

# 트래픽 손실을 예측을 통한 신경망 UPC 알고리즘에 관한 연구

변재영\*, 이영주, 정석진, 김영철  
전남대학교 전자공학과  
광주광역시 북구 용봉동 300, 500-757  
E-mail : jypyun@neuron.chonnam.ac.kr \*

## Study on a Neural Network UPC Algorithm Using Traffic Loss Rate Prediction

Jae-Young Pyun \*, Young-Ju Lee, Suk-Jin Jung, Young-chul Kim  
Dept. of Electronics Eng. Chonnam National University  
E-mail : jypyun@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. This paper proposes a new UPC(Usage Parameter Control) mechanism that varies the token generation rate and the buffer threshold of Leaky Bucket by using a Neural Network controller observing input buffers and token pools, thus achieving the improvement of performance. Simulation results show that the proposed adaptive algorithm uses of network resources efficiently and satisfies QoS for the various kinds of traffics.

### 1. 서 론

ATM은 광대역 정보 통신망을 구현하기 위하여 특수한 형태의 패킷형 전달 방식으로서 일정 크기를 갖는 패킷들의 연속적인 흐름인 ATM 셀(cell)에 의하여 정보가 전달되며, 다양한 트래픽을 수용하면서 사용자와 망이 요구하는 각종 성능을 만족하도록 트래픽 제어 능력을 제공하고 있다.

트래픽 제어는 사용자의 서비스 품질에 대한 요구를 만족시키면서 동시에 망 자원(링크, 대역폭, 버퍼공간, 스위치 용량, Processing)이용을 최소화하는데 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 망의 현재 상태와 신호원의 특성을 기반으로 연결 설정 여부를 결정한다. 연결이 설정된 후 각 신호원은 트래픽 전송을 시작하며 망과의 협상 파라미터 준수 여부를 확인하고 위반 트래픽에 대한 조치를 취하기 위해 UPC가 수행되어야 한다.

트래픽을 감시하고 제어하기 위한 기존의 제안된 UPC 메커니즘들은 LB(Leaky Bucket), JW(Jumping Window), TJW(Triggered Jumping Window), MW(Moving Window) 그리고 EWMA(Exponentially Weighted Moving Window Average), Virtual Scheduling 등이 있으나 메커니즘마다의 특성에 따라 조금씩의 차이점을 보이고 있다<sup>[2,4]</sup>.

논의되어왔던 UPC 기법중 Buffered Leaky Bucket은 입력 버퍼를 이용하여 트래픽 shaping 기능을 수행하며 망과 협상된 최대 셀 도착 간격을 위반한 트래픽에 대해 셀 손실을 줄일 수 있는 장점이 있으나 비피 사용으로 인한 셀 지연이 늘어나는 단점이 있다. 또한 망 자원이 분할할 때나 휴지 상태일 때도 제공되는 서비스는 일정하며 비피 지연을 전혀 고려하지 않기 때문에 서로 다른 서비스 품질을 요구하는 지연 민감 트래픽 그리고 손실 민감 트래픽에 대해 적절한 조치를 취할 수 없다<sup>[5]</sup>.

본 논문에서 제안되는 알고리즘은 망 자원의 효율성을 높이고자 망 상황에 따라 망 정보를 Buffered Leaky Bucket에 전달하고 트래픽 class별 예측기를 통해 비피 사용으로 인한 셀 지연 증가를 낮추고 손실율을 감소시키는 적응적이고 지능적인 트래픽 제어를 할

수 있다. 이 때 트래픽 예측기로 신경회로망(Neural Network)을 사용하며 과거의 트래픽에 기반하여 앞으로의 트래픽 손실량을 예측한다<sup>[1,3,6]</sup>. 제안된 알고리즘에 의한 트래픽 감시, 조정 능력을 평가하기 위해 트래픽의 특성에 따라 지연 민감 트래픽과 손실 민감 트래픽을 class별 분류하고 성능을 측정하였다.

본 논문 구성은 다음과 같다. 2장에서는 지연 민감 트래픽과 손실 민감 트래픽으로 구분되는 트래픽 특징을 설명하고 3장에서는 신경회로망 사용 파라미터 제어(Neural Leaky Bucket)의 구성과 기능을 살펴본다. 4장에서는 시뮬레이션 결과와 고찰을 그리고 마지막으로 5장에서는 결론을 내린다.

## 2. 트래픽 분류

### 2.1. On-off Model

On-off 모델에서 셀은 침묵상태에 있을 때 전혀 도착하지 않고, 버스트 상태에 있을 때는 일정한 간격을 두고 도착한다. 버스트당 셀의 수는 평균  $E[X]$ 를 갖는 지수함수(exponential) 분포로 가정되고, 침묵(silence) 기간은 평균  $E[S]$ 를 갖는 지수함수(exponential)분포로 가정된다. 이것은 한 개의 소스에서 발생하는 지연 민감 트래픽인 음성 트래픽을 모델링 할 수 있다.

$$\alpha^{-1} = E[X] \times \Delta,$$

$$\beta^{-1} = E[S],$$

$$\text{평균 셀율} = \frac{E[X]}{\alpha^{-1} + \beta^{-1}}.$$

여기서  $\alpha^{-1}$ 는 버스트 구간,  $\beta^{-1}$ 는 침묵 구간,  $\Delta$ 는 버스트간격을 각각 나타낸다.

### 2.2. IPP Model

IPP 트래픽 신호원 모델은 On-off 모델의 변형으로 버스트 구간동안 셀들이 포아송(Poisson) 프로세스에 따라 도착하며 침묵구간에는 그 셀 도착 흐름의 포아송 프로세스가 중단된다고 가정한다. On-off 모델에서 버스트상태가 지수 분포를 따르는 기간동안 포아송 분포를 따르는 셀이 발생하는 특수한 모델이 된다. 이것은 고속 데이터가 갖는 버스트 특성을 잘 표현하는 손실 민감 트래픽이 된다.

## 3. 셀 손실을 예측을 위한 신경회로망 사용 파라미터 제어기(UPC)

### 3.1. 신경회로망 트래픽 손실 예측기

과거 트래픽에 기반하여 트래픽 셀 손실율을 예측하기 위하여 적응성과 비선형 특성을 가진 신경 회로망을 이용할 수 있다. 예측을 위해 사용된 신경 회로망은 하나의 은닉층을 갖고 있는 MLP (Multi-layered Perceptron)이며, 학습을 위해 모멘텀 항과 학습률(learning rate) 적용이 가능한 오류 역전파 알고리즘(Error back-propagation algorithm)을 사용한다.

#### (1) 학습 패턴

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

#### ① 입력패턴

$I^{t-\Delta}$  : 시간  $t-\Delta$ 구간 사이의 입력 트래픽 셀 수.

(10 개의 트래픽 구간별( $\Delta$ )샘플 추출).

$B^{t-\Delta}$  : 시간  $t-\Delta$ 구간 사이의 입력 버퍼 상태.

$BC^{t-\Delta}$  : 시간  $t-\Delta$ 구간 사이의 입력 버퍼 변화 상태(증가, 감소).

$T^{t-\Delta}$  : 시간  $t-\Delta$ 구간 사이의 토큰 풀의 상태.

#### ② 목적 패턴(출력)

$C_t$  : 시간  $t$  에서 손실된 셀 수.

#### ③ 정규화 과정

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

### 3.2. 신경회로망 Leaky Bucket

망 자원의 효율적인 사용을 위해서는 망에서의 트래픽 폭주 상태 여부를 수시로 확인하여야 하며 이때 다중화기 버퍼의 상태는 망의 상태를 뜻하므로 다중화기 버퍼에서의 셀 손실과 버퍼 유효 공간 정보를 UPC 단에 전달함으로써 신경회로망 Leaky Bucket(Neural L.B)이 동작한다.

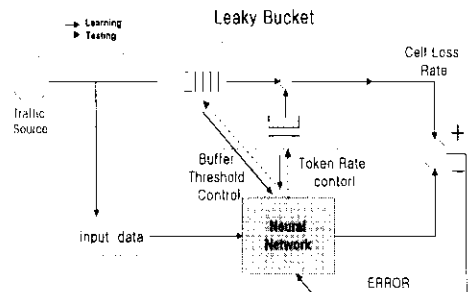


그림 1. Neural L.B 의 구조.

Leaky Bucket의 특징은 셀이 토큰 풀(Token Pool)로부터 토큰을 얻을 때만 망으로 전송되며 토큰 풀이 비어 있을 때에 입력 버퍼에 도착하는 셀들은 대기한

다. 그리고 버퍼가 차있으면 도착한 셀들은 탈락한다. 이러한 L.B의 특성을 이용하여 토큰 발생율과 입력 버퍼의 한계값(threshold value)을 신경회로망에 의한 트래픽 예상 셀 손실율에 근거하여 제어한다.

(1) Neural Leaky Bucket 제어 알고리즘

1. 신경망 트래픽 손실 예측기에 의해 토큰 발생율과 버퍼 한계값을 가변화하기 위해 class별 off-line 학습(learning) 과정을 수행한다.
2. 망내 셀 스케줄링을 위한 network 버퍼에서 셀 손실 발생은 트래픽 폭주를 의미하므로 UPC에 버퍼 초과 셀 손실 상황을 전달하고 신경망 트래픽 예측기능을 정지시킨다. 이는 망 전송 트래픽을 줄이고 망을 보호하기 위함이다.  
(전송 delay는 200 time slot으로 가정한다.)
3. 계속적인 망내 셀 손실이 발생하지 않으면 다시 신경망 트래픽 예측 기능을 가동시켜 트래픽 전송량을 증가시킨다.
4. 가변 파라미터는 다음과 같다.

$$\text{token 발생 간격} = -(\text{MAX}-\text{MIN}) \cdot \text{CLR} + \text{MAX},$$

$$\text{Buffer Threshold} = -(\text{max}-\text{min}) \cdot \text{CLR} + \text{max}.$$

여기서 CLR : 예상 셀 손실율,  
 MAX · MIN : 토큰 발생 간격의 최대값과 최소값,  
 max · min : 버퍼 한계값의 최대값과 최소값.

(2) 예측 셀 손실율 증가

다음 window 구간에서의 예측 셀 손실율을 증가시 토큰 발생 간격을 줄여 토큰 발생 횟수를 늘리고 망으로 진입하는 셀 수를 늘린다. 단, 토큰 발생율의 최대치가 최대 셀율을 넘지 않는 범위 내에서 유지한다. 또한 지연 민감 트래픽을 위하여 버퍼 한계값을 줄이고 버퍼 지연을 최소화시킨다.

(3) 예측 셀 손실율 감소

예측 셀 손실율이 0 에 가까울수록 망과 초기에 협상하였던 토큰 발생율과 같이 유지하여 정상적인 트래픽 제어가 되도록 하는 반면 버퍼 한계값을 최대치로 유지하여 셀 손실율을 줄인다. 특히, 손실 민감 트래픽의 경우에는 class별 특성에 따라 버퍼 한계값을 가변화하지 않고 일정하게 유지하여 손실율을 최대한 줄일 수 있다.

4. 시뮬레이션 및 결과

4.1 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 발생시키고 트래픽의 다중화를 위해서 각각의 source 마다 단일 버퍼를 갖는 DWRR 스케줄링 알고리즘<sup>[7]</sup>을 사용하였다. 그리고 Neural L.B의 성능 측정을 위해 Buffered L.B과의 network utilization, cell loss rate, buffer delay 성능 비교를 한다.

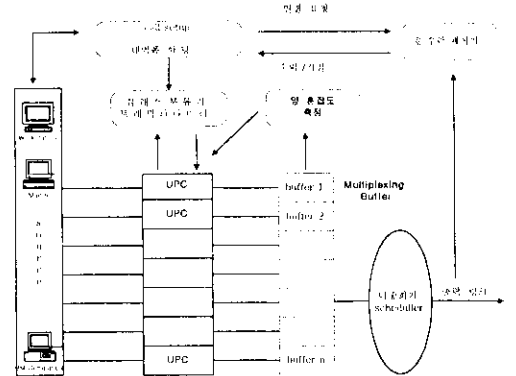


그림 2. 시뮬레이션 환경 및 과정.

표 1. 트래픽 파라미터.

Class	Class 1	Class 2	Class 3
지연 민감	○	○	
손실 민감		○	○
Modelling	VBR(on-off)	VBR(IPP)	VBR(IPP)
peak_rate	50 cells/s	200 cells/s	400 cells/s
active_time	0.3 sec	0.1 sec	0.1 sec
idle_time	0.6 sec	0.5 sec	0.8 sec
mean_rate	16.7 cells/s	33.3 cells/s	50 cells/s
source 수	30개	30개	30개
( $\frac{\text{peak\_rate}}{\text{mean\_rate}}$ )	3	6	8
입력버퍼(B)	5, 5	20, 25	20, 25
토큰풀(M)			
셀 스케줄링	DWRR 알고리즘 <sup>[7]</sup>		
호수락제어	등가 대역 제어 알고리즘		
링크 용량	2000 cells/sec		
holding time	평균 6초의 지수합수 분포		
호도착률	평균 0.1초의 지수합수 분포		

4.2 실험 결과

class별 가변 토큰 발생간격은 window 구간(4)에서 각각 78, 35, 25 time slot(class 1,2,3)으로 초기 설정되고 60% 변화를 주었으며 버퍼 한계값은 (2~5, 11~20, 11~20)로 신경망 예측기에 의해 제어하였다. 본 논문에서 제안된 알고리즘은 트래픽 양이 증가함에 따라 트래픽 손실량과 버퍼 지연이 증가하게 되는

상황에서 이때 발생하는 손실 양을 예측하고 network 폭주 신호에 반응하여 그림 3 에서처럼 Neural L.B이 셀 손실 QoS 측면에서 Buffered L.B보다 더 나은 성능을 보이고 있다. 그리고 그림에서의 class별 QoS 파라미터 값의 서로 다른 분포는 UPC의 입력 버퍼(B)와 트론 풀(M)의 크기 선택에 의한 것이다. 이것은 호 수락 제어(CAC)와 협상된 token 발생율이 매우 작거나 network caller가 트래픽 표시자(Traffic Descriptor)의 값을 정확하게 알지 못하더라도 Neural L.B은 잘 적용할 수 있음을 뜻하며, network 자원과 QoS의 조건에 기반한 적응적인 트론을 적용이 가능함을 보인다.

더불어 그림 4 에서는 UPC 버퍼에서의 트래픽 평균 지연시간이 트래픽 양 증가에 따라 감소함을 보여주며 Neural L.B을 통한 트래픽 파라미터에 대한 성능은 Buffered L.B보다 우수함을 증명한다. 적은 손실과 지연을 겪은 Neural L.B은 그림 5, 6 에서처럼 network 이용률을 향상시킨다. 이는 트래픽의 손실율이 예측되어 active time 때 token 발생이 많게하고 예상 손실율이 없을 때는 정상적인 Buffered L.B 제어기능으로 shaping을 통한 bursty traffic의 셀 간격 유지를 통해 network 이용률을 최대화할 수 있기 때문이다.

### 5. 결론

본 논문에서는 ATM 트래픽 제어기중 망내 진입하고자 하는 트래픽의 협약 조건 이행을 감시하고 조절하는 사용 파라미터 제어를 신경회로망을 통해 적응적으로 적용한 예를 보이고 있다. 망 상태에 따라 트론 발생율과 버퍼 한계값을 조절함으로써 트래픽 특성에 따라 셀 손실을, 버퍼 지연 그리고 망 이용률이 개선됨을 알 수 있었으며, 신경망의 학습 능력 정도에 따라 필요한 QoS를 더욱 만족시킬 수 있다. 본 보의 실험에서는 몇 개의 샘플 트래픽에 대해서 학습하고 적용하였으나 실시간 트래픽 학습 환경을 구축할 시 더 나은 성능을 얻을 수 있으리라 보인다.

#### [참고 문헌]

- [1] 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.
- [2] X. Wu, Lambadaris, H. Lee and A. R. Kaye, "A Comparative Study of Some Leaky Bucket Network Access Schemes", *IEEE SUPERCOM ICC*, pp. 1586-1591, May 1994.
- [3] Ahmed A. Tarraf, Ibrahim W. Habib, Tarek N. Saadawi, "A Novel Neural Network Traffic Enforcement Mechanism for ATM Networks", *IEEE SUPERCOMM ICC*, pp. 779-783, 1994
- [4] M. Ritter, S. Kornprobst, F. Hubner, "Performance Comparison of Design Alternatives for Source Policing Devices in ATM Systems" *IEEE ICCS/ISPACS*, Feb. 1997.
- [5] V. Catania, G. Ficili, S. Palazzo, D. Panno, "A Fuzzy Expert System For Usage Parameter Control In ATM Networks" *Proc. Globecom 95*, vol 2, pp. 1338-1342, Nov. 1995.
- [6] 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.
- [7] Sung Won Lee, Dong Ho Cho, Yong Ki Park, "Improved Dynamic Weighted Cell Scheduling Algorithm based on Earliest Deadline First Scheme for Various Traffics of ATM Switch," *Proc IEEE Global Telecommunication Conference*, vol 3, Nov. 1996.




그림 3. class별 셀 손실율.




그림 4. class별 버퍼 지연(msec).




그림 5. Buffered L.B(load=1).




그림 6. Neural L.B(load=1).