

ATM 망에서 뉴럴 네트워크를 이용한 적응 폭주제어

The Adaptive Congestion Control Using Neural Network in ATM network

李 庸 日*, 金 映 權**

(Yong-Il Lee* and Yung-Kwon Kim**)

요 약

트래픽의 통계적 변동과 고도의 시변 특성 때문에, 최소의 반응시간을 가지고 고도의 동적인 기술과 적응 그리고 학습능력을 요구하는 네트워크의 자원으로 관리하도록 한다. 뉴럴 네트워크는 ATM 셀 도착율과 큐 길이를 정규화시키며, 그것은 적응 학습 알고리즘을 가지고, ATM 네트워크에서 발생하는 폭주를 방지하기 위한 방법을 연구한다.

Abstract

Because of the statistical fluctuations and the high "time-variability" nature of the traffic, managing the resources of the network require highly dynamic techniques with minimal intervention and reaction times, and adaptive and learning capabilities.

The neural networks normalizes the ATM cell arrival rate and queue length and has the adaptive learning algorithm, and experimentally investigated the method to prevent the congestion generated in ATM networks.

Keyword : Queuing Analysis, Congestion Control, Neural Network, Adaptive Learning Algorithm

I. 서 론¹

ATM(Asynchronous Transfer Mode)은 서로 다른 트래픽 특성과 QoS(Quality of Service) 요구 조건을 갖는, 다양한 서비스를 지원하는 연결형 스위칭 및 다중화 기술이다.

ATM 은 연결형 트래픽을 직접 또는 적응 계층을 통하여 처리하고, 비연결형 트래픽은 적응 계층을 통

하여 처리한다. ATM 가상 연결(VC : Virtual Connection)은 CBR, VBR, ABR, UBR 서비스에서 동작할

수 있으며[1][2], 망으로 전송된 ATM 셀 각각은 송신원에서 수신단으로 가상 연결을 설정해 주는 주소 정보를 이용한다. ATM 가상 접속은 테이블 구축 방법에 따라 PVC와 SVC가 있는데, 그 선택은 망의 규모, 요구되는 QoS 등에 따라 결정된다[3][4][5]. 특히, ATM 계층의 트래픽 제어는 예상 가능한 모든 B-ISDN 서비스에 충분한 ATM 계층의 QoS 등급을 제공하고, AAL 프로토콜에 무관하고, AAL 프로토콜 상위계층 프로토콜에 무관하면서, 네트워크가 폭주 상태일 때도 ATM 계층의 QoS를 계속 유지시킬 수 있어야 한다. 그림 1-1은 ITU I.371에 정의되어 있는 ATM 트래픽 제어 기능의 위치를 나타낸다.

*慶北專門大學 電子科

(Dept. of Electronic, Kyungpook College)

**建國大學校 電子工學科

(Dept. of Electronic Engineering, Konkuk Univ.)

接受日: 1998 年 4 月 22 日, 修正完了日: 1998 年 7 月 23 日

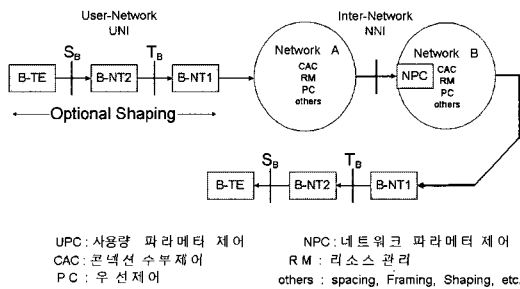


그림 I-1 트래픽 및 폭주 제어 기능을 위한 참조 구성

Fig. I-1 Reference point for traffic/congestion control functions.

CCITT는 B-ISDN 망에서의 링크 속도로 155[Mbps](155.52)와 622[Mbps](622.080)의 두가지를 권고하고 있다. 반응 동작에는 사용 파라미터의 변경, 기존 FMBS(Frame Mode Bearer Service)에서 사용중인 형태의 BECN / FECN (Backward / Forward Explicit Congestion Notification) 등이 검토되고 있다. ATM 네트워크에서 폭주 방법은 그림 I-2와 같다. BECN(역방향 명시적 폭주 제어 통지) 방법은 망

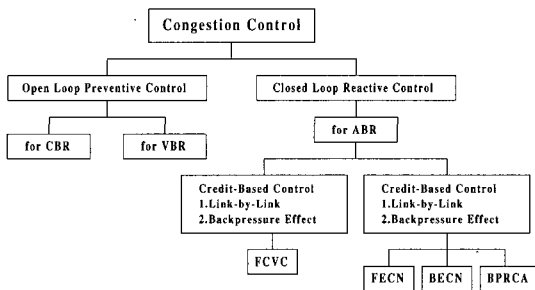


그림 I-2 폭주 제어 메커니즘의 분류

Fig. I-2 The classification of congestion control mechanism.

관리용 셀(OAM cell)을 이용해서 각 노드와 사용자에게 알리는 방식이며, 폭주 정보가 폭주가 일어난 큐잉 포인트에서 송신원으로 바로 전송된다. 그림 I-3은 BECN 방법의 예를 나타낸 것으로, 출력 버퍼에 도착한 모든 셀의 VPI/VCI가 래치되며, 버퍼에 양자화시킨 셀의 개수에 비해 도착 셀이 너무

많으면 지연시키는 메커니즘을 행함으로써 폭주를 제어하는 것이다.

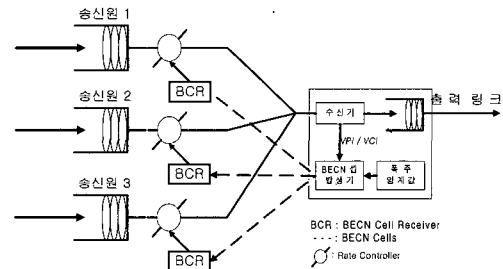


그림 I-3 BECN 방법

Fig. I-3 BECN method.

II. 뉴럴 네트워크를 이용한 폭주 제어

뉴럴 네트워크는 빠르고 유연하고 적응적이며 그리고 지능적인 제어를 제공함으로써, 출현하는 새로운 텔레커뮤니케이션 하부구조에 공헌을 하고 있다. 뉴럴 네트워크는 그래프 토폴로지에서 연결된 병렬 분포된 뉴런의 대규모 시스템이다[6].

현재 사용하는 큐잉 모델의 주요한 단점은 정상 상태 결과만이 다루기 쉽고, 결과적으로 그런 모델 기반에 잘 맞춰진 어떤 제어 알고리즘이, 정상 상태 조건하에서만 최적 성능을 보장하게 된다는 것이다.

그러나, 뉴럴 네트워크는 적응적이며 유연하고 최적 제어가 가능하므로 적합한 방법으로 생각될 수 있다. 적응적 또는 최적 라우팅, 멀티미디어 트래픽 예측등과 같은 고속 네트워크 제어의 많은 중요한 부분은, 뉴럴 네트워크에 의해 실행되는 효율적인 결정함수로 인해서 유익할 것이며, 이 점이 뉴럴 네트워크의 강력한 효용성이다. 지도된 훈련 모델중에서, 다층 퍼셉트론은 보통 가장 간단하고도 정확한 해를 산출하기 때문에 가장 많이 사용된다.

III. 시뮬레이션 모델

본 논문에서 제안한 시뮬레이션 모델의 구성도는 그림 III-1과 같다.




그림 III-1. 제안한 방법의 시뮬레이션 모델

Fig. III-1 Simulation model of proposed method.

이 모델에서, Q 는 최대 큐 길이를 의미하며 100~1,000까지로 정한다. 그리고 R 은 Ra/Rs (arrival process)이며, NN 은 뉴럴 네트워크를 의미한다. 이 그림에서 각각 n 개의 소스로 구성된 두 클래스가 동시에 하나의 수신기로 셀을 전송할 수 있으며, 큐 길이 Q 를 가진 버퍼가 오버플로우가 되면 셀이 삭제된다. 폭주 신호는 q/Q 로 정규화된 임계값보다 클 때 발생되며, 이 임계값을 넘어서면 제어신호가 발생하여 소스의 전송속도를 제어한다.

여기서 뉴럴 네트워크의 학습 회수는 10,000~15,000번 훈련시켰으며 폭주를 판정하게 된다. 오차역전과 학습 방법은 3계층 순방향 뉴럴 네트워크 구조이며, 입력층에 4개의 뉴런을 사용하였다. 하나는 정규화된 큐 길이 값을 추적하기 위하여 사용되고, 나머지 3개는 최근 3사이클에 걸친 셀 도착율을 위해 사용된다.

VBR 서비스 트래픽($\lambda_1 \sim \lambda_n$)은 ABR 서비스 트래픽($b_1 \sim b_n$)보다 높은 우선 순위를 가지도록 하여, 버퍼에 VBR 서비스 셀이 대기하고 있는 경우 ABR 서비스보다 우선적으로 전송된다. 본 논문에서 VBR 서비스 트래픽은 평균 4.5[Mbps], 최대 14.84[Mbps], 352×240 픽셀의 특성을 가지며, 초당 30 프레임을 발생하는 MPEG 비디오 열을 가정하였다.

LAN에서 발생하는 트래픽은 ABR 서비스 특성과 같이 버스트성이 크고, 대역폭을 미리 예측할 수 없는

특성을 가지고 있으며, 일반적으로 버스트한 구간이 평균적으로 수 [Kbps]인 특성을 가진다.

III-1. 비디오 소스(VBR 서비스 ; AR 모델)

행위의 변화가 심한 화상회의 및 방송 TV와 같은 화상 소스에 대해서도 1차 AR 모델은 잘 적용될 수 있음을 보이며, 이에 대한 정의는 다음과 같다[7][8]

$$\lambda(n) = a\lambda(n-1) + b\omega(n) \quad (\text{III-1})$$

여기서, $\lambda(n)$ 은 n 번째 프레임의 비트율, a, b 는 상수, 그리고 $\omega(n)$ 은 가우시안 랜덤 과정(Gaussian Random Process)을 나타내며, 평균 η 와 분산값 1을 갖는다.

여기서, $|a| < 1$ 을 가정하면, n 이 커짐에 따라 평형상태에 도달하게 되고, 평형상태에서의 평균 $E(\lambda)$ 와 이산 자기공분산(discrete autocovariance) $C(n)$ 은 화상전화의 실험 데이터로부터 다음과 같은 데이터를 얻을 수 있다.

$$E(\lambda) = 0.52 \text{ [bits/pixel]} \quad (\text{III-2})$$

$$C(n) \approx 0.0536 \times (e^{-0.13})^n \text{ [bits/pixel]}^2 \quad (\text{III-3})$$

이산 자기공분산 $C(n)$ 은 $n/\tau = 30$ [frames/s] 표본화에 의한 실험적 근사화로부터 $\hat{C}(r) = 0.0536 \times e^{-39r}$ 를 얻을 수 있다. 따라서 이들 실험 데이터들로부터, 다음 파라미터들을 구할 수 있다.

$$a \approx 0.8781, b \approx 0.1108, \eta \approx 0.572 \quad (\text{III-4})$$

III-2. 고속 LAN 데이터 (ABR 서비스 ; MMPP 모델)

고속 LAN 데이터에서 발생하는 트래픽 과정은 일반적으로 ON-OFF 모델로 잘 표현된다. 하나의 소스는 최고 비트율 MAX, activity factor ρ (=AVG/MAX, AVG는 평균 비트율), 그리고 평균 버스트 지속기간 MBD으로 특징지어지며, 이러한 소스는 다음 세가지 파라미터로 표현되는 2-상태 마르코프 과정(ON-OFF 모델)으로 표현된다.

- birth rate(수식): OFF 상태에서 ON 상태로의 평균 전이율

$$\alpha = \frac{\rho \cdot MAX}{(1-\rho)MBD} \quad (III-5)$$

- deth rate(수식 = MAX/MBD) : ON 상태에서 OFF 상태로의 평균 전이율
- ON 상태에서의 셀 발생율(A = MAX/L).


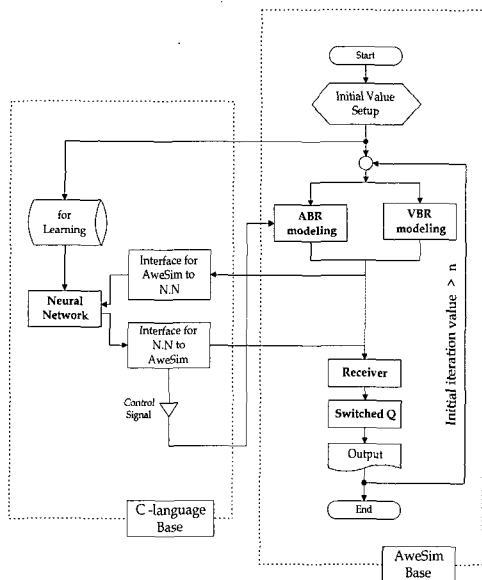


그림 III-2 ON-OFF 모델.

Fig. III-2 ON-OFF model.



그림III-3. 시뮬레이션 모델의 흐름도

Fig. III-3 The flowchart of the simulation model.

여기서 L은 ATM 셀 내에서 헤더부를 뺀 순수 데이터 크기이다.

그림 III-3은 본 논문에서 제안한 모델을 시뮬레이션하기 위한 프로그램의 개략도로서, 크게 두 부분으로 나누면, AweSim과 C언어를 기반으로 구성되어 있다. ABR과 VBR 서비스는 각각 MMPP 모델과, 1차 AR 모델로 프로그래밍 되었다. ABR과 VBR 서비스

에서 생성된 셀들은 뉴럴 네트워크가 처리할 수 있는 데이터로 변환한 후에, NN에게 NN이 저장된 정보를 활용하여 데이터 처리를 하게 된다.

IV. 시뮬레이션 결과 고찰

IV-1. 뉴럴 네트워크를 적용하지 않은 경우의 셀 손실율




그림 IV-1. NN 무적용 셀 손실율

Fig. IV-1. Cell loss rates without NN

그림 IV-1은 Q=1,000, 셀 활성영역 발생율=0.304, 지속시간 d=1이며, 그리고 뉴럴 네트워크가 없을 때, 100,000 셀 타임에 대한 셀 손실율이다. 초기 셀 타임에는 10⁻⁸ 차원에서 유지되나, 시간이 경과함에 따라 셀 폭주가 증가하게 되며, 대략 5,000 셀 타임이 지나면, 10⁻⁶ 차원에 이르게 되어, 셀 타임 증가에 따라 차츰 증가하는 경향을 보이도록 모델링한 입력 트래픽의 특성을 보이고 있다.

IV-2. 뉴럴 네트워크를 적용한 경우의 셀 손실율

그림 IV-2는 Q=100, 셀 활성영역 발생율=0.467, 지속시간 d=3인 경우의 결과이다. 전체 시스템에 대해서 살펴보면, 셀 손실율이 10⁻⁷ 차원으로 수렴하고 있음이 검증되었다. 이 그림에선 전체적으로, Q 길이를 100개의 셀로 정한 결과인데, 0.6, 0.7, 0.8로




그림 IV-2. NN 적용 셀 손실율

Fig. IV-2. Cell loss rates with NN

정규화시킨, q/Q 의 셀 수가 각각 다른 경우에는, 셀 손실율도 서로 차이가 나고 있다.

V. 결론

본 연구에서 제안한 모델은, 기존의 통계적 방법이 가지고 있는 계산의 복잡성 및 비적응성을 뉴럴 네트워크를 이용함으로써 극복하였다. 성능 결과 뉴럴 네트워크를 근간으로 한 해는, 알고리즘 접근 방식보다 보다 낫은 결과와 간단하고 빠르다는 것이 입증되고 있다. ABR VBR queue의 입출력 셀 수를 비교하고, switch queue의 입출력 셀 수도 비교하여 셀 손실율을 도출했다. 이처럼 셀 손실율과 링크 이용도 등을 시뮬레이션 출력 레포트로 확인했다.

후후 연구 과제로는 최적화에 잘 적용될 수 있는, 여러 가지 다른 뉴럴 네트워크 알고리즘도 적용시켜

볼 수 있을 것이며, 다만 ATM 다중화기에서의 폭주 제어를 연구해 보아야 한다. 그리고 빠른 속도 제어를 위해서 뉴로-퍼지 시스템도 적용해 볼 예정이다.

참 고 문 헌

- [1] I-TUT Recommendation I.371, "Traffic Control and Congestion Control in B-ISDN", November. 1995.
- [2] T. M. Chen and S. S. Liu, ATM Switching Systems, 1995.
- [3] David E. McDysan, Darren L. Spohn, ATM Theory and Application, McGraw-Hill Series on Computer Communications, 1994.
- [4] W. Stallings, Data and Computer Communications, Fourth Edition, 1994.
- [5] B. J. Vickers, T. Suda, "Connectionless Service for Public ATM Network", IEEE Communications Magazine, pp34-71, August. 1994.
- [6] Yeung-Keun Park, Gyungho Lee, "Application of Neural Networks in High-Speed Communication Networks", IEEE Communication Magazine, pp.68-74, October. 1995.
- [7] B. Maglaris, D. Anastassiou, P. SEN, "Performance Models of Statistical Multiplexing in Packet Video Communion", IEEE Trans. on Communion, Vol.36, no.7 July. 1988.
- [8] 장수영, 방승양, 권오준, "ATM 망에서 호 연결 수락 제어를 위한 신경망 모델 개발에 관한 연구", 포항 공대 최종연구보고서, 8. 1997.

저 자 소 개



李庸日 (會員申請中)

1983년 2월 건국대학교 전자공학과 졸업(공학사). 1985년 2월 건국대학교 대학원 전자공학과 졸업(공학석사). 1998년 2월 건국대학교 대학원 전자공학과 졸업(공학박사). 1990년 ~ 현재 경북 전문대학 전자과 조교수.

관심분야 : ATM 폭주, 뉴럴 네트워크, 집적광학등

金 暎 權 (IEEE senior member)

第1卷 第1號 論文 97-01-14 參照.

現在 建國大學校 電子·情報通信工學部 教授.