

On-line 학습을 통한 ATM 호레벨 트래픽 제어 연구

서 현 승*, 백 종 일, 김 영 철

전남대학교 전자공학과

광주광역시 북구 용봉동 300, 500-757

E-mail : hsseo@neuron.chonnam.ac.kr *

A Study on the Traffic Controller of ATM Call Level Based on On-line Learning

Hyun-Seung Seo *, Jong-il Paek, Young-Chul Kim

Dept. of Electronics Eng. Chonnam National University

E-mail : hsseo@neuron.chonnam.ac.kr *

Abstract

In order to control the flow of traffics in ATM networks and optimize the usage of network resources, an efficient control mechanism is necessary to cope with congestion and prevent the degradation of network performance caused by congestion. To effectively control traffic in UNI(User Network Interface) stage, we proposed algorithm of integrated model using on-line learning neural network for CAC(Call Admission Control) and UPC(Usage Parameter Control). Simulation results will show that the proposed adaptive algorithm uses of network resources efficiently and satisfies QoS for the various kinds of traffics.

I. 서 론

ATM은 광대역 정보 통신망을 구현하기 위하여 기존의 회선 교환망이나 패킷 교환망과 같은 전용망의 개념에서 탈피하여 음성, 데이터, 화상 등 고속 광대역 정보를 효과적으로 전송할 수 있으며, 화상회의 서비스 등과 같은 멀티미디어 서비스를 제공 할 수 있는 특수한 형태의 패킷형 전달 방식으로서 일정 크기를 갖는 패킷들의 연속적인 흐름인 ATM 셀(cell)에 의하여 정보가 전달되며, 사용자와 망이 요구하는 각종 성능을 만족하도록 트래픽 제어 능력을 제공하고 있다.^[1]

트래픽 제어는 사용자의 서비스 품질에 대한 요구를

만족시키면서 동시에 망 자원(링크, 대역폭, 버퍼공간, 스위치 용량, Processing)이용을 최대화하는데 필요하며 반응 제어보다는 예방 제어(Preventive Control)가 트래픽 제어의 주된 수단으로 대두되고 있다. 예방 제어의 대표적인 예로서 연결 수락 제어 (CAC: Call Admission Control)와 사용 파라미터 제어 (UPC: Usage parameter Control)를 들 수 있으며 사용자가 신호원의 통계적 특성을 나타내는 트래픽 파라미터를 망에 전달하면, CAC는 새로운 호의 설정단계에서 사용자가 신고하는 자신의 트래픽 특성 값과 서비스 품질 기준 그리고 망의 상태를 바탕으로 새로이 연결을 요구하는 호와 이미 서비스중인 호 모두의 서비스 품질을 만족하고 동시에 망 자원을 효율적으로 사용할 수 있도록 호의 수락 여부를 결정하는 것으로 수학적 모델에 의한 방법, 관측에 의한 방법, 등가 대역폭에 의한 방법으로 분류된다. 연결이 설정된 후 각 신호원은 트래픽 전송을 시작하며 망과의 협상 파라미터 준수 여부를 확인하고 위반 트래픽에 대한 조치를 취하기 위해 UPC 가 수행되고 있다. 트래픽을 감시하고 제어하기 위한 기존의 제안된 UPC 메커니즘들은 LB(Leaky Bucket), TJW(Triggered Jumping Window), JW(Jumping Window), MW (Moving Window), GCRA(Generic Cell Rate Algorithm), EWMA(Exponentially Weighted Moving Window Average), Virtual Scheduling등이 있으나 메커니즘마다의 특성에 따라 조금씩의 차이를 보이고 있다.^[6]

본 논문에서 제안되는 알고리즘은 망 자원의 효율성을 높이고자 망 상황에 따라 각각의 소스에서 발생할 수 있는 셀 손실을 예측하여 호 설정 단계에서부터 수락/거절의 판단의 근거로 사용하고, 수락이 결정된 호

※ 본 논문은 정보 통신부에서 지원하는 대학 기초 연구 지원 사업으로 수행된 결과입니다.

의 셀이 UPC의 입력 버퍼에 전송되게 되며 호 수락 단계에서 설정된 파라미터의 값을 위반하는지 감시하게 된다. 이 때 트래픽 예측기로 신경회로망(Neural Network)을 사용하며 과거의 트래픽에 기반하여 앞으로의 트래픽 손실량을 예측한다^[2,3,4,5]. 제안된 알고리즘에 의한 호 수락여부 결정과 트래픽 감시, 조정 능력을 평가하기 위해 트래픽의 특성에 따라 지연 민감 트래픽과 손실 민감 트래픽을 class별로 분류하고 성능을 측정하였다.

본 논문의 구성은 2장에서는 셀 손실을 위한 신경회로망을 사용한 호 레벨 트래픽 제어의 구성과 기능을 살펴보고 3장에서는 시뮬레이션 결과와 고찰을 마지막으로 4장에서는 결론을 내린다.

II. 셀 손실을 예측을 위한 신경회로망 호 레벨 트래픽 제어

본 논문의 예측기로 사용된 신경 회로망은 하나의 은닉층(hidden layer)을 갖고 있는 MLP(Multi-Layered Perceptron)이며 학습을 위해 모멘텀항과 학습율(learning rate) 적용이 가능한 오류 역전파 알고리즘(Error back-propagation)을 사용하였다.

트래픽 발생 source는 호 수락 제어와 사용자 파라미터 제어 상호간의 특성을 고려하고 트래픽 특성에 따라 3개의 클래스로 나누어서 시뮬레이션을 하였으며, 호 수락제어와 사용자 파라미터 제어를 연동한 호 레벨 트래픽제어의 흐름선도를 그림1에서 보여주고 있다.




그림 1 호 레벨에서 트래픽 제어 흐름선도
Fig. 1 Traffic control flow chart in the call level

1. 신경망 호 수락 제어

1) 패턴 테이블

학습 패턴={ AR_1, AR_2, \dots, AR_i : Target}

AR_i : 신경망의 입력값(클래스 i 의 셀 발생율)

Target : 신경망의 출력값

신경망의 입력 값으로 3개의 클래스별 셀손실률이 들어오게 되는데 이들 입력값을 2진 비트로 정규화 과정을 그림 2에서 보여 주고 있다.




그림 2 패턴 정규화
Fig. 2 Pattern regulation

2) 패턴 갱신 방법

신경망 학습을 위한 패턴으로 약 200개의 패턴을 사용하는데 매 주기 발생되는 새로운 패턴 값을 랜덤한 위치에 저장을 하고 학습 패턴이 200개가 넘게 되면 가장 오래된 패턴을 버리는 형식으로 하였다.

3) 신경망 호 수락 제어 알고리즘

정해진 측정구간 동안의 셀 발생률과 셀 손실률을 통해 새로운 패턴을 얻고, 새로운 패턴을 패턴 테이블에 랜덤한 위치에 갱신시킨다. 새로운 패턴으로 갱신된 패턴 테이블을 학습하고, 이를 통해서 다음 호 요청에 반영한다. 만약 어떤 측정구간에 QoS를 위반한 패턴이 발생되었는데 새로운 호가 호 요청을 하면 그 구간 동안 기존 호의 해지가 없을 경우 새로 요청한 호는 거절되고, 같은 구간 동안 호의 해지가 있었다면 그 시점까지의 측정결과와 새로운 호의 등가대역 이용률을 해당 클래스에 가산하여 신경망 제어기에 입력한다. 어떤 측정구간에 QoS를 위반한 패턴이 발생되지 않고 새로운 호가 호 요청을 하면 그 시간까지의 측정결과와 새로운 호의 등가 대역 이용률을 해당 클래스에 가산하여 신경망 제어기에 입력 한다.

2. 사용자 파라미터 제어

1) Learning Process

그림 3은 신경망 학습 패턴 추출 구간을 나타내며, 현재 시간 t 를 기준으로 왼쪽은 과거 시점을, 그리고

오른쪽은 미래 시점을 의미한다. 신경망 학습을 위한 입력 패턴은 $t-\Delta$ 에서 입력 버퍼 단의 셀 수와 토큰 풀의 토큰 수, 그리고 셀 손실율이며, 시간 t 에서의 셀 손실율을 목표 패턴으로 사용한다.




그림 3 UPC에서 신경망 학습 과정
Fig. 3 N.N Learning Process in the UPC

① 신경망 입력패턴

- $I^{t-\Delta}$: 시간 $t-\Delta$ 구간 사이의 입력 트래픽 셀 수(4 개의 트래픽 구간별(Δ)샘플 추출).
- $B^{t-\Delta}$: 시간 $t-\Delta$ 구간의 입력 버퍼 셀 수.
- $T^{t-\Delta}$: 시간 $t-\Delta$ 구간의 토큰 풀의 토큰 수.
- $C^{t-\Delta}$: 시간 $t-\Delta$ 구간의 손실된 셀 수.

② 신경망 목표 패턴(출력)

C_t : 현재 시간 t 에서 손실된 셀 수.

③ 입·출력 패턴

$$H(t-\Delta) = [I^{t-\Delta}, \dots, I^{t-\Delta}, B^{t-\Delta}, T^{t-\Delta}, C^{t-\Delta}; C_t]^T$$

④ 정규화 과정

입력 패턴의 경우 트래픽은 샘플 구간내 최대 발생 셀 수, 버퍼 상태는 버퍼 크기, 그리고 토큰 상태는 토큰 풀 최대 크기로 각각 정규화한다.

2) Prediction Process

그림 4에서 신경회로망은 학습 데이터에 의해 다음 측정 구간에서의 셀 손실율의 예측방법을 보여준다.




그림 4 신경망 셀 손실율 예측 프로세스
Fig. 4 Prediction process of the cell loss rate using a Neural Network

① 예측 셀 손실율 증가

$t+\Delta$ 의 예측 셀 손실율 증가시 가중치를 예측하고

손실율에 근거하여 변화시킴으로 해서 토큰 발생 간격을 줄인다. 줄어든 토큰 발생 간격은 토큰 발생 횟수를 증가시키고 망으로 진입하는 셀 수를 증가시킨다. 단, 토큰 발생률의 최대치가 최대 셀율을 넘지 않는 범위 내에서 유지한다.

② 예측 셀 손실율 감소

예측 셀 손실율이 0에 가까울수록 망과 초기에 협상 하였던 토큰 발생률과 같이 유지하여 정상적인 트래픽 제어가 되도록 하는 반면 버퍼 한계값을 최대치로 유지하여 셀 손실율을 줄인다.

III. 시뮬레이션 및 결과

1. 실험 환경

본 논문에서 다양한 트래픽의 특성에 따른 class별 분류를 위하여 다음과 같이 지연 민감 트래픽과 손실 민감 트래픽을 각각 On-off, 그리고 IPP 모델로 발생 시켰다. 트래픽 제어 알고리즘의 실험을 위하여 호 수락 제어와 사용자 파라미터 제어를 그림 5와 같이 구성하고 제안 알고리즘의 실험 모델로 설정하였으며,

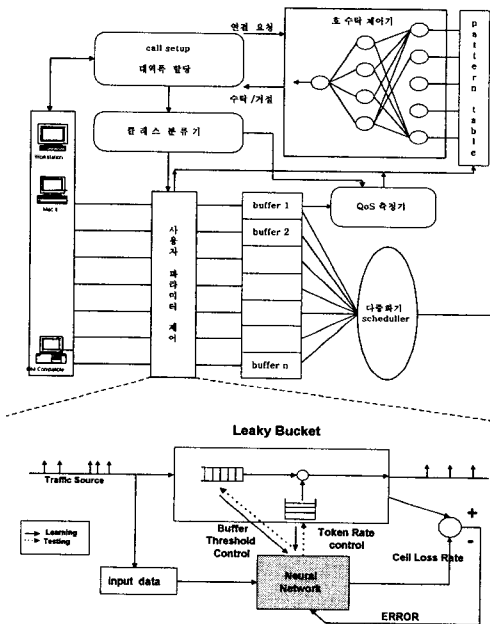


그림 5 호 레벨 트래픽 제어의 실험 모델
Fig. 5 Simulation model of call level traffic control

제한한 연동 모델의 성능을 비교하기 위해서 신경망을 사용한 호 수락 제어와 사용하지 않는 등가 대역 호 수락 제어를 가지고 신경망을 사용한 NLB와 그렇지

않은 BLB의 cell loss rate, buffer delay를 비교한다.

표 1. 트래픽 파라미터
Table 1. Traffic Parameter

Class	Class 1	Class 2	Class 3
지연 민감	○	○	
손실 민감		○	○
Modelling	VBR(on-off)	VBR(IPP)	VBR(IPP)
peak_rate	500 cells/s	500 cells/s	700 cells/s
active_time	0.65 sec	0.15 sec	0.12 sec
idle_time	0.35 sec	0.15 sec	0.18 sec
셀 스케줄링	DWRR 알고리즘		
링크 용량	2000 cells/sec		

2. 실험 결과

본 논문에서 제안된 알고리즘은 각각 특성이 다른 트래픽에서 발생하는 손실 양을 예측하고 network 폭주 신호에 반응하여 표 2 에서처럼 신경망을 사용한 CAC와 연동한 NLB가 QoS의 특성을 나타내주는 셀 손실과 셀 지연에서 신경망을 사용하지 않는 BLB보다 더 나은 성능을 보이고 있다. 또한 표 3에서처럼 신경망을 사용하지 않는 CAC와 연동한 NLB가 신경망을 사용하지 않는 BLB보다 성능이 향상되었음을 보여 주고 있다. 이것은 호 수락 제어(CAC)와 협상된 token 발생율이 매우 작거나 network caller가 트래픽 표시자(Traffic Descriptor)의 값을 정확하게 알지 못하더라도 Neural LB는 잘 적응할 수 있음을 뜻하며, network 자원과 QoS의 조건에 기반한 적응적인 토큰을 적용이 가능함을 보인다.

그리고, 표 3, 4를 보면 ATM 호 레벨에서의 호 수락 제어와 사용자 파라미터 제어에서 신경망을 사용한 방법이 그렇지 않는 방법에 비해 성능이 개선된 점을 보여 주고 있다.

표 2. 연동 모델의 시뮬레이션 결과(1)
Table 2. Simulation result of combined model(1)

		class 1	class 2	class 3
BLB	셀 손실	0.0014	0.001	0.0008
	셀 지연	14m/s	10.6m/s	6m/s
NLB	셀 손실	0.0006	0.0004	0.0001
	셀 지연	3m/s	1.7m/s	0.3m/s

표 3. 연동 모델의 시뮬레이션 결과(2)

Table 3. Simulation result of combined model(2)

		class 1	class 2	class 3
BLB	셀 손실	0.0041	0.0037	0.0028
	셀 지연	45.2m/s	49.5m/s	25.5m/s
NLB	셀 손실	0.0032	0.0034	0.0011
	셀 지연	20m/s	18.5m/s	10.3m/s

IV. 결론

본 논문에서는 ATM 트래픽 제어기중 신경망을 사용하여 망에 진입하고자 하는 호의 수락 여부를 결정하는 호 수락 제어와 수락된 호의 트래픽 협약 조건을 위반하는지 감시하고 조절하는 사용자 파라미터 제어에 신경망을 사용하고 두 제어기를 연동시킨 모델을 제안하였다. 신경망의 학습 능력과 예측 능력의 사용으로 셀 손실을 예상하고 미연에 방지하기 때문에 신경망을 사용하지 않는 경우 보다 QoS가 향상됨을 알 수 있었다. 따라서 이러한 지능적인 제어방식은 고속화되고·다양화되는 통신망에서 보다 효율적인 제어방식에 응용될 수 있을 것이다.

[참고 문헌]

- [1] 임주환, 성단근, 한치문, 김영선, "ATM 교환", 홍릉 과학출판사, 1996, 11월.
- [2] Hiramatsu, A, "Integration of ATM Call Admission Control and Link Capacity Control by Neural Networks," *IEEE J. Sel. Areas in Commun.* pp. 1131-1138, Sep.1991.
- [3] Ahmed A. Tarraf, Ibrahim W. Habib, Tareck N. Saadawi, "A Novel Neural Network Traffic Enforcement Mechanism for ATM Networks", *IEEE SUPERCOMM ICC*, pp. 779-783, 1994
- [4] I. Habib, A. Tarraf, T.Saadawi, "A Neural network controller for congestion control in ATM multiplexers" *Computer Networks and ISDN Systems*, V.29 N.3 , pp. 325-334, Jan. 1997.
- [5] Shigeo Shioda, Hiroshi Saito, " Satisfying QoS standard with combined strategy for CAC and UPC", *Proceedings of the International Conference on Communications ICC'95 Volume 2* 1995. 06. 18
- [6] The ATM Forum, Technical committee, Traffic management specification version 4.1, March 1999.