

## CAPÍTULO 2

### MARCO TEÓRICO

#### 2.1 Sobre la Pancreatitis. Descripción de la enfermedad y su diagnóstico.

El páncreas es un órgano de forma irregular que se encuentra en la parte superior del intestino delgado (Fig. 2-1). La pancreatitis es una inflamación del páncreas producida por un mal funcionamiento de éste, muchas veces debido al abuso del alcohol o por una obstrucción del conducto pancreático. Durante este proceso las enzimas segregadas por el páncreas provocan el deterioro del órgano así como de las regiones contiguas.

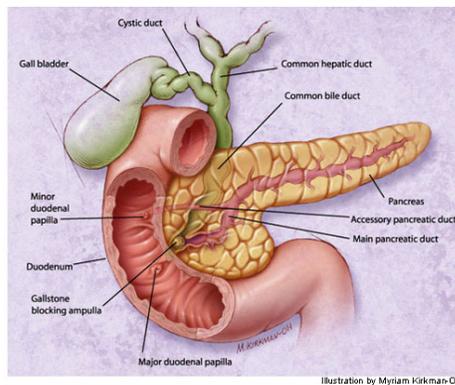


Figura 2-1. Diagrama de la región del páncreas. [AFP, 2000]

La forma “suave” del padecimiento ocurre entre un 80% y 85% de los pacientes y es autocontrolada, con recuperación en unos cuantos días. En el 15-20% de los pacientes con la forma más severa de pancreatitis es

necesaria una hospitalización prolongada y comúnmente puede requerirse intervención quirúrgica, aún así la supervivencia no está asegurada. La incidencia de la pancreatitis aguda está entre 17-28 de cada 100,000 pacientes. Los pacientes con pancreatitis severa deben ser identificados lo antes posible (dentro de un plazo de 7 días) y manejados por un equipo con experiencia en la prevención y el tratamiento de sus complicaciones.

Los pacientes frecuentemente se quejan de dolor intenso del abdomen superior que irradia a través de la espalda. También presentan náusea y vómito. Los hallazgos abdominales varían desde suavidad epigástrica en una exploración profunda hasta un dolor abdominal agudo con distensión. Por lo tanto es esencial establecer el origen de la pancreatitis. En algunos casos, se indica el tratamiento de alguna de las causas específicas de la pancreatitis, tal como una colecistectomía para pacientes con obstrucción del conducto pancreático. Inicialmente puede ser difícil distinguir entre paciente severamente enfermos de aquellos con pancreatitis ligera. Es recomendable el uso de tomografías con medio de contraste oral e intravenoso si las funciones renales del paciente son adecuadas. La tomografía puede confirmar el diagnóstico y puede servir como un indicador útil de la severidad. Otras pruebas de diagnóstico útiles son:

prueba de gases arteriales, CBC, químicas sanguíneas como calcio, glucosa y creatinina [SSAT. 1996].

### 2.1.1 Sobre los estudios Radiológicos usados para el diagnóstico de pancreatitis

Para ayudar al diagnóstico de la pancreatitis se utilizan diversos estudios. A continuación se señalan los estudios utilizados así como una descripción de su papel en el diagnóstico:

**Radiografías simples:** Las radiografías simples pueden apoyar el diagnóstico de la pancreatitis aguda cuando se encuentran ciertos hallazgos. Un duodeno lleno de gas posterior a una obstrucción es un hallazgo más específico para una pancreatitis. Sin embargo, ninguna de las anomalías radiológicas en una radiografía simple puede ser usada para propósitos de diagnóstico.

**Ultrasonografía:** La ultrasonografía es un estudio aceptable para iniciar la evaluación cuando se sospechan causas biliares. La ultrasonografía pancreática tiene las siguientes ventajas: no es invasiva, es relativamente económica y puede ser ejecutada sin trasladar al encamado. La sensibilidad del estudio en la detección de la pancreatitis está entre un 62 y 95 por ciento. Sin embargo, en el 35% de los casos, el páncreas se oscurece y no es posible realizar un diagnóstico adecuado.

Tomografía Computarizada (TC). Una TC con medio de contraste brinda la mejor vista del páncreas y las estructuras aledañas. Un estudio de TC puede ser útil cuando otros estudios son inconcluyentes, cuando el paciente tiene síntomas severos, cuando hay fiebre presente o cuando existen leucocitos persistentes que señalan una infección secundaria. Además, un estudio de TC es especialmente útil diagnosticando complicaciones relacionadas con la pancreatitis aguda o como un estudio de seguimiento en pacientes que están clínicamente deteriorados. Los hallazgos de una TC en la pancreatitis pueden mostrar inflamación señalada por agrandamiento del páncreas, contornos irregulares, daño de la grasa peripancreática, necrosis, que es tejido muerto en el páncreas, y pseudoquistes que son partes del tejido pancreático que a dejado de funcionar adecuadamente [AFP, 2000].

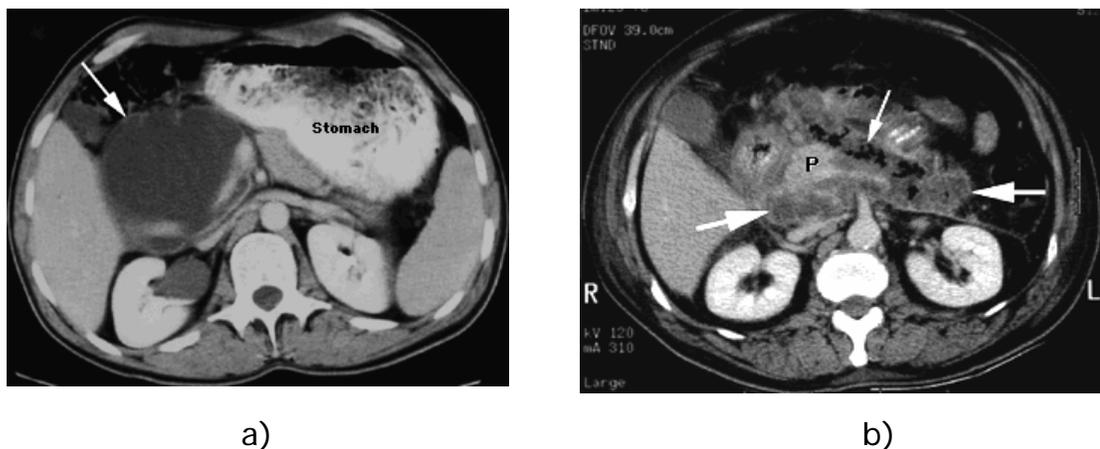


Figura 2-2. Tomografías de páncreas enfermos. a) inflamación de la cabeza del páncreas, b) colecciones de fluido y necrosis.

[UpToDate, 2002]

Un sistema automático o semiautomático para ayudar al diagnóstico de la pancreatitis aguda requiere de un estudio que aporte una cantidad considerable de información y esta información debe de tener la menor cantidad de ruido de ser posible. Por esta razón el uso de radiografías simples quedó descartado para este proyecto. La calidad de estas imágenes no es suficiente como para crear un sistema confiable. La confiabilidad de la ultrasonografía es más elevada, sin embargo aún existe un margen de ineficacia considerable inclusive para el diagnóstico tradicional. Además las características de las imágenes tomadas por este método dificultan la extracción de información de la imagen. Las imágenes obtenidas por TC proveen una calidad insuperable entre estos estudios radiológicos, además la información aportada en relación a la pancreatitis también es la más valiosa. De igual manera, al ser computarizada es sencillo obtener estos estudios en forma digital. Por estas razones, se decidió utilizar imágenes de tomógrafo para la creación de este sistema.

### 2.1.2 Índice de Balthazar

Las imágenes de tomógrafo son evaluadas en base al índice de Balthazar. Esta evaluación consiste en asignar puntos a la imagen en base a los hallazgos encontrados. La puntuación resultante sirve para determinar la

severidad de la enfermedad así como también permite hacer un pronóstico de la enfermedad. A continuación se muestra la forma en que se asigna la puntuación:

$$\text{Puntuación Final} = \text{Puntuación Tabla 2-1.a} + \text{Puntuación Tabla 2-1.b}$$

## **2.2 Sobre el estándar de Imágenes Digitales y Comunicaciones en la Medicina (DICOM)**

Durante mucho tiempo las instituciones médicas tuvieron dificultades para el manejo de los estudios radiológicos que realizaban. Las compañías que fabricaban el hardware médico tenían diferentes formas de guardar y transmitir la información que sus aparatos generaban.

Las instituciones tenían que arreglárselas para poder manejar información de diferentes fuentes y la creación de repositorios de información para la investigación se hacía muy difícil. Este problema ha sido un fenómeno común en la industria tecnológica y generalmente se resuelve de la misma manera, creando estándares para regular las tecnologías. En el caso de la medicina y la radiología este estándar es el "Digital Imaging and Communications in Medicine Standard" o DICOM.

Tabla 2-1. Asignación de puntuación del índice de Balthazar. a) En base a los hallazgos en el páncreas y generales, b) en base a la necrosis.  
[Radiology Journal, 2002]

Grado	Descripción	Puntos
A	Páncreas normal	0
B	Páncreas agrandado	1
C	Inflamación del páncreas y/o daño a la grasa peripancreática	2
D	Única colección de fluidos	3
E	Dos o más colecciones de fluidos	4

a)

Porcentaje de necrosis	Puntos
0	0
< 30	2
30 – 50	4
> 50	6

b)

Este protocolo creado por la ACR (Colegio Americano de Radiología) y el NEMA (Asociación Nacional de Fabricantes Eléctricos) para atacar problemas como la comunicación en red entre diferentes equipos médicos y la forma de almacenamiento en disco de información radiológica. Esta

última es la que tiene nuestro interés pues define la entrada que recibe el sistema para el diagnóstico de pancreatitis.

El estándar DICOM especifica la forma en que se debe de guardar esta información en archivos digitales y el contenido que estos archivos pueden tener. En el caso de las tomografías este archivo contiene un “encabezado” con información sobre el paciente, el médico, el estudio radiológico efectuado, la forma en que se realizó el estudio, el aparato que se utilizó para realizarlo, entre otras cosas. Después del encabezado viene la imagen radiológica. Esta consiste de un mapa de densidades obtenidas a través del barrido axial sobre el paciente. La densidad o intensidad de un punto en una tomografía depende del tejido en esa área, de la cantidad de medio de contraste absorbido y de la intensidad de los rayos X utilizados durante el estudio. Esta información puede interpretarse como una imagen en escala de grises si se hace una superposición de la escala de grises sobre la escala de densidades (unidades Hounsfield). La escala de densidad, o intensidad como algunas veces se le llama, va de -1000 a 1000 o de -1000 a 4000 dependiendo del aparato tomográfico. Solamente contamos con 255 niveles de gris donde 0 es blanco y 255 negro por lo que es necesario hacer una transformación de unidades Hounsfield a nuestra escala de grises. El área que nuestra escala de niveles de gris cubre es llamada

“ventana” y es de tamaño variable. La unidad donde nuestra ventana se centra es llamada “centro” o “nivel de ventana”. La forma en que se hace esta transformación de escalas esta definida por el estándar DICOM.

La figura 2-3 muestra la forma en que se hace la transformación de escalas.

Es importante recordar que la información del padecimiento se encuentra en la escala original. La interpretación a niveles de gris es solamente una herramienta para poder realizar un diagnóstico visual. Un sistema que trabaja con archivos de este tipo debe utilizar la información original para realizar sus funciones.

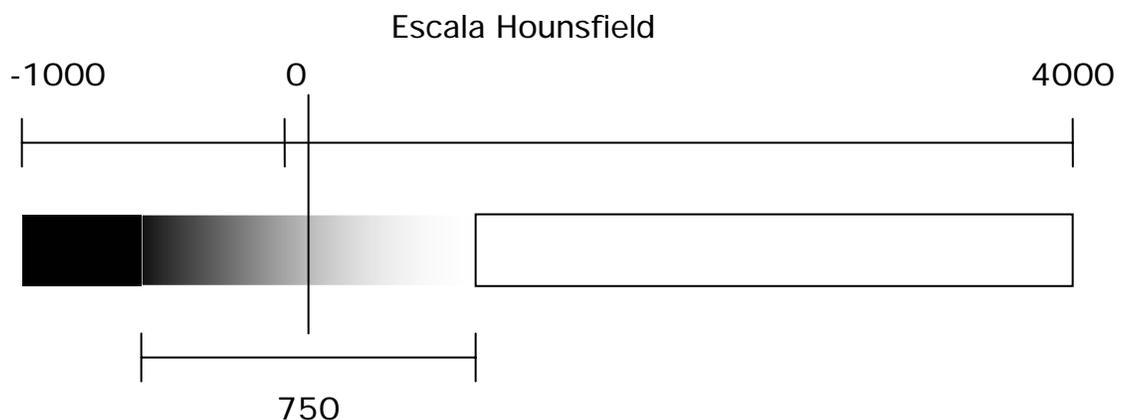


Figura 2-3. Representación de una transformación a escala de grises con Centro en un valor aproximado a 0 en escala Hounsfield y un ancho de ventana de aproximadamente 750 unidades.

## 2.3 Sobre los reconocedores o clasificadores de patrones

De manera general se puede decir que todo sistema de reconocimiento de patrones debe de incluir los siguientes pasos: Adquisición de Datos, Pre-procesamiento de los datos, y Reconocimiento [Bow, 1992].

### 2.3.1 Adquisición de Datos

Antes de cualquier paso, deben de tenerse los datos que van a ser analizados. La adquisición de datos puede parecer un poco ajena al proceso mismo de reconocimiento de patrones, pues involucra procedimientos que generalmente están fuera de éste y varía tremendamente de aplicación a aplicación. La adquisición de datos es el proceso mediante el cual se obtiene aquello que será utilizado para el reconocimiento. Pueden utilizarse procedimientos automáticos o manuales. Ejemplos de este proceso son medir los niveles de concentración de ciertos químicos en el agua y registrar las mediciones o utilizar cámaras digitales para obtener imágenes del rostro.

En el caso específico de esta aplicación el proceso de adquisición de datos corresponde desde el trabajo realizado por el sistema tomográfico cuando se obtienen los cortes axiales del paciente hasta la creación de los archivos DICOM que contienen estos cortes.

### 2.3.2 Pre-Procesamiento

Generalmente existen dos problemas principales en los datos obtenidos que dificultan el proceso de reconocimiento, uno es el ruido y otro la dimensionalidad.

Le llamamos ruido a todo aquello que representa una interferencia en un proceso, en nuestro caso es el proceso de reconocimiento. El ruido puede ser introducido en nuestro conjunto de datos por diversos factores. Entre estos factores podemos encontrar el humano y el producido por los instrumentos de medición. El proceso de eliminación de ruido puede ser tan simple como eliminar aquellos datos que parecen tenerlo y volver a tomar la medición, ó puede llegar hasta la aplicación de algoritmos que realizan una eliminación de este ruido basándose en características propias del mismo y de los datos originales.

Dimensionalidad se refiere a la cantidad de datos que definen un problema. La selección de características y la extracción de las mismas en reconocimiento de patrones esta relacionada con el uso de herramientas matemáticas para reducir esta dimensionalidad [Young-Fu, 1985]. Mediante estas reducciones también eliminamos redundancia sin que en el proceso se pierda información valiosa. La forma más simple de reducción de la dimensionalidad es simplemente descartar subgrupos de datos dentro de

nuestros datos de entrada. Algo más complejo es procesar nuestros datos para formar un nuevo conjunto de datos que serán nuestra nueva entrada. Existen diferentes técnicas para llevar a cabo reducciones dimensionales como son el “análisis de las componentes principales”, el “uso de ventanas”, el “análisis de discriminantes, entre otros [Micheli-tzanakou, 2000].

Este nuevo conjunto de datos representa de manera condensada nuestras entradas iniciales y permiten un mejor comportamiento de los reconocedores. Entre más se acerque nuestro conjunto de datos a su representación ideal mejor se comportará un sistema clasificador. Este nuevo conjunto de datos es llamado **vector de características** [Escalera, 2001].

### 2.3.3 Reconocimiento

El reconocimiento es la última parte en un sistema clasificador. Es la etapa de mayor grado de abstracción del sistema. Aquí se utilizan las “características” halladas en el conjunto de entrada para realizar la clasificación. Se pueden utilizar métodos a priori, llamados así porque utilizan conocimiento previo sobre las clases que se clasificarán [Escalera, 2001], u otros métodos que utilicen datos estadísticos obtenidos de ejemplos de las clases a reconocer, o redes neuronales artificiales que

dependiendo su topología pueden comportarse como clasificadores estadísticos o de otras maneras más complejas.

La correcta clasificación de los datos que se le muestran a un clasificador depende en gran medida de los datos que se le proporcionen de entrada. Si los datos fueron refinados a través de un proceso de pre-procesamiento adecuado es posible obtener buenos resultados en muchos casos.

## **2.4 Sobre Redes Neuronales Artificiales**

Las Redes Neuronales Artificiales son estructuras para procesar información. Están compuestas de muchos procesadores simples (Neuronas), cada uno de ellos puede tener una pequeña cantidad de memoria local. Estos procesadores están conectados por canales unidireccionales que llevan información numérica. Estas unidades procesadoras trabajan únicamente con los datos locales y los datos que les llegan a través de estos canales. [FAQ, 2002] Una red RNA, esencialmente, hace mapeos funcionales no lineales entre conjuntos de variables, por lo tanto, en principio puede ser usada para mapear cualquier conjunto de información a un conjunto de valores de salida deseados [Bishop, 1995].

Una RNA puede estar implementada en un algoritmo (software) o directamente en hardware.

La figura 2-4 representa a uno de estos neurones. Las entradas a un neurón pueden ser las variables de un problema o las salidas de neurones de niveles anteriores. A la conexión entre una entrada o un neurón, contra otro neurón, se le llama sinapsis. Cada sinapsis tiene un "peso" asignado que representa la intensidad o importancia de esa conexión. Cuando se le pide a un neurón que dé una salida para un conjunto de variables de entrada, el neurón realiza la sumatoria de la multiplicación de sus entradas con su correspondiente peso. Esta suma es después evaluada por una función llamada función de activación, que devuelve la salida de ese neurón para dicha sumatoria. Cada neurón en una red utiliza la misma función de activación.

Así, la salida de un neurón depende de 2 cosas: las entradas que éste reciba y los pesos que este neurón haya asignado para cada conexión. Los pesos de las conexiones para cada neurón son independientes entre sí y son estos valores los que permiten que un neurón dé la salida deseada. [Gurney, 2003]

A la modificación de estos pesos se le llama entrenamiento y, de una manera simplista, se realiza calculando la diferencia entre la salida deseada de ese neurón y la salida real. La modificación de estos pesos está en proporción al error, al valor de entrada para cierta conexión y a un factor de aprendizaje. Es gracias a este entrenamiento que se puede hacer que una RNA sea capaz de mapear un conjunto de entradas con su correspondiente salida para

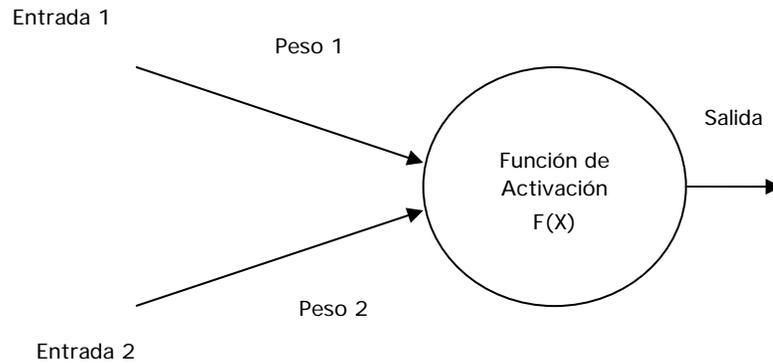


Figura 2-4. Representación de un Neurón.

virtualmente cualquier función. En el caso del reconocimiento de patrones, las entradas que se le proporcionan a la red corresponden al vector de características y la salida de la red a la clase a la que este vector corresponde.

La figura 2-5 representa una RNA típica. En esta red pueden verse varios niveles de neuronas. Las salidas de todos los neuronas de un nivel constituyen las entradas para cada uno de los neuronas del siguiente nivel. El nivel que recibe las entradas al sistema se le llama nivel de entrada, los niveles que se encuentren entre este nivel y el último se les llama niveles escondidos o intermedios. La salida de la red se calcula nivel por nivel hasta llegar al último nivel, llamado nivel de salida. A la forma en que están conectados los nodos se le llama topología y a la topología descrita anteriormente se le llama "feed-forward" o "alimentada hacia adelante".

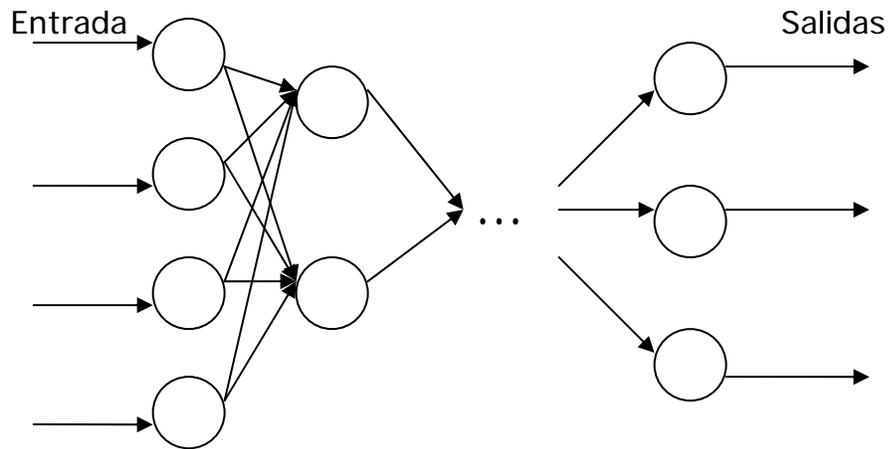


Figura 2-5. Red alimentada hacia delante de varios niveles.

El “conocimiento” de la red está almacenado en los pesos de cada conexión y es el proceso de entrenamiento el que pone ese conocimiento allí. Existen diferentes formas de entrenar a una red, en el caso de las redes alimentadas hacia delante de varios niveles el algoritmo más popular es el de retro-propagación.

Para entrenar una red de este tipo utilizando retro-propagación es necesario un conjunto de entradas para las cuales se sepa la salida deseada. Cada par de entrada y salida deseada es llamado *vector de entrenamiento*. Al conjunto de vectores de entrenamiento se le llama *conjunto de entrenamiento*. El algoritmo toma cada uno de los vectores de entrada, hace que la red calcule la salida para la entrada de ese vector de entrenamiento y compara esta salida con la salida deseada. La diferencia entre la salida deseada para cierto neurón del nivel de salida y la salida real de ese neurón constituye su error. El

algoritmo calcula el error para cada neurón de salida, este error se propaga hacia los niveles anteriores y el algoritmo modifica cada uno de los pesos para las conexiones en base a esta propagación del error. Se llama iteración al proceso de recorrer de la manera descrita el conjunto de entrenamiento. El proceso de entrenamiento termina cuando se alcanza un número de iteraciones determinado o cuando se cumple cierta condición con el aprendizaje. Este algoritmo cae dentro de los algoritmos *supervisados* debido a que requiere que para cada entrada se sepa con anterioridad la salida deseada. La combinación de una red alimentada hacia delante y el algoritmo de entrenamiento de retro-propagación son la solución más común a la mayoría de los problemas atacados utilizando redes neuronales, esto en virtud de la sencillez de su implementación y su excelente desempeño para la resolución de la mayoría de los problemas.

Durante el proceso de entrenamiento pueden surgir diferentes dificultades. Uno de estas dificultades es la caída en mínimos locales. Lo que el algoritmo de retro-propagación busca es encontrar el mínimo error dentro de una función dada, sin embargo, si esta función contiene mínimos locales el algoritmo puede estancarse en uno de ellos. Esto depende del punto del que el algoritmo haya partido al iniciar. Este punto está definido por los pesos iniciales de las conexiones en la red. Si se cree que la red pudo haber caído en un mínimo local

lo indicado es reiniciar los pesos de la red y comenzar desde el principio el entrenamiento. Existen diferentes métodos para tratar de evitar la caída en mínimos locales pero explicarlos va más allá del alcance de este documento.

Debido a que el conocimiento está distribuido entre los pesos de cada una de las conexiones y no está concentrado en un solo lugar, una red de este tipo es tolerante al ruido en las señales de entrada. Es decir, una red neuronal adecuadamente entrenada es capaz de dar una respuesta correcta inclusive si la señal o datos de entrada son diferentes a las utilizadas durante el entrenamiento. Esta capacidad es llamada generalización y es gracias a ella que las RNA's son tan exitosas en el reconocimiento de patrones.

Otro problema que se presenta y vale la pena mencionar es el fenómeno de "sobreentrenamiento" [FAQ's, 2002] ("overfitting", "overlearning", "overtraining"). Este fenómeno ocurre cuando se entrena demasiado una red y ésta deja de aprender para solamente memorizar. Los resultados son que la red puede tener un error muy bajo para los patrones utilizados para el entrenamiento pero para patrones fuera del conjunto de entrenamiento el error es mayor. Una red que presenta "sobreentrenamiento" pierde su capacidad de generalización. Existen diferentes formas de evitar el "sobreentrenamiento", entre ellas podemos encontrar a la "selección de modelos", "sacudidas (jittering)", el "paro prematuro", "decaimiento de

pesos", "aprendizaje bayesiano" y las "redes combinatorias". Para más información de estos métodos consultar [FAQ's, 2002].

#### 2.4.1 Tipos de RNA's

Existen muchos tipos de redes neuronales y aun más modificaciones de estos tipos [FAQ's]. Estas RNA's comparten características como la capacidad de generalizar y abstraer, el paralelismo y el conocimiento distribuido, entre otras. Las principales características por las cuales las RNA's se diferencian son su topología y la forma de entrenamiento.

En cuanto a la topología se puede decir que las redes neuronales se dividen en 2 grandes grupos: "Alimentadas hacia delante" y "Alimentadas hacia atrás" o recurrentes. Las redes "alimentadas hacia delante" son las redes que se explicaron anteriormente. Las conexiones en estas redes no forman ciclos y pueden computar una respuesta rápidamente. Estas redes son entrenadas por diversos métodos, cada uno con ventajas y desventajas. Uno de estos métodos es el de retro-propagación. El segundo tipo de red, la red recurrente, se caracteriza porque las conexiones entre los neurones pueden formar ciclos. Para computar una respuesta una red recurrente debe pasar por un periodo de estabilización, por esta razón generalmente son más lentas. Las redes recurrentes también tienden a ser más difíciles de entrenar.

La forma de entrenar divide a las RNA's en 2 grupos, redes supervisadas y no supervisadas. Las redes supervisadas requieren que para cada patrón utilizado en el entrenamiento se sepa de antemano la salida deseada. El entrenamiento se encarga de modificar la red para hacer que esta devuelva valores lo más cercano posibles a lo correcto. La segunda forma de entrenamiento, la no supervisada, no requiere que se le presente con la salida deseada para cada entrada. Las redes no supervisadas clasifican las entradas que reciben en grupos, creando nuevos grupos cuando una entrada no cae dentro de un grupo existente.