

論文99-36C-7-5

ATM 망에서 다중화기 정보에 의한 Neural UPC에 관한 연구

(Study on a Neural UPC by a Multiplexer Information in ATM)

金永哲*, 邊幸瑩**, 徐鉉承***

(Young Chul Kim, Jae Young Pyun, and Hyun Seung Seo)

요 약

ATM망에서 트래픽 흐름을 제어하고 망 자원 사용을 효율적으로 사용하기 위해서는 폭주(Congestion) 발생에 의한 망 성능 저하를 막고 폭주 현상에 대처할 수 있는 적응적인 제어가 필요하다. 본 논문에서는 모든 트래픽에 대해 고정된 형태의 제어를 하는 Buffered Leaky Bucket과 적응성과 예측 기능을 갖는 신경 회로망(Neural Network)을 이용하여 버퍼의 효율성을 높이고 망의 서비스 품질(QoS)로 구별되는 셀 손실율과 버퍼 지연을 테스트 및 성능 비교를 하였다. 또한 입력 트래픽의 다중화를 위해 사용되는 DWRR과 DWEDF의 셀 스케줄링 알고리즘이 균등 지연을 만족할 수 있도록 개선하였다. 셀 스케줄러로부터 망의 폭주 정보는 신경회로망을 이용한 Leaky Bucket에서 예측된 트래픽 손실율을 제어하고 손실율 정도에 따라 토큰 발생율과 버퍼 한계값은 제어된다. 이러한 트래픽 손실율 예측은 다음 입력 트래픽에 대한 손실과 버퍼 지연을 줄일 수 있도록 제어의 효율성을 높일 수 있으며 다른 제어방식에도 응용될 수 있다.

ATM 트래픽에 대한 신경회로망 학습과 예측 테스트를 위해 확률 랜덤 변수에 의해 발생된 셀 발생과 예측을 모의 실험하였으며, 이때 다양한 트래픽의 QoS가 향상되었음을 알 수 있었다.

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. In this paper, Buffered Leaky Bucket which applies the same control scheme to a variety of traffics requiring the different QoS(Quality of Service) and Neural Networks lead to the effective buffer utilization and QoS enhancement in aspects of cell loss rate and mean transfer delay. And the cell scheduling algorithms such as DWRR and DWEDF for multiplexing the incoming traffics are enhanced to get the better fair delay. The network congestion information from cell scheduler is used to control the predicted traffic loss rate of Neural Leaky Bucket, and token generation rate and buffer threshold are changed by the predicted values. The prediction of traffic loss rate by neural networks can enhance efficiency in controlling the cell loss rate and cell transfer delay of next incoming cells and also be applied for other traffic controlling schemes. Computer simulation results performed for random cell generation and traffic prediction show that QoS of the various kinds of traffics are increased.

* 正會員, 全南大學校 電子工學科
(Dept. of Electronics Eng., Chonnam Nat'l Univ.)

** 學生會員, 高麗大學校 電子工學科
(Dept. of Electronics Eng., Korea Univ.)

*** 學生會員, 全南大學校 電子工學科

(Dept. of Electronics Eng., Chonnam Nat'l Univ.)

※ 본 논문은 1998년도 대학 기초 연구과제 연구비(No. AB-97-G0470)에 의하여 연구되었음

接受日字:1999年2月23日, 수정완료일:1999年6月23日

I. 서론

광대역 종합 통신망(B-ISDN)은 통신망의 디지털화와 고속화에 의해 멀티미디어의 트래픽 수용에 대응함으로써 가입자에게 다양한 형태의 서비스를 제공할 수 있는 기반을 마련해 주고 있다^[1]. 그러나 점차 다양화되고 복잡해져가는 수요자의 요구 사항을 충분히 만족시키기 위해서는 통신망의 고속화와 더불어 지능화가 필수적으로 이루어져야 한다. 더욱이 ITU-T에서 B-ISDN의 전송 방식으로 ATM이 표준화되고 인공 지능 응용 분야에 대한 개발 연구가 활발히 진행되면서 인공 지능 신경망(Neural Network)을 이용한 지능제어의 가능성을 보여주고 있다.^[6] ATM 통신망에서의 지능제어는 트래픽 제어에 중점적으로 연구중이며, 연구의 방향은 신경망의 적응적인 제어를 이용해서 ATM 트래픽 제어중 서비스의 초기의 셀 전송을 위해 사용자로부터 호 요구 신호가 발생하게 되면 셀 발생율과 망의 흐름 상태를 학습하고 학습된 파라미터의 값에 따라서 수락여부를 결정하므로써 망의 폭주를 사전에 예방하여 효율성을 증가시킬 수 있도록 호 수락 제어에 사용할 수 있다.^[2] 또한, 신경망의 도착 셀 수에 대한 count process를 통해 도착 트래픽 Probability Density Function (PDF)을 예측하고 2개의 신경망 N.N1과 N.N2를 이용하여 off-line 학습과 on-line 학습을 기반으로 ATM에서의 사용자파라미터 제어를 하는 알고리즘이 있다. 이 방법에서는 policing을 위해 각 VC/VP에 2개의 신경망이 필요하며, 도착 트래픽의 count process만의 정보를 학습하고 있다. 그러나 학습된 정보에 의한 다음 도착 트래픽의 PDF 예측은 off-line 학습시 얻은 학습 데이터에 지나치게 의존하고 있기 때문에 non-stationary 트래픽에 대한 PDF 예측은 어렵게 되는 단점이 있다.^[4] 그렇지만, 본 논문에서 제안하는 알고리즘은 하드웨어적인 부담감을 줄일 수 있도록 각 VC/VP에 1개의 신경망을 사용하며, non-stationary 트래픽에도 적용이 가능하도록 학습 방법과 학습 패턴들을 달리하고 있다.^[10] 또한 congestion control은 ATM traffic control중에서 과잉밀집의 영향 및 과잉 밀집상태의 전파를 최소화하기 위한 방법으로 사용자가 이용할 수 있는 최대 비트율을 줄이고 이를 감시하며 사용자가 이 값을 초과할 때 feedback 정보에 의해 다시 재조정할 수 있다. 이때 feedback 신호에 의한 round trip 전파 지연요소를 고려하여 Neural Network 학습을 한 후 트래픽율을 제어

하는 기법이 있다.^[7] 이와 같이 신경회로망의 최적화와 예측 기능은 수시로 변하는 환경에서 적용이 가능하므로 ATM과 같이 상이한 트래픽 특성을 수용하며, 셀 손실율, 전송 지연, 에러율에 대한 다양한 QoS (Quality of Service)를 요구하는 제어 시스템에서 유용하게 이용될 수 있다.

실제 ATM망에서는 트래픽 전송 효율화를 위해 사용되는 통계적인 다중화(statistical multiplexing) 방식과 버스티(bursty)한 트래픽 특성으로 망에서 폭주(congestion)를 유발할 수 있다. 이러한 폭주 현상을 방지하기 위해 트래픽을 감시하고 제어하는 사용자 파라미터 제어(UPC: Usage Parameter Control)가 사용되며 대표적인 UPC 알고리즘으로 LB(Leaky Bucket), JW(Jumping Window), TJW (Triggered Jumping Window), MW(Moving Window) 그리고, EWMA (Exponentially Weighted Moving Window Average), Virtual scheduling 등이 있다.^[3,5]

UPC 기법중 Buffered Leaky Bucket(BLB)은 입력 버퍼를 이용하여 트래픽 shaping 기능을 수행하며 망과 협상된 최대 셀 도착 간격을 위반한 트래픽에 대해 셀 손실을 줄일 수 있는 장점이 있으나 버퍼 사용으로 인한 셀 지연이 늘어나는 단점이 있다. 또한 망 자원이 분주할 때나 휴지 상태일 때도 제공되는 서비스는 일정하며 버퍼 지연을 전혀 고려하지 않기 때문에 서로 다른 서비스 품질을 요구하는 지연 민감 트래픽 그리고 손실 민감 트래픽에 대해 적절한 조치를 취할 수 없다.

본 논문에서 제안되는 알고리즘은 망 자원의 효율성을 높이고자 망 상황에 따라 망 정보를 BLB에 전달하며 class별 트래픽 손실율 예측기를 통해 버퍼 사용으로 인한 셀 지연과 손실율을 감소시키는 적응적인 트래픽 제어를 할 수 있도록 하였다. 이때 트래픽 예측기로 신경회로망을 이용한 새로운 형태의 BLB를 제안하며, 본 논문에서 이를 Neural Leaky Bucket(NLB)라 칭한다. 신경회로망의 on-line 학습과 예측기능으로 다양한 트래픽 패턴에 적용할 수 있으며, 과거의 트래픽에 기반하여 앞으로의 트래픽 손실량을 예측하는 NLB의 트래픽 QoS를 평가하기 위해 트래픽의 특성에 따라 지연 민감 트래픽과 손실 민감 트래픽을 class별 분류하고 성능을 측정하였다.

또한 각 VCC(Virtual Channel Connection)의 트래픽 다중화를 위해 각 VCC마다 버퍼를 갖으며 셀 스케줄링에 의해 서비스될 수 있도록 DWRR (Dynamic

Weighted Round Robin)과 DWEDF (Dynamic Weighted Earliest Deadline First) 알고리즘을 이용하였다.^[8, 9] 이 다중화기는 트래픽 다중화 기능과 함께 동적인 트래픽 서비스를 목적으로 하고 있다. 하지만 실제 성능 측정을 위해 응용된 DWRR과 DWEDF에서는 트래픽이 많이 도착하는 VCC에게 상대적으로 많은 서비스를 제공함으로써 적은 양의 트래픽을 전송하는 VCC에서 불균등한 지연이 발생하게한다. 공평성을 만족하지 못하고 있는 이러한 DWRR과 DWEDF 알고리즘에서 지연 시간의 deadline을 이용하여 우선순위를 재결정할 수 있는 Jumping 기법 스케줄링을 추가함으로써 균등한 서비스를 제공하도록 하였다.(이후 제안된 스케줄링 기법을 PJ scheduling: Priority Jump scheduling이라 칭한다.).

본 논문 구성은 다음과 같이 구성된다. II장에서는 BLB, NLB, 그리고 트래픽 모델 및 특징을 설명하고, III장에서는 다중화기로 사용되는 PJ scheduling에 대해서 살펴본다. IV장에서는 시뮬레이션 결과와 고찰을 그리고 마지막으로 V장에서는 결론을 내린다.

II. Neural Leaky Bucket

1. Buffered Leaky Bucket

가장 일반적인 형태인 BLB 알고리즘은 트래픽의 입력율을 조절하기 위해서 토큰 풀(token pool)로부터 발생하는 토큰의 수와 입력 버퍼의 크기로 결정된다. 입력 버퍼단에 도착하는 셀은 토큰 풀에 토큰이 존재하면 즉시 BLB로부터 출발하여 망으로 진입하게된다. 이때의 토큰 발생률은 연결 수락 제어(CAC: Call Admission Control)시 협상된 파라미터에 따라 결정되어 발생된 토큰은 토큰 풀에 저장된다. 그리고 토큰 풀은 유한 크기를 가지며, 토큰 수가 토큰 풀의 크기를 초과하면 토큰 생성은 중단된다.^[1, 3, 5] 반면 call setup 과정에서 결정된 토큰 발생율에 의한 트래픽 입력율 제어는 입력 트래픽과 가변적인 환경을 갖는 망 상황을 고려하지 않는 제어를 하게되며, 이는 버퍼의 이용 효율성이 낮다는 문제점이 있다.

2. Neural Leaky Bucket

ATM 망의 트래픽은 가입자가 선언한 트래픽 기술인자(traffic description)에 대한 신뢰성이 낮고 불확실성(uncertainty)을 내포하고 있다. 이러한 문제점 개선

을 위해 본 논문에서는 패턴 인식과 예측 기능이 있는 신경회로망을 이용하여 트래픽 손실을 예측하였다. 다양한 트래픽 도착 분포(arrival distribution) 형태는 수학적 해석이나 트래픽 관찰만으로는 예측이 어려우나 신경회로망을 이용한 트래픽 손실을 예측은 버퍼단에서의 overflow에 의하여 발생하는 현재 셀 손실, 버퍼에서의 queuing cell의 위치, 그리고 토큰 풀에 남아있는 토큰 수를 측정하고 학습시킴으로써 다음 트래픽 손실을 예측이 가능하게 된다. 이렇게 예측된 트래픽 손실율은 그림 1과 같이 자원 이용률과 QoS 향상을 위해 제어 파라미터인 토큰 발생률과 버퍼의 한계값(threshold)을 제어한다. 다만 이러한 제어는 망 폭주 상황 정보를 OAM (Operation, Administration and Maintenance) 셀이나 시그널링에 의해 전파되어 UPC에서 트래픽 전송량을 조절하도록 지원되어야 한다. 본 논문의 예측기로 사용된 신경 회로망은 하나의 은닉층(hidden layer)을 갖고 있는 MLP(Multi-layered Perceptron) 이며, 학습을 위해 모멘텀항과 학습률(learning rate)적용이 가능한 오류 역전파 알고리즘(Error Back-Propagation algorithm)을 사용한다.




그림 1. Neural Leaky Bucket의 모델
Fig. 1. Model of Neural Leaky Bucket.

1) Learning Process

신경 회로망 입력 벡터로서 현재 시간(t)에서의 최근 패턴 추출 구간(Δ)을 제외한 10개의 과거 샘플 구간에서의 도착 셀 분포와 현재 구간에서의 버퍼와 토큰 상태를 그림 2에서처럼 추출한다. 식 (1)은 이때의 학습 파라미터로서 실시간 학습을 위하여 사용되며, 식 (2)는 학습 목표값으로서 셀 손실율을 의미하고 있다. 즉, $t-\Delta$ 에서의 목표값은 현재 패턴 추출 구간의 target 셀 손실율이며, 현재 패턴 추출 구간 t에서의 셀 도착율과 손실율을 통하여 다음 구간인 현재 패턴 추출 구간에서의 셀 손실율을 예측한다.

실시간 학습을 하기 위해서 신경망의 출력과 목적 패

턴의 차이값이 임의의 한계값이 되도록 학습은 반복되며 실시간 학습을 위해 각 샘플 구간에서 한정적인 학습 iteration을 갖도록 하였다.




그림 2. 제안된 신경망 학습 과정
Fig. 2. N.N Learning Process of the proposed neural network.

$$H(t-\Delta)=[I^{t-10\Delta}, \dots, I^{t-\Delta}, B^{t-\Delta}, T^{t-\Delta}; C_t]^T. \quad (1)$$

$$T(t-\Delta) = \frac{\text{the lost cells during time } t}{\text{the arrived cells during time } t} \quad (2)$$

① 입력패턴

$I^{t-\Delta}$: 시간 $t-\Delta$ 구간 사이의 입력 트래픽 셀 수
(10 개의 트래픽 구간별(Δ)샘플 추출).

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

$T^{t-\Delta}$: 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 크기, 그리고 토큰 상태는 토큰 풀 최대 크기로 각각 정규화한다.

2) Prediction Process




그림 3. 신경망을 셀 손실율 예측 프로세스
Fig. 3. Prediction process of the cell loss rate using a Neural Network.

그림 3에서 신경회로망은 학습데이터에 의해 다음 측정 구간에서의 셀 손실율을 예측한다. 랜덤 확률 분포의 트래픽은 컴퓨터 시뮬레이션을 통해 발생되어지며, 이때 발생된 트래픽 분포 형태에 따라 각 source에서의 트래픽 손실 예측은 달라지게 된다. 신경망의 예측과정

에서의 출력값은 다음 도차 시간에서의 트래픽 손실율로 임의의 예측값(K) 이상일 때와 이하일 때를 구별하고 토큰 발생율을 조절하며, 특히 지연 민감 트래픽의 경우는 버퍼 한계값을 유동적으로 조절할 수 있다. 단, 손실 민감 트래픽의 경우는 버퍼 한계값 변화는 손실율을 줄이기 위해 최대 버퍼크기를 유지하도록 한다.

```

if (CLR>=K)
    token 발생 간격=  $\alpha*(1-CLR)*(st\_token)$ ;
else
    token 발생 간격=  $\beta*(1-CLR)*(st\_token)$ ;
end
Buffer Threshold =  $-(st\_B-min)*CLR + (st\_B)$ .
    
```

여기서

CLR : 예상 셀 손실율.

α, β : 토큰을 변화를 위한 가중치.

min : 버퍼 한계값의 최소값.

st_token, st_B : 기준 토큰 발생 간격(st_token)과 기준 버퍼 크기(st_B)로 Call setup에서 설정된다(Buffered L.B에서 사용).

(1) 예측 셀 손실율 증가

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

(2) 예측 셀 손실율 감소

예측 셀 손실율이 0 에 가까울수록 망과 초기에 협상 하였던 토큰 발생률과 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.

위와 같은 토큰 발생율과 버퍼 한계값 조절은 망 폭주 신호가 NLB에 도착하지 않은 경우에 해당되며 폭주 신호의 발생시에는 계속적인 트래픽 진입을 억제시켜야 되므로 신경망에 의한 토큰율과 버퍼 한계값 가변은 하지 않고 정상적인 shaping 동작을 갖는 BLB 알고리즘에 의해 제어되도록 한다.(폭주 신호 전송 delay는 100 time slot으로 가정한다). 계속적인 망내 셀 손실이 발생하지 않으면 다시 신경망 트래픽 예측 기능을 가동시키고 트래픽 도착과 손실 상황에 따라 토큰 발생 주기를 가

변화하여 트래픽이 전송될 수 있도록 한다.

III. PJ(Priority Jump) 스케줄링

ATM망에서 다양한 특성을 갖는 트래픽들은 지연과 손실 민감도에 따라 분류되며, 음성과 영상 같은 트래픽은 허용한계 이내의 셀 손실은 허용하지만 지연에 민감하고, 파일 전송과 같은 데이터 트래픽은 실시간 전송보다 셀 손실에 민감한 트래픽이다. 이와 같은 트래픽 특성을 최대한 반영하는 다중화 알고리즘이 필요하다.

VCC에서의 채널별 셀 다중화를 위한 WRR (Weighted Round Robin) 알고리즘을 개선한 DWRR과 DWEDF는 QoS 파라미터의 PCR(Peak Cell Rate)과 MCR(Mean Cell Rate)을 이용하여 가중치를 각 VCC에 부여함으로써 각 소스들의 트래픽을 서비스한다. 가중치에 따른 scheduling 기법인 DWRR과 DWEDF에서는 각 round가 다음 3개의 state 중 1개의 state를 갖게 된다. 그리고 P는 cycle내에 도착 가능한 최대 셀 수에 해당하며, M은 평균 셀 수에 해당한다. P와 M에 따라 서비스하는 DWRR과 DWEDF에서는 VBR과 CBR이 state 1에서 시작되어 state 2로 천이된 후 ABR 서비스를 지원하도록 하고 있다.




그림 4. DWRR의 사이클과 라운드
Fig. 4. Cycle and round for DWRR.

state 1 : (P > 0, M > 0)

다음 round에서 source는 방문 받게 된다.

state 2 : (P > 0, M ≤ 0)

state 1상태의 다른 source가 있는 한 state 2 상태의 source는 방문 받지 않는다.

state 3 : (P ≤ 0, M ≤ 0)

ABR 트래픽 전송이 가능하다(in DWEDF). 각 round 초기화가 이루어지며, 새로운 입력 셀에 대한 측정.

각 state에서의 서비스 우선 순위 결정에 있어서 Round Robin 방식에 의존하는 DWRR은 지연 deadline에 기반한 DWEDF와 차이를 갖고 있다. 또한 DWEDF에서는 DWRR을 수정하여 state 3에서 도착

하는 VBR트래픽에 대한 Invalid cell로 평가하여 tagging 기법을 이용하는 DWEDF_CLP와 트래픽을 폐기하는 DWEDF_BLOCK로 구분된다.

DWRR과 DWEDF에서는 state 1 상태의 VCC연결이 없는 경우에 state 2 상태의 연결을 지원할 수 있도록 되어있다. 하지만 여러 개의 bursty 트래픽이 망으로 진입하고자할 때 해당 사이클 구간의 평균 도착 셀 수에 해당하는 M 값이 각 VCC마다 다르기 때문에 낮은 M 값을 갖는 VCC의 bursty 트래픽은 다른 입력 트래픽보다 먼저 state 2 상태로 천이될 경우의 수가 많다. 그리고 state 1 상태에서 서비스가 끝나고 state 2에서 대기중인 트래픽들은 나머지 VCC의 트래픽 소스들이 모두 state2 상태로 천이될 때까지 버퍼에서 대기함으로써 지연을 가중시킨다. 즉, 전송 우선 순위가 높은 트래픽이 많아질수록 전송 우선 순위가 낮은 트래픽은 전송 기회가 적어지는 단점이 발생하게된다. 이는 망의 QoS를 저하시키고 대역폭 이용률을 떨어뜨린다. 이러한 불균등한 (unfair) 버퍼 지연은 그림 5와 같이 burst성의 차이가 많은 트래픽이 망으로 진입하는 경우에 더욱 커지게 된다.

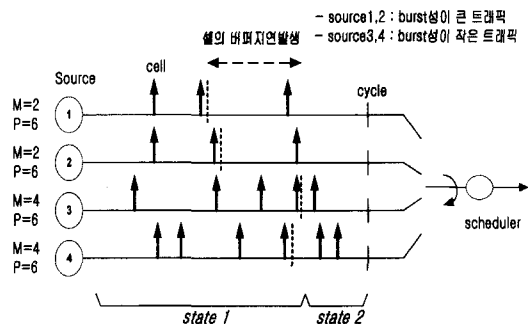


그림 5. DWRR과 DWEDF 셀 스케줄링
Fig. 5. Cell scheduling for DWRR and DWEDF.

불균등한 서비스의 예를 보이고 있는 그림 5에서 VCC 1과 2는 M=2이고 P=6이며, 다른 VCC 3과 4보다 M이 작기 때문에 스케줄러로부터 서비스를 받을 때 state 천이시 상대적 불이익을 받을 수 있다. VCC 1은 M=2 이므로 2개의 셀을 state 1에서 서비스 받을 수 있고 다음 셀이 도착하더라도 state 2에서 다른 VCC 2, 3, 4가 state1의 서비스를 종결할 때까지 대기하게된다. 이와 같이 트래픽의 양이 많은 VCC들이 우선적으로 스케줄링이 되면 우선 순위가 낮은 트래픽의 VCC에게 큰 지연을 초래하게 되므로 각 VCC에 제공되는 QoS를 좀 더 균등하게 제공하도록 제어해야 한다. 이를 위해 본 논

문에서는 bust성이 큰 셀에 대하여 불균등한 버퍼 지연을 감소시키기 위해 도착 셀의 지연정도에 따라 제어할 수 있는 PJ(Priority Jump)기능의 스케줄링을 사용함으로써 지연의 균등성(fairness)을 효과적으로 보장할 수 있다. M이 작고 burst성이 큰 source의 셀들이 state 2 상태에서 일정한 지연 시간(PJ time)을 초과하게 되면, 아직 state 1의 서비스가 종결되지 않은 state 1의 VCC 보다 먼저 서비스 받을 수 있는 권한을 부여하도록 하여 전체 도착 셀들의 지연 시간을 균일하도록 할 수 있다. 그림 5의 예제의 경우 VCC 1이 state 1의 서비스가 끝나고 state 2의 서비스를 위해 대기하는 도중 지연이 PJ time을 초과하면 서비스가 가능하도록 하는 것이다.

IV. 시뮬레이션 및 성능 분석

1. PJ 스케줄링의 실험 및 성능

제안된 알고리즘의 스케줄링 성능 측정을 위해 DWRR과 DWEDF를 함께 비교하였다. 단, 본 실험에서 사용한 DWRR과 DWEDF는 해당 사이클당 P와 M 변수 값 초과시 입력되는 트래픽을 invalid cell로 평가하고 DWEDF_BLOCK에서처럼 Jumping Window에 의한 셀 폐기를 한다. 이는 실험의 간편성과 DWRR과 DWEDF의 차이점을 도출하기 위해서이다. 본 실험을 위해 사용된 트래픽은 표 1과 같이 2000(cells/sec)의 링크를 이용하는 7개의 입력 채널을 임의 선정하였으며, 이때 burst크기가 각각 달라지도록 Mean rate를 설정하였다.

표 1. Cell scheduling의 트래픽 조건

Table 1. Traffic conditions of cell scheduling.

| | | | | | | | |
|--|--------------------|-----|-----|-----|-----|-----|-----|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| | 400 | 400 | 400 | 400 | 400 | 400 | 400 |
| | 120 | 160 | 200 | 240 | 280 | 320 | 360 |
| | 20 | 20 | 20 | 20 | 20 | 20 | 20 |
| | 6 | 8 | 10 | 12 | 14 | 16 | 18 |
| | 20, 40 cell units | | | | | | |
| | 100 cell time unit | | | | | | |
| | 2000 cells/sec | | | | | | |

하지만 state 2로의 천이후 나머지 VCC의 state 1 서비스 종결을 기다리는 VCC 트래픽중 PJ(Priority Jump) 시간인 20과 40 cell unit을 초과한 셀들은 다른

VCC의 state1 서비스가 종결되지 않았더라도 서비스하도록 한다

그림 6은 발생 트래픽의 도착 셀 수를 각 VCC별로 표현한 것으로서 peak rate와 mean rate가 큰 VCC 7에서 더 많은 셀 수가 발생함을 알 수 있다.




그림 6. 각 VCC의 도착 트래픽

Fig. 6. Arrival traffics of each VCC.

그림 7과 8은 300,000 time slot unit동안의 simulation을 통해 얻은 결과로서 source 7에 가까울수록 Peak rate와 Mean rate가 크기 때문에 도착 트래픽량도 많아진다.

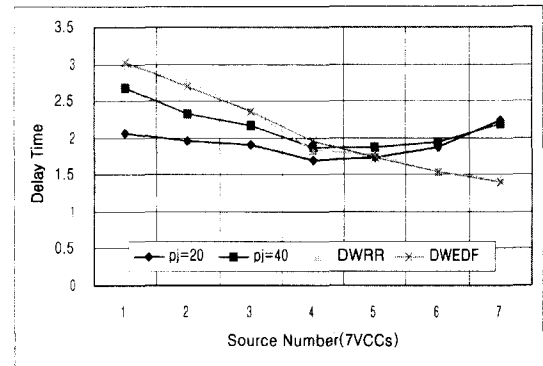


그림 7. Cell Scheduling에서 버퍼 지연(msec)

Fig. 7. Buffer delay(msec) of cell scheduling.

결과적으로 그림 7에서 보는바와 같이 트래픽 양이 낮은 VCC에서 제안한 알고리즘이 DWRR과 DWEDF 보다 더 낮은 셀 지연을 보여주고 있고 트래픽의 양에 관계없이 1~7번까지의 source에 지연이 균등하게 발생하는 것을 볼 수 있다. 이는 각 망 이용자에게 셀 발생에 관계없이 균등한 서비스 제공에 관한 Fairness 문제에 있어서 제안한 알고리즘이 DWRR과 DWEDF보다 적절하며 동적으로 제어함을 의미한다. 반면 그림 8에서는 제안하는 알고리즘과 DWRR과 DWEDF의 시뮬레이션 결과로서 트래픽 상황과 지연에 따르는 버퍼 최대의 크기를 나타내주고 있다. 본 논문에서 제안하는 PJ 알고리

좁은 망을 이용하는 모든 사용자에게 효율적으로 분할하고자 하는게 목적이며, 시뮬레이션 결과 기존의 알고리즘에 비교해서 모든 사용자에게 망의 사용을 균등하게 배분한 것을 볼 수 있다. 그렇지만 그림 8에서 보여주듯이 균등한 망사용을 위해서 평균 셀 발생률이 많은 VCC 6, 7은 버퍼에 대기 상태를 유지해야하기 때문에 셀의 손실을 최소화하기 위해 요구되는 버퍼의 크기가 증가하는 것을 볼 수 있다.




그림 8. Cell Scheduling에서의 최대 버퍼 크기
Fig. 8. Maximum Buffer Size for Cell Scheduling.

따라서, 이러한 버퍼 크기 요구량이 증가한다는 것은 하드웨어적으로 비효과적일 수 있다, 그렇지만, 망을 사용하고자하는 여러 사용자에게 동등한 지연을 보장하지 못하고 다른 사용자보다 많은 트래픽을 전송하는 사용자가 더 작은 평균 버퍼 지연을 갖게 되면 망의 이용측면에서 unfairness 상태가 될 수 있으며, 서비스 사용에 대한 Payment(과금)시에 형평성의 문제를 갖게된다. 따라서 본 논문에서는 망 운용 측면에서 버퍼 크기가 다소 증가하더라도 효율적인 망사용에서의 균등성을 보장받을 수 있는 알고리즘을 제시하였다.

2. Neural Leaky Bucket 실험 및 성능

본 논문에서는 다양한 트래픽의 특성에 따른 클래스별 분류를 위하여 다음과 같이 지연 민감 트래픽과 손실 민감 트래픽을 각각 On-off, 그리고 IPP (Interrupted Poisson Process) 모델로 발생시키고 NLB와 다중화기를 그림 9와 같이 실험 모델로 설정하였다. 본 모의 실험은 WS Sparc-20 환경하에서 MATLAB v5.1을 이용하였으며, trainbpx() 함수를 사용하였다 실험을 위해 신경망 패턴 추출 구간(Δ)은 각 클래스별로 50, 70, 40 time slot(class 1, 2, 3)으로 임의의 설정하였으며, 이것은 트래픽 발생시 active time의 비례비와 시뮬레이션의 반복으로 결정한 것이다. 또한 성능 비교를 위해

BLB의 버퍼와 토큰 발생 간격은 st_token과 st_B로 결정하였다.

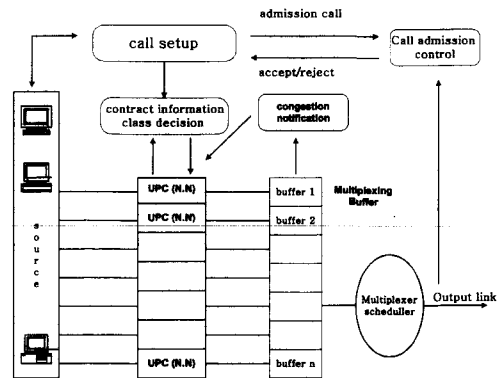


그림 9. Neural Leaky Bucket의 실험 모델
Fig. 9. Simulation model of Neural Leaky Bucket.

표 2. 트래픽 파라미터
Table 2. Traffic Parameter.

| 지연 민감 | ○ | ○ | |
|-----------------------|----------------------------------|-------------|-------------|
| 손실 민감 | | ○ | ○ |
| Modelling | VBR(on-off) | VBR(IPP) | VBR(IPP) |
| peak_rate | 450 cells/s | 700 cells/s | 900 cells/s |
| active_time | 0.3 sec | 0.3 sec | 0.1 sec |
| idle_time | 0.6 sec | 0.5 sec | 0.8 sec |
| st_token | 9 | 4 | 11 |
| α, β, \min | $\alpha=0.88 \beta=1.25 \min=50$ | | |
| 입력버퍼(B) 토큰풀(M) | 60, 10 | 30, 5 | 60, 10 |
| 링크 용량 | 2000 cells/sec | | |

100 time slot까지의 1차학습을 통해 100 time slot 이후 학습과 예측 기능이 동작하도록 하였으며, 20000 time slot동안의 시뮬레이션 결과를 나타내는 그림 10, 11, 12은 각 클래스의 트래픽 도착 특징과 예측 셀 손실율에 따라 토큰율이 가변됨을 볼 수 있으며 ($K=0.0001$), measurement time은 Δ 에 해당하는 것으로 시뮬레이션 시간동안의 모든 패턴 추출 구간별로 발생되어진 토큰 발생율을 나타낸다. 즉, 셀 발생의 증가를 예측하게 되면 NLB는 토큰 발생율을 증가 시켜서 셀의 지연이나 손실을 감소 시키고 셀 발생의 감소가 예측되면 토큰 사용의 효율성을 위해 발생율을 감소시킨다. 즉, 트래픽의 도착 시점과 함께 증가하는 토큰의 수는 손실 확률 증가를 의미하게 되며 트래픽의 active time 때 토큰 발생이

많게하고 예상 손실율이 없을 때는 토큰 발생율을 낮추고 버퍼에 의존한 채 shaping을 통한 bursty traffic의 셀 간격 유지를 한다. NLB의 학습과 인식 기능은 BLB보다 상대적으로 적은 양의 토큰을 발생시키지만 손실율이 줄어들 수 있도록 진행되고 트래픽 QoS를 보장해줄 수 있다.




그림 10. Class 1의 토큰 발생
Fig. 10. Token generation of class 1.




그림 11. Class 2의 토큰 발생
Fig. 11. Token generation of class 2.




그림 12. Class 3의 토큰 발생
Fig. 12. Token generation of Class 3.

이러한 토큰을 가변화로 인해 호 수락 제어(CAC)와 협상된 토큰 발생율이 매우 작거나 network caller가 호 수락때 협상된 파라미터값을 만족 하지만 셀 발생이 항상 일정하지 않고 실 시간적으로 가변성을 가지며 발생하는 트래픽 표시자(Traffic Descriptor)의 값을 정확하게 알 수는 없을 것이다. 이처럼 예측할 수 없는 셀의 발생을 NLB는 신경망의 학습과 인식을 이용하여 셀

의 발생을 예측 할 수 있을 것이다. 따라서, 본 논문에서 제안하는 NLB는 셀 손실율 예측 기능에 필요한 학습 패턴 입력을 토큰 풀, 입력 버퍼와 과거 손실율에서 받아들이기 때문에 실제의 video 신호나 non-stationary 트래픽이 입력되더라도 망의 상황에 잘 적용할 수 있고 network 자원과 QoS의 조건에 만족할 수 있는 토큰을 적용이 가능함을 보인다.

표 3은 성능 테스트 결과로서 셀 손실율과 버퍼에서의 셀의 지연이 향상됨을 볼 수 있으며, 발생된 토큰의 수가 class 2와 3에서 적음을 알 수 있다.

표 3. Neural Leaky Bucket의 시뮬레이션 결과

Table 3. Simulation results of Neural Leaky Bucket.

| 셀손실율 | BLB | 0.2342 | 0.0753 | 0.1604 |
|---------|-----|-------------|----------|-------------|
| | NLB | 0.1314 | 0.0715 | 0.1320 |
| 버퍼지연 | BLB | 148.5(msec) | 48(msec) | 161.5(msec) |
| | NLB | 116.5(msec) | 46(msec) | 151.5(msec) |
| 총발생 토큰수 | BLB | 2222 | 4000 | 1818 |
| | NLB | 2354 | 3546 | 1659 |

반면 class 1에서는 많은 셀 손실이 예상되므로 토큰을 BLB보다 많이 발생시킴을 볼 수 있다. 이와같이 NLB 알고리즘은 BLB에 비해 트래픽 QoS를 더욱 보장해줄 수 있으며, 망 다중화기나 스위치에서의 트래픽 전송 효율과 이용률 향상에 기여할 수 있다.

V. 결론

본 논문에서는 ATM망에서 신경회로망의 예측 기능에 기반하여 트래픽 제어와 감시(Monitor) 기능의 사용자 파라미터 제어(UPC) 알고리즘을 제안하고 컴퓨터 모의 실험을 통해 성능을 평가하였다. 또한 트래픽의 통계적 다중화를 위한 Cell scheduling에서 지연 균등성을 만족시킬 수 있는 PJ Cell scheduling을 제안하였다.

그리고 모든 트래픽에 대해 고정된 형태의 제어를 하는 Buffered Leaky Bucket에 비해 균등성을 갖는 Cell Scheduler와 Neural Network을 이용한 Leaky Bucket은 버퍼의 효율성을 높이고 망의 서비스 품질(QoS)로 구별되는 셀 손실율과 버퍼 지연 성능이 향상됨을 알 수 있었다. 신경회로망을 이용한 Leaky Bucket

에서의 트래픽 손실을 예측은 다음 입력 트래픽에 대한 손실과 버퍼 지연을 줄일 수 있도록 제어의 효율성을 높일 수 있으며 이러한 트래픽 손실 예측은 UPC에만 국한되지 않고 호 수락 제어(Call Admission Control), 트래픽 셰이핑(Shaping), 우선 순위 제어(Priority Control), 링크 용량 제어(Link Capacity Control) 등에 이용될 수 있다는 장점이 있다. 이러한 지능적인 제어 방식은 고속화되고 다양화되는 통신망에서 응용될 수 있으며, QoS 성능향상 등에 기여할 수 있다.

참 고 문 헌

- [1] The ATM Forum, Technical committee, Traffic management specification version 4.0, April 1996.
- [2] Hiramatsu, A, "Integration of ATM Call Admission Control and Link Capacity Control by Neural Networks," *IEEE J. Sel. Areas in Comm.* pp. 1131-1138, Sep. 1991.
- [3] X. Wu, I. Ambadaris, H. Lee and A. R. Kaye, "A Comparative Study of Some Leaky Bucket Network Access Schemes", *IEEE SUPERCOR ICC*, pp. 1586-1591, May 1994.
- [4] Ahmed A. Tarraf, Ibrahim W. Habib, Tareck N. Saadawi, "A Novel Neural Network Traffic Enforcement Mechanism for ATM Networks", *IEEE SUPERCOR ICC*, pp. 779-783, 1994.
- [5] Naoaki Yamanaka, Youichi Sato, and Ken-Ichi Sato "Performance Limitation of the Leaky Bucket Algorithm for ATM Networks." *IEEE Transactions on Communications*, V.43 N.8, pp. 2298-2300, 1995.
- [6] V. Catania, G. Ficili, S. Palazzo, D. Panno, "A Fuzzy Expert System For Usage Parameter Control In ATM Networks" *Proc, Globecom' 95*, pp. 1338-1342, 1995.
- [7] 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.
- [8] 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, pp. 1959-1963, 1996.
- [9] Chiung-Shien Wu, Gin-Kou Ma, and Bao-Shuh P.Lin, "A Cell Scheduling for VBR Traffic in an ATM Multiplexer" *Proc. Globecom'95*, Vol. 1, pp. 632-637, Nov 1995.
- [10] J. Y. Pyun, Y. J. Lee, Y. C. Kim, "An Adaptive UPC Algorithm Using a Neural Network Prediction in ATM Networks", *Proc IEEE ISPACS'98*, Vol 2, pp. 913-917, Nov. 1998.

저 자 소 개



邊 宰 璽(學生會員)

1997년 2월 조선대학교 전자 공학과 졸업(공학사). 1999년 2월 전남대학교 대학원 전자공학과 졸업(공학 석사). 1999년 3월 ~ 현재 고려대학교 대학원 전자공학과 박사과정. 주 관심분야는 ATM 트래픽 제어, 네


트워크 통신



金 永 哲(正會員)

1959년 1월 2일생. 1981년 2월 한양대학교 전자공학과 졸업(공학사). 1987년 5월 Univ. of Detroit, Electrical Eng.(공학 석사). 1993년 5월 Michigan State U. Electrical Eng.(공학 박사). 1993

년 8월 ~ 현재 전남대학교 전자공학과 조교수. 주 관심 분야는 ATM트래픽 제어, 신경망 구현 및 응용, VLSI/ASIC



徐 鉉 承(學生會員)

1972년 6월 26일생. 1998년 2월 조선대학교 전자공학과 졸업(공학사). 1998년 8월 ~ 현재 전남대학교 대학원 전자공학과 석사과정. 주 관심 분야는 ATM 트래픽 제어, 네트워크 통신, IP over ATM