

01162



**UNIVERSIDAD NACIONAL AUTONOMA  
DE MEXICO**



**DIVISION DE ESTUDIOS DE POSGRADO  
FACULTAD DE INGENIERIA**

**REDES NEURONALES EN MODELADO  
HIDROLOGICO: PREDICCIÓN DE AVENIDAS  
EN LA PRESA HUITES**

**TESIS**

PRESENTADA POR:

**VICTOR RICARDO TOLEDO REYES**

COMO REQUISITO PARA OBTENER EL GRADO DE  
**MAESTRO EN INGENIERIA**  
**(HIDRAULICA)**

TESIS CON  
FALLA DE ORIGEN

MEXICO, D. F., 1997



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

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

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

*A Lourdes, Adelina y Valeria*

## **Agradecimientos**

El presente trabajo se realizó en gran parte en el Instituto Mexicano de Tecnología del Agua en 1995, como un proyecto de desarrollo, y se concluyó a tiempo parcial en 1996 en el Servicio Meteorológico Nacional. Agradezco a dichas instituciones las facilidades brindadas para su realización.

Asimismo, agradezco al M. en I. Jorge Sánchez Sesma, su interés, apoyo, y valiosas sugerencias hechas para el desarrollo de este trabajo. Inicialmente como colega y, posteriormente, como director de tesis. De igual manera, a los miembros del jurado revisor: Dr. Ramón Domínguez, Dr. Carlos Escalante, M. en C. Carlos Gutiérrez y M. en I. Mauricio Escalante, por la lectura del trabajo y sus valiosos comentarios, los cuales me fueron de gran utilidad para concluir esta tesis.

## INDICE

Resumen .....	ix
Introducción .....	xi
1. Predicción hidrológica	
1.1. Tipos de predicción hidrológica .....	1
1.2. Predicción de avenidas en México .....	2
1.2.1. Sistemas para la predicción de avenidas .....	2
1.2.2. Predicción de avenidas en algunas cuencas grandes ..	3
2. Redes neuronales	
2.1. Redes neuronales computacionales .....	5
2.2. Origen y desarrollo de las redes neuronales .....	6
2.3. Redes neuronales en ciencias de la tierra y en hidrología .....	6
2.4. Clases y tipos de redes neuronales .....	7
2.5. Red neuronal de retropropagación .....	8
2.5.1. Procedimiento de cálculo y entrenamiento .....	9
2.5.2. Obtención de las ecuaciones de entrenamiento.....	12
2.5.3. Programa de cómputo utilizado .....	16
3. Emulación de dos modelos hidrológicos con redes neuronales	
3.1. Modelado de sistemas con redes neuronales .....	17
3.1.1. Modelado de sistemas .....	17
3.1.2. Redes neuronales como modelos matemáticos .....	17
3.1.3. Entrenamiento y generalización .....	17
3.2. Construcción de un modelo de red de retropropagación .....	18
3.2.1. Arquitectura y tamaño de la red .....	18
3.2.2. Preprocesamiento de los datos y formación de patrones	18
3.2.3. Entrenamiento .....	19
3.3. Dos modelos matemáticos hidrológicos clásicos .....	19

3.4.	Emulación del modelo de Hidrogramas Unitarios .....	20
3.4.1.	El modelo de hidrogramas unitarios .....	20
3.4.2.	Datos, tamaño de la red y formación de patrones .....	20
3.4.3.	Entrenamiento y generalización .....	21
3.5.	Emulación del modelo Muskingum .....	22
3.5.1.	El modelo Muskingum .....	22
3.5.2.	Datos, tamaño de la red y formación de Patrones .....	23
3.5.3.	Entrenamiento y generalización .....	23
3.6.	Discusión de resultados .....	24
4.	La cuenca de la presa Huites	
4.1.	La presa Huites .....	25
4.2.	La cuenca de la presa Huites .....	27
4.2.1.	Precipitación .....	28
4.2.2.	Características de las lluvias de invierno y las de verano	29
4.2.3.	Evaporación potencial .....	31
4.2.4.	Avenidas extremas registradas en el sitio de la presa	32
5.	Análisis del proceso de lluvia-escorrimento de invierno en la cuenca	
5.1.	Estimación óptima de la precipitación .....	34
5.2.	Cálculo de valores puntuales y precipitación media .....	36
5.3.	Gráficas de lluvia-escorrimento .....	39
5.4.	Volúmenes de lluvia, escurrimento y pérdidas .....	40
6.	Modelación del proceso lluvia-escorrimento de invierno en la cuenca	
6.1.	Consideraciones o hipótesis básicas para la modelación .....	42
6.2.	Construcción de los modelos de redes .....	43
6.2.1.	Arquitectura y tamaño de la red .....	43
6.2.2.	Preprocesamiento de los datos y formación de patrones	44
6.2.3.	Entrenamiento .....	45

6.3. Pruebas de homogeneidad de datos y tamaño de red .....	46
6.4. Pruebas de predicción a posteriori .....	52
6.5. Discusión de resultados .....	56
6.6. Posibilidad de predicción a priori .....	59
Conclusiones .....	61
Referencias .....	63
<b>Anexos</b>	
Anexo 1 .....	70
Anexo 2 .....	72
Anexo 3 .....	75
Anexo 4 .....	81

## INDICE DE FIGURAS

Figura 2.1	Esquema de una red neuronal de retropropagación .....	8
Figuras 3.1	Comparación de hidrogramas calculados por convolución y por la red .....	22
Figuras 3.2	Comparación de hidrogramas transitados por Muskingum y por la red .....	24
Figura 4.1	Mapa de la República Mexicana por regiones hidrológicas	26
Figura 4.2	Cuenca del río Fuerte y ubicación de la presa Huites .....	26
Figura 4.3	Estaciones climatológicas convencionales .....	27
Figura 4.4	Normal pluviométrica semanal y acumulada .....	28
Figuras 4.5	Lluvia diaria promedio en el área de la cuenca en verano ..	30
Figuras 4.6	Lluvia diaria promedio en el área de la cuenca en otoño e invierno .....	31
Figura 4.7	Normal de evaporación en la región de la cuenca .....	32
Figura 5.1	Malla de estimación puntual de lluvia .....	37
Figuras 5.2	Gráficas de lluvia escurrimiento en meses de invierno .....	39
Figuras 5.3	Volúmenes de lluvia (4 días), escurrimiento (15 días) y pérdidas (en mill. m <sup>3</sup> ) por evento .....	41
Figura 6.1	Codificación de los datos de entrada y salida, y estructura de la red .....	44
Figuras 6.2	Ajuste de hidrogramas con una red de 92-10-10 neuronas y 500 ciclos de entrenamiento .....	47
Figuras 6.3.	Ajuste de hidrogramas con una red de 36-10-10 neuronas y 500 ciclos de entrenamiento .....	49
Figuras 6.4	Ajuste de hidrogramas con una red de 92-10-10 neuronas variando el número de ciclos de entrenamiento ..	53
Figuras 6.5	Ajuste de hidrogramas variando el número de neuronas en la capa intermedia de la red .....	54

<b>Figuras 6.6</b>	<b>Ajustes de hidrogramas con una red de 92-10-10 para diferentes ciclos de entrenamiento, eliminándose los 4 eventos extremos .....</b>	<b>56</b>
<b>Figura 6.7</b>	<b>Ubicación de estaciones climatológicas con transmisión vía satélite .....</b>	<b>59</b>

## INDICE DE TABLAS

Tabla 4.1	Avenidas máximas registradas en el sitio de la presa .....	33
Tabla 5.1	Días anteriores a las avenidas con lluvia .....	38
Tabla 6.1	Comparación del error RMS obtenido considerando distinto número de puntos en la cuenca y 4 días de lluvia en cada punto .....	50
Tabla 6.2	Comparación del error RMS obtenido considerando 9 puntos en la cuenca con 6 y 8 días de lluvia en cada punto.....	51

## RESUMEN

Las redes neuronales son técnicas computacionales inspiradas en estructuras biológicas, que intentan simular los procesos de aprendizaje utilizados por el cerebro humano. Han alcanzado amplio éxito en aplicaciones que requieren clasificación o reconocimiento de patrones, optimización combinatoria, control de sistemas y predicción. En esta tesis se investiga la utilidad de las redes neuronales para modelar el proceso hidrológico de lluvia-escorrentía en cuencas grandes, con fines de predicción. Como caso de estudio se eligió la cuenca de la presa Huites (Presa Luis Donaldo Colosio) en el estado de Sinaloa, con el fin de predecir a corto plazo el escurrimiento de entrada a la presa producido por lluvias de invierno.

Inicialmente se ubica el problema a resolver en el contexto del estado actual de la predicción de avenidas en México. Después se expone de manera general la tecnología de redes neuronales. Así como la teoría, operación, construcción y entrenamiento de un tipo particular de red neuronal, la red de retropropagación. Seguidamente, como ejemplos de prueba, se utiliza dicha red neuronal para emular el mapeo de dos modelos matemáticos hidrológicos; el de Hidrogramas Unitarios y el de Muskingum. Los resultados muestran la habilidad de la red para aproximar ambos modelos y su potencial para ser usada como modelo de procesos hidrológicos.

Posteriormente, se hace un análisis del proceso de lluvia-escorrentía de invierno en la cuenca de la presa Huites, cuya área es de 26,020 km<sup>2</sup>. Y se aplica el tipo de red neuronal mencionado para modelar el proceso. Para entrenar la red, en varias pruebas, se utilizan datos de lluvia diaria y gastos medios diarios de 50 avenidas de invierno, ordinarias y extraordinarias, ocurridas de 1961 a 1987. Predicciones a posteriori, muestran que la red neuronal utilizada es una herramienta robusta y adecuada para modelar el proceso, principalmente en el caso de eventos extremos. Con la red entrenada, dado el tamaño de la cuenca,

es posible predecir un hidrograma de respuesta de la cuenca (10 valores de gasto medio diario) desde el día de inicio de la avenida, conociéndose el gasto medio máximo con 24 horas de anticipación.

## INTRODUCCIÓN

La predicción a priori, a distintos plazos, de fenómenos hidrológicos como lluvias o avenidas es indispensable para fines de prevención o planificación en muchas de las actividades del ser humano. Tanto en el caso de que el agua sea escasa, como en el de que sea excesiva. El más importante es la protección civil. Otros fines son la planificación y diseño de obras hidráulicas, así como el aprovechamiento óptimo del recurso.

La predicción de volúmenes de escurrimientos de entrada a presas es un ejemplo de este último fin. Contando con estimaciones confiables, a corto plazo, es posible aplicar políticas óptimas de operación de la presa, para el mejor control y aprovechamiento de las avenidas, con diversos fines. Como, por ejemplo, generación de energía eléctrica, prevención de inundaciones, riego, etc... Este tipo de predicción podría ser de gran utilidad en algunas presas del país, como la presa Huites, ubicada en el norte del estado de Sinaloa, región donde la disponibilidad de agua es escasa a lo largo de casi todo el año. Sin embargo, en el sitio de la presa se presentan avenidas medianas y extremas con cierta frecuencia, las cuales suelen representar graves riesgos por inundaciones, por lo que deben de ser controladas y aprovechadas. Por lo anterior se escogió la cuenca de la presa Huites como caso de estudio en este trabajo.

La predicción de avenidas requiere de una infraestructura tecnológica costosa y de recursos humanos altamente calificados, que usualmente sólo los países desarrollados podían costear. En México, la predicción de avenidas se ha visto limitada principalmente por la carencia de instrumentación suficiente para la medición de lluvia en tiempo real, o para el pronóstico a corto plazo. Recientemente se han instalado en el país, redes básicas de radares meteorológicos y de estaciones climatológicas automáticas; así como equipos receptores de imágenes meteorológicas de satélite. Esta nueva plataforma tecnológica permitirá contar con mediciones y pronósticos de lluvia a corto plazo,

para el empleo de modelos hidrológicos e hidráulicos de simulación con fines de predicción de avenidas.

En el país se cuenta con experiencia en el desarrollo y aplicación de modelos, principalmente hidráulicos, para la simulación del tránsito de avenidas. Así como en el desarrollo de modelos de lluvia-escorrentamiento, pero su aplicación con fines de predicción es prácticamente nula. En este trabajo se investiga un nuevo enfoque de modelado del proceso de lluvia-escorrentamiento, con fines de predicción, utilizando la tecnología computacional de reconocimiento de patrones con redes neuronales.

La finalidad de esta tesis es investigar la utilidad de las redes neuronales computacionales para modelar el proceso hidrológico de lluvia-escorrentamiento en cuencas grandes, con fines de predicción de avenidas. Como caso de estudio se eligió la cuenca de la presa Huites (Presa Luis Donaldo Colosio) en el estado de Sinaloa, con el fin de predecir el volumen de escurrimientos en la entrada de la presa, conociendo la cantidad de lluvia previa ocurrida en la cuenca y alrededores.

Las redes neuronales fueron primeramente exploradas en los años 40. Sin embargo, no es hasta mediados de los años 80, cuando nuevos enfoques impulsan un importante resurgimiento de la redes neuronales. A partir de 1986 aplicaciones de redes neuronales han sido reportadas en la literatura científica de muchas disciplinas. En los años 90 comenzaron a publicarse aplicaciones en ciencias de la tierra. En hidrología y geohidrología, desde 1991, han sido publicados relativamente pocos trabajos. El presente es un trabajo pionero en el modelado del fenómeno de lluvia-escorrentamiento utilizando redes neuronales. Hasta 1995, no se encontró ningún trabajo similar.

El contenido de esta tesis se organiza de la siguiente manera. En el capítulo 1 se define el tipo de predicción hidrológica que se pretende realizar en este trabajo, y se menciona brevemente el estado actual de la predicción de avenidas en

México. En el capítulo 2 se expone la teoría general sobre redes neuronales y en particular sobre la red neuronal de retropropagación. En el capítulo 3 se emula con dicha red neuronal el funcionamiento de dos modelos de predicción hidrológica. En el capítulo 4 se describen las características hidroclimatológicas de la cuenca de la presa Huites. En el capítulo 5 se analiza el proceso de lluvia-escorrentamiento de invierno en la cuenca de la presa. Finalmente, en el capítulo 6 se construyen varias alternativas de modelado con el mismo tipo de red neuronal. Se presentan los resultados de varias pruebas realizadas y se hace una discusión de los resultados obtenidos.

## 1. PREDICCIÓN HIDROLÓGICA

Dado el carácter de elemento vital del agua para el ser humano, y para todas sus actividades, la respuesta a preguntas como: ¿Cuándo habrá sequía y que tan larga será? ¿Que tan grave será una inundación?, revisten de una gran importancia social y económica. Por lo cual algunos hidrólogos (v.g. Eagleson, 1994) sostienen que el objetivo primordial de la hidrología es la predicción.

En general la predicción hidrológica pretende evaluar cuantitativamente, a priori y en determinados sitios, la evolución de algún fenómeno relacionado con el agua, en cualquier etapa del ciclo hidrológico; como lluvias o escurrimientos, con fines de prevención y planeación. El término engloba distintos tipos o modalidades, distintos fines y diferentes plazos.

### 1.1 Tipos de predicción hidrológica

La estimación probabilística a largo plazo (decenas de años) de lluvias y avenidas de diseño para la construcción de obras hidráulicas, es una de las modalidades. De hecho la estimación de avenidas de diseño es uno de los problemas a que hidráulicos e hidrólogos se han dedicado desde el siglo pasado. Otras modalidades son la predicción estadística a mediano plazo (uno o varios meses), más conocida como pronóstico y la predicción a corto plazo (uno o varias días), generalmente hecha mediante modelos matemáticos.

Es frecuente que el término predicción hidrológica sea utilizado limitándolo a la estimación a priori del volumen de escurrimientos que se presentarán en determinado sitio, ya sea a mediano o corto plazos. Este es el tipo de predicción hidrológica que se investiga en esta tesis para la presa Huites. Específicamente, una modalidad de la predicción de avenidas: La determinación a priori, a corto plazo, del gasto medio diario de una avenida, en la entrada de la presa, debida a la ocurrencia de lluvias medianas o extraordinarias en el área de la cuenca de la

presa.

## **1.2 Predicción de avenidas en México**

### **1.2.1 Sistemas para la predicción de avenidas**

La predicción de avenidas requiere de la interacción de varios sistemas:

- a) Sistemas o redes de medición.
- b) Sistemas de telecomunicaciones.
- c) Sistemas de recepción y procesamiento de la información.
- d) Modelos computacionales de simulación hidrológica.

Esto es, la predicción de avenidas y la hidrológica, en general, requiere de una infraestructura tecnológica y de recursos humanos altamente calificados que, usualmente sólo los países desarrollados podían costear. Por esta razón, la predicción hidrológica en México es asunto del futuro. La predicción de avenidas se ha visto limitada en el país, hasta los últimos años, principalmente por la carencia de instrumentación suficiente para la estimación de lluvia en tiempo real. Aunque con anterioridad se habían hecho intentos de instalar sistemas locales de medición y de predicción (v.g. Acosta, 1988; Salas y Espinosa, 1994), no es hasta los años recientes, con la modernización del Servicio Meteorológico Nacional (Gonzales y Garduño, 1994), que el país cuenta con nuevos sistemas de cobertura nacional.

En los años recientes el Servicio Meteorológico nacional instaló cerca de 700 estaciones climatológicas automáticas (v.g. Collado y Toledo, 1994). Asimismo, cuenta con una nueva red de radares meteorológicos (Rosengaus, 1992; Mendoza y Rosengaus, 1994) y con equipos de recepción de imágenes meteorológicas, cuya utilización para la estimación de lluvia se encuentra en etapa de validación (v.g. Sánchez y Sosa, 1993; García y Rosengaus, 1994). Con

esta nueva plataforma tecnológica se inicia un nuevo desarrollo de la predicción hidrológica en el país.

Por otra parte, en México se cuenta con experiencia en el desarrollo de modelos de simulación de tránsito de avenidas. Estos son, tanto hidráulicos, basado en las ecuaciones de Saint Venant (v.g. Cruickshank, 1974; Aguilera, 1979; Espinosa, 1982; Aldama y Martínez, 1988; Aparicio et.al., 1988; Escalante y Aparicio, 1990; Jiménez y Domínguez, 1994), como hidrológicos (v.g. Escalante y Raynal, 1988; Gutiérrez y Raynal, 1987; Collado y Wagner, 1990; Campos, 1990). Se han desarrollado también algunos modelos de lluvia-escurrimiento, principalmente por técnicas de hidrogramas unitarios (v.g. Consultores S.A., 1978; Aparicio, 1982; Campos, 1987; Gutiérrez y Raynal 1989; Campos, 1990; Salas y Espinosa, 1994). Sin embargo, para predicción de avenidas a priori, únicamente se han hecho intentos con modelos hidráulicos de tránsito de avenidas en planicies de inundación, como se menciona en la siguiente sección.

### **1.2.2 Predicción de avenidas en algunas cuencas grandes del país**

En el país las cuencas de los ríos más caudalosos como son, entre otros, el Pánuco, el Grijalva, el Papaloapan, el Fuerte, son extensas y se dividen en subcuencas altas, medias y planicies de inundación. Por el gran tamaño de las cuencas, el tiempo de traslado de los escurrimientos desde las partes altas hasta la salida al mar es de varios días. Por lo tanto, es teóricamente posible predecir las avenidas a la salida de cuencas altas, con algunas horas de anticipación, contando con mediciones de lluvia en tiempo real. Los hidrogramas predichos pueden ser utilizados como entrada en modelos hidráulicos de tránsito de avenidas, en las planicies de inundación.

Estos criterios han servido como base para el desarrollo de modelos de predicción de avenidas, principalmente en las cuencas del Río Papaloapan y del Río Pánuco. Cuencas en donde los ciclones causan serias inundaciones, como las ocurridas

en Tampico en 1955. En dichas cuencas se ha pretendido integrar modelos de lluvia-escorrentamiento de hidrogramas unitarios con modelos hidráulicos de tránsito de avenidas en las planicies de inundación (v.g. Consultores S.A., 1978; Aguilera, 1979; Espinosa, 1982). Sin embargo, por carecerse de mediciones de lluvia en tiempo real en toda la cuenca, tales modelos no han sido aplicados integralmente para predicciones a priori.

En ambas cuencas se han hecho intentos de predecir avenidas a priori, utilizando los modelos de tránsito de avenidas en planicies de inundación. Con la limitante de que no se ha contado con los hidrogramas completos de entrada a las planicies de inundación, lo cual ha limitado considerablemente la precisión de los resultados

Actualmente se dedican muchos esfuerzos a la estimación de lluvia en tiempo real. Y se continúa con el desarrollo de modelos de tránsito de avenidas. Los modelos de lluvia-escorrentamiento son una parte necesaria para la predicción de avenidas en cuencas grandes. Sin embargo, son los que han sido tradicionalmente menos estudiados en el país. Este trabajo pretende contribuir al estudio de dicho proceso, con el nuevo enfoque de reconocimiento de patrones.

## **2. REDES NEURONALES**

### **2.1 Redes neuronales computacionales**

Las nuevas teorías de percepción humana, aprendizaje, lenguaje y memoria motivaron un nuevo enfoque y una nueva arquitectura computacional. La creencia de que un sistema inteligente, en el sentido de inteligencia artificial, puede ser generado mediante el comportamiento colectivo de conjuntos de elementos procesadores, condujo al desarrollo de modelos de conjuntos de redes neuronales computacionales.

Las computadoras convencionales son competentes y rápidas para procesos numéricos, creación y manejo de bases de datos, y procesamiento de palabras. Sin embargo, para muchos problemas de lenguaje, robótica, reconocimiento de patrones, y optimización combinatoria, no son apropiadas por su funcionamiento secuencial. La tecnología de redes neuronales son técnicas computacionales alternativas basadas en teorías de interconexión masiva y procesamiento en paralelo.

Una red neuronal es un grupo de elementos procesadores. Típicamente un subgrupo realiza cálculos independientes y pasa los resultados a otro grupo, hasta que finalmente un grupo de uno o varios elementos procesadores determina la salida de la red (ver Figura 2.1). Las redes neuronales tienen las siguientes características.

1. Combinan cálculos individuales en cada elemento con memoria asociativa.
2. Cada elemento de la red está interconectado a los demás mediante alguna topología de transmisión de información.
3. Operan predominantemente en paralelo.

4. Poseen cierta habilidad para adaptar su funcionamiento a sus entradas y salidas.

## **2.2 Origen y desarrollo de las redes neuronales**

Primeramente exploradas en los años 40 (McCulloch y Pitts, 1943), las redes neuronales tuvieron cierto auge en los años 50 y 60, principalmente como dispositivos electrónicos. En los años 70, fueron prácticamente olvidadas, como resultado de un trabajo de Minsky y Papert (1969) que causó pesimismo. A mediados de los años 80 nuevos enfoques impulsaron un importante resurgimiento de las redes neuronales (Rumelhart et. al., 1986). Descripciones más detalladas de la historia de las Redes Neuronales se pueden encontrar en muchos trabajos (v.g. Daniell, 1991; Rao y Rao 1993; Fu, 1994). A partir de 1986 aplicaciones exitosas de redes neuronales han sido reportadas en la literatura científica de muchas disciplinas.

## **2.3 Redes neuronales en ciencias de la tierra y en hidrología**

El uso de redes neuronales en ciencias de la tierra es muy reciente. A partir de 1990 comenzaron a publicarse muy diversas aplicaciones. Por ejemplo, en el modelado del efecto invernadero en climatología (Kok et.al., 1991); en la clasificación de eventos sísmicos (Dysart y Pully, 1990) en sismología; en la clasificación de imágenes de satélite (Ritter y Hepner, 1990) en percepción remota. En México, se han reportado trabajos de identificación del tiempo de arribo de ondas sísmicas (Ortega, 1993); y en la predicción de la calidad del aire en la ciudad de México (Ruiz et. al., 1994).

En hidrología y geohidrología, se han publicado relativamente pocos trabajos, algunos de ellos se citan a continuación. En problemas geohidrológicos, han sido utilizadas inicialmente en remediación óptima de acuíferos (Rogers et.al., 1993; Rogers y Dowla, 1994) y en caracterización de acuíferos (Rizzo y Dougherty,

1994). En hidráulica fluvial en la cuantificación del transporte de sedimentos (Trent et.al.,1993).

En predicción hidrológica, han sido aplicadas a la predicción (a posteriori) de escurrimientos pequeños, en una cuenca de España (Crespo y Mora, 1993). A la simulación del escurrimiento provocado por el deshielo de un glaciar, en la región de los montes Himalayas, India (Buch et. al.,1993). A la predicción de la salinidad del río Murray en la ciudad de Adelaide en Australia (Maier y Dandy, 1994); a la estimación de consumo de agua, y a la regionalización de escurrimientos en Camberra, Australia (Daniell,1991); así como a la predicción de lluvias y escurrimientos a mediano plazo en Colombia (Mesa y Carvajal, 1994). Hasta 1995 no se encontró ningún trabajo que tratara de modelar el proceso de lluvia-escurrimiento en cuencas grandes con redes neuronales, por lo que este es un trabajo pionero que inicia una nueva línea de investigación en hidrología.

#### **2.4 Clases y tipos de redes neuronales**

Algunos autores, por ejemplo Maren (1991), han sugerido que la estructura o arquitectura de una red neuronal puede ser descrita en tres niveles: micro, meso y macro. En este enfoque, la microestructura describe las características de cada nodo o neurona en la red. La mesoestructura describe cómo la red es organizada, incluyendo características como a) número de capas, b) patrones de interconexión, y c) flujo de la información. Finalmente, la macroestructura define cómo diferentes redes son ligadas para producir nuevas redes que interactúan para resolver determinados problemas.

Desde 1986 los modelos o tipos de redes neuronales han aumentado rápidamente. En su ahora clásico trabajo, Rumelhart et. al. (1986) describían 4 tipos de redes. En 1988 se conocían cerca de 26 tipos y en 1991 Maren (1991) describió cerca de 48 tipos. Los tipos de redes neuronales que usualmente han sido usados en ciencias de la tierra son los que realizan mapeos matemáticos. Un

tipo de dichas redes se describe a continuación.

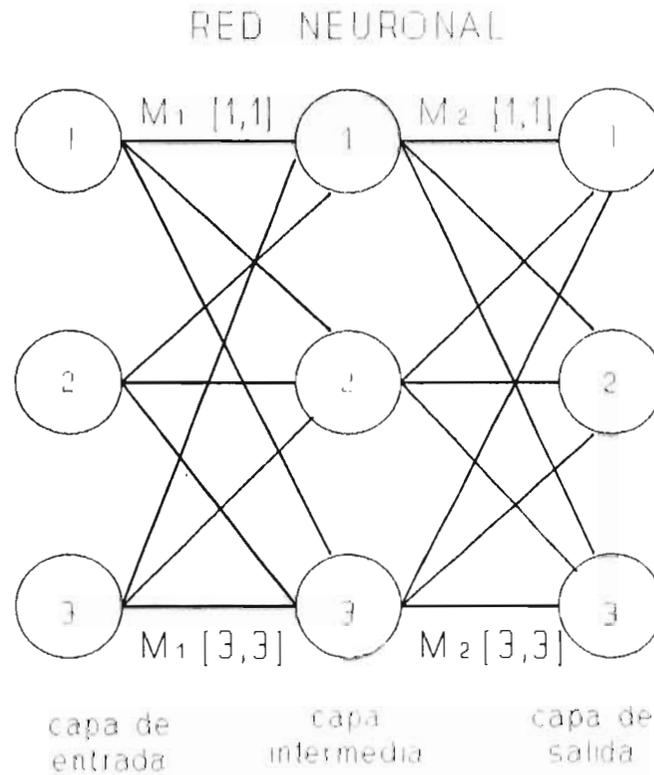


Figura 2.1 Esquema de una red neuronal de retropropagación (3-3-3).

---

## 2.5 Red neuronal de retropropagación

Las redes de retropropagación son uno de los modelos de redes neuronales más utilizados. Aprenden a resolver un problema desarrollando una memoria capaz de asociar (o mapear) un largo número de patrones de entrada a la red con un conjunto de patrones de salida o efectos, mediante un proceso numérico denominado entrenamiento. Para lo cual se requiere un conjunto de ejemplos de la acción del mapeo. Una vez entrenada, la red puede calcular patrones de salida

para diversos patrones de entrada, no usados en el entrenamiento. Por lo que el modelo construido puede ser utilizado para predecir.

La red neuronal de retropropagación mapea vectores de entrada. Si hay  $k$  neuronas en la capa de entrada y  $m$  neuronas en la capa de salida, entonces la red hace un mapeo del espacio de  $k$  dimensiones a un espacio de  $m$  dimensiones. Por supuesto, una vez entrenada, lo que mapea depende de los pares de patrones (o vectores) que fueron usados como ejemplos para entrenar la red. La red no tiene conexiones de retroalimentación, sin embargo, los errores son propagados hacia atrás durante el entrenamiento, a lo cual debe su nombre.

### 2.5.1 Procedimiento de cálculo y entrenamiento

Un patrón de entrada o vector es presentado en la capa de entrada. El patrón de dígitos es pasado a la siguiente capa intermedia de neuronas. La salida de cada neurona de esta capa son calculadas por los pesos asociados  $M_1[i,j]$  y las entradas  $x_i$ , como se indica abajo. De esta manera, las salidas  $y_i$  de esta capa se convierten en entradas para la siguiente, ya sea la capa de salida u otra intermedia, hasta determinarse la salida de la red.

Por ejemplo, para la red mostrada en la Figura 2.1 el valor de salida de la neurona  $j$  intermedia es

$$y_j = f\left(\left(\sum_{i=1}^3 x_i M_1[i, j]\right) + \theta_j\right) \quad (2.1)$$

Y el valor de salida de la neurona  $j$  de la ultima capa es

$$z_j = f\left(\left(\sum_{i=1}^3 y_i M_2[i, j]\right) + \tau_j\right) \quad (2.2)$$

donde  $\theta_i$  y  $r_i$  son valores tope o sesgo, y  $f(.)$  es la función sigmoide

$$f(s) = 1 / (1 + \exp(-s)) \quad (2.3)$$

Esta última función puede ser cualquier otra que sea fácilmente derivable y que esté acotada a valores entre 0 y 1.

Para el entrenamiento, el patrón calculado y el de salida deseado se comparan. Una función de este error es determinada para cada componente, y los pesos asociados entre la última capa intermedia y la de salida se corrigen. Cálculos similares, basados en el error de la salida son hechos para corregir los pesos asociados entre las capas restantes. El procedimiento se repite tantas veces como sea especificado, o hasta que el error de comparación esté dentro de una tolerancia requerida. Las ecuaciones de este procedimiento se presentan a continuación (Rao y Rao, 1993), las cuales se deben a Rumelhart, et.al. (1986).

Componente  $i$  del vector de diferencias de salida esto es, valor deseado ( $d$ ) y valor calculado por la red ( $z$ ).

$$d_i - z_i \quad (2.4)$$

Componente  $i$  del error en la capa de salida

$$e_i = z_i (1 - z_i) (d_i - z_i) \quad (2.5)$$

Componente  $i$  del error en la capa intermedia

$$t_i = y_i (1 - y_i) \left( \sum_{j=1}^3 M_2 [i, j] e_j \right) \quad (2.6)$$

Ajuste para los pesos entre la neurona  $i$  en la capa intermedia y la neurona  $j$  en la capa de salida

$$\Delta M_2[i, j] = \mu y_i e_j \quad (2.7)$$

Ajuste para los pesos entre la neurona  $i$  de entrada y la neurona  $j$  en la capa intermedia

$$\Delta M_1[i, j] = \lambda x_i t_j \quad (2.8)$$

$\mu$ ,  $\lambda$  son parámetros de "aprendizaje", que se eligen arbitrariamente, dentro de intervalos especificados.

Ajuste del valor  $\tau_j$  para la neurona  $j$  de la capa de salida

$$\Delta \tau_j = \mu e_j \quad (2.9)$$

Ajuste del valor  $\theta_j$  para la neurona  $j$  de la capa intermedia

$$\Delta \theta_j = \lambda e_j \quad (2.10)$$

## 2.5.2 Obtención de las ecuaciones del entrenamiento

La forma estándar de medir el funcionamiento de una red de mapeo es mediante el cálculo de

$$P = - \sum_s \left( \sum_z (d_{sz} - o_{sz})^2 \right) \quad (2.11)$$

donde

$P$  es una medida del funcionamiento de la red

$s$  es el subíndice para los eventos

$z$  es el subíndice para las salidas calculadas

$d_{sz}$  son las salidas observadas

$o_{sz}$  son las salidas calculadas por la red

La medida del funcionamiento depende, como puede verse en las ecuaciones 2.1 y 2.2, de los pesos. Por lo que, un máximo o un mínimo de la función se encuentra donde el gradiente de  $P$ , con respecto a cada peso, es nulo. Uno de los métodos para minimizar la función 2.11 es el del paso de menor descenso (v.g. Winston, 1992). Esto es, cada peso se modifica iterativamente, en un valor proporcional a la derivada parcial

$$\frac{\partial P}{\partial w_{ij}} \quad (2.12)$$

donde los subíndices en  $w_{ij}$  indican el peso asociado de la neurona  $i$  de la capa anterior a la neurona  $j$  de la capa siguiente. Con fines de simplificación se calculará la derivada parcial para cada evento; esto es, se elimina el subíndice de eventos, en el entendido que cada peso debe ser modificado sumando el valor calculado para cada evento.

El efecto de los pesos  $w_{ij}$  en el valor de  $P$  es mediante la variable intermedia,  $o_j$ , la salida de la neurona  $j$ . Por lo que, usando la regla de la cadena, la derivada se puede expresar

$$\frac{\partial P}{\partial w_{ij}} = \frac{\partial P}{\partial o_j} \frac{\partial o_j}{\partial w_{ij}} = \frac{\partial o_j}{\partial w_{ij}} \frac{\partial P}{\partial o_j} \quad (2.13)$$

Ahora, considerando la derivada parcial  $\partial o_j / \partial w_{ij}$ . El valor de  $o_j$  se obtiene

mediante  $o_j = f\left(\sum_i o_i w_{ij}\right)$  donde  $f(\cdot)$  es la función sigmoide. Tratando la suma

como una variable intermedia,  $\sigma_j = \sum_i o_i w_{ij}$ , y aplicando de nuevo la regla

de la cadena, tenemos

$$\frac{\partial o_j}{\partial w_{ij}} = \frac{df(\sigma_j)}{d\sigma_j} \frac{\partial \sigma_j}{\partial w_{ij}} = \frac{df(\sigma_j)}{d\sigma_j} o_i = o_i \frac{df(\sigma_j)}{d\sigma_j} \quad (2.14)$$

Sustituyendo esta ecuación en la ecuación  $\partial P / \partial w_{ij}$  tenemos la siguiente

ecuación clave

$$\frac{\partial P}{\partial w_{ij}} = o_i \frac{df(\sigma_j)}{d\sigma_j} \frac{\partial P}{\partial o_j} \quad (2.15)$$

Nótese que la derivada parcial,  $\partial P / \partial o_j$ , puede ser expresada en términos

de la derivada parcial,  $\partial P / \partial o_k$ , en la siguiente capa a la derecha. Debido

a que el efecto de  $o_j$  en  $P$  es a través de la salidas de las neuronas en la siguiente

capa,  $o_k$ , por lo que dicha derivada se puede calcular

$$\frac{\partial P}{\partial o_j} = \sum_k \frac{\partial P}{\partial o_k} \frac{\partial o_k}{\partial o_j} = \sum_k \frac{\partial o_k}{\partial o_j} \frac{\partial P}{\partial o_k} \quad (2.16)$$

El valor de  $o_k$  se calcula de manera similar a la capa anterior, mediante  $o_k = f\left(\sum_j o_j w_{jk}\right)$  donde  $f(\cdot)$  es la función sigmoide. Tratando la suma

como una variable intermedia,  $\sigma_k = \sum_j o_j w_{jk}$ , y aplicando nuevamente la

regla de la cadena, tenemos

$$\frac{\partial o_k}{\partial o_j} = \frac{df(\sigma_k)}{d\sigma_k} \frac{\partial \sigma_k}{\partial o_j} = \frac{df(\sigma_k)}{d\sigma_k} w_{jk} = w_{jk} \frac{df(\sigma_k)}{d\sigma_k} \quad (2.17)$$

Sustituyendo este resultado en la ecuación,  $\partial P / \partial o_j$ , tenemos la siguiente

ecuación clave

$$\frac{\partial P}{\partial o_j} = \sum_k w_{jk} \frac{df(\sigma_k)}{d\sigma_k} \frac{\partial P}{\partial o_k} \quad (2.18)$$

De las dos ecuaciones anteriores se concluye que la derivada parcial de P con respecto a cualquier peso en una capa dada, se obtiene de cálculos anteriormente realizados en la capa vecina a la derecha.

Para terminar, resta todavía calcular la derivada parcial de P con respecto a cada salida en la última capa

$$\frac{\partial P}{\partial o_z} = \frac{\partial}{\partial o_z} (d_z - o_z)^2 = 2(d_z - o_z) \quad (2.19)$$

Y finalmente evaluar la deriva de la función sigmoide,  $f$ , con respecto a su argumento.

$$f(\sigma) = \frac{1}{1 + e^{-\sigma}}$$

$$\frac{df(\sigma)}{d\sigma} = \frac{d}{d\sigma} \left[ \frac{1}{1 + e^{-\sigma}} \right] \quad (2.20)$$

$$= (1 + e^{-\sigma})^{-2} e^{-\sigma}$$

$$= f(\sigma)(1 - f(\sigma))$$

$$= o(1 - o) \quad (2.21)$$

la derivada de la función sigmoide se expresa en terminos de la salida en cada neurona.

Los cambios en los pesos dependen de un parámetro de proporcionalidad,  $r$ , que debe ser lo más grande posible para conseguir un rápido aprendizaje. Así, finalmente, se tienen las fórmulas para la modificación de los pesos por el algoritmo de retropropagación.

$$\Delta w_{ij} = r o_i o_j (1 - o_j) \beta_j$$

$$\beta_j = \sum_k w_{jk} o_k (1 - o_k) \beta_k \quad (2.22)$$

$$\beta_z = d_z - o_z$$

La última ecuación se usa para neuronas en la capa de salida, y la penúltima para neuronas en capas intermedias. Las cuales son equivalentes a las ecuaciones (7) y (8) respectivamente.

### 2.5.3 Programa de cómputo utilizado

En este trabajo se usó un programa en lenguaje C++ codificado por Rao y Rao (1993), el cual permite usar hasta 5 capas de neuronas. El proceso de cálculo es el siguiente. Dado los vectores de entrada  $\mathbf{x}$  (normalizados) y los vectores de salida  $\mathbf{d}$  (normalizados), la red inicializa las matrices de pesos  $M_1$  y  $M_2$  (para el caso de tres capas), así como los valores  $\theta_i$  y  $\tau_i$ , con números aleatorios. Comparando los valores  $d$  y  $z$  (deseado y calculado por la red) obtiene el error  $e_i$  y  $t_i$ , los cuales usa para modificar los pesos de las matrices  $M_1$  y  $M_2$ . El proceso se repite hasta que el error  $P$  (ec. 2.11) sea menor que un valor especificado, o hasta que se alcance un número de ciclos dado.

### **3. EMULACIÓN DE DOS MODELOS HIDROLÓGICOS CON REDES NEURONALES**

#### **3.1 Modelado de sistemas con redes neuronales**

##### **3.1.1 Modelado de sistemas**

Un sistema es un conjunto de partes o unidades que forman un todo y que operan o funcionan conjuntamente. La teoría de sistemas estudia su comportamiento en términos de relaciones cuantitativas o cualitativas entre variables definidas del sistema. De esta manera un sistema puede ser imitado o simulado por algo a lo que se denomina modelo. Un lenguaje debe ser escogido dependiendo del aspecto a ser modelado. El lenguaje matemático ha sido usado en casi todas las disciplinas científicas para expresar la teoría cuantitativamente (Fu, 1994).

##### **3.1.2 Redes neuronales como modelos matemáticos**

El modelado de sistemas con redes neuronales se fundamenta en la teoría de sistemas. Dado un sistema físico, se supone que una red neuronal puede modelarlo con base a un conjunto de ejemplos que codifican la entrada/salida del sistema. La base de usar las redes neuronales como modelos matemáticos, es el mapeo. Las redes neuronales aprenden a realizar el mapeo de una entrada dada en una salida requerida por autoadaptación de sus pesos, proceso al que se denomina entrenamiento. La capacidad de modelado de la red se deberá a su habilidad de aprender la función matemática que subyace en la operación del sistema (Fu, 1994).

##### **3.1.3 Entrenamiento y Generalización**

Suponiendo que se desea emular con una red neuronal la función  $f(x)$ . Para

propósitos del entrenamiento, un conjunto de ejemplos se selecciona del dominio. Cada ejemplo es representado por  $(\mathbf{x}, \mathbf{y})$ , donde  $\mathbf{y} = f(\mathbf{x})$ . El objetivo del entrenamiento es que,  $\mathbf{y} = f(\mathbf{x}) = F_{nn}$ , para todo vector,  $\mathbf{x}$ , en el dominio, no limitado al conjunto de entrenamiento. Siendo  $F_{nn}$  la función que calcula la red. Si esto se logra, se dice que la red es capaz de generalizar la función  $f(\mathbf{x})$ , para todo el dominio, a partir del conjunto de ejemplos de entrenamiento. La capacidad de generalizar de una red depende (Fu, 1994), de la arquitectura y tamaño de la red, del algoritmo de aprendizaje, de la complejidad del problema, y del número y calidad de los ejemplos de entrenamiento.

Es posible que durante el aprendizaje la red sea sobreentrenada. Esto es, que la red sobrepasando un cierto número de ciclos, pierda capacidad de predecir salidas correctas a ejemplos no utilizados en el entrenamiento. Cuando esto ocurre, se dice que la red tiende a memorizar los patrones.

### **3.2 Construcción de un modelo de red neuronal de retropropagación**

#### **3.2.1 Arquitectura y tamaño de la red**

Se debe tratar de optimizar el tamaño de la red; esto es, el número de capas y de neuronas en cada capa, lo cual determina el número de pesos. Un número grande o reducido de pesos puede causar pobre resolución del problema. No existe a priori un criterio para determinar el tamaño de la red. Únicamente mediante pruebas de la generalización que efectúa la red es posible determinar si un tamaño es adecuado o no.

#### **3.2.2 Preprocesamiento de los datos y formación de patrones**

El preprocesamiento se realiza para normalizar los vectores de entrada y salida de cada ejemplo. La normalización puede hacerse por distintos procedimientos. Además se pueden utilizar técnicas de realce, así como técnicas de filtrado de los

datos (Rao y Rao, 1993). Cada pareja de ejemplos debe formarse siguiendo el patrón u orden (temporal o espacial) de los datos.

### **3.2.3 Entrenamiento**

Una vez determinado el tamaño de la red, y preprocesados los datos, 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. Por lo que se requiere realizar varias pruebas para acercarse al número apropiado de ciclos, de acuerdo al error de predicción, que se calcula como se indica en la ecuación (2.11). Si el error de predicción es aceptable (Fu, 1994), no importa si se alcanzó el mínimo global, y ni siquiera un mínimo local. A esta prueba se le llama correlación cruzada, y es la prueba que se utilizó en este trabajo.

### **3.3 Dos modelos matemáticos hidrológicos clásicos**

Los modelos matemáticos hidrológicos se pueden clasificar en dos grandes grupos: determinísticos y estocásticos. En cada grupo los modelos pueden ser de parámetros concentrados o distribuidos. Los primeros utilizan parámetros medios del sistema, los segundos distribuidos (Chow et al., 1993).

Dos modelos hidrológicos ya clásicos en hidrología, propuestos en los años 30, son el modelo de lluvia-escorrentía de hidrogramas unitarios, y el modelo Muskingum de tránsito de avenidas. Ambos son determinísticos, lineales, y de parámetros concentrados. Teóricamente pueden ser utilizados en predicción, esto es, para simular la respuesta del sistema, una vez determinados sus parámetros (v.g. Linsley et al., 1975). Con objeto de analizar la capacidad de una red neuronal de aprender el funcionamiento de algunos modelos hidrológicos lineales, los dos modelos anteriores se escogieron para emular su funcionamiento

con una red neuronal de retropropagación.

### **3.4 Emulación del modelo de hidrogramas unitarios**

#### **3.4.1 El modelo de hidrogramas unitarios**

El proceso de lluvia-escorrimento en una cuenca, puede simularse considerando a la cuenca como un sistema lineal, por consiguiente la lluvia efectiva (entrada al sistema) y el gasto de escurrimiento directo (salida del sistema) están relacionados por la integral de convolución

$$Y(t) = \int H(z)X(t-z)dz \quad (3.1)$$

Donde  $X(.)$  es la entrada al sistema,  $Y(.)$  la salida, y  $H(.)$  es la función de transferencia. En hidrología esta última toma el nombre de hidrograma unitario instantáneo.

#### **3.4.2 Datos, tamaño de la red y formación de patrones**

Los patrones de lluvia (hietogramas medios) y los de escurrimientos (hidrogramas) utilizados, son sintéticos. Esto es, se generaron con un método que consiste en convolucionar diferentes hietogramas (obtenidos con base a curvas de intensidad de lluvia) con un hidrograma unitario conocido, hasta conseguir un hidrograma con un gasto pico requerido (Toledo, 1994a). Para lo cual se utilizó un hidrograma unitario identificado para la cuenca del río Teapa, Chiapas, (Espinosa et.al., 1994) y datos de lluvia de la región.

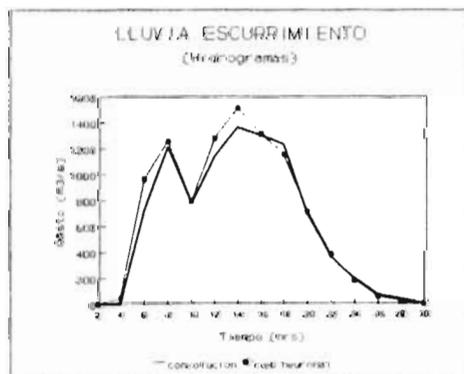
Se generaron 24 ejemplos o parejas de patrones de lluvia y escurrimiento. Los gastos pico de los hidrogramas se distribuyen uniformemente en valores cuyos periodos de retorno son de 5 a 100 años. Los hietogramas tienen un máximo de 8 valores reales, de lluvia media efectiva (mm) acumulada en la cuenca cada 2 horas. Y los hidrogramas obtenidos tienen un máximo de 15 valores reales de

gasto instantáneo en la salida de la cuenca (en  $m^3/seg$ ) cada dos horas.

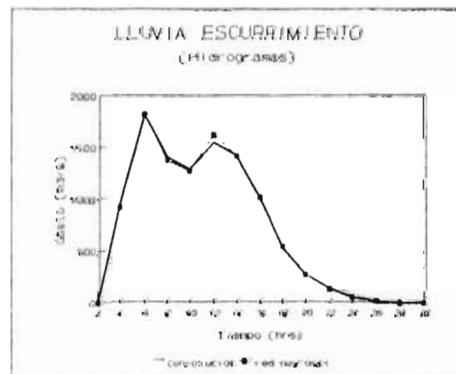
Dado el número de valores de lluvia y escurrimiento, se determinó probar con una red de 10 neuronas de entrada, 10 intermedias, y 15 de salida. Los patrones se normalizaron, finalmente, dividiendo cada valor entre un valor mayor a todos los registrados, de todos los ejemplos. Cada patrón tiene un orden temporal. Mayores detalles de la formación de los ejemplos utilizados y sus gráficas pueden encontrarse en Toledo (1994b).

### 3.4.3 Entrenamiento y generalización

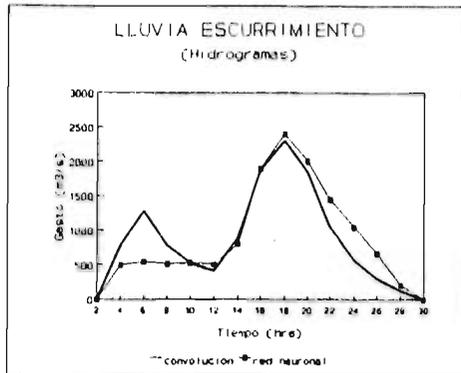
Se utilizaron 20 patrones elegidos al azar para entrenar la red, y los cuatro restantes para analizar su capacidad de predicción. El proceso se repitió varias veces, eligiendo al azar los cuatro ejemplos a predecir, y variando el número de ciclos, en cada caso. En las Figuras 3.1 se presentan hidrogramas calculados por el modelo matemático (línea gruesa) y predichos por la red (línea delgada), de uno de los casos realizados. El número de ciclos especificado fue 1000. Se encontró que con menos de 900 ciclos y más de 1100 el error de predicción aumenta. Nótese en las figuras la similitud de los hidrogramas predichos por la red, con los calculados por el modelo lineal. La red, sin embargo, como se analizará más adelante, no fue capaz de predecir adecuadamente 2 de los 20 ejemplos.



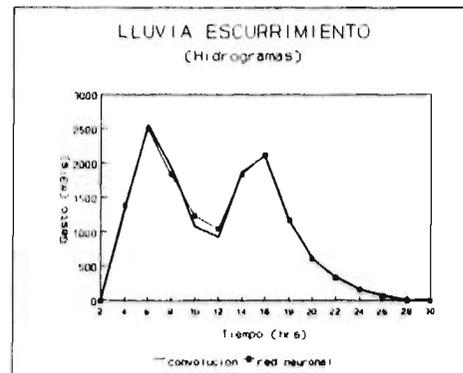
3.1.a



3.1.b



3.1.c



3.1.d

Figuras 3.1 Comparación de hidrogramas calculados por convolución y por la red.

### 3.5 Emulación del modelo Muskingum

#### 3.5.1 El modelo Muskingum

El tránsito de avenidas mediante el modelo de Muskingum se hace utilizando la siguiente ecuación recursiva

$$O_{i,1} = C_1 I_i + C_2 I_i + C_3 O_i \quad (3.2)$$

donde

$$C_1 = \frac{Kx + \Delta t/2}{\alpha}; C_2 = \frac{\Delta t/2 - Kx}{\alpha}; C_3 = \frac{K(1-x) - \Delta t/2}{\alpha}; \quad (3.3)$$

$$\alpha = K(1-x) + \Delta t/2 \quad (3.4)$$

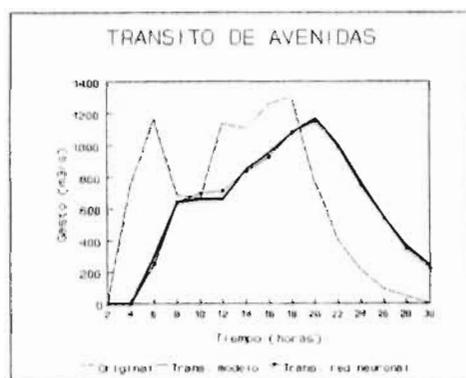
Siendo  $I$ , los valores del hidrograma por transitar y,  $O$ , los valores del hidrograma transitado. Los parámetros  $x$ ,  $k$ , se determinan experimentalmente (v.g. Escalante y Raynal, 1988).

### 3.5.2 Datos, tamaño de la red, y formación de patrones

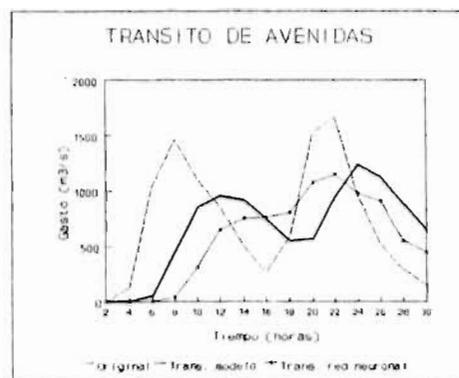
Con la ecuación (12) se hizo el tránsito de 20 de los hidrogramas del ejemplo anterior, utilizando un valor de  $x = 0.5$ , de  $K = 2.5$  y un incremento de dos horas en el tiempo. Los hidrogramas, originales y transitados, se utilizaron para formar los patrones de entrada y de salida respectivamente, con 15 valores cada uno. Se decidió formar una red con 15 neuronas de entrada 10 intermedias y 15 de salida. Los valores de cada pareja de hidrogramas se normalizaron, dividiendo sus valores por el valor mayor de todos los ejemplos.

### 3.5.3 Entrenamiento y generalización

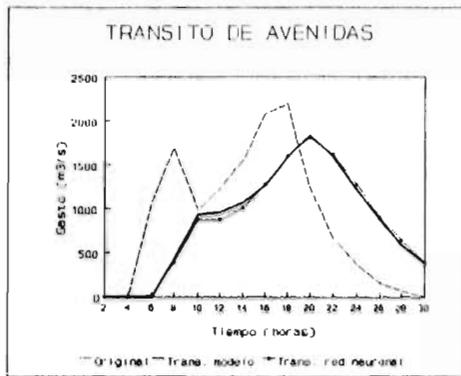
Se utilizaron 16 de las veinte parejas de hidrogramas, originales y transitados, para entrenar la red. Y al igual que en la prueba anterior, los hidrogramas restantes se utilizan para comparar la salida que da la red con el resultado del modelo numérico lineal. Se hicieron varias pruebas de entrenamiento, cambiando los cuatro hidrogramas de predicción, y el número de ciclos. El número de ciclos apropiado oscila en los 1400. Resultados de una de las pruebas se presentan en las Figuras 3.2. El hidrograma original se grafica con línea punteada, y los predichos por la red y calculado con el modelo lineal, con línea delgada y gruesa respectivamente. La red, en este caso, no fue capaz de predecir correctamente 2 de los 16 ejemplos, lo cual se analizará en la siguiente sección.



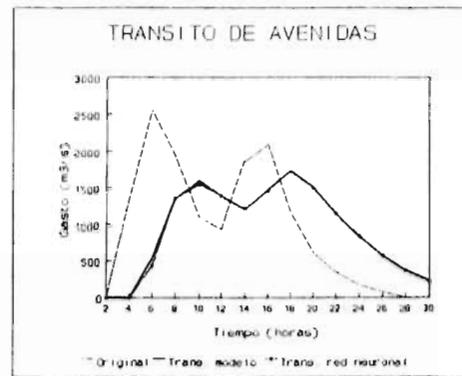
3.2.a



3.2.b



3.2.c



3.2.d

Figuras 3.2 Comparación de hidrogramas transitados por Muskingum y por la red.

### 3.6 Discusión de resultados

En este capítulo se mostró la capacidad de un tipo de red neuronal de emular el mapeo matemático de dos modelos hidrológicos. Se expone brevemente el modelado de sistemas con redes neuronales, y el procedimiento seguido para *entrenar* la red. La red, en ambos modelos, aproxima aceptablemente la función en casi todos los casos, sin lograr generalizar el mapeo de los modelos a partir del conjunto de ejemplos dado. Es de esperarse que con un mayor número de ejemplos la red logre generalizar el mapeo de los modelos, ya que las redes neuronales sólo predicen correctamente eventos similares a los del conjunto de entrenamiento (Fu, 1994).

Sin necesidad de determinar con cuántos ejemplos más la red es capaz de generalizar, los resultados obtenidos muestran la habilidad de la red para emular el mapeo de dos funciones matemáticas distintas, por autoadaptación de sus pesos; así como su potencial para ser utilizadas en modelado de procesos hidrológicos e hidrometeorológicos, ya que la red puede realizar mapeos no necesariamente lineales.

## 4. LA CUENCA DE LA PRESA HUITES

### 4.1 La presa Huites

La presa Huites se encuentra a la salida de la parte alta de la cuenca del Río Fuerte, en la región hidrológica 10, en el estado de Sinaloa, México. En el mapa de México por regiones hidrológicas (Figura 4.1) se muestra en un recuadro la ubicación de dicha región. Y en la Figura 4.2, se muestra la cuenca del río Fuerte y la ubicación de la presa. Su construcción se inició en 1990, y a fines de 1995 fue inaugurada oficialmente como *Presa Luis Donald Colosio*. Fue construida con fines de generación de energía eléctrica, riego, y control de avenidas, principalmente. La altura de la cortina, desde su base, es de aproximadamente 150 metros. Su capacidad de almacenamiento es de 4568 millones de m<sup>3</sup> al nivel de aguas máximas extraordinarias (NAME), y de 2908 millones de m<sup>3</sup> al nivel de aguas máximas ordinarias (NAMO). Los gastos máximos de diseño son de 30,000 m<sup>3</sup>/s de entrada al vaso y 22,445 m<sup>3</sup>/s de salida por el vertedor (Domínguez y Espino, 1992). Otros datos de las características principales de la presa, se pueden ver en el Anexo 1 (v.g. Revista Tlaloc, 1994).

Es importante mencionar que en el sitio de la presa se han registrado avenidas extraordinarias, como las ocurridas en 1960 y 1990, cuyo volumen de escurrimientos sobrepasa el volumen de almacenamiento de la presa al NAMO. Por lo que la predicción de avenidas ordinarias y extremas, permitiría llevar a cabo políticas óptimas de operación de la presa. En este trabajo, por la escasez de datos hidrométricos y pluviométricos dentro de la cuenca, requeridos para la aplicación de modelos como el del hidrograma unitario; se propone la utilización de las técnicas computacionales de redes neuronales con tal finalidad. También pueden ser empleados modelos de parámetros distribuidos, como el modelo MERCEDES (Domínguez et.al., 1994). Estos modelos, sin embargo, requieren además de los datos de lluvia y escurrimiento información adicional. Como topografía, tipo de suelo, etc..., lo cual complica su aplicación.



Figura 4.1 Mapa de la República Mexicana por regiones hidrológicas.

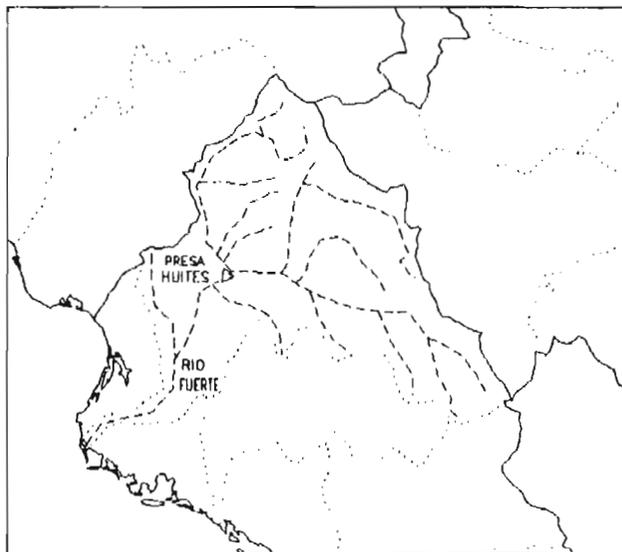


Figura 4.2 Cuenca del río Fuerte y ubicación de la presa Huites.

## 4.2 La cuenca de la presa Huites

La cuenca de la presa Huites tiene un área de 26,020 km<sup>2</sup>. La longitud del cauce principal es de aproximadamente 330 km. A la presa llegan dos afluentes principales el Río Chinipas, y el Río San Miguel. La diferencia de altitud de la parte más baja de la cuenca (donde se ubica la presa), y los puntos más altos es de aproximadamente 2300 metros. Los cauces de los ríos son cañones que en algunos tramos alcanzan gran profundidad, y carecen de áreas de inundación. No existen obras importantes de infraestructura hidráulica, como presas y canales, aguas arriba de la presa Huites. Las características hidrológicas y el proceso de lluvia-escorrimento de invierno en la cuenca se analizan en las siguientes secciones.

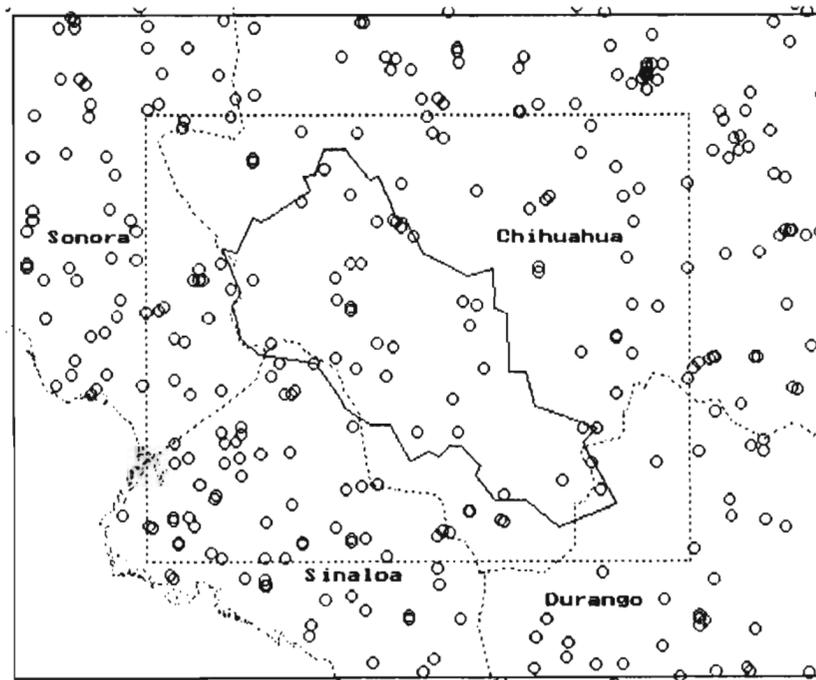


Figura 4.3 Estaciones climatológicas convencionales en un área de 25 y 29 grados de latitud y -110 y -105 grados de longitud. El contorno cerrado delimita la cuenca.

#### 4.2.1 Precipitación

El análisis de precipitación que se presenta, se hizo utilizando los datos de 230 estaciones climatológicas con que cuenta el banco de datos CLICOM del Servicio Meteorológico Nacional en la región mostrada en la Figura 4.3, siendo el periodo de registro de la mayoría de estaciones de 1961 a 1987. Los cálculos y el manejo de los datos se hicieron con el programa CLIMAS (Toledo y Millán, 1994c). En la Figura 4.4 se presenta la normal pluviométrica semanal de la región delimitada por el rectángulo interior de la Figura 4.3, la cual se obtuvo promediando las normales pluviométricas semanales de 122 estaciones climatológicas con más de 10 años de registro.

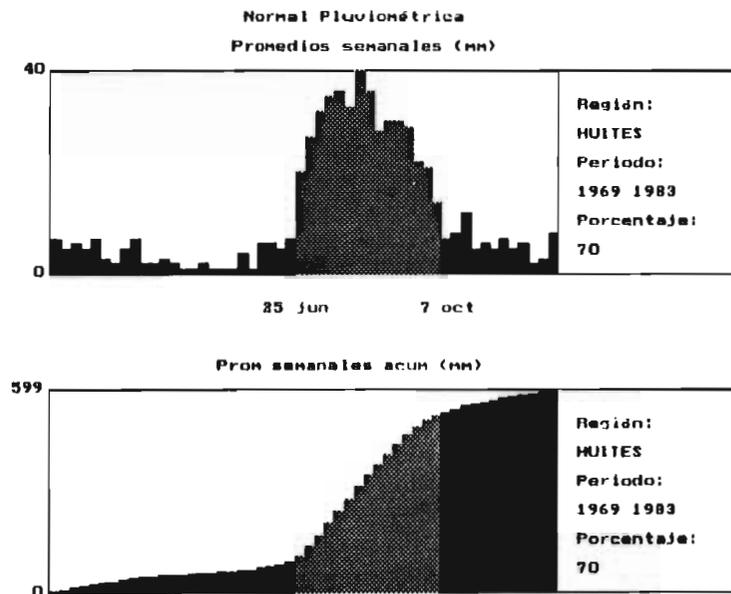


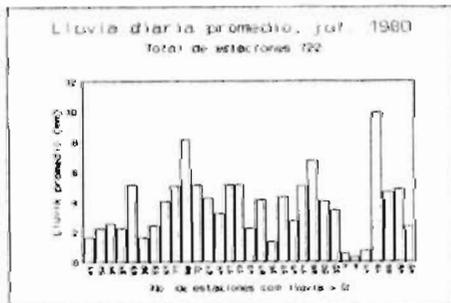
Figura 4.4 Normal pluviométrica semanal y acumulada.

En dicha figura se puede ver, en tono gris, el periodo promedio en que se precipita el 70% del total anual promedio de lluvia (lluvias de verano). En

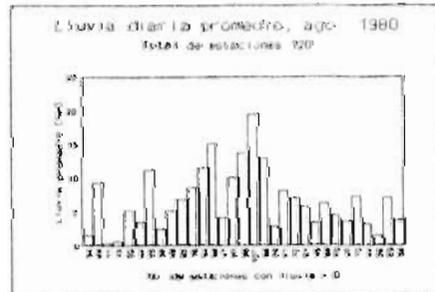
promedio, un 80% se precipita de junio a octubre. De noviembre a principios de marzo se precipita en promedio un 15% (período al que se denomina de lluvias de invierno). Mientras que en los meses de marzo, abril, y mayo, se precipita en promedio el 5% restante. La precipitación anual promedio en la región es de aproximadamente 600 mm. A continuación se analizan las lluvias de ambos periodos.

#### 4.2.2. Características de las lluvias de invierno y las de verano

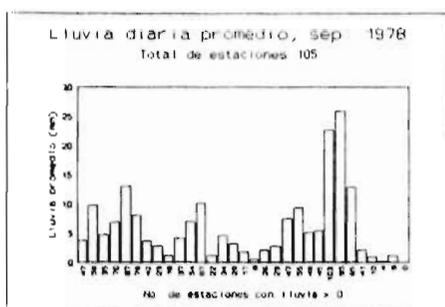
En las Figuras 4.5 se gráfica, para distintos meses, la precipitación diaria promedio (mm) en la región del recuadro punteado de la Figura 4.3. Se indica, para cada día, el número de estaciones con lluvia mayor que cero. Nótese en las Figuras 4.5 a,b, y c, que en los meses de julio, agosto y septiembre llueve todos los días en la región. Sin embargo, el número de estaciones con lluvia es, por lo general, mucho menor que el total de estaciones. Esto indica que las lluvias de verano ocurren por sectores de la región, con excepción de las lluvias ciclónicas, como las ocurridas en septiembre de 1978 (ver Figura 4.5.c). Esto se debe a que las lluvias de verano son producidas por sistemas meteorológicos de origen tropical de poca extensión (con excepción de los ciclones) los cuales producen lluvias regionales, e incluso muy locales, de gran intensidad y poca persistencia temporal. La zona se ve afectada por ciclones tropicales en los meses de septiembre y octubre, principalmente (Jáuregui, 1989).



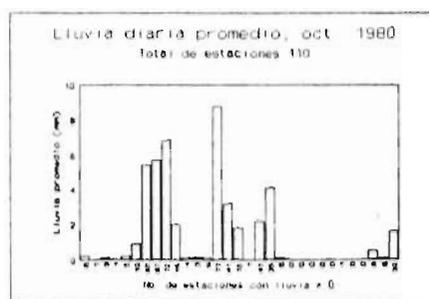
4.5.a



4.5.b



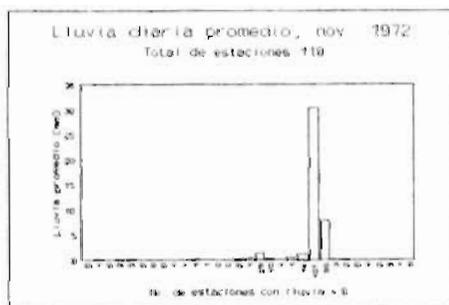
4.5.c



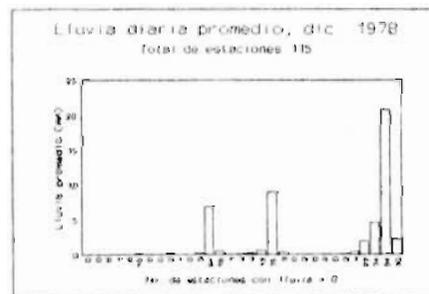
4.5.d

Figuras 4.5 Lluvia diaria promedio en el área de la cuenca en verano.

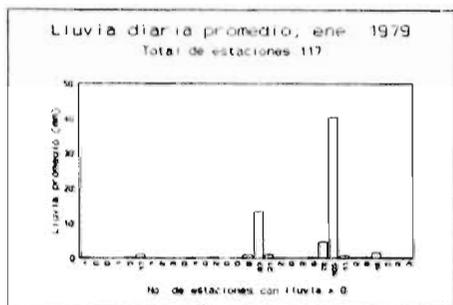
En octubre las lluvias comienzan a presentarse más aisladas en el tiempo (ver Figura 4.5.d), siendo éste un mes de transición a las llamadas lluvias de invierno. Véase en las Figuras 4.6 que durante los meses de noviembre a febrero, las lluvias se presentan aisladas temporalmente y con gran extensión espacial. Como lo indica el número de estaciones con lluvia, que es siempre cercano al total de estaciones. Esto se debe a que las lluvias de invierno las producen frentes fríos de gran extensión, denominados Equipatas. Los cuales se trasladan desde latitudes polares, donde se originan, y producen lluvias persistentes de baja intensidad.



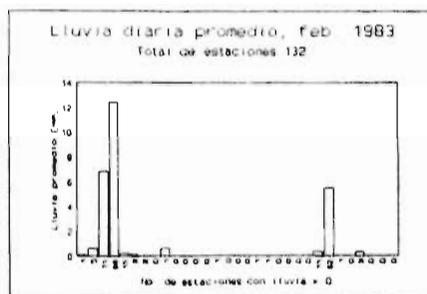
4.6.a



4.6.b



4.6.c



4.6.d

Figuras 4.6 Lluvia diaria promedio en el área de la cuenca en otoño e invierno.

#### 4.2.3 Evaporación potencial

En la Figura 4.7 se presenta la normal semanal de evaporación potencial de la región de la cuenca; obtenida, como en el caso de la lluvia, promediando las normales de 122 estaciones climatológicas convencionales, situadas dentro del rectángulo punteado de la Figura 4.3.

Véase en la figura mencionada que, de mediados de octubre a mediados de febrero, periodo de las lluvias de invierno, se evapora sólo un 20% del total promedio anual. Asimismo, que la evaporación potencial semanal promedio en los meses de verano, comienza a decrecer exponencialmente con el inicio de las lluvias de verano. Y es en promedio (30 mm) el doble de la de invierno (15 mm).

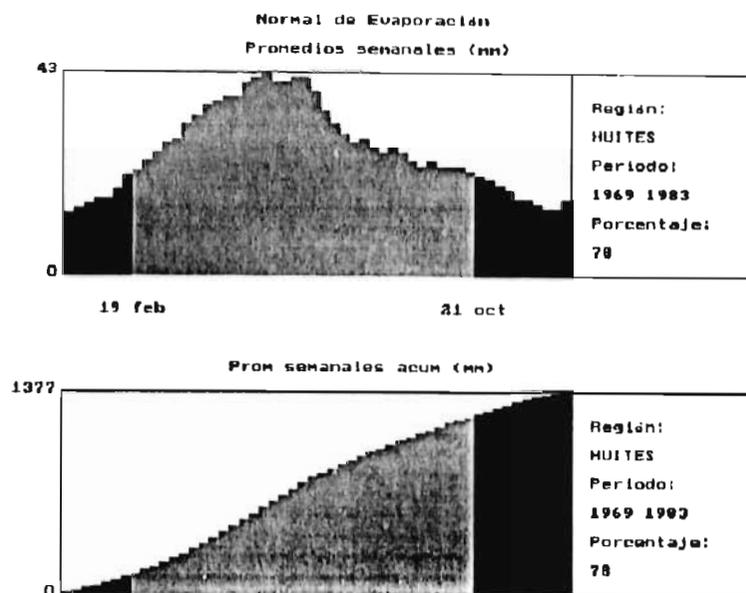


Figura 4.7 Normal de evaporación en la región de la cuenca.

#### 4.2.4 Avenidas extremas registradas en el sitio de la presa

La distribución temporal de la lluvia mostrada en la normal pluviométrica puede sugerir que las mayores avenidas se presentan de junio a octubre. Sin embargo, como puede verse en la Tabla 4.1, las mayores avenidas registradas en el sitio de la presa Huites, desde 1940, ocurren de noviembre a principios de marzo. La excepción son las avenidas ocurridas en septiembre de 1958 y septiembre de 1978, debidas a lluvias ciclónicas. Las lluvias de septiembre de 1978 son del orden de las que produjeron las mayores avenidas de invierno. Sin embargo, dichas lluvias ciclónicas no produjeron el volumen de escurrimientos de aquellas.

Esta diferencia en el volumen de escurrimiento puede deberse principalmente a las pérdidas por evaporación en verano, dada la gran extensión de la cuenca. La evaporación potencial semanal promedio en los meses de verano, como ya se

mencionó en la sección anterior, es el doble de la de invierno. En los meses de invierno la infiltración puede ser menor que en los meses de verano, principalmente en las partes altas de la cuenca, ya que las bajas temperaturas pueden causar cristalización del agua en el subsuelo. Se ha sugerido también que a los escurrimientos de invierno contribuyen *deshielos*, principalmente provenientes de las partes altas de las cuencas.

Los escurrimientos máximos en el sitio de la presa Huites muestran una cuasiperiodicidad de cinco a seis años (ver anexo 2). Lo cual puede estar relacionado con la influencia del FENOS (Fenómeno el Niño-Oscilación del Sur). Sin embargo, esta relación o dependencia no ha sido investigada con profundidad en zona (v.g. Acosta, 1989).

Tabla 4.1 Avenidas máximas registradas en el sitio de la presa.

FECHA	GASTO MEDIO MÁXIMO DIARIO(m <sup>3</sup> /s)
DICIEMBRE 9 DE 1943	8,600.4
ENERO 14 DE 1949	6,758.4
ENERO 15 DE 1955	4,007.3
SEPTIEMBRE 21 DE 1958	2,613.1
ENERO 12 DE 1960	8,991.0
FEBRERO 22 DE 1973	5,801.1
NOVIEMBRE 9 DE 1974	3,811.9
SEPTIEMBRE 27 DE 1978	5,939.3
FEBRERO 5 DE 1979	4,443.9
MARZO 4 DE 1983	8,000.0
DICIEMBRE 15 DE 1984	4,510.3
DICIEMBRE 29 DE 1990	11,350.0

## **5. ANÁLISIS DEL PROCESO LLUVIA-ESCURRIMIENTO DE INVIERNO EN LA CUENCA**

En la sección anterior se vio que las avenidas más grandes en el sitio de la presa se presentan en invierno, por tanto son las que más interesa predecir. En consecuencia, en este capítulo se analiza el proceso de lluvia-escorrentamiento de invierno, con objeto de formar los patrones ejemplos del proceso que servirán para entrenar una red neuronal que lo simule.

### **5.1 Estimación óptima de la precipitación**

La precipitación media sobre un área ha sido tradicionalmente calculada en hidrología con base en los bien conocidos Polígonos de Thiessen. No obstante la gran popularidad de los Polígonos de Thiessen, este método sólo provee el valor de la precipitación media sobre un área, pero se desconoce la precisión de la estimación. Además de que esto es un punto esencial para el análisis de la confiabilidad de la estimación, también se requiere que el método empleado para calcular la precipitación media sea capaz de identificar y reproducir las variaciones espaciales de tormentas típicas.

Las variaciones espaciales de la lluvia pueden modelarse mediante procesos estocásticos que las representen en forma continua sobre la región considerada; esto es, la precipitación se maneja como un campo aleatorio. El método Kriging (v.g. Delhome, 1978; Kafritsas y Bras, 1985) permite estimar valores puntuales o funciones lineales del campo aleatorio en una región, utilizando un conjunto limitado de valores puntuales. Adicionalmente a la estimación puntual o promedio de la precipitación, este método provee una medida de la precisión de los valores estimados, lo que permite diseñar o mejorar formalmente una red climatológica (v.g. Delhome, 1978; Toledo y Collado, 1990, Collado y Toledo, 1994).

El método Kriging provee un estimador de funciones lineales de un campo

aleatorio, que toma en cuenta la variabilidad espacial a través de la covariancia, el semivariograma o la covariancia generalizada del proceso  $Z(\mathbf{x})$ . A su vez, esas funciones tienen que identificarse y sus parámetros estimarse a partir de la observación  $z(\mathbf{x})$ . Entonces, la precipitación media sobre un área  $A$ , definida como

$$P = \frac{1}{A} \int_A Z(\mathbf{x}) \, d\mathbf{x} \quad (5.1)$$

se calcula con un estimador lineal que considera  $n$  estaciones climatológicas

$$\hat{P} = \sum_{i=1}^n \lambda_i Z(x_i) \quad (5.2)$$

donde los pesos  $\lambda_i$ ,  $i = 1, \dots, n$  se determinan de tal manera que el valor esperado del estimador sea igual al valor esperado de la precipitación media

$$E(P) = E(\hat{P}) \quad (5.3)$$

y que el error cuadrado medio de la estimación sea mínimo

$$\text{Var}(P - \hat{P}) = \min \quad (5.4)$$

La condición (5.3) asegura que el estimador no produzca errores sistemáticos en los valores estimados; es decir, Kriging es un estimador insesgado. La propiedad (5.4) establece un criterio para minimizar la variancia de estimación; esto es, cualquier otro estimador lineal e insesgado tiene una variancia del error de la estimación mayor que la de Kriging.

Introduciendo un multiplicador de Lagrange  $\mu$ , el error cuadrado medio de la estimación puede minimizarse sujeto a la condición de insesgadura. Después de

formar la función auxiliar, de derivar con respecto a los pesos  $\lambda$  y al multiplicador de Lagrange  $\mu$ , y de igualar a cero, se obtiene un sistema lineal de ecuaciones con igual número de incógnitas, llamado sistema Kriging, de donde se obtienen los pesos óptimos, los multiplicadores de Lagrange, así como el valor de la mínima variancia del error de la estimación.

La estimación de la precipitación con el método Kriging considera, *i*) las distancias entre estaciones climatológicas, *ii*) las distancias entre los puntos de observación y un punto que describe el área A, y *iii*) la estructura espacial de la precipitación a través de la función de covariancia generalizada. La estimación de la precipitación media sobre el área A (que también puede ser un punto), para ciertas observaciones  $z(x_i)$ , se obtiene utilizando los pesos óptimos en el estimador (5.2). Mayores detalles sobre el método Kriging y sobre la identificación y estimación de parámetros de la función de covariancia generalizada, pueden consultarse en varios autores (v.g., Kafritzas y Bras 1985; Collado, 1988).

## **5.2 Cálculo de valores puntuales y precipitación media**

De registros hidrométricos se tomaron las fechas en que se presentaron avenidas, ordinarias y extraordinarias, de fines de octubre a principios de marzo. Dado que los datos de lluvia con que se contó son de 1962 a 1987, la búsqueda se redujo a ese periodo. Se determinó la fecha de ocurrencia de cerca de 50 avenidas. Para cada una se obtuvieron los datos de lluvia diaria de 20 días (14 días antes del día en que se registra el gasto medio diario máximo, GMDM, y 4 días después). Para cada uno de los días (1000 en total) se obtuvieron valores puntuales de lluvia diaria, mediante interpolación con el método Kriging (Collado, 1988), en la malla regular que se muestra en la Figura 5.1. Para lo cual se utilizaron todas las estaciones climatológicas mostradas en la Figura 4.3.

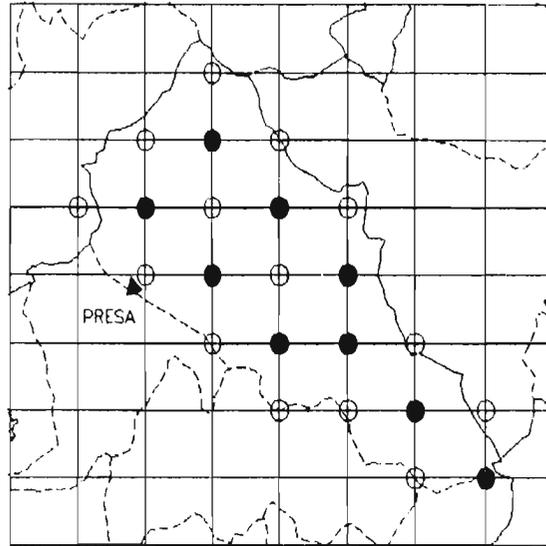


Figura 5.1 Malla de estimación puntual de lluvia.

Se calculó también la precipitación media diaria en la cuenca, mediante el promedio aritmético de los valores estimados por interpolación, en puntos situados dentro y cerca de la cuenca (señalados con círculos en la Figura 5.1). En la tabla 5.1 se presentan las fechas de los días, previos a las avenidas, que tienen lluvia media en la cuenca mayor a 0.5 mm. El GMDM, en cada evento, se presenta el último día a la derecha.

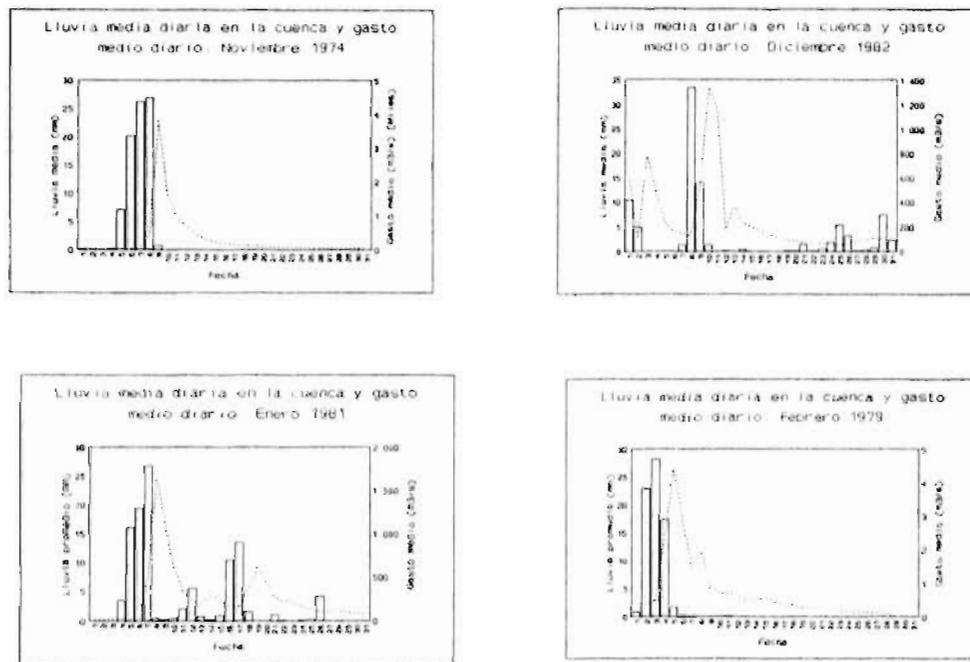
Con base en la malla de valores puntuales estimados se hicieron mapas de isoyetas. Algunos de dichos mapas se presentan en el Anexo 3. Los valores de lluvia, para cada día, se normalizaron a 100 milímetros. En cada página se presentan dos mapas que muestran similitud en la distribución espacial de la lluvia. Nótese por la fecha de cada pareja de mapas, que dicha similitud ocurre aproximadamente por la misma época del año.

Tabla 5.1. Días anteriores a las avenidas con lluvia. El GMDM se presenta el último día del periodo en cada evento.

Periodo	Fecha de los días con lluvia mayor a 0.5 mm																	
sep61	26	oct61	10	26	27	28	29	30	-	02	-	04	05	06	07	08	09	10
oct61	25	nov61	08	-	-	27	28	29	30	31	01	-	-	04	-	06	07	08
ene62	13	ene62	26	-	-	-	-	-	-	-	-	-	-	-	23	24	25	-
sep62	21	oct62	05	21	22	23	24	25	26	-	-	-	-	01	02	03	04	-
nov63	28	dic63	12	-	-	30	-	-	-	-	-	-	-	-	09	10	11	12
ene65	25	feb65	09	-	-	-	-	-	-	-	02	03	-	05	06	07	08	-
dic65	09	dic65	23	09	-	-	12	13	14	-	16	17	-	19	20	21	22	-
ene66	27	feb66	10	27	-	-	-	-	-	-	-	-	-	06	07	08	09	-
dic67	02	dic67	17	02	03	04	-	-	-	-	-	-	-	12	13	14	15	-
nov68	01	nov68	15	-	-	-	-	-	-	-	-	-	-	11	12	13	14	15
feb69	01	feb69	15	-	-	03	04	05	-	-	08	09	-	11	12	13	14	-
nov69	21	dic69	05	-	-	-	-	-	-	-	-	-	-	01	02	03	04	-
feb70	08	feb70	22	-	-	-	-	-	-	-	-	-	-	18	19	20	-	-
oct71	12	oct71	26	12	13	14	15	16	17	-	-	-	-	-	24	25	26	-
dic71	06	dic71	20	-	-	-	-	-	-	-	-	-	15	16	17	18	19	-
dic71	22	ene72	05	-	-	-	-	-	-	-	-	-	-	-	02	03	04	-
oct72	16	oct72	30	16	-	18	19	20	-	-	-	-	25	26	27	28	29	30
nov72	11	nov72	25	-	-	-	-	-	17	-	-	-	20	21	22	23	-	-
dic72	24	ene73	07	-	25	26	27	28	-	-	31	01	02	03	04	05	06	-
feb73	08	feb73	22	08	09	-	-	-	-	-	-	-	-	-	19	20	21	-
oct74	26	nov74	09	-	-	-	29	-	31	-	-	-	-	05	06	07	08	09
dic74	13	dic74	27	-	-	-	-	18	-	-	-	-	-	-	24	25	26	27
ene75	20	feb75	03	-	-	22	-	-	-	-	27	28	29	30	31	01	02	-
oct76	10	oct76	24	-	-	12	13	14	-	-	-	-	-	20	-	22	23	24
nov76	06	nov76	20	-	-	-	-	-	12	13	-	15	16	17	18	19	-	-
feb78	17	mar78	03	-	-	-	-	-	-	-	-	26	27	-	01	02	-	-
oct78	10	oct78	24	-	11	12	-	-	-	-	-	-	19	20	21	22	23	24
dic78	17	dic78	31	-	18	19	-	-	-	-	-	-	-	-	28	29	30	31
dic78	12	ene79	26	-	-	-	-	16	17	18	-	-	-	-	23	24	25	-
ene79	22	feb79	05	-	23	24	25	-	-	28	-	-	-	01	02	03	04	05
nov80	25	dic80	09	-	-	-	-	-	-	-	-	-	-	-	06	07	08	-
dic80	24	ene81	08	-	-	-	-	-	-	-	-	-	-	04	05	06	07	-
feb81	18	mar81	04	-	-	20	-	-	-	-	-	26	27	28	01	02	03	-
sep81	24	oct81	08	-	-	-	-	29	30	01	02	03	04	05	06	07	08	-
dic81	30	ene82	13	-	-	-	-	-	-	-	-	-	09	10	11	12	-	-
sep82	17	oct82	01	-	-	-	-	22	-	-	-	26	27	28	29	30	-	-
nov82	26	dic82	10	26	-	-	-	01	02	-	-	-	-	-	08	09	10	-
ene83	18	feb83	01	18	19	20	-	-	-	-	-	-	-	-	30	31	-	-
ene83	23	feb83	06	-	-	-	-	-	29	30	-	-	-	-	03	04	05	-
feb83	19	mar83	05	-	-	-	-	-	25	-	-	-	01	02	03	04	05	-
oct83	06	oct83	20	06	-	-	-	-	-	-	-	-	16	17	18	19	20	-
nov83	10	nov83	24	-	-	-	-	-	-	-	-	-	20	21	22	-	-	-
nov83	21	dic83	05	21	22	-	-	-	-	-	-	-	01	02	-	-	05	-
dic86	05	dic86	19	05	06	07	-	-	-	-	-	13	14	15	16	17	-	-
dic87	05	dic87	19	-	-	-	-	-	-	12	-	-	-	16	17	18	-	-

### 5.3 Gráficas de lluvia-escorrimento

De los datos hidrométricos de la estación Huites, se obtuvieron valores de los gastos medios diarios (GMD) de las avenidas seleccionadas, 4 días antes del pico de la avenida y 15 días después. Se observó que, en general, el gasto medio vuelve a ser el mismo que había antes de la avenida, aproximadamente 15 días después del inicio de la avenida. Se hicieron gráficas como las que se muestran en las Figuras 5.2, de lluvia media diaria en la cuenca (mm) y GMD ( $m^3/s$ ).



Figuras 5.2 Gráficas de lluvia escurrimiento en meses de invierno.

Del análisis de dichas gráficas y de la tabla 5.1 se encontró:

- 1) Las lluvias de invierno duran, en general, no más de cuatro días.
- 2) Hay pocos eventos con lluvia antecedente.

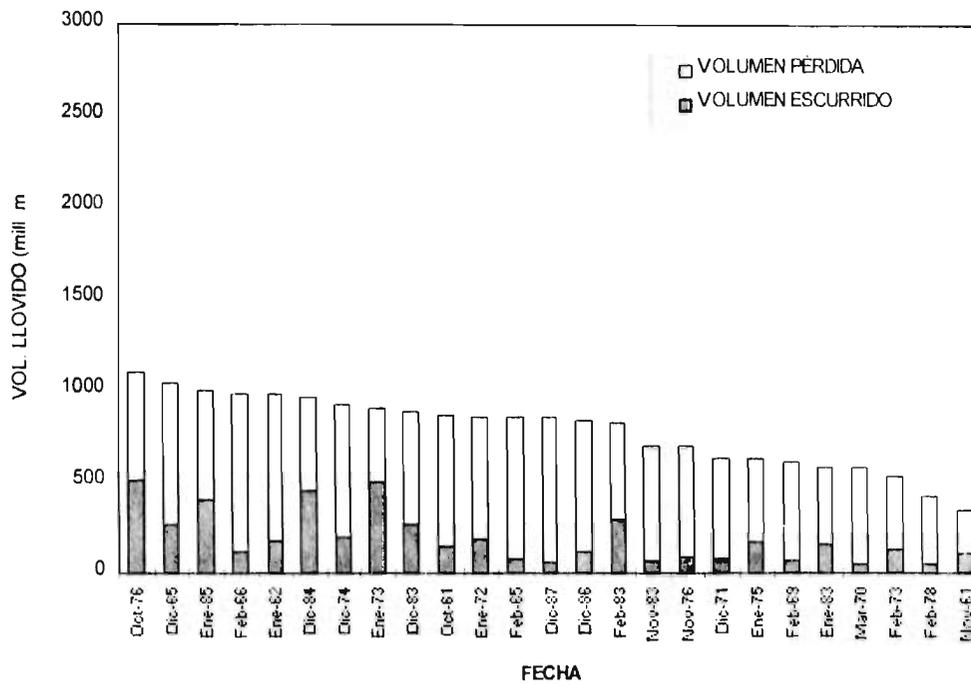
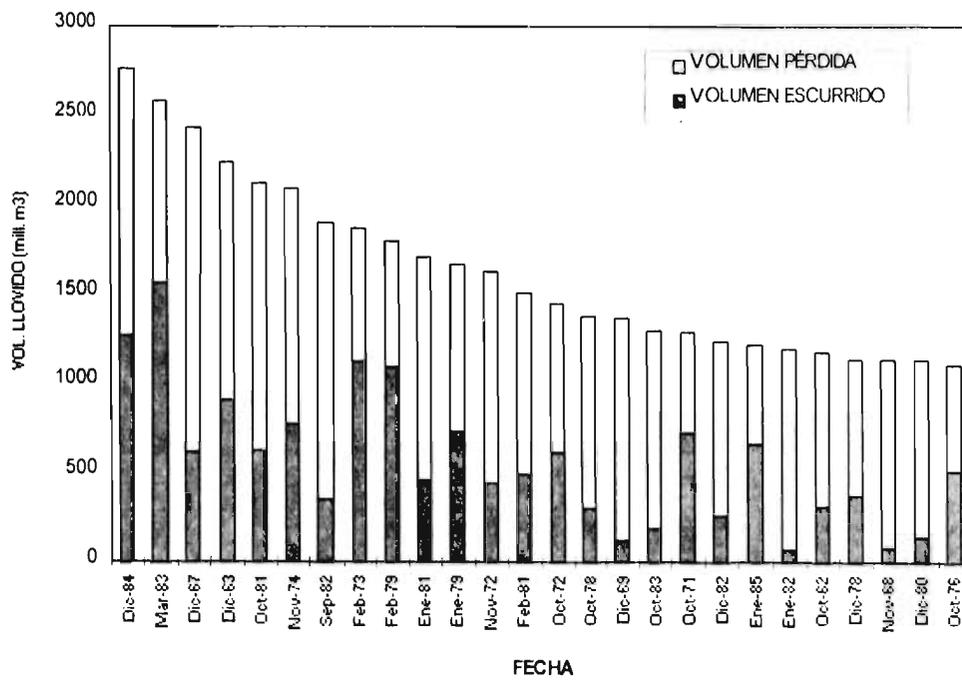
3) En general, cuando hay lluvia antecedente, las tormentas se separan por tres o más días entre sí.

4) Por tiempo de respuesta de la cuenca, es posible predecir los gastos medios diarios de una avenida, desde su inicio. Conociendo la lluvia previa a la avenida, de cuando menos 4 días. El gasto medio diario máximo (GMDM) se presenta un día después del último día con lluvia significativa.

#### **5.4 Volúmenes de lluvia, escurrimiento, y pérdidas**

Para cada evento, se calculó el volumen total de lluvia acumulada en cuatro días en la cuenca. Así como el volumen de los escurrimientos de 15 días en el sitio de la presa, restándose cada día el volumen correspondiente al gasto base (gasto medio registrado antes del inicio de la avenida). Las pérdidas (evapotranspiración e infiltración) se calcularon obteniendo la diferencia entre el volumen llovido y el escurrido. Los resultados se consignan en la tabla del anexo 4. El porcentaje de pérdidas varía de 38% a 92% del total llovido. Los valores más altos de pérdidas corresponden, en general, a los eventos con volúmenes de lluvia más pequeños (ver Figuras 5.3).

Como puede verse en las gráficas, eventos con un volumen acumulado de lluvias similar, pueden tener volúmenes de escurrimientos muy diferentes. El volumen de escurrimientos depende, fuertemente, de la distribución espacial y temporal diaria de la lluvia, así como de las pérdidas. Las cuales dependen a su vez, del contenido de humedad del suelo. Los modelos de lluvia-escurrimiento para cuencas grandes deben considerar, necesariamente, dichas distribuciones.



Figuras 5.3 Volúmenes de lluvia (de cuatro días), escurrimiento (15 días) y pérdidas por evento (en millones de m³).

## **6. MODELACIÓN DEL PROCESO DE LLUVIA-ESCURRIMIENTO DE INVIERNO EN LA CUENCA DE LA PRESA HUITES**

### **6.1 Consideraciones o hipótesis básicas para la modelación**

De acuerdo a la teoría expuesta sobre la red de retropropagación y al análisis hecho del proceso de lluvia-escorrimento de invierno en la cuenca, se establecieron las siguientes hipótesis básicas para utilizar dicha red en la modelación del proceso:

1) Si bien los datos no son absolutamente confiables, se supone que son representativos del proceso a simular. Sin embargo, para contar con un conjunto homogéneo de datos, se harán pruebas para detectar eventos no representativos del proceso y eliminarlos.

2) La cuenca se considera como un sistema invariante en el tiempo, cuyo proceso de lluvia-escorrimento puede ser modelado (o emulado) por una red neuronal de retropropagación, con base a sus entradas (lluvia) y salidas (escorrimento y pérdidas).

3) Es posible representar la variación espacial diaria de la lluvia en la cuenca, mediante valores puntuales en los nodos de una malla regular en la cuenca, utilizando la red actual de estaciones convencionales que es deficiente. La distancia entre los nodos de la malla se determinará experimentalmente.

4) Se considera que por lo menos 4 valores de lluvia diaria, previa a la avenida, en cada punto de la malla, son suficientes para modelar el escurrimento medio diario directo (de no más de 15 días) a la salida de la cuenca. Por lo que se harán pruebas considerando la lluvia de 4 a 8 días previos a la avenida.

5) La red neuronal puede realizar intrínsecamente la corrección de pérdidas por

infiltración y evapotranspiración, ya que los patrones de lluvia tendrán una misma estructura temporal y espacial para cada evento. Con lo cual se persigue que el entrenamiento determine el peso que cada valor del patrón de lluvia tiene en el escurrimiento.

6) La evapotranspiración cambia espacialmente en la cuenca, pero las variaciones durante la temporada de invierno en cada punto no son significativas. En consecuencia, en cada punto de la cuenca con valor de lluvia, se haría la misma corrección para cada evento, por lo cual no se requiere hacer ninguna corrección temporal por evaporación.

## **6.2 Construcción de los modelos de redes**

### **6.2.1 Arquitectura y tamaño de la red**

El tamaño de la red, esto es, el número de capas y de neuronas en cada capa, como ya se mencionó, debe tratar de reducirse. De manera que la red modele adecuadamente el comportamiento del sistema, sin sacrificar información relevante y sin usar información irrelevante, principalmente si se cuenta con pocos ejemplos del funcionamiento del sistema.

Esto es particularmente importante en el caso de la lluvia. Dado que podemos contar con valores de lluvia en una malla regular que abarca la cuenca, se requiere determinar cual es la mayor distancia entre puntos de una malla regular para no perder en forma discreta la información de las variaciones espaciales fundamentales. Además es necesario considerar la distribución temporal (diaria) de la lluvia. Lo cual aumenta el número de valores de entrada. La única manera de determinar un tamaño adecuado de la red es experimentalmente, como se muestra en las primeras pruebas de la sección 6.3.

### 6.2.2 Preprocesamiento de los datos y formación de patrones

La distribución espacial y temporal de la lluvia se proporciona al modelo de red en la estructura de los patrones, así como la evolución del gasto medio diario a la salida de la cuenca. La estructura general de la red y la codificación de los datos para formar los patrones de entrada y salida puede verse en la Figura 6.1. Se hicieron pruebas formando los patrones de entrada, con diferente número de valores puntuales en la cuenca, y diferente número de valores diarios en cada punto. Los patrones de salida (los valores de gastos medios diarios) se formaron con 10 valores secuenciales.

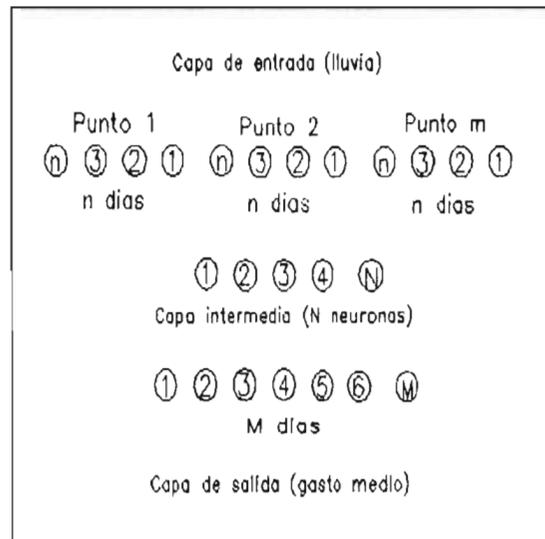


Figura 6.1 Codificación de los datos de entrada y salida, y estructura de la red.

Los valores de cada patrón, tanto de lluvia como de escurrimiento, fueron normalizados linealmente; esto es, fueron divididos entre una cantidad mayor a los valores de todos los ejemplos. A cada valor del hidrograma se resta el gasto base medio, considerando como gasto base medio el que se presenta antes del

inicio de la avenida. Se escribieron programas de cómputo para el preprocesamiento y formación de los patrones de entrenamiento de cada ejemplo, así como para la graficación de los resultados.

### 6.2.3 Entrenamiento

Como ya se mencionó en la sección 3.1.3 la capacidad de generalizar de una red; esto es, de predecir correctamente cualquier evento, incluido o no en los ejemplos de entrenamiento, depende de varios factores. Siendo estos: arquitectura y tamaño de la red; número de ciclos de entrenamiento y algoritmo de aprendizaje; complejidad del problema; y número y calidad de los ejemplos utilizados para entrenar la red. Tomando en consideración dichos factores se hicieron más de 50 pruebas, las cuales duraron de 15 minutos a varias horas de procesamiento en microcomputadoras 386, dependiendo del tamaño de la red y del número de ciclos requerido.

Los resultados de algunas pruebas relevantes se presentan a continuación. La medida del ajuste de la red para cada evento de entrenamiento, o de predicción, es el error cuadrático medio (conocido como RMS, por sus siglas en inglés). El cual resulta de la comparación de los,  $n$ , gastos medios diarios medidos y los valores calculados por la red, mediante

$$RMS = \frac{1}{n} \sum_z (d_z - o_z)^2 \quad (6.1)$$

donde

RMS, es una medida de la calidad del resultado

$z$ , es el subíndice de las salidas

$d_z$  son los valores observados

$o_z$  son los valores calculados por la red

### 6.3 Pruebas de homogeneidad de los datos y tamaño de red

Estas pruebas se realizaron con objeto de analizar la capacidad de la red de ajustar cada uno de los ejemplos de entrenamiento. Así como para determinar un tamaño adecuado de la red. Para estas pruebas se utilizaron 45 ejemplos. Es importante mencionar que el gasto medio diario máximo (GMDM) de 41 de los ejemplos es menor de 3,000 m<sup>3</sup>/s, siendo el GMDM de la mayor avenida aproximadamente 8,000 m<sup>3</sup>/s.

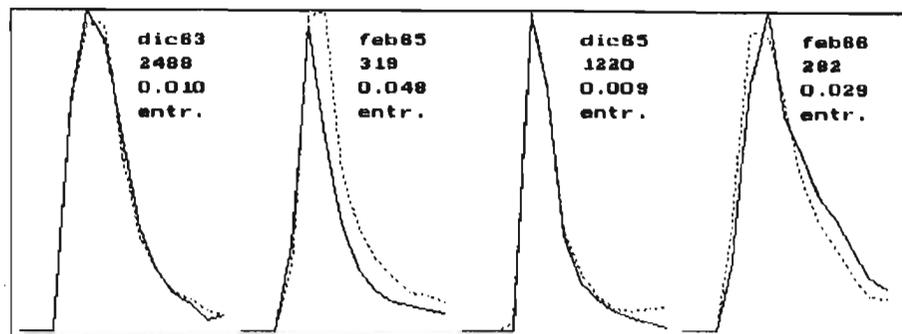
#### *Prueba No. 1*

Los patrones de lluvia se formaron considerando 23 puntos en la cuenca con 4 valores de lluvia diaria en cada uno. La distribución de los puntos se muestra en la Figura 5.1, con círculos negros y blancos. En otras palabras, los patrones de lluvia incluyen 23 hietogramas de lluvia diaria. Los patrones de escurrimiento se formaron con 10 valores secuenciales de GMD. Se utilizó una capa intermedia de 10 neuronas. Esto es, el número de neuronas en cada capa de la red fue de 92-10-10 respectivamente. Se hicieron varias corridas aumentando en cada una el número de ciclos de entrenamiento.

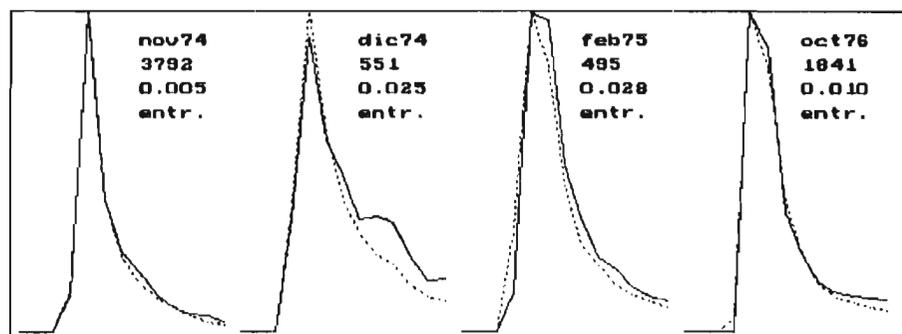
En las Figuras 6.2 se muestran resultados, de algunos eventos, para 500 ciclos de entrenamiento. Con línea punteada se dibuja el hidrograma calculado por la red y con línea continua el hidrograma medido. Se indica la fecha del evento, el GMDM mayor de ambos hidrogramas (medido y calculado), y el RMS (ecuación 3.1) de ajuste normalizado para cada evento. También se indica si el resultado es de entrenamiento (entr.) o predicción a posteriori (pred.).

En la tabla 6.1 se presentan los errores ordenados de mayor a menor, para todos los eventos. Nótese que la red ajusta aceptablemente la mayoría de los ejemplos, con excepción de varios ejemplos con GMDM menor a 1000 m<sup>3</sup>/s. Asimismo, que el error disminuye conforme aumenta el GMDM. Si bién algunos eventos, con GMDM pequeños (como puede verse en las figuras 6.2) son aceptablemente

ajustados. Los eventos 10 eventos con mayor error de ajuste se consideraron como no homogéneos, y se eliminaron en las pruebas de predicción a posteriori.



6.2.a



6.2.b

Figuras 6.2. Ajuste de hidrogramas con una red de 92-10-10 neuronas y 500 ciclos de entrenamiento.

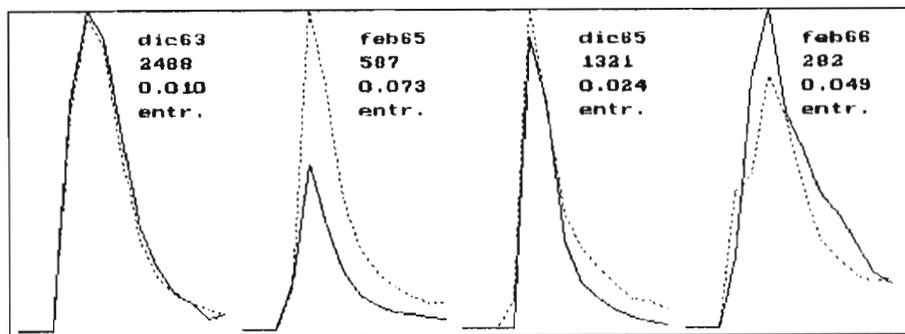
### Prueba No. 2

Los patrones de lluvia se formaron considerando 9 puntos en la cuenca con 4 valores de lluvia diaria en cada uno. La distribución de los puntos se muestra en la Figura 5.1 con círculos negros. En cada sitio se hizo un promedio del valor de lluvia de 5 puntos. Los patrones de escurrimiento se formaron con 10 valores secuenciales de GMD. Se utilizó una capa intermedia de 10 neuronas. El número

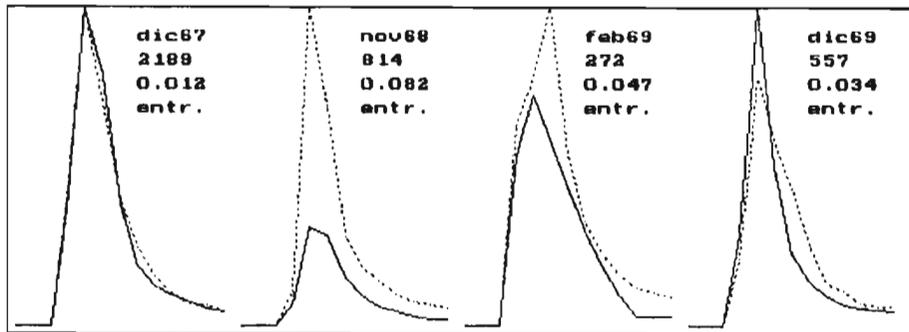
de neuronas en cada capa de la red fue de 36-10-10 respectivamente. Se hicieron varias corridas aumentando el número de ciclos de entrenamiento.

En las Figuras 6.3 se muestran algunos resultados obtenidos para 500 ciclos. Asimismo en la tabla 6.1 se presentan los errores de ajuste ordenados de mayor a menor para todos los eventos. Como puede verse en dicha tabla, siendo igual el número de ciclos que en la prueba anterior, los ajustes tienen mayor error que en la prueba anterior, posiblemente porque se pierde información al considerar menos puntos. Comparar, por ejemplo, los eventos de las figuras 6.2a y 6.3a. Como en la prueba anterior, la red no ajusta bien varios de los eventos con GMDM menor a 1000 M<sup>3</sup>/s (ver Figura 6.3b).

Por otra parte, con objeto de considerar la lluvia antecedente, se hicieron pruebas incluyendo un mayor número de días en cada uno de los 9 puntos (6 y 8 días). Los errores obtenidos en dichas pruebas se muestran en la tabla 6.2. Sin embargo, como puede verse en la tabla, la inclusión de más días de lluvia antecedente no mejora el error de ajuste. Esto era de esperarse, ya que en general todos los eventos considerados carecen de lluvia antecedente significativa (ver tabla 5.2).



6.3.a



6.3.b

Figuras 6.3. Ajuste de hidrogramas con una red de 36-10-10 neuronas y 500 ciclos de entrenamiento.

Tabla 6.1 Comparación del error RMS obtenido considerando distinto número de puntos en la cuenca y 4 días de lluvia en cada punto.

23 puntos 4 días (92-10-10)			9 puntos 4 días (36-10-10)		
FECHA	RMS	GMDM	FECHA	RMS	GMDM
Mar-70	0.0766	161.6	Mar-70	0.0943	161.6
Dic-86	0.0568	268.5	Nov-68	0.0822	254.0
Mar-78	0.0556	158.6	Ene-82	0.0812	190.1
Dic-71	0.0524	204.6	Nov-83	0.0761	266.0
Nov-68	0.0507	254.0	Ene-83	0.0759	692.2
Feb-69	0.0484	196.5	Nov-61	0.0750	713.5
Feb-65	0.0479	301.6	Feb-65	0.0726	301.6
Ene-83	0.0426	692.2	Mar-78	0.0680	158.6
Ene-82	0.0370	190.1	Dic-86	0.0664	268.5
Dic-69	0.0369	557.1	Feb-75	0.0660	491.6
Dic-87	0.0345	189.5	Dic-87	0.0656	189.5
Nov-61	0.0328	713.5	Dic-71	0.0490	204.6
Ene-72	0.0322	549.9	Feb-66	0.0486	281.9
Nov-76	0.0306	191.1	Feb-69	0.0471	196.5
Feb-66	0.0288	281.9	Nov-76	0.0447	191.1
Nov-83	0.0287	266.0	Ene-62	0.0416	672.8
Feb-83	0.0278	1020.6	Oct-61	0.0403	476.4
Feb-75	0.0275	491.6	Ene-73	0.0399	1863.8
Oct-61	0.0262	476.4	Feb-83	0.0362	1020.6
Dic-74	0.0251	504.9	Ene-72	0.0362	549.9
Dic-82	0.0222	1208.1	Oct-71	0.0358	1952.2
Ene-73	0.0221	1863.8	Dic-78	0.0357	1367.1
Ene-62	0.0191	672.8	Dic-74	0.0347	504.9
Oct-71	0.0188	1952.2	Dic-69	0.0344	557.1
Dic-80	0.0183	598.6	Oct-72	0.0342	1628.7
Oct-72	0.0182	1628.7	Dic-82	0.0324	1208.1
Oct-62	0.0177	1118.0	Dic-80	0.0278	598.6
Sep-82	0.0175	1756.7	Oct-62	0.0266	1118.0
Oct-83	0.0168	914.0	Oct-78	0.0256	857.4
Oct-78	0.0155	857.4	Dic-65	0.0245	1200.5
Dic-78	0.0148	1367.1	Ene-79	0.0193	2478.5
Dic-83	0.0138	1222.9	Oct-76	0.0168	1830.3
Ene-81	0.0138	1637.2	Dic-83	0.0160	1222.9
Mar-81	0.0103	2131.2	Oct-83	0.0157	914.0
Dic-63	0.0100	2488.0	Mar-81	0.0152	2131.2
Oct-76	0.0096	1830.3	Feb-79	0.0144	4103.8
Dic-65	0.0093	1200.5	Nov-72	0.0136	1864.5
Oct-81	0.0088	2356.6	Dic-67	0.0118	2179.9
Ene-79	0.0088	2478.5	Dic-63	0.0103	2488.0
Dic-67	0.0087	2179.9	Sep-82	0.0100	1756.7
Nov-72	0.0050	1864.5	Ene-81	0.0096	1637.2
Nov-74	0.0048	3792.3	Feb-73	0.0084	5733.1
Feb-79	0.0034	4103.8	Nov-74	0.0082	3792.3
Feb-73	0.0023	5733.1	Oct-81	0.0080	2356.6
Mar-83	0.0019	7953.6	Mar-83	0.0066	7953.6

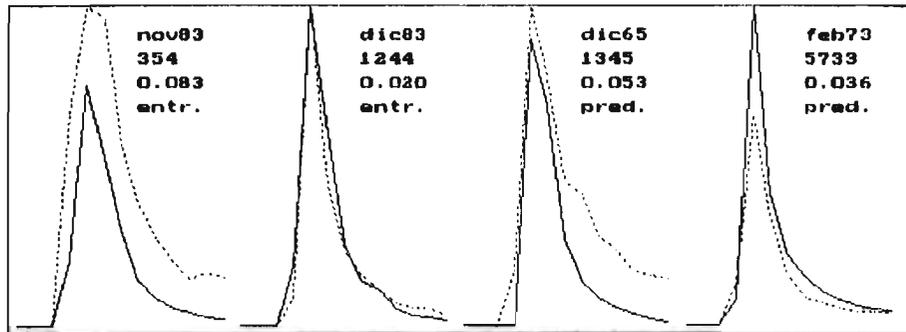
Tabla 6.2 Comparación del error RMS obtenido considerando 9 puntos en la cuenca con 6 y 8 días de lluvia en cada punto.

9 puntos 6 días (54-10-10)			9 puntos 8 días (72-10-10)		
FECHA	RMS	GMDM	FECHA	RMS	GMDM
Ene-83	0.0950	692.2	Mar-70	0.0930	161.6
Mar-70	0.0858	161.6	Nov-83	0.0908	266.0
Nov-68	0.0844	254.0	Nov-68	0.0878	254.0
Nov-83	0.0757	266.0	Ene-83	0.0824	692.2
Ene-82	0.0665	190.1	Ene-82	0.0655	190.1
Feb-65	0.0644	301.6	Feb-65	0.0639	301.6
Mar-78	0.0615	158.6	Dic-71	0.0632	204.6
Nov-61	0.0582	713.5	Mar-78	0.0618	158.6
Dic-86	0.0552	268.5	Nov-76	0.0607	191.1
Ene-62	0.0462	672.8	Dic-86	0.0606	268.5
Dic-71	0.0459	204.6	Ene-72	0.0585	549.9
Nov-76	0.0450	191.1	Dic-74	0.0578	504.9
Ene-72	0.0448	549.9	Nov-61	0.0545	713.5
Dic-80	0.0447	598.6	Feb-69	0.0486	196.5
Feb-69	0.0437	196.5	Dic-87	0.0463	189.5
Dic-87	0.0435	189.5	Dic-80	0.0462	598.6
Oct-62	0.0394	1118.0	Feb-66	0.0460	281.9
Dic-69	0.0378	557.1	Oct-78	0.0456	857.4
Dic-74	0.0374	504.9	Feb-83	0.0432	1020.6
Oct-72	0.0366	1628.7	Oct-72	0.0422	1628.7
Oct-71	0.0358	1952.2	Oct-71	0.0368	1952.2
Feb-66	0.0314	281.9	Oct-62	0.0358	1118.0
Dic-78	0.0306	1367.1	Feb-75	0.0343	491.6
Sep-82	0.0298	1756.7	Ene-79	0.0308	2478.5
Oct-61	0.0285	476.4	Oct-76	0.0288	1830.3
Feb-75	0.0271	491.6	Ene-73	0.0285	1863.8
Oct-78	0.0270	857.4	Nov-72	0.0276	1864.5
Ene-73	0.0235	1863.8	Sep-82	0.0276	1756.7
Dic-82	0.0233	1208.1	Dic-78	0.0261	1367.1
Dic-65	0.0218	1200.5	Dic-69	0.0259	557.1
Feb-83	0.0175	1020.6	Dic-82	0.0257	1208.1
Nov-72	0.0169	1864.5	Nov-74	0.0250	3792.3
Ene-81	0.0163	1637.2	Ene-62	0.0222	672.8
Ene-79	0.0157	2478.5	Oct-61	0.0217	476.4
Mar-81	0.0148	2131.2	Ene-81	0.0209	1637.2
Nov-74	0.0133	3792.3	Mar-81	0.0201	2131.2
Feb-73	0.0125	5733.1	Dic-65	0.0189	1200.5
Dic-83	0.0120	1222.9	Feb-73	0.0168	5733.1
Dic-67	0.0107	2179.9	Dic-83	0.0122	1222.9
Oct-81	0.0105	2356.6	Dic-67	0.0116	2179.9
Feb-79	0.0098	4103.8	Dic-63	0.0115	2488.0
Oct-83	0.0094	914.0	Oct-83	0.0105	914.0
Oct-76	0.0079	1830.3	Feb-79	0.0104	4103.8
Dic-63	0.0060	2488.0	Oct-81	0.0077	2356.6
Mar-83	0.0057	7953.6	Mar-83	0.0045	7953.6

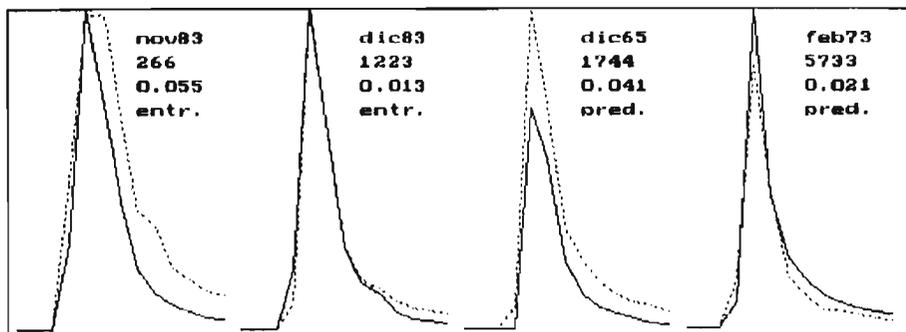
## 6.4 Pruebas de predicción a posteriori

### Prueba No. 3

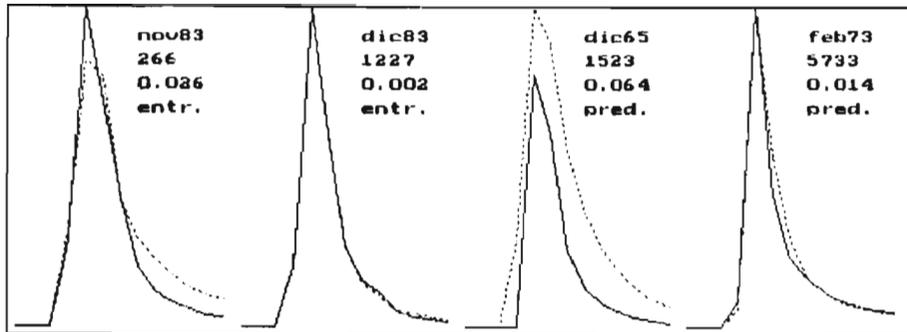
En esta prueba se entrenó la red con 30 eventos y se utilizó la red para predecir 5 eventos. Los valores de lluvia se dieron en 23 puntos, con cuatro días en cada punto. Se utilizó una capa intermedia de 10 neuronas, y 10 valores de escurrimiento. El tamaño de red fue de 92-10-10. Manteniendo fijo el tamaño de la red se aumentó en varias pruebas el número de ciclos. En las Figuras 6.4 se muestran algunos resultados obtenidos. Se encontró el mejor ajuste para 500 ciclos (ver Figura 6.4.c). Nótese como la red predice correctamente el hidrograma de gastos medios de la avenida de febrero de 1973 con un GMDM de 5733 m<sup>3</sup>/s, sobrestimando la avenida de diciembre de 1965 con un GMDM de 1100 m<sup>3</sup>/s.



6.4.a. 100 ciclos de entrenamiento.



6.4.b. 350 ciclos de entrenamiento.

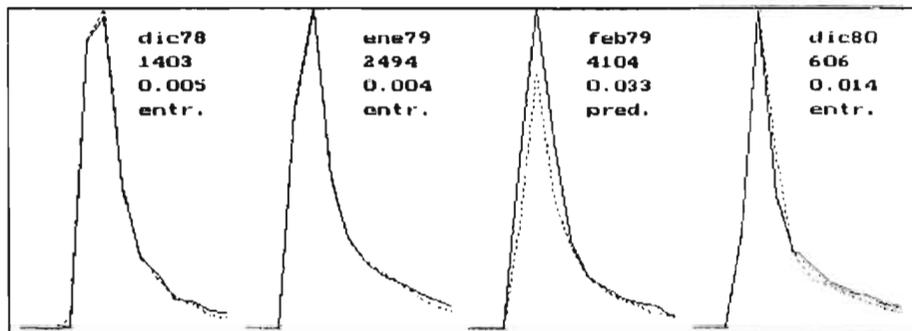


6.4.c. 500 ciclos de entrenamiento.

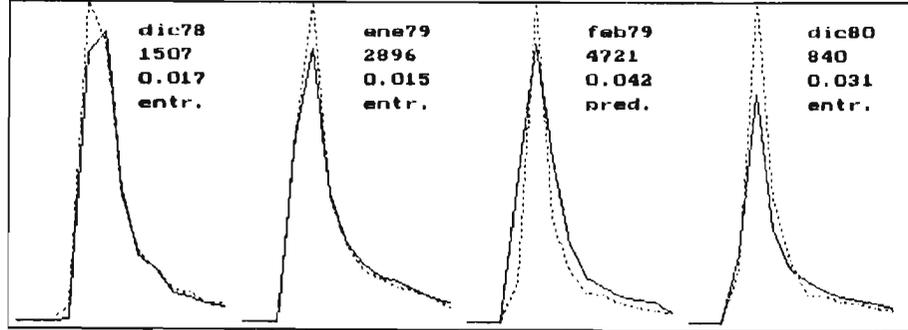
Figuras 6.4. Ajuste de hidrogramas con una red de 92-10-10 neuronas variando el número de ciclos de entrenamiento.

*Prueba No. 4*

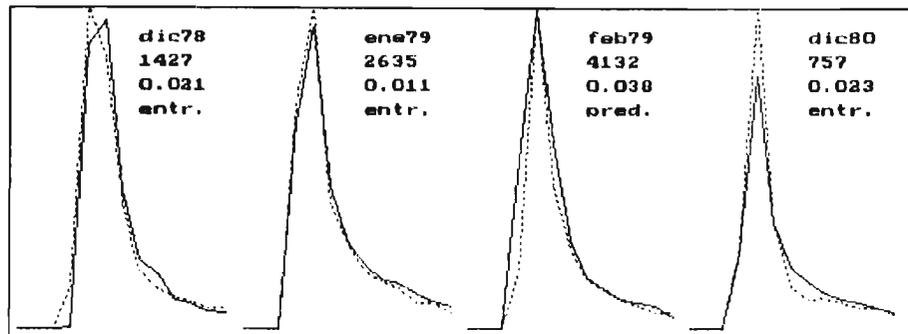
Esta prueba fue similar a la anterior, en el número de ejemplos de entrenamiento y en el tamaño de las capas de entrada y salida. Se analiza la resolución de la red variando el número de neuronas intermedias, para el mismo número de ciclos de entrenamiento. Se hicieron pruebas con 10, 15 y 20 neuronas intermedias, para 500 ciclos en cada caso. En las Figuras 6.5 se muestran algunos resultados para este caso. Se encontró un menor error de ajuste con 15 neuronas (ver Figura 6.5.a). Si bien el GMDM se predice mejor con 10 neuronas intermedias (Figura 6.5.c)



6.5.a. Red de 92-15-10 neuronas.



6.5.b. Red de 92-20-10 neuronas.



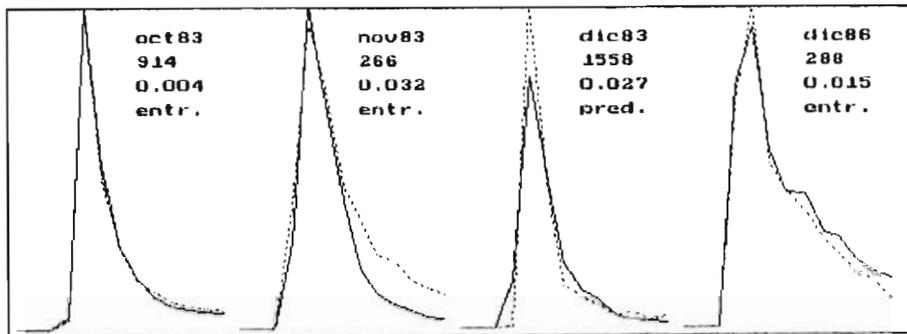
6.5.c. Red de 92-10-10 neuronas.

Figuras 6.5. Ajuste de hidrogramas variando el número de neuronas en la capa intermedia de la red, para el mismo número de ciclos (500).

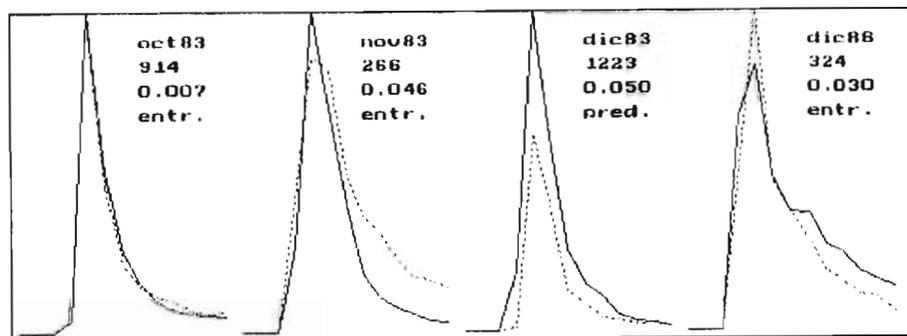
**Prueba No. 5**

En esta prueba se utilizó el mismo tamaño de la red que en las pruebas 3 y 4. Se eliminaron los eventos extraordinarios; esto es los 4 eventos con GMDM mayor a 3000 m<sup>3</sup>/s. Esto se hizo porque por efectos de la normalización los eventos más grandes resultan mejor representados. Inicialmente se utilizaron los 45 ejemplos de la prueba 1. Nuevamente se encontró que la red no puede ajustar los ejemplos eliminados en la prueba 3 y 4. Por lo que para las siguientes pruebas fueron eliminados. En las Figuras 6.6 se presentan los resultados de predicción

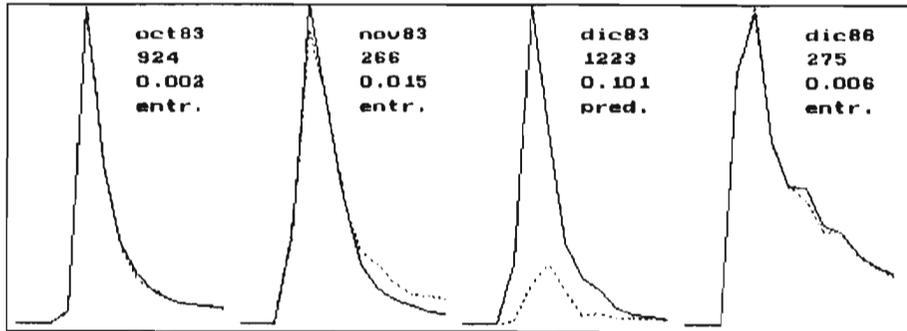
de algunos eventos. En el primer caso se hicieron 500 iteraciones y en el segundo 100 y en el tercero 10000. En el primer caso la predicción de la avenida de diciembre de 1983 es aceptable (Figura 6.6a). En el segundo la predicción es pobre ya que es muy bajo el número de ciclos (Figura 6.6b). Y en el tercer caso (Figura 6.6c), con un número grande de ciclos, la predicción es muy pobre. Esta es una característica de la red neuronal de retropropagación, el sobreentrenamiento. Esto es, más allá de un número apropiado de ciclos la red pierde su capacidad de predicción. Con la red entrenada sin eventos extremos, es de esperarse una mejor predicción de eventos medianos como es el caso de la avenida predicha en esta prueba.



6.6.a. 500 ciclos de entrenamiento.



6.6.b. 100 ciclos de entrenamiento.



6.6.c. 1000 ciclos de entrenamiento.

Figuras 6.6. Ajustes de hidrogramas con una red de 92-10-10 para diferentes ciclos de entrenamiento, eliminándose los 4 eventos extremos.

### 6.5 Discusión de resultados

La capacidad predictiva de un modelo matemático depende de varios factores, como son: las características intrínsecas del modelo; la complejidad del problema; y la cantidad y calidad de los datos usados para calibrarlo, principalmente. Ningún modelo puede simular exactamente un fenómeno físico, ya que éste sólo toma en cuenta las variables más importantes del proceso, y se basa en suposiciones que no se cumplen a cabalidad. Por lo que un modelo es exitoso o robusto si arroja errores de simulación aceptables. A continuación se analizan los resultados obtenidos, con base en el error medio cuadrático de ajuste (RMS).

En las dos primeras pruebas de tamaño de la red y de homogeneidad de datos se encontró que el menor error de ajuste (RMS) se obtiene cuando se utiliza en la capa de entrada 92 valores (4 días de lluvia en 23 puntos de la cuenca). Con objeto de reducir el número de valores de entrada se hicieron pruebas considerando 4,6, y 8 días de lluvia en 9 puntos de la cuenca. El RMS en cada caso aumentó con relación al obtenido en la primera prueba, y es muy similar en

los tres casos; esto es, considerar más de 4 días de lluvia en cada punto no mejora los resultados. El tamaño apropiado de la red es, por consiguiente, el tamaño de la primera prueba (92-10-10).

Con relación a la homogeneidad de los datos, en todas las pruebas anteriores se encontró que los eventos con mayor error de ajuste son, por lo general, los eventos con GMDM más pequeños. Por lo que para las pruebas de predicción a posteriori, se consideraron a éstos como no homogéneos, y no se consideraron como ejemplos de entrenamiento.

En las pruebas de predicción a posteriori se encontró lo siguiente. En la prueba No.3 se determinó que el menor error RMS en la predicción de algunos eventos, con una red de 92-10-10 neuronas, se obtiene para 500 ciclos de entrenamiento. En la prueba No.4 se hicieron pruebas modificando el número de neuronas intermedias. Se encontró que el error disminuye al considerar menos neuronas en esta capa. Esto se debe a que a mayor cantidad de neuronas intermedias, la red tiene que ajustar un mayor número de pesos. En la prueba No.5 se eliminaron los eventos extremos, encontrándose que de esta manera la red mejora la predicción de eventos medianos. Esto ocurre debido a que al normalizar los valores de entrada con respecto a un valor más bajo, los eventos medianos resultan mejor caracterizados.

De los resultados obtenidos, se puede afirmar que el tipo de red neuronal utilizada es una herramienta robusta para modelar el proceso de lluvia-escurrimiento de invierno en la cuenca de la presa Huites. La red puede ajustar la mayoría de los ejemplos de entrenamiento. Sin embargo, no es posible afirmar que con los ejemplos utilizados para el entrenamiento, la red sea capaz de generalizar la predicción (ver sección 3.1.3). Ya que las redes neuronales sólo pueden predecir correctamente la salida de patrones similares a los del conjunto de entrenamiento (Fu, 1994). Lo cual, sin embargo, no es una fuerte limitante para el problema que aquí se estudia.

Como se mencionó en la sección 5.2 y puede verse en los mapas del Anexo 3, la distribución espacial de la lluvia en la cuenca, presenta patrones similares para tormentas de diferentes años. Temporalmente la lluvia también tiende a presentar patrones de concentración, ya sea en los primeros días, o en los últimos. En consecuencia, es de esperarse que no se requiera un número muy grande de ejemplos, para tener una alta probabilidad de que el evento a predecir sea similar a alguno de los de entrenamiento. Esta característica del proceso estudiado se manifiesta en los resultados presentados. Con un conjunto muy reducido de ejemplos de entrenamiento, se pudieron predecir correctamente, a posteriori, avenidas medianas y extremas. Como, por ejemplo, las predicciones de las avenidas de Febrero de 1973 (Figura 6.4.c); febrero de 1979 (Figura 6.5.c); diciembre de 1983 (Figura 6.6.a).

Por supuesto, mientras mayor sea el número de ejemplos de entrenamiento incluido, mayor es la probabilidad de que un ejemplo nuevo sea similar a alguno de los de entrenamiento, para que la red haga una predicción correcta. Es importante incluir en un futuro la mayor cantidad de eventos registrados, para aumentar *la memoria* de eventos de la red (codificada en las matrices de pesos). Principalmente los eventos ocurridos en 1960 y 1990, así como algunos eventos anteriores a 1960 y los registrados hasta la fecha. Los cuales no se introdujeron por no tenerse los datos de lluvia en medios magnéticos.

Considerando que el proceso de lluvia-escurrimiento es un proceso sumamente complejo. Si al hecho de que se contó con pocos ejemplos de entrenamiento, se suma que la red de estaciones de medición de lluvia utilizada es deficiente, los resultados muestran que las redes neuronales son una herramienta robusta y adecuada para modelar el proceso de lluvia - escurrimiento en la cuenca de la presa Huites, con fines de predicción.

## 6.6 Posibilidad de predicciones a priori

La finalidad última del desarrollo de modelos como el que se presenta en este trabajo es su utilización para realizar predicciones exitosas a priori. Lo cual depende no sólo de la capacidad predictiva del modelo sino de muchos factores adicionales. Como por ejemplo, contar con datos confiables y oportunos para alimentar el modelo. En México esta ha sido la limitación más importante, para la operación de modelos de predicción. En un futuro próximo las redes de estaciones automáticas y de radares meteorológicos, a cargo del Servicio Meteorológico Nacional, permitirán contar con mediciones y estimaciones de lluvia en tiempo real. Particularmente, la cuenca de la presa Huites es una de las regiones del país mejor instrumentadas con estaciones automáticas, como puede verse en la Figura 6.7.

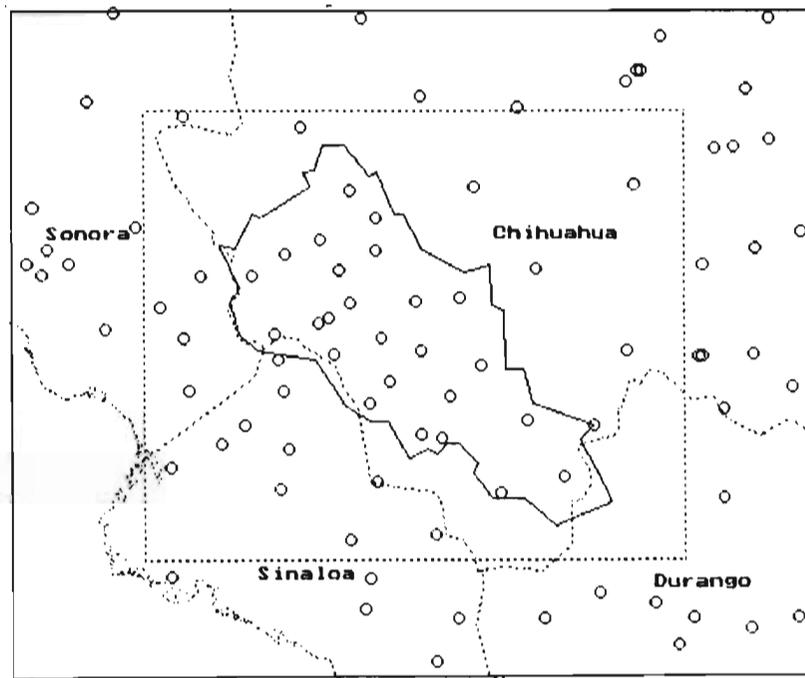


Figura 6.7 Ubicación de estaciones climatológicas con transmisión vía satélite.

Nótese la mejor distribución de las estaciones automáticas con relación a las estaciones convencionales (ver Figura 4.3). La distribución básica actual de estaciones automáticas en la región, es suficiente para realizar predicciones a priori con modelos de redes neuronales como el que se presenta en este trabajo, contando con la lluvia diaria de todas las estaciones, en tiempo real o casi real. Por el tamaño de la cuenca, el tiempo de respuesta permitiría predecir el GMDM con 24 horas de anticipación. Para predicciones a priori se podría tener una red entrenada con todos los eventos, y otra sin eventos grandes, para poder predecir eventos medianos con mayor confiabilidad.

## CONCLUSIONES

Se describió brevemente el estado actual de la predicción de avenidas en México. Y se expuso de manera general la tecnología de redes neuronales; así como la teoría, operación, y entrenamiento de un tipo particular de red neuronal, la red de retropropagación. El empleo de dicha red neuronal para emular el mapeo de dos modelos matemáticos hidrológicos, mostró su habilidad para aproximar ambos modelos y su potencial para ser usada como modelo de procesos hidrológicos.

Se hizo un análisis del proceso de lluvia-escorrentamiento en la cuenca de la presa Huites, cuya área es de 26,020 km<sup>2</sup>, y se usó el tipo de red neuronal mencionado para modelar el proceso de lluvia-escorrentamiento de invierno. Para entrenar la red, en varias pruebas, se utilizaron datos de lluvia diaria y gastos medios diarios de cerca de 50 avenidas ordinarias y extraordinarias ocurridas de 1961 a 1987.

Los resultados de las pruebas realizadas muestran que las consideraciones básicas establecidas para el modelado del proceso con el tipo de red neuronal utilizado son válidas. Por consiguiente, la red neuronal utilizada es una herramienta robusta y apropiada para modelar el proceso, y puede ser utilizada para la predicción de eventos a priori, principalmente en el caso de avenidas extremas. Dado el tamaño de la cuenca, es posible predecir un hidrograma de respuesta de la cuenca (10 valores de gastos medios diarios), desde el inicio de la avenida, conociéndose el gasto medio máximo con 24 horas de anticipación.

El modelado del proceso de lluvia-escorrentamiento presentado, puede ser clasificado como determinístico, de parámetros distribuidos, no lineal, y con memoria asociativa de eventos. Este nuevo enfoque de modelado, basado en el reconocimiento de patrones, es apropiado en hidrología debido a la existencia de patrones similares de distribución espacial y temporal de la lluvia para diferentes eventos. Así como patrones similares de escurrimientos (la forma del hidrograma). La confiabilidad de predicción de la red neuronal utilizada aumenta

mientras mayor sea el número de eventos utilizados para entrenar la red.

El proceso de lluvia-escorrimento en cuencas grandes, es un proceso sumamente complejo de modelar. Para lo cual se utilizan modelos matemáticos basados en la física del problema, y en las características geomorfológicas de las cuencas. Estos modelos, en nuestro medio, son de difícil aplicación por la insuficiencia de datos hidroclimatológicos. El modelado con redes neuronales presentado en este trabajo simplifica el problema de requerimiento de datos, al utilizar únicamente datos diarios de lluvia (de una red de estaciones deficiente) y escurrimientos medios.

Por los resultados obtenidos en esta tesis, se recomienda continuar con la investigación de la utilidad de redes neuronales en la solución de problemas hidrológicos e hidrometeorológicos. La utilización de modelos, como el propuesto, para la predicción de escurrimientos a priori en la presa Huites, o en otras cuencas del país, es cada día más factible. Actualmente, en México cuenta con una nueva plataforma tecnológica para la estimación de lluvia en tiempo real y para el pronóstico a corto plazo. Lo cual, aunado al desarrollo y aplicación de modelos de simulación, dará un nuevo impulso a la predicción de avenidas en el país.

## REFERENCIAS

Acosta G., A., 1988. Sistemas telemétricos para el control de inundaciones. *Ingeniería Hidráulica en México*, Septiembre/Diciembre:59-63.

Acosta G., A., 1988. El Niño: Sus efectos sobre el norte de México. *Ingeniería Hidráulica en México*, III(1): 13-29.

Aldama, A.A., P. Martínez, 1988. Esquema de malla adaptiva para flujo transitorio con frontera móvil. X Congreso Nacional de Hidráulica, Morelia, Michoacán.

Aguilera, V., 1979. Tránsito de avenidas en la cuenca del río Pánuco. Comisión del Plan Nacional Hidráulico, SARH. México.

Aparicio, J. 1982. Un modelo distribuido de la relación lluvia-escorrentamiento. Tesis de maestría, DEPFI, UNAM, 1982.

Aparicio, J., A.A. Aldama, C. Espinosa, 1988. Un esquema de diferencias finitas para la simulación de flujo unidimensional a superficie libre. XIII Congreso Latinoamericano de Hidráulica. La Habana, Cuba.

Buch, A.M., H.S. Mazumdar, P.C. Pandey, 1993. Application of artificial neural networks in hydrological modeling: a case study of runoff simulation of a Himalayan Glacier basin. *Proceedings of the International Joint conference on Neural Networks*, v 1 1993. Publ by IEEE, 971-974.

Campos A., D.F., 1987. Modelo Precipitación-Escorrentamiento de Eventos. Tesis doctoral presentada en la DEPFI de la UNAM. México D.F., 120 pp.

Campos A., D.F., 1990. Aplicación del modelo DEPFI-IMTA de pronóstico de

crecientes. Ingeniería Hidráulica en México, número especial:116-122.

Collado, J., 1988. Estimación óptima de la precipitación con el método Kriging. Ingeniería Hidráulica en México. III(4):34-45.

Collado, J., y A. Wagner, 1990. Un método para transitar avenidas en redes hidrográficas preservando correlación de gastos. XI Congreso Nacional de Hidráulica. Zacatecas, Zacatecas. México.

Collado J., y V. Toledo., 1994. Diseño de la red telemétrica climatológica hidroclimatológica y sinóptica de México. XVI Congreso Latinoamericano de Hidráulica. Santiago, Chile.

Consultores S.A., 1978. Estudio de la planicie de inundación del río Papaloapan. México, D.F., México.

Crespo J.L., E. Mora, 1993. Drought estimation with neural networks. Advances in Engineering Software 18 (1993) 167-170, 1994 Elsevier Science Limited.

Cruickshank, C., 1974. Modelos para el tránsito de avenidas en cauces con llanuras de inundación. Instituto de Ingeniería, UNAM. México.

Chow, V.T., D.R. Maidment, y L.W. Mays, 1993. Hidrología Aplicada. McGraw-Hill interamericana.

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.

Delhomme, J.P., 1978. Kriging in the hidrosiences. Advances in water resources, 1(5):251-266.

Domínguez M., R., y C. Espino, 1992. Análisis hidrológico para el diseño del vertedor de la presa Huites. Instituto de Ingeniería, UNAM, proyecto 2320. 37 pp.

Domínguez M., R., C. Bouvier, y G.F. Mariles, 1994. MERCEDES un modelo de pronóstico de avenidas para cuencas heterogéneas. Revista Tlaloc, Año 1 No. 3.

Dysart, P.S., and J.J. Pulli, 1990. Regional seismic event classification at the NORESS array: Seismological measurements and the use of neural networks. Bull. Seismol. Soc. Am., 80, 1920.

Eagleson, P.E. 1994. The evolution of modern hydrology (from watershed to continent in 30 years). Adv. Water Res. 17:3-18.

Escalante, C.A., y J.A. Raynal, 1988. Algoritmos de estimación de parámetros del método de Muskingum: un análisis comparativo. Memorias del X congreso Nacional de Hidráulica, Tomo II, Morelia, Michoacán.

Escalante, M., y J. Aparicio, 1990. Simulación numérica de flujo bidimensional esquema de direcciones alternantes. XI Congreso Nacional de Hidráulica, Tomo III, Zacatecas, Zacatecas.

Espinosa, N.L., 1983. Modelo matemático de tránsito de avenidas para la cuenca baja del río Papaloapan. Comisión del Plan Nacional Hidráulico, SAHR. México.

Espinosa, N.L., J. Magaña, O. Santillán, y V. Toledo, 1994. Modelo de lluvia-escurrimiento para la cuenca del Río Grijalva. XIII Congreso Nacional de Hidráulica. Puebla, Puebla. México.

Fu, L.M., 1994. Neural networks in computer intelligence. McGraw-Hill.

García R., F., y M. Rosengaus, 1994. Calibración de un modelo para estimación de lluvia a partir de imágenes infrarrojas GOES. XIII Congreso Nacional de Hidráulica, Puebla, Puebla.

González-Villareal, F., H. Garduño, 1994. Water resources planning and management in México. Water resources development, Vol. 10, No. 3.

Gutierrez C., J.A. Raynal, 1989. Programa Hidrología de Superficie HIDROS. Ingeniería Hidráulica en México. Vol. IV, Núm 1, II época. Enero/Abril.

Jáuregui, E., 1989. Los ciclones del norte de México y sus efectos sobre la precipitación. Ingeniería Hidráulica en México, IV(3):43-50.

Jiménez, A.A., y R. Domínguez, 1994. Modelación numérica del funcionamiento hidráulico del sistema de canales y lagos de Texcoco. XIII Congreso Nacional de Hidráulica, Puebla, Puebla. México.

Kafritzas, J., and Bras, R.L., 1981. The practice of kriging. R.M. Parsons Laboratory. MIT. Reporte No. 263.

Kok, R., R. Lacroix, E. Taillefer, 1991. Greenhouse climate modelling with an artificial neural network. Canadian society of agriculture engineering conference, Fredericton, New Brunswick, Canada, July 1991. Can Agric Eng, 33(2).

Linsley, R.K., M.A. Koler, and J.L.H. Paulus, 1975. Hydrology for Engineers. McGraw-Hill.

Maier, H.R., G.C. Dandy, 1994. Forecasting salinity using neural networks and multivariate time series models. Proceedings of the Water Down Under 1994 Conference. Australia v 1 p 297-302.

Maren, A. J., C. T. Harston, and R. M. Pap, 1990. Handbook of Neural Computing Applications, Academic, San Diego, Calif.

McCulloch, W. S., and W. Pitts, 1943. A logical calculus of ideas immanent in nervous activity, J. Math. Biophys., 5, 115-133.

Mendoza, M., y M. Rosengaus, 1994. Cálculo de coberturas reales de radares meteorológicos en México. XIII Congreso Nacional de Hidráulica, Puebla, Puebla.

Mesa O., L.F. Carvajal, 1994. Análisis espectral singular y redes neuronales aplicadas en hidrología. Avances en recursos hidráulicos. Medellín, Colombia, Número 2, 1994.

Minsky, M., and S. Papert, Perceptrons, MIT Press, Cambridge, Mass., 1969. (Expanded edition, Cambridge, Mass., 1988.)

Ortega R., 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.

Revista Tlaloc, 1994. El Proyecto Huites. Septiembre, año 1 No. 3.

Ritter, N.D., and G.F. Hepner, 1990. Application of an artificial neural network to land-cover classification of thematic mapper imagery. Comput. Geosci., 16, 873.

Rizzo, D. M., and D. E. Dougherty, 1994. Characterization of aquifer properties using artificial neural networks: Neural kriging, Water Resour. Res., 30(2), 483-

497,

Rogers, L. L., V. M. Johnson, and F. U. Dowla, 1993. Network dissection of neural networks used in optimal groundwater remediation, paper presented at the Second USA/CIS Joint Conference on Environmental Hydrology, Am. Inst. of Hydrol., Arlington, Va., May 15-21.

Rogers, L. L., and F. U. Dowla, 1994. Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling, *Water Resour. Res.*, 30(2), 457-481.

Rosengaus, M., 1992. COBRADAR, un sistema para el cálculo de la cobertura real de radares meteorológicos. Instituto Mexicano de Tecnología del Agua, grupo de Huracanes, reporte No.4, 165 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.

Salas S., M.A., y M.J. Espinosa, 1994. Ajuste en tiempo real de modelos hidrológicos para el pronóstico de avenidas. XIII Congreso Nacional de Hidráulica, Puebla, Puebla.

Sánchez-Sesma, J., and M.A., Sosa, 1993. Estimation of tropical cyclon rainfall with GOES-IR imagery: an adaptation test and calibration of the Adler-Negri CST. 20th Conference on Hurricanes and Tropical Meteorology. Sn. Antonio, Texas.

Toledo, V., y J. Collado, 1990. Mejoramiento de redes pluviométricas usando el método kriging. XI Congreso Nacional de Hidráulica. Zacatecas, Zacatecas, México.

Toledo, V., 1994a. Procedimiento para obtener hidrogramas de diseño en cuencas altas. Ingeniería Hidráulica en México, Vol. IX, Núm. 2, págs. 33-43.

Toledo, V., 1994b. Redes Neuronales y Predicción Hidrológica. Instituto Mexicano de tecnología del Agua. Informe del proyecto SH-9415-2.

Toledo, V., y V. Millán, 1994c. CLIMAS: Manejador de datos climatológicos para aplicaciones específicas. Memorias del XIII Congreso Nacional de Hidráulica. Puebla, Puebla; México.

Trent R., A. Molinas, N. Gagarian, 1993. Artificial neural network for computing sediment transport. Proceedings National Conference on Hydraulic Engineering. Publ by ASCE, New York, NY, USA. p 1049-1050.

Winston, P.H., 1992. Artificial Intelligence. Capítulo 22. Addison-Wesley, 574 pp.

## **ANEXO 1**

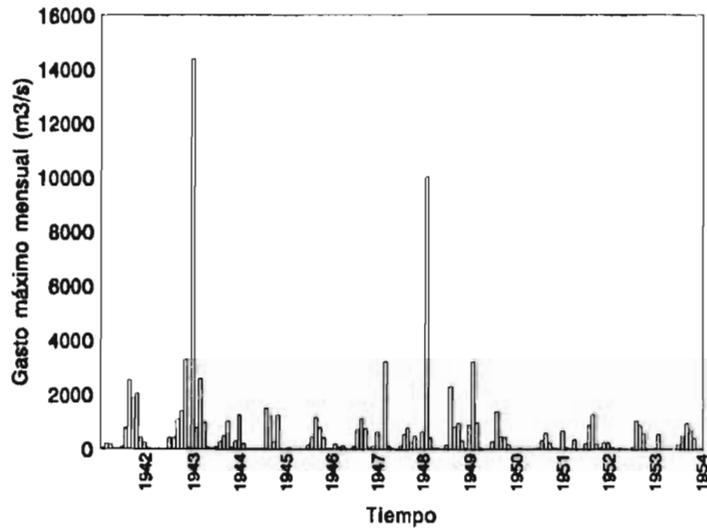
**Datos de la presa Huites.**

<b>Datos de la presa Huites</b>	
<b>Capacidades</b>	<b>Volúmenes en millones de m/3</b>
Total del vaso al NAME	4,568
Total del vaso al NAMO	2,908
Para azolves	500
Útil para riego y generación	2,408
Para control de avenidas	1,102
Superalmacenamiento	558
<b>Elevaciones</b>	<b>Metros sobre el nivel del mar</b>
Parapeto ciego aguas arriba de la cortina	292.00
De la corona de la cortina	290.75
Nivel de control superior NAME	290.00
Nivel de conservación NAMO	270.00
Elevación de la cresta vertedora	258.00
Nivel mínimo para diseño de la obra de toma	215.00
Elevación del umbral de la obra de toma	190.00
<b>Gastos máximos</b>	<b>Metros cúbicos por segundo</b>
De entrada al vaso	30,000
De salida del vertedor	22,445

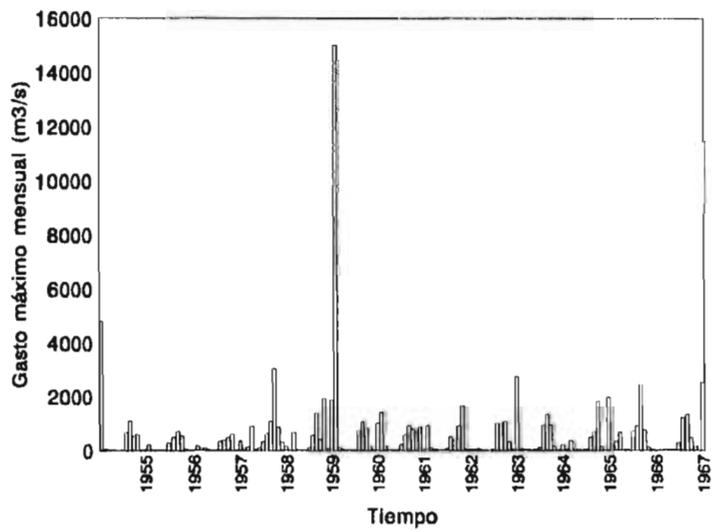
## ANEXO 2

Gráficas de gastos máximos mensuales ( $m^3/s$ ), en el sitio de la presa Huites de 1942 a 1993.

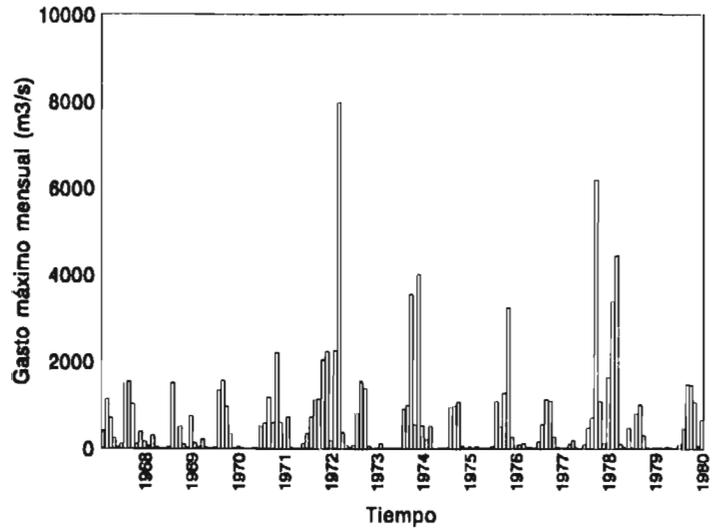
## Gastos máximos mensuales (1942 - 1954)



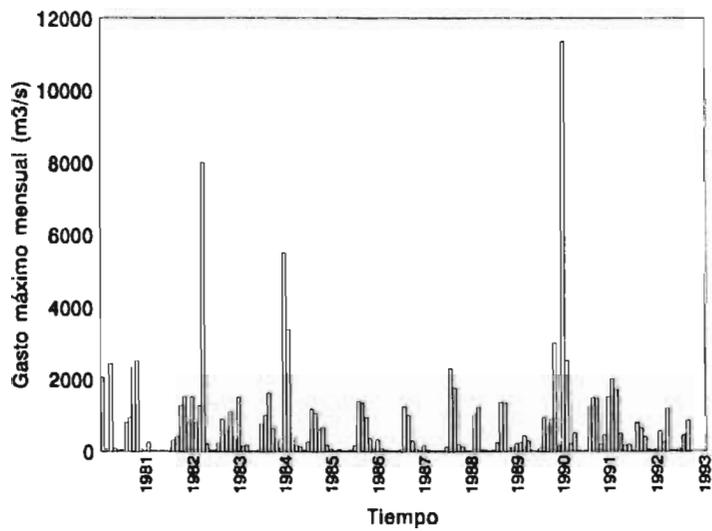
## Gastos máximos mensuales (1955 - 1967)



## Gastos máximos mensuales (1968 - 1980)



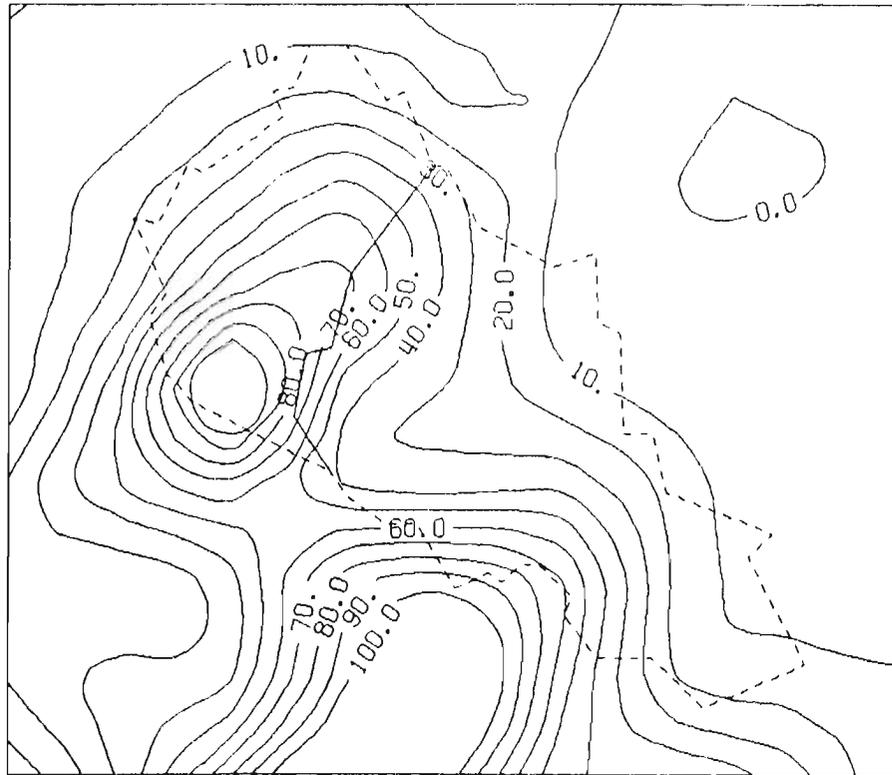
## Gastos máximos mensuales (1981 - 1993)



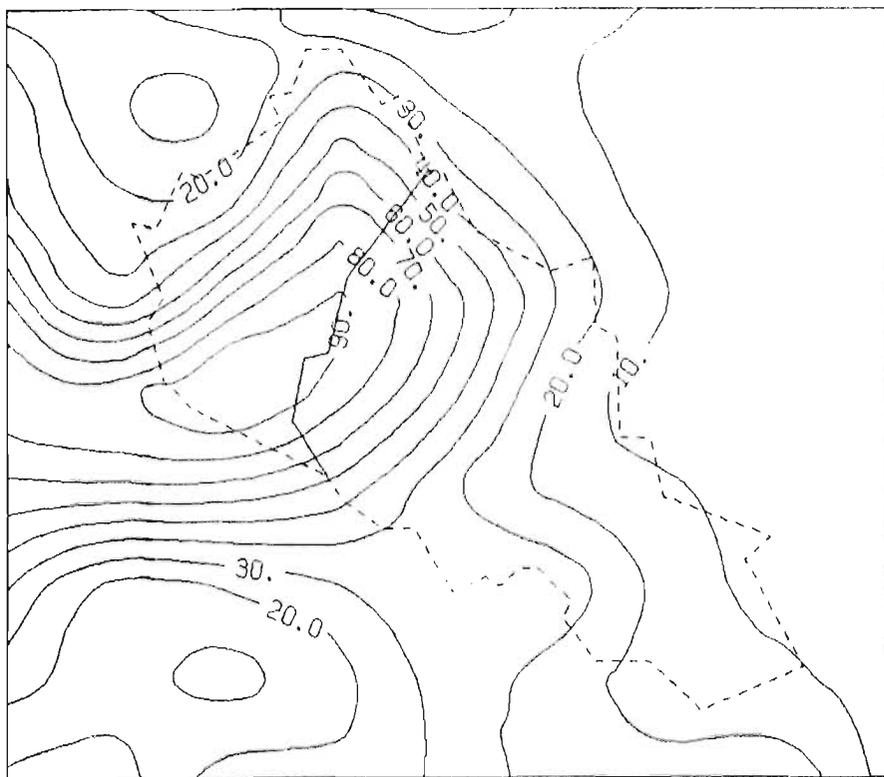
### **ANEXO 3**

**Mapas de isoyetas diarias (normalizadas a 100 mm). Nótese la similitud de la distribución espacial de la lluvia en cada pareja de mapas.**

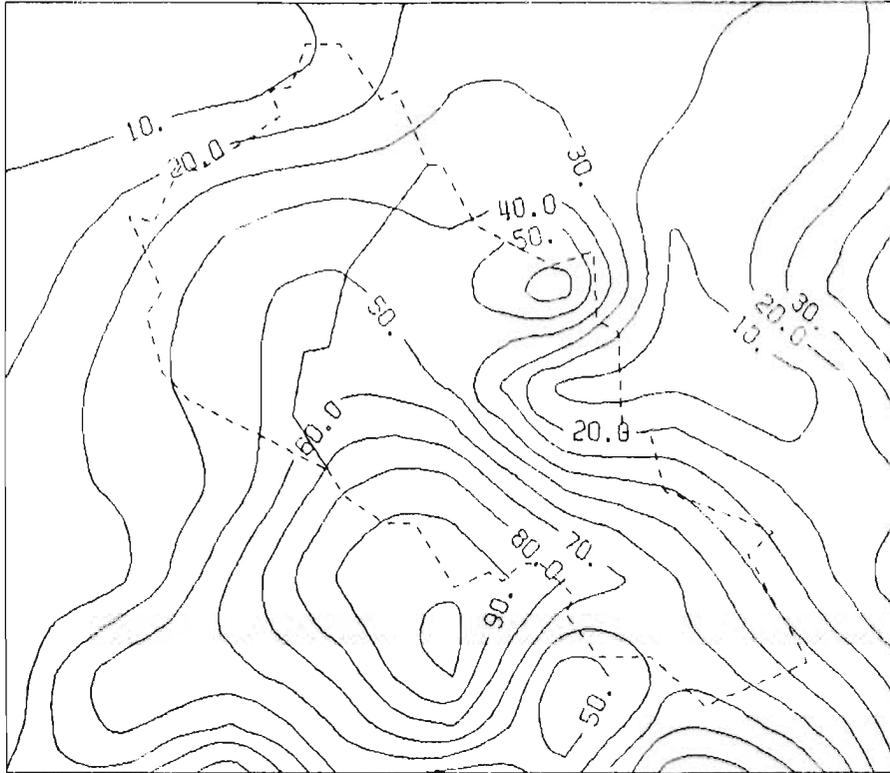
oct2571



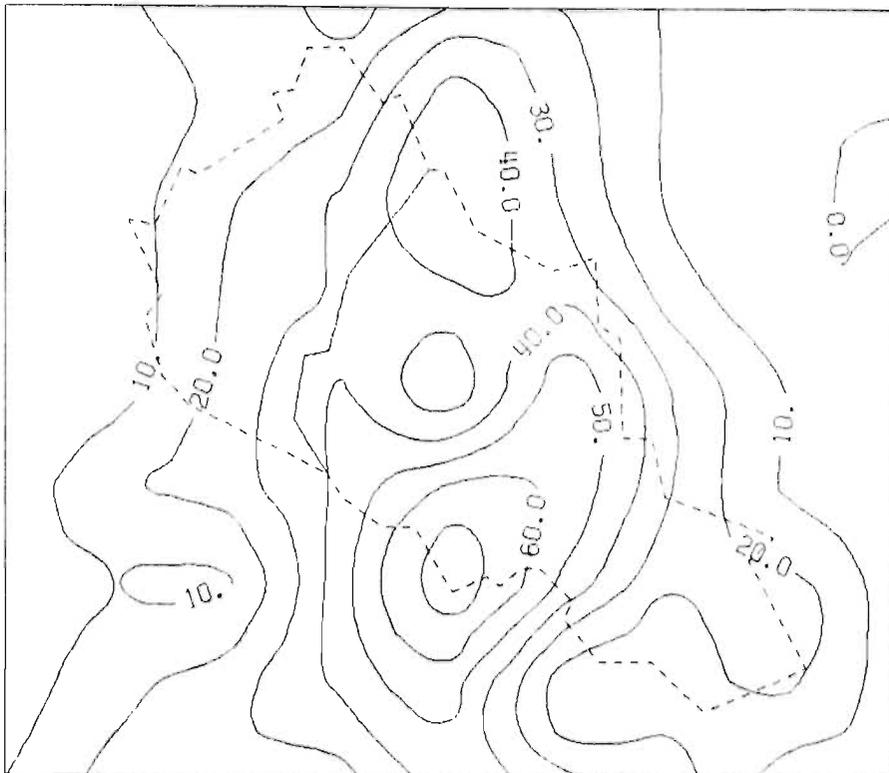
oct 28 72



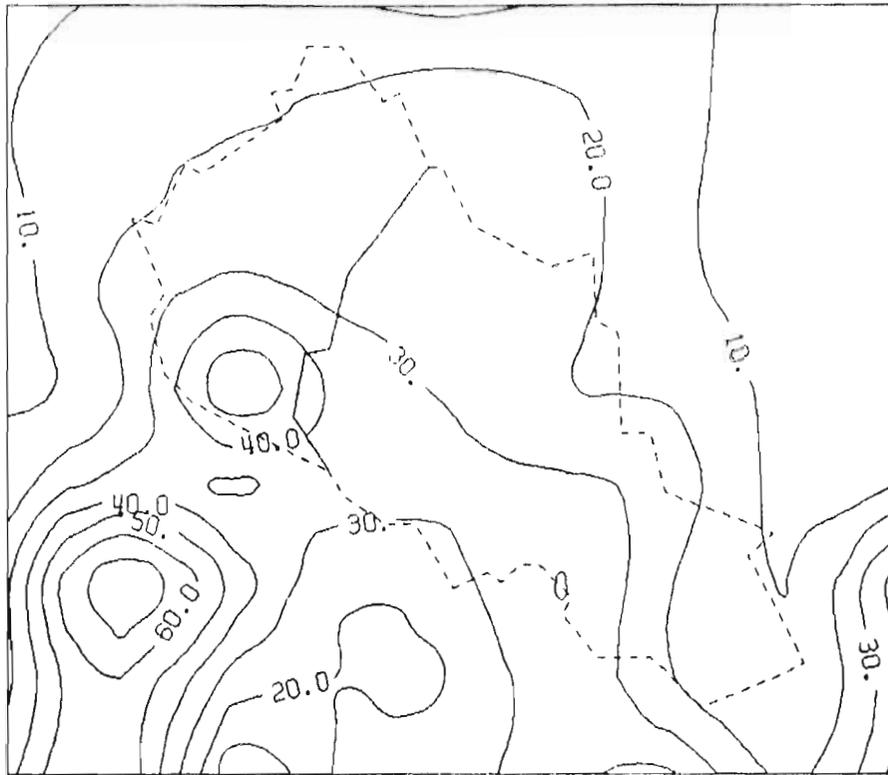
nov 22 72



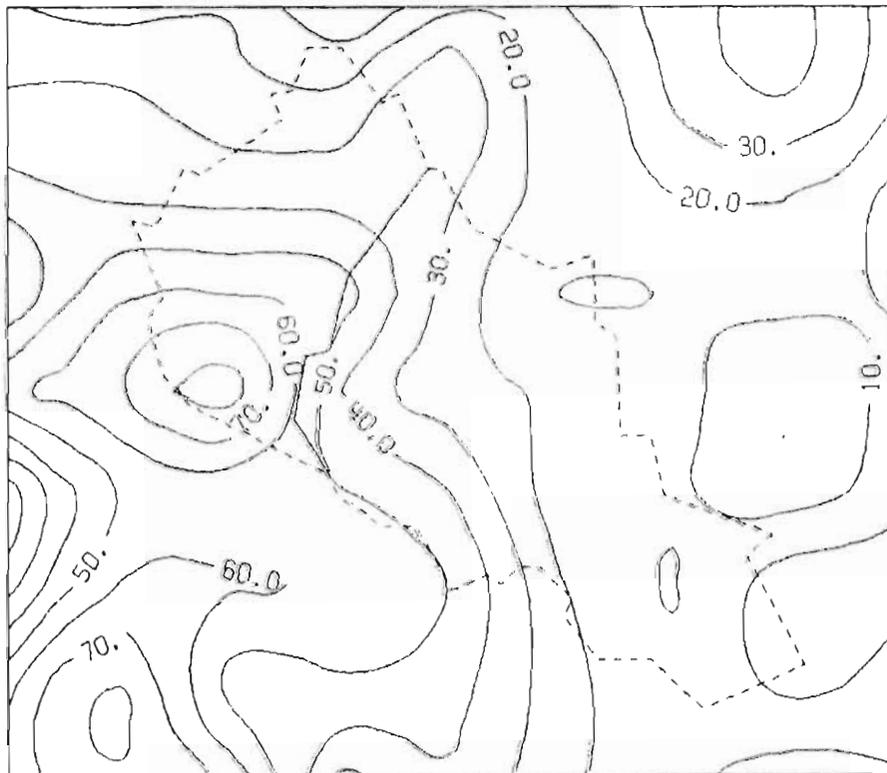
dic 07 80



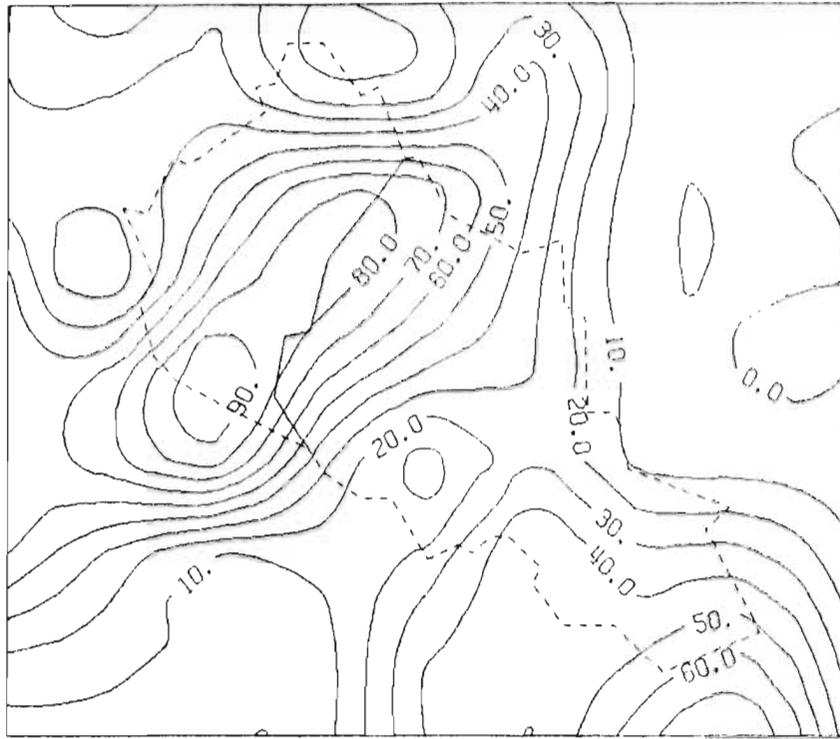
nov 25 82



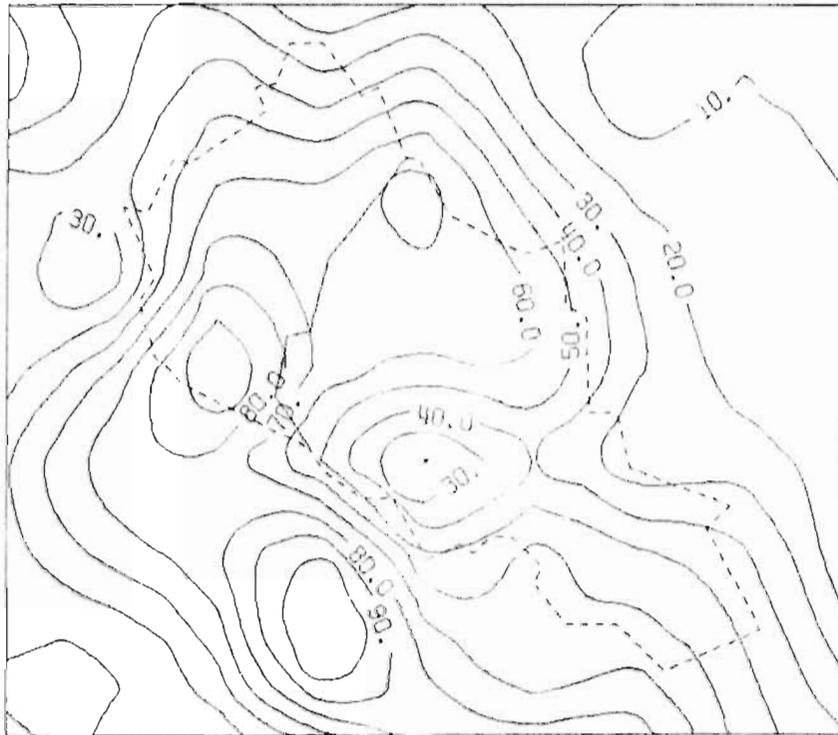
dic 08 82



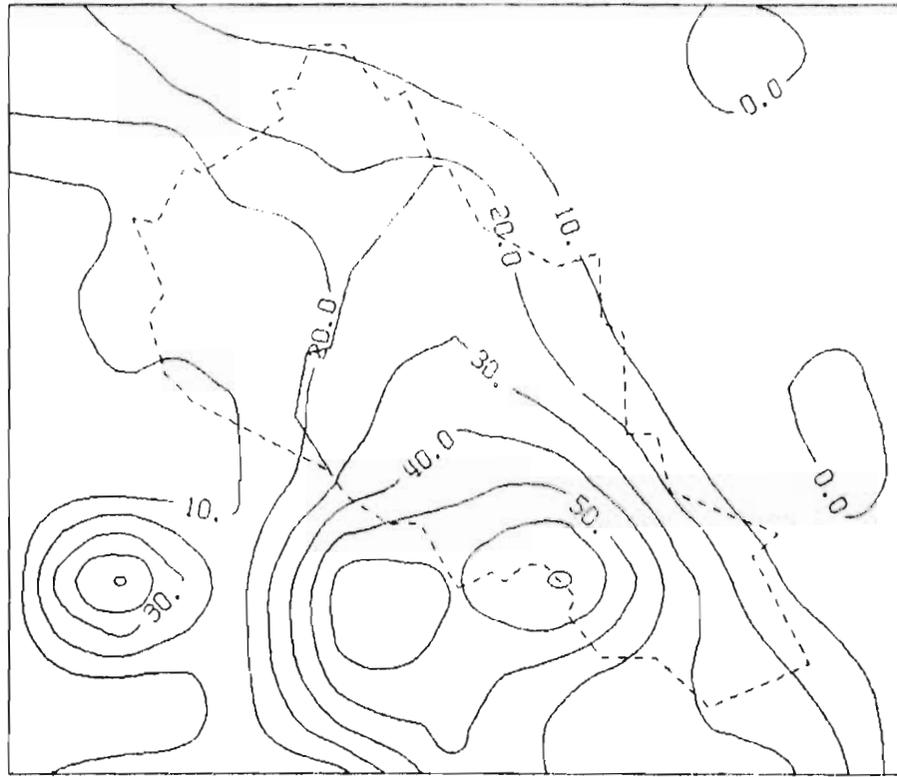
dic 30 78



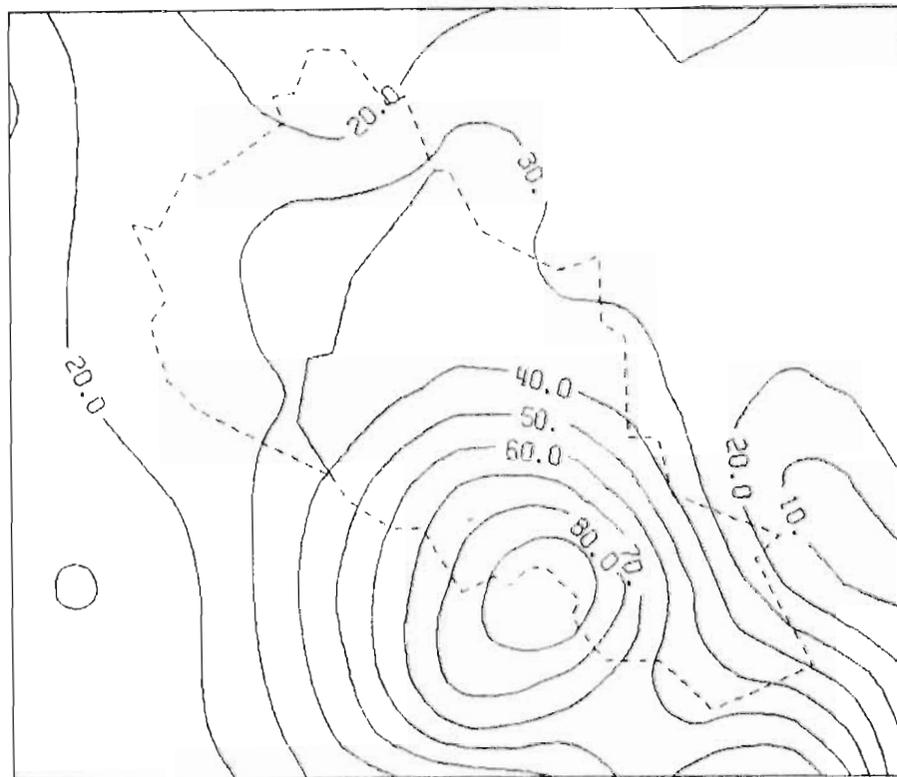
ene 24 79



feb 03 79



feb 20 73



## ANEXO 4

Volúmenes de lluvia, escurrimiento y pérdidas por evento (en millones de m<sup>3</sup>).

FECHA	DIAS				VOLUMEN LLOVIDO	VOLUMEN ESCURRIDO	VOLUMEN PÉRDIDAS	% PÉRDIDAS
	LLUVIA MEDIA(MM)							
FEB 81	28	01	02	03	1501.8	488.0	1013.8	68
MAR 81	9.2	5.3	22.9	20.4				
OCT 81	04	05	06	07	2121.0	618.0	1502.9	71
	11.9	6.6	3.7	59.4				
ENE 82	09	10	11	12	1191.2	68.2	1123.0	94
	0.8	9.3	31.2	4.5				
SEP 82	27	28	29	30	1896.2	350.3	1545.9	82
	1.6	6.2	55.1	10.0				
DIC 82	06	07	08	09	1230.6	259.5	971.1	79
	0.0	0.0	33.4	13.9				
ENE 83	28	29	30	31	578.6	161.7	417.0	72
	0.0	0.0	21.7	0.4				
FEB 83	02	03	04	05	821.4	296.6	524.8	64
	0.0	8.9	22.1	0.5				
MAR 83	01	02	03	04	2580.9	1552.3	1028.7	40
	3.1	19.4	56.1	20.6				
OCT 83	16	17	18	19	1293.4	188.4	1105.0	85
	0.7	2.7	36.4	9.9				
NOV 83	20	21	22	23	698.6	66.9	631.7	90
	0.7	16.4	10.7	0.1				
DIC 83	01	02	03	04	877.7	269.4	608.4	69
	21.4	12.3	0.0	0.0				
DIC 84	11	12	13	14	2756.9	1263.5	1493.4	54
	41.0	29.6	21.1	14.3				
DIC 84	25	26	27	28	960.0	452.2	508.6	53
	0.0	0.1	6.4	30.5				
ENE 85	10	11	12	13	1004.3	406.6	597.7	60
	0.0	4.7	32.0	1.8				
ENE 85	21	22	23	24	1212.5	657.7	554.8	46
	0.0	8.5	28.3	9.7				
DIC 86	15	16	17	18	832.7	113.8	718.9	86
	8.2	8.0	15.8	0.0				
DIC 87	15	16	17	18	850.7	60.3	790.4	93
	0.0	1.0	12.2	19.4				

FECHA	DIAS				VOLUMEN LLOVIDO	VOLUMEN ESCURRIDO	VOLUMEN PÉRDIDAS	% PÉRDIDAS
	LLUVIA MEDIA (MM)							
OCT 61	06	07	08	09	862.7	147.3	715.3	83
	2.6	5.3	18.4	6.9				
NOV 61	04	05	06	07	338.3	112.5	225.7	67
	0.4	0.1	2.3	10.1				
ENE 62	22	23	24	25	978.2	173.8	804.5	82
	0.2	2.7	32.2	2.4				
OCT 62	01	02	03	04	1178.6	307.2	871.4	74
	0.5	1.9	4.8	38.1				
DIC 63	08	09	10	11	2241.8	898.3	1343.5	60
	0.5	27.6	42.9	15.1				
FEB 65	05	06	07	08	853.6	79.0	774.5	91
	0.4	5.4	14.6	12.5				
DIC 65	19	20	21	22	1034.7	264.4	770.3	74
	1.0	0.3	9.3	29.1				
FEB 66	06	07	08	09	983.3	116.6	866.6	88
	0.5	18.8	13.2	5.2				
DIC 67	12	13	14	15	2432.2	612.5	1819.7	75
	1.0	13.8	37.2	41.5				
NOV 68	11	12	13	14	1136.2	78.6	1057.6	93
	1.0	0.0	31.3	11.3				
FEB 69	11	12	13	14	604.2	71.3	532.9	88
	0.4	6.0	16.1	0.8				
DIC 69	01	02	03	04	1361.5	122.2	1239.3	91
	1.1	31.2	19.4	0.6				
MAR 70	18	19	20	21	577.2	45.3	531.9	92
	0.3	15.8	6.1	0.0				
OCT 71	22	23	24	25	1283.9	725.4	558.5	43
	0.0	0.0	8.4	40.9				
DIC 71	16	17	18	19	629.4	74.9	554.5	88
	2.8	4.7	14.4	2.3				
ENE 72	01	02	03	04	856.7	186.6	670.1	78
	0.2	15.2	16.6	0.9				

FECHA	DIAS				VOLUMEN LLOVIDO	VOLUMEN ESCURRIDO	VOLUMEN PÉRDIDAS	% PÉRDIDAS
	LLUVIA MEDIA (MM)							
OCT 72	26	27	28	29	1440.7	609.0	831.7	58
	1.3	14.5	27.2	12.4				
NOV 72	21	22	23	24	1620.8	445.0	1175.9	73
	0.8	43.9	17.4	0.2				
ENE 73	03	04	05	06	903.2	500.9	402.3	45
	0.6	1.4	12.7	20.0				
FEB 73	06	07	08	09	524.6	123.2	401.4	77
	0.5	9.7	9.9	0.0				
FEB 73	18	19	20	21	1866.1	1122.0	744.1	40
	0.0	7.9	33.5	30.2				
NOV 74	05	06	07	08	2084.3	772.6	1311.8	63
	7.0	20.1	26.1	26.9				
DIC 74	23	24	25	26	924.4	198.7	725.7	79
	0.1	12.0	23.1	0.3				
ENE 75 -	30	31	01	02	627.7	166.9	460.7	73
FEB 75	5.3	7.5	10.1	1.2				
OCT 76	20	21	22	23	1100.0	512.4	587.5	53
	1.4	0.1	14.7	26.1				
NOV 76	16	17	18	19	695.1	84.6	110.4	88
	4.2	9.1	8.4	4.9				
FEB 78 -	27	28	01	02	418.4	46.9	371.4	89
MAR 78	3.0	0.0	12.9	0.2				
OCT 78	20	21	22	23	1377.2	305.9	1071.3	78
	4.1	16.4	14.4	18.0				
DIC 78	27	28	29	30	1138.5	371.4	767.1	67
	0.1	2.0	8.6	33.1				
ENE 79	22	23	24	25	1665.1	729.5	935.6	56
	0.1	5.5	55.3	3.2				
FEB 79	01	02	03	04	1801.0	1095.7	705.3	39
	0.8	22.9	28.1	17.4				
DIC 80	05	06	07	08	1133.2	140.7	992.5	88
	0.0	6.6	34.9	2.0				
ENE 81	04	05	06	07	1706.5	458.2	1248.3	73
	3.5	16.0	19.3	26.7				