Capítulo 4 Redes Neuronales en la Predicción

La predicción de errores en una red de computadoras, basada en el tráfico que produce, es una tarea muy difícil. Un buen analista debe contar con muchos elementos que le permitan conocer la red, además del conocimiento de tráfico producido por redes semejantes a ésta. Es muy importante que el análisis sea realizado por un experto en el área.

Las redes neuronales artificiales cuentan con el potencial para realizar este tipo de análisis, ya que en la mayoría de los casos son muy buenas en el reconocimiento de patrones complejos, que es básicamente el caso que ocurre con el tráfico producido por una red de computadoras.

4.1 Tipos de Redes Neuronales Artificiales usados para la predicción

El tráfico producido en una red de computadoras no es mas que una serie de tiempo, es decir un conjunto de valores de un mismo atributo sensados en períodos regulares. Para predecir series de tiempo se han utilizado las redes neuronales alimentadas hacia adelante (*feed-forward*) y las redes recurrentes (*recurrent*). Dentro de la redes alimentadas hacia adelante existen diferentes algoritmos, como son: *Linear Associator, Backpropagation, Cascade Correlation, Cascade 2, RAN (resource Allocating Network)*. En la redes recurrentes tenemos entre otros: *Recurrent Cascade Correlation, Simple Recurrent Networks, Real-Time Recurrent Learning, Sequential Cascaded Network* (McCluskey [1993]). Para la predicción del siguiente valor en una serie de tiempo una buena opción son las RNA alimentadas hacia adelante con ventanas en el tiempo (F.W.Op ´t Landt [1997]).

4.2 Algunos trabajos de predicción con redes neuronales

En los últimos años se cuenta con muchos trabajos en la predicción de series de tiempo utilizando redes neuronales artificiales, de los cuales podemos mencionar los siguientes:

- Predicción de acciones. Consiste en el desarrollo de una red neuronal capaz de realizar la predicción del precio de las acciones para un número dado de compañías. Esta predicción se realiza mediante redes alimentadas hacia adelante, y el objetivo en este particular caso es predecir el siguiente valor en la serie de tiempo: el próximo precio de la acción (F.W.Op ´t Landt [1997]).
- Predicción de tráfico vehicular. Se han utilizado redes neuronales recurrentes para la predicción a corto plazo del tráfico en una carretera, a fin de prevenir congestiones y tener un control del acceso a la autopista. Para esto se utilizan datos estimados de otros días con propiedades similares; los mejores resultados se obtuvieron con una red multi-recurrente, y se pudo comprobar que las redes neuronales resolvieron este tipo de predicción y obtuvieron mejores resultados que los métodos estadísticos convencionales (Ulbricht).
- Predicción del tráfico en una autopista. Dierdre predice el volumen y el nivel de ocupación de una autopista, los resultados obtenidos fueron mejores que los obtenidos por técnicas usadas anteriormente. Se demostró que las redes neuronales con exactitud pueden predecir el volumen y la ocupación 1 minuto por adelantado, se utiliza una red neuronal multicapa entrenándose mediante retropropagación, este trabajo se auxilia de una rampa de medición de lógica

difusa (*fuzzy logic ramp metering*) para realizar la predicción (Dierdre R, Cynthia E [1995]).

- Predicción de la transición mensual del índice de precios de acciones. Usando recurrencia y retropropagación, la red neuronal es entrenada para aprender conocimiento experimental y para predecir la transición de precios de acciones, tomando como entrada principal algunos indicadores económicos y obtieniendo la transición relativa de la composición del índice de precios de acciones, usando ocho años de datos económicos, la predicción del crecimiento mensual o la caída del índice del precio de acciones. Los resultados indican que las redes neuronales son herramientas eficientes para la predicción del precio de las acciones (Ho Lee,Cheol Park [1992]).
- Predicción de Tornado. Basada en atributos obtenidos de un radar Doppler, el cual observa diferentes fenómenos que a la larga llegan a producir tornados. Las tormentas eléctricas algunas veces llegan a producirlos, pero no siempre son antecedente de ello. Una red neuronal alimentada hacia adelante es usada para diagnosticar cuales fenómenos detectados por el radar llegarán a producir un tornado. La red neuronal es diseñada para la identificación de *tornado-yielding meso-cyclones*, con ese fin, se desarrollaron procedimientos para determinar el tamaño del conjunto de entrenamiento y el número de nodos ocultos necesarios para el funcionamiento óptimo. Se mostró que la red neuronal encontrada de este modo supera un algoritmo basado en reglas (Marzban, Stumpf [1998]).

4.3 Uso de lógica difusa para la detección/corrección de las deficiencias en el funcionamiento de una red de computadoras (Lewis Lundy).

Un método viable para la temprana detección y corrección de problemas de funcionamiento de una red de computadoras, es la construcción de algoritmos que interpreten y conviertan en símbolos entendibles el flujo de las lecturas numéricas de los monitores de la red, y que provean un mecanismo de inferencia sobre los símbolos. Este mecanismo debe contener el conocimiento del mejor experto en el área. Las implementaciones actuales de este tipo de soluciones presentan el conocimiento en un marco de trabajo basado en reglas.

Los sistemas monitores actuales de la red reportan sus datos de manera muy precisa, algunos de estos datos son:

- Carga en la red.
- Tasa de colisiones de paquetes.
- Tasa de la transmisión de paquetes
- Tasa de aplazamiento de paquetes
- Tiempo de adquisición del canal
- Rendimiento en la transferencia de archivos.

Estos datos son comparados con los valores ideales, así que aquellos valores que excedan un umbral dado producen una alarma. Además se cuenta con herramientas muy buenas, que producen gráficas en las que se despliega la información dada. Sin embargo, excepto para fallas pequeñas, hay pocos expertos capaces de interpretar estos valores y alarmas usando el sentido común y de apuntar hacia la causa de las deficiencias del funcionamiento, tales como entropía de la red, colgado/reiniciado, y bajo rendimiento en la

transferencia de los archivos. Las razones de estas deficiencias, pueden incluir una sobrecarga en el enlace de red, un enrutador con poco procesador, o un ajuste incorrecto del temporizador para el buffer de transmisión. Además, la tarea de la detección/corrección de problemas de funcionamiento es cada vez más difícil con el advenimiento de las redes heterogéneas.

Las deficiencias en el funcionamiento son muy difíciles de detectar y corregir, y hay pocos expertos bien entrenados en el área. El sistema RBR (Rule-Based Reasoning) realizado por L. Lewis en 1998 busca disminuir este problema, recolectando el conocimiento de expertos. Desafortunadamente, los sistemas RBR, tienen un defecto: pueden llegar a ser muy frágiles y imposibles de mantener conforme la red va desarrollándose. Una alternativa es la representación del conocimiento mediante lógica difusa que es un sistema matemático que trata con descripciones imprecisas (Zadeh [1965]) en un entorno de trabajo. Las ventajas del método de lógica difusa son las siguientes:

1.- La red numérica de datos se representa en términos entendibles con sentido común.

2.- Una regla difusa no tiene que trabajar con datos de entrada exactos para contribuir a una solución

3.- La implementación del conocimiento es intuitivo y directo

4.- El método tiene un fundamento que parece matemático

El trabajo de Lewis está en desarrollo. Se están definiendo gramáticas para representar el conocimiento que implica el manejo de las carencias en el funcionamiento. Además se están utilizando diferentes herramientas para la obtención de datos, tales como *Netsnoop de Silicon Graphics' Netvisualizer*, *Cabletron System´s SpectroWATCH*, después de estas pruebas los autores podrán reportar los pros y contras del método.

4.4 Redes Neuronales Artificiales en la predicción de errores en redes de computadoras –NEUGENTS –

La predicción de caída del sistema utilizando NEUGENTS es una tecnología propietaria de *Computer Associates*, el cual usa redes neuronales artificiales, para su predicción (Computer Associates [1999]).

Estos neugents "estudian" su ambiente destino, se familiarizan con su comportamiento normal y pueden identificar rápidamente cuando el sistema se está saliendo de su estado de operación normal.

La clave del manejo de la predicción es identificar las series de condiciones que consistentemente conducen a otros estados conocidos. Aprendiendo del comportamiento pasado, éstos módulos predicen fallas potenciales o cuellos de botella (con probabilidades estadísticas) antes de que ocurran, alertando al administrador del sistema para que tome medidas preventivas. Con el tiempo, estas "acciones evasivas" aumentan el desempeño, reducen el tiempo en que se deja de producir, y mejoran la productividad.

Estos Neugents en realidad generan un escenario de como interactúan los atributos de la infraestructura de las tecnologías de información y la carga de trabajo de la aplicación.

4.4.1 El proceso de aprendizaje de los Neugents

Para hacer su trabajo efectivamente, los Neugents, primeramente tienen que "aprender". Este proceso simplemente requiere la recolección de varias semanas de datos de desempeño del sistema para ser monitoreados.

Los Neugents trabajan en conjunto con un agente de desempeño histórico. Una vez que este agente recolecta toda la información del desempeño del sistema, las facilidades de

los neugents de "auto-aprendizaje" analizan estos datos y construyen un perfil de personalidad única para el sistema a ser monitoreado.

Los Neugents utilizan tecnología de redes neuronales para cumplir con este "aprendizaje" en minutos.

Los Neugents aprenden descubriendo los modos típicos de operación de un sistema. Para hacer esto, los Neugents evalúan como cambian en el transcurso del tiempo, cientos de variables de operación, aprendiendo para asociar patrones de cambio con cambios en el desempeño del sistema. Esto libera al administrador del sistema de escribir y mantener conjuntos agotadores y estáticos de reglas para monitorear el sistema.

4.4.2 Alarmas basadas en contextos

Una vez que los Neugents han creado un perfil personalizado único para el sistema a ser supervisado, la tecnología está lista para empezar el monitoreo en tiempo real y las alarmas basadas en contexto.

Los Neugents evalúan como las variables de operación actuales cambian en el tiempo, analizando esta información con lo que han aprendido de experiencias pasadas. Entonces ejemplifican una predicción, con un factor estadístico de certeza, en el que el sistema estará en el futuro cercano.

Una predicción típica de un problema ejemplificado por los Neugents puede aparecer de la siguiente manera:

A las 11:00 a.m., un neugent predice una probabilidad del 95% de que el servidor AB232 se quedará sin memoria virtual en aproximadamente 45 minutos.

La predicción es apoyada por las siguientes métricas en el funcionamiento:

- La entrada de mensajes de mantenimiento de la red (Internet Control Message Protocol: Mensajes recibidos por segundo) es mas alto que lo esperado. Es 1.75 y nunca ha sido mayor a 1.324
- La entrada WWW (el servicio HTTP: Bytes recibidos por segundo) es mas alto que lo esperado. Es 1482 y nunca había sido mayor a 1268
- La memoria virtual leída del disco (Memoria: paginas de entrada / seg) es mas baja que lo esperado. Es 26.8 y debe ser mayor a 43.1
- La RAM disponible (memoria: Bytes disponibles) está dentro de los límites.
- La memoria virtual de intercambio (memoria: paginas / segundo) está dentro de los límites.
- Las operaciones de lectura de la memoria virtual (memoria: paginas leídas / seg) está dentro de los límites
- Las operaciones de escritura de la memoria virtual (memoria: paginas escritas / seg) está dentro de los límites

Hay que hacer notar que esta alarma indica el tipo de problema, la probabilidad (como un porcentaje) y el razonamiento detrás de la deducción, (habilitando el análisis de causas de raíz) también como el tiempo esperado de ocurrencia.