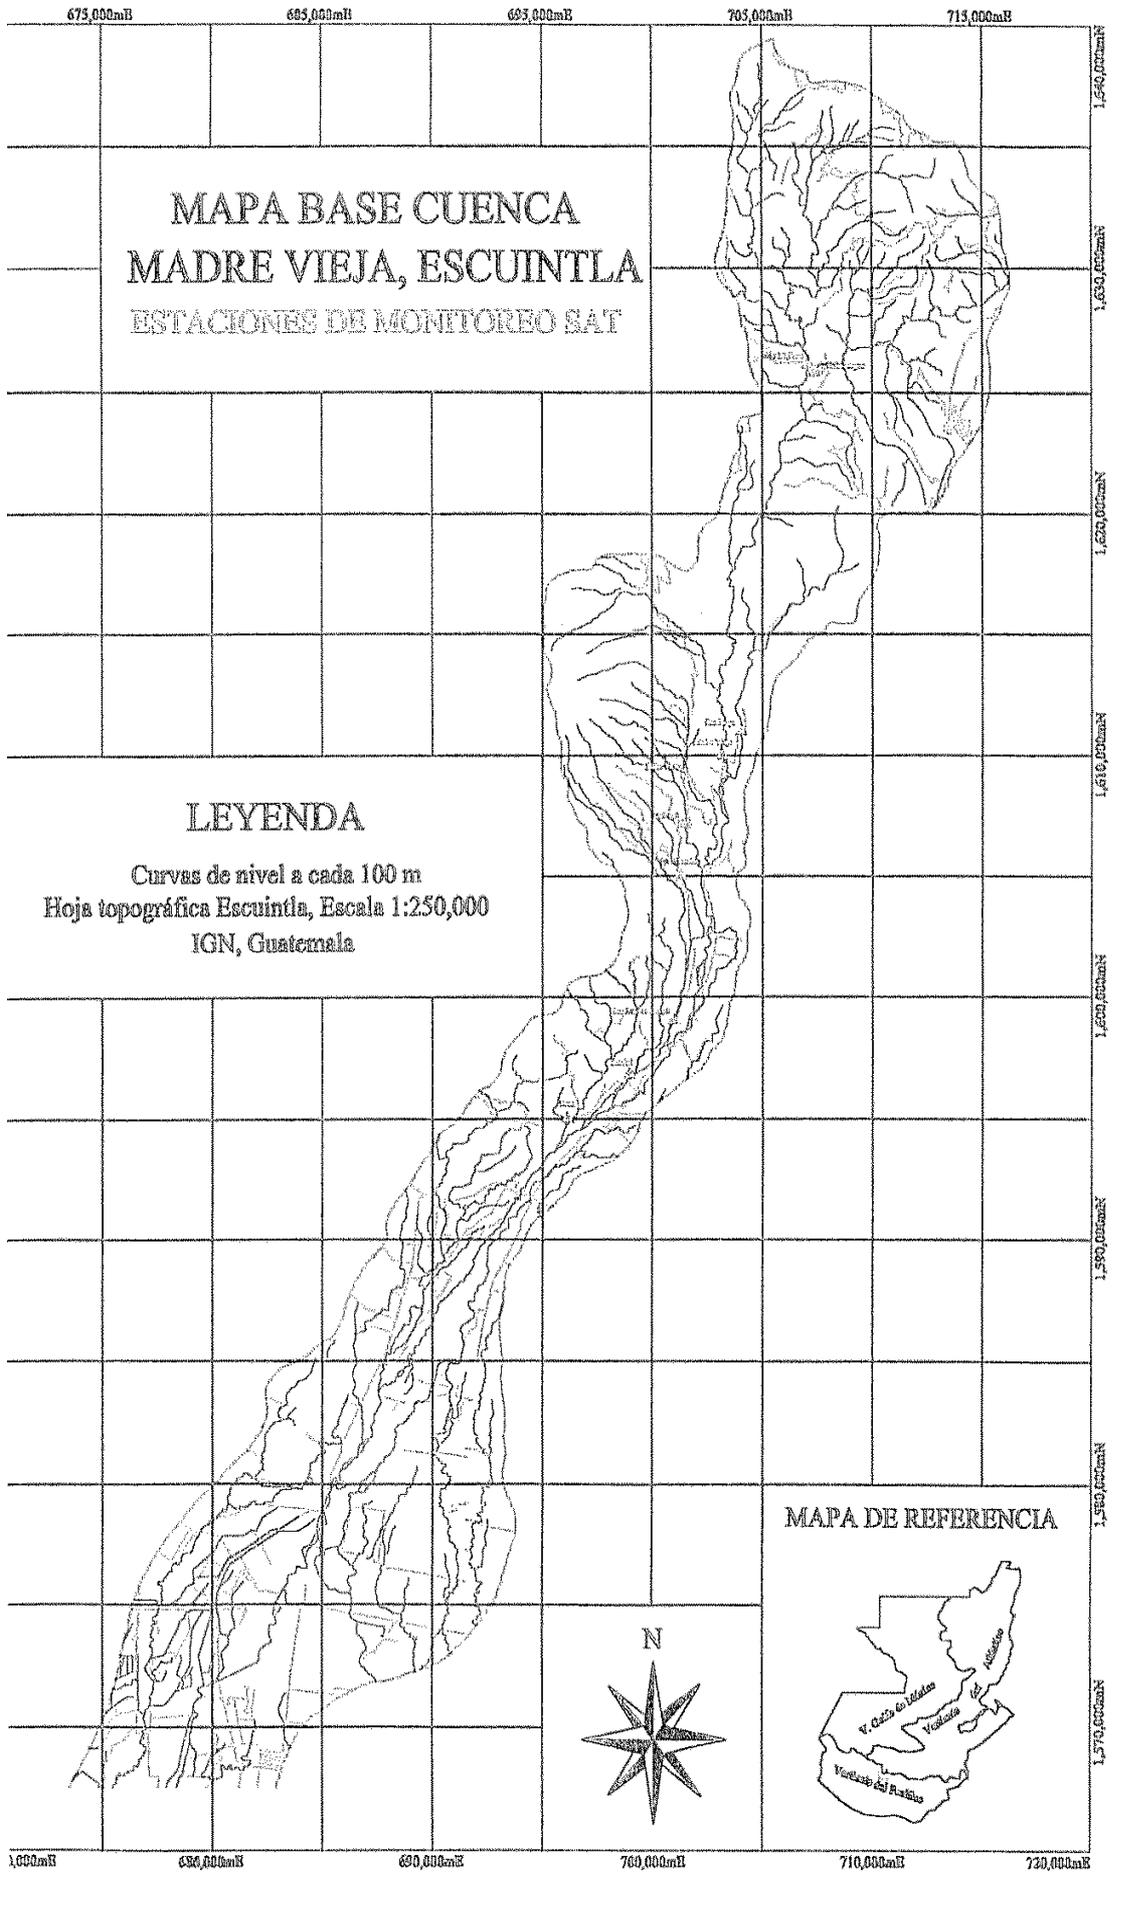
3.3.2 INSTRUMENTOS DE MEDICIÓN

Los instrumentos de medición pueden ser sensores, como los que ha instalado CONRED en la cuenca del río Coyolate o simplemente Escalas de nivel que un operador pueda observar, para registrar el dato y reportarlo.

3.3.2.1 Medición

La medición tiene que hacerse regularmente, cada una o dos horas cuando exista una crecida. Es necesario llevar un registro escrito del dato sitio, aunque este no sea transmitido por vía radio. Sólo con un registro metódico, se podrán utilizar los datos para establecer criterios empíricos de alarma y para calibrar modelos numéricos como el que se propondrá más adelante.

El objetivo de la medición será generar tablas como la siguiente para cada avenida o crecida que ocurra.

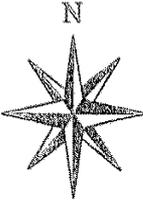


**MAPA BASE CUENCA
MADRE VIEJA, ESCUINTLA**
ESTACIONES DE MONITOREO SAT

LEYENDA

Curvas de nivel a cada 100 m
Hoja topográfica Escuintla, Escala 1:250,000
IGN, Guatemala

MAPA DE REFERENCIA



Puntos	t0	t1	t2	t3	ti	tn
P1	1	1	2	3	1	1
P2	1	2	3	4	3	1
P3	2	3	4	5	2	1
...	3	3	4	5	4	2
P10	2	2	3	4	5	2

3.3.3 OPERACIÓN DEL SISTEMA DE ALERTA

Dado que las poblaciones más vulnerables se encuentran aguas abajo de Patulul el sistema que se propone tiene como objetivo dar una alerta temprana con una anticipación de al menos cinco horas a la población de Patulul, y con tiempo mayor a poblaciones aguas más abajo.

3.3.3.1 Alerta empírica:

Una vez instalados los sensores o escalas en los sitios mencionados, se establecerán de manera tentativa niveles mínimos de alertamiento. Los cuales se calibrarán con la adquisición de datos. Los sitios de emisión de alarma son los siguientes:

- Río Madre Vieja
- Río San Jorge
- Río Santa Teresa
- Río Quixayá
- Río Los Farrales

Contando con tablas de datos como la que se muestra anteriormente, será posible adecuar los niveles mínimos críticos en cada sitio mencionado para emitir la alarma.

3.3.3.2 Alerta mediante modelos matemáticos:

El propósito de utilizar un modelo matemático para dar una señal de alarma es dar valores cuantitativos de los niveles que alcanzará el río, por ejemplo en la población de Patulul, con varias horas de anticipación,

basándose en los niveles que han alcanzado los ríos mencionados en los sitios de medición.

Para esto se requiere como se menciona en la metodología.

- Seleccionar el modelo
- Contar con datos para calibrar el modelo
- Aplicación del modelo a la predicción

El modelo que se propone usar es un modelo de redes neuronales. Como no se cuenta con datos no es posible calibrarlo. Se mostrará la calibración de un modelo como el mencionado para la cuenca del río Villalobos. Una vez calibrado el modelo para su aplicación en predicción es necesario contar con datos de entrada de manera inmediata, para poder emitir la alarma de acuerdo a los resultados del modelo.

3.4 MODELO CUENCA MADRE VIEJA

3.4.1 PROPÓSITO DEL MODELO

Se propone el diseño de un modelo que permita transitar avenidas de los Puntos de medición de Niveles propuestos con anterioridad PN3 (Río Madre Vieja), PN4 (Río San Jorge), PN5 (Río Santa Teresa), PN6 (Río Quixayá), PN7 (Río Los Farrales) al sitio PN9 (Río Madre Vieja en Patulul), con el propósito de utilizarlo para la predicción de niveles. Esto es que, que con base en la evolución de los niveles que se presentan en los puntos PN3, PN4, PN5, PN6 y PN7 obtenga con anticipación una estimación confiable de los niveles que se presentarán en el punto PN9. Para esta cuenca se propone un intervalo de tiempo de medición de valores de una hora.

3.4.2 TAMAÑO DE LA RED Y ESTRUCTURA DE DATOS

Se propone una red como la que se muestra en la Figura 3.4. Tres capas con tres neuronas en cada una. Las matrices de pesos serán por consiguiente $M1[15,3]$ y $M2[3,3]$. La estructura de los datos se indica debajo de cada neurona. Con esta estructura se pretende que la red correlacione los vectores de entrada (t_k, t_{k+1}, t_{k+2}) en los puntos PN3, PN4, PN5, PN6 y PN7, con los vectores $(t_{k+3}, t_{k+4}, t_{k+5})$ en el punto PN9. Lo cual se hace mediante el proceso denominado entrenamiento. Una vez obtenidas las matrices de pesos, es posible utilizar la red en predicciones a priori.

3.4.3 FORMACIÓN DE PATRONES

Cada pareja de ejemplos debe formarse siguiendo el mismo orden de los datos establecido en la estructura de la red. Contando con una tabla de datos de los puntos PN3, PN4, PN5, PN6, PN7 y PN9 ordenados como en la tabla 2.1 del ejemplo numérico. La formación de los patrones de datos de entrada y salida se indica en una tabla guía (ver Tabla 3.4). Los datos de esta tabla, normalizados, son los que se introducen al programa Backprop, eliminando las dos primeras columnas. El programa solicita el número de capas y de neuronas en cada capa.

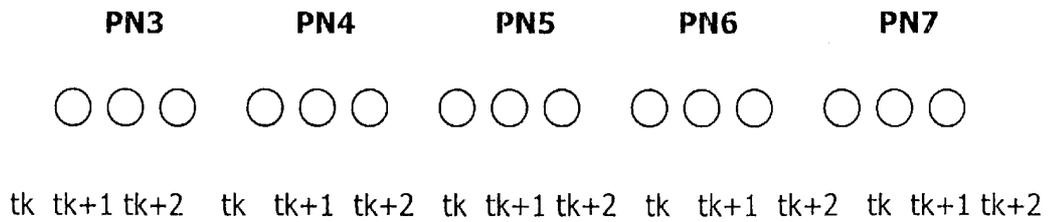
3.4.4 ENTRENAMIENTO Y PREDICCIÓN

Una vez formada la tabla de patrones de datos normalizados, se inicia el procedimiento iterativo de modificar los pesos; esto es, el entrenamiento. Se debe encontrar el número adecuado de ciclos para lograr el mejor funcionamiento de la red, en su respuesta a eventos conocidos, no usados en el entrenamiento (predicción a posteriori). Una vez hecho este procedimiento la red puede usarse en predicciones a priori, contando con datos de los sitios de entrada en el menor tiempo posible después de que se generan.

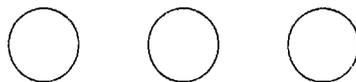
MADRE VIEJA

TAMAÑO Y ESTRUCTURA DE DATOS DE LA RED

PATRON DE ENTRADA



PATRON INTERMEDIO



PATRON DE SALIDA

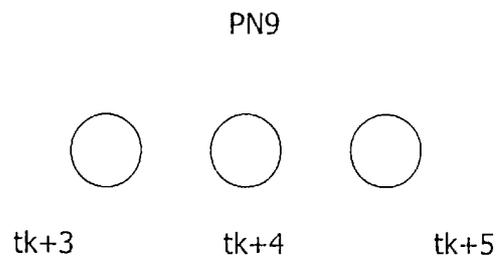


Figura 3.4

Tabla 3.6

Evento o avenida	Indice k	PN3 tk	PN3 tk+1	PN3 tk+2	PN4 tk	PN4 tk+1	PN4 tk+2
1	0	t0	t1	t2	t0	t1	t2
1	1	t1	t2	t3	t1	t2	t3
1	2	t2	t3	t4	t2	t3	t4
1	3	t3	t4	t5	t3	t4	t5
1	4	t4	t5	t6	t4	t5	t6
1	5	t5	t6	t7	t5	t6	t7
1	n	tn	tn+1	tn+2	tn	tn+1	tn+2

Tabla 3.7

Evento o avenida	Indice k	PN5 tk	PN5 tk+1	PN5 tk+2	PN6 tk	PN6 tk+1	PN6 tk+2
1	0	t0	t1	t2	t0	t1	t2
1	1	t1	t2	t3	t1	t2	t3
1	2	t2	t3	t4	t2	t3	t4
1	3	t3	t4	t5	t3	t4	t5
1	4	t4	t5	t6	t4	t5	t6
1	5	t5	t6	t7	t5	t6	t7
1	n	tn	tn+1	tn+2	tn	tn+1	tn+2

Tabla 3.7

Evento o avenida	Indice k	PN7 tk	PN7 tk+1	PN7 tk+2	PN9 tk+3	PN9 tk+4	PN9 tk+5
1	0	t0	t1	t2	t3	t4	t5
1	1	t1	t2	t3	t4	t5	t6
1	2	t2	t3	t4	t5	t6	t7
1	3	t3	t4	t5	t6	t7	t8
1	4	t4	t5	t6	t7	t8	t9
1	5	t5	t6	t7	t8	t9	t10
1	n	tn	tn+1	tn+2	tn+3	tn+4	tn+5

4 REFERENCIAS

Daniell, T.M., 1991. Neural networks: Applications in Hidrology and Water Resources Engineering. International Hydrology & Water resources Symposium, pp. 797-802, Perth 2-4, October 1991.

Fu, L.M., 1994. Neural networks in computer intelligence. McGraw-Hill, Inc.
Minsky, M., and S. Papert, 1988. Perceptrons, MIT Press, Cambridge, Mass., 1969. (Expanded edition, Cambridge, Mass.)

Linsley, R., Kohler, M. and Paulhus, J., 1982, Hydrology for engineers, McGraw-Hill Company, New York.

Ortega-Ruiz, R., 1993. Identificación del primer arribo de fase S mediante redes neuronales. Memorias del X congreso nacional de ingeniería sísmica, Puerto Vallarta, Jal. México.

Rao V. B. and Rao H. V., 1993. C++ neural networks and fuzzy logic. ed. MIS: Press, New York, USA, 408 pp.

Ruiz-Suarez, J.C., R. Smith, J. Torres and L.G. Ruiz, 1994. Short-term forecasting of ozono by means of a bidirectional associative memory. In AIENG 94, Computational Mechanics Publications.

Rumelhart, D. E., J. L. MacClelland, and de PDP Research Group, 1986. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, vol. 1, MIT Press, Cambridge, Mass.

The Integrated Land and Water Information System (ILWIS), 1997, Applications guide, v. 2.1 for Windows, International Institute for Aerospace Survey & Earth Sciences, Enschede, The Netherlands.

Toledo, V., 1994. Redes neuronales y predicción hidrológica. Instituto Mexicano de Tecnología del Agua. México.

Toledo, V. , 1996. Predicción de escurrimientos usando redes neuronales. Memorias del XVII congreso Latinoamericano de Ingeniería Hidráulica. Guayaquil, Ecuador.

Toledo, V., 1997. Redes Neuronales en modelado hidrológico: predicción de avenidas en la presa Huites. Tesis de maestría en ingeniería hidráulica, DEPFI, Universidad Nacional Autónoma de México.

Winjker, L., 2000, Apuntes del curso "Geo-hazard zonation using GIS for the Central American Region", Regional Action Program Central America RAP-CA, International Institute for Aerospace Survey & Earth Sciences, Enschede, The Netherlands.