

ATM 망에서 트래픽 다중화 정보에 의한 적응적 UPC 알고리즘에 관한 연구

김 영 철[†] · 변 재 영^{††} · 서 현 승^{†††}

요 약

본 논문에서는 ATM 망에서 폭주 발생에 의한 망 성능 저하을 막고 폭주 현상에 효과적으로 대처할 수 있는 새로운 신경망 Buffered Leaky Bucket 알고리즘을 제안하였으며 제안된 알고리즘의 정당성을 검증하기 위하여 서로 다른 서비스 품질(QoS)을 요구하는 트래픽 환경하에서 셀 손실율과 버퍼 지연을 테스트하고 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 신경망을 이용한 Leaky Bucket에서 예측된 트래픽 손실율을 제어하고 손실율 정도에 따라 토큰 발생율이 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 신경망 학습과 예측 테스트를 위한 시뮬레이션 결과를 통해 다양한 트래픽의 QoS가 향상되었음을 알 수 있었다.

A Study on an Adaptive UPC Algorithm Based on Traffic Multiplexing Information in ATM Networks

Young-Chul Kim[†] · Jae-Young Pyun^{††} · Hyun-Seung Seo^{†††}

ABSTRACT

In this paper, we propose a new neural Buffered Leaky Bucket algorithm for preventing the degradation of network performance caused by congestion and dealing with the traffic congestion in ATM networks. We justify the validity of the suggested method through performance comparison in aspects of cell loss rate and mean transfer delay under a variety of traffic conditions requiring the different QoS(Quality of Service). Also, the cell scheduling algorithms such as DWRR and DWEDF used for multiplexing the incoming traffics are induced to get the delay time of the traffics fairly. The network congestion information from cell scheduler is used to control the predicted traffic loss rate of Neural Leaky Bucket, and token generation rate is changed by the predicted values. The prediction of traffic loss rate by neural networks can effectively reduce the cell loss rate and the cell transfer delay of next incoming cells and be applied to other traffic control systems. Computer simulation results performed for traffic prediction show that QoSs of the various kinds of traffics are increased.

* 본 연구는 1998년 정보통신분야 우수대학원 지원사업의 연구비 지원에 의한 것임.

† 정 회 원 : 전남대학교 전자공학과 교수

†† 준 회 원 : 고려대학교 대학원 전자공학과

††† 준 회 원 : 전남대학교 대학원 전자공학과

논문접수 : 1999년 2월 5일, 심사완료 : 1999년 8월 12일

1. 서 론

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 저능화가 필수적으로 이루어져야 한다. 더욱이 ITU-T에서 B-ISDN의 전송 방식으로 ATM이 표준화되고 인공 지능 응용 분야에 대한 개발 연구가 활발히 진행되면서 신경회로망(Neural Network)을 이용한 지능제어의 가능성을 보여주고 있다[2, 4, 6, 7, 10]. 신경망의 최적화와 예측 기능은 수시로 변하는 환경에서 적용이 가능하므로 ATM과 같이 상이한 트래픽 특성을 수용하며, 셀 손실율, 전송 지연, 에러율에 대한 다양한 Quality of Service (QoS)를 요구하는 제어 시스템에서 유용하게 이용될 수 있다.

실제 ATM망에서는 트래픽 전송 효율화를 위해 사용되는 통계적인 다중화(statistical multiplexing) 방식과 버스터(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 Leaky Bucket (LB), Jumping Window (JW), Triggered Jumping Window (TJW), Moving Window (MW) 그리고 Exponentially Weighted Moving Window Average (EWMA), Virtual scheduling 등이 있다[3, 5].

UPC 기법 중 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 지역 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 각 소스별 트래픽 손실율 예측기를 통해 버퍼 사용으로 인한 셀 지연과 손실율을 감소시키는 적응적인

트래픽 제어를 할 수 있도록 하였다. 트래픽 예측기로 신경망을 이용한 새로운 형태의 BLB를 제안하며, 본 논문에서 이를 Neural Leaky Bucket (NLB)라 칭한다. 신경망의 on-line 학습과 예측기능으로 다양한 트래픽 패턴에 적용할 수 있으며, 과거의 트래픽에 기반 하여 앞으로의 트래픽 손실량을 예측하는 NLB의 트래픽 QoS를 평가하기 위해 버퍼 threshold를 이용하여 토큰 가변화를 할 수 있는 BLB를 함께 테스트하고 IV장에서 성능을 비교하였다.

신경망을 사용한 다른 policing 기법으로는 신경망의 도착 셀 수에 대한 count process를 사용하여 도착 트래픽의 확률 밀도 함수를 예측한다[4]. 2개의 신경망 N.N1과 N.N2를 이용하여 off-line 학습과 on-line 학습을 기반으로 하고 있는 이 알고리즘에서는 policing을 위해 각 VC/VP에 2개의 신경망이 필요하며, 도착 트래픽의 count process만의 정보를 학습하고 있다. 그러나 학습된 정보에 의한 다음 도착 트래픽의 확률 밀도 함수 예측은 off-line 학습시 얻은 학습 데이터에 지나치게 의존하고 있기 때문에 non-stationary 트래픽에 대한 확률 밀도 함수의 예측은 어렵게 되는 단점이 있다. 반면 제안하는 알고리즘은 하드웨어적인 부담감을 줄일 수 있도록 각 VC/VP에 1개의 신경망을 사용하며, non-stationary 트래픽에도 적용이 가능하도록 학습 방법과 학습 패턴들을 달리하고 있다.

본 논문에서는 NLB를 통과하고 망으로 진입하는 각 Virtual Channel Connection (VCC)의 트래픽 다중화를 위해 셀 스케줄링에 의해 서비스될 수 있도록 Dynamic Weighted Round Robin (DWRR)과 Dynamic Weighted Earliest Deadline First (DWEDF) 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 발생하게 한다. 공평성을 만족하지 못하고 있는 이러한 DWRR과 DWEDF 알고리즘에서 지연 시간의 deadline을 이용하여 우선 순위를 재설정할 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. 2장에서는 BLB,

NLB, 그리고 트래픽 모델 및 특징을 설명하고, 3장에서는 다중화기로 사용되는 PJ scheduling에 대해서 살펴본다. 4장에서는 시뮬레이션 결과와 고찰을 그리고 마지막으로 5장에서는 결론을 내린다.

2. Neural Leaky Bucket

2.1 Buffered Leaky Bucket

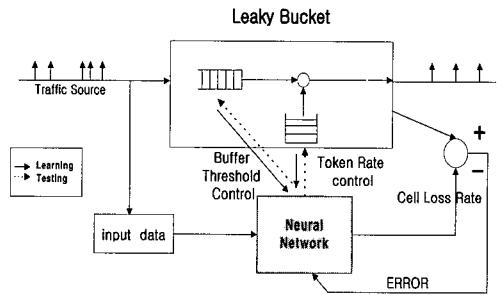
가장 일반적인 형태인 BLB 알고리즘은 트래픽의 입력 용량을 조절하기 위해서 토큰 폴(token pool)로부터 발생되는 토큰의 수와 입력 버퍼의 크기로 결정된다. 입력 버퍼 단에 도착하는 셀은 토큰 폴에 토큰이 존재하면 즉시 BLB로부터 출발하여 망으로 진입하게 된다. 이때의 토큰 발생률은 연결 수락 제어(CAC : Call Admission Control) 시 협상된 파라미터에 따라 결정되어 발생된 토큰은 토큰 폴에 저장된다. 그러나 토큰 폴은 유한 크기를 가지므로, 토큰 수가 토큰 폴의 크기를 초과하면 토큰 생성은 중단된다[1, 3, 5]. 반면 call setup 과정에서 결정된 토큰 발생율에 의한 트래픽 입력을 제어는 입력 트래픽과 가변적인 환경을 갖는 망 상황을 고려하지 않는 제어를 하게 되며, 이는 버퍼의 이용 효율성이 낮다는 문제점이 있다.

2.2 Neural Leaky Bucket

ATM망의 트래픽은 가입자가 선언한 트래픽 기술 인자(traffic description)에 대한 신뢰성이 낮고 불확실성(uncertainty)을 내포하고 있다. 이러한 문제점 개선을 위해 본 논문에서는 패턴 인식과 예측 기능이 있는 신경망을 이용하여 트래픽 손실을 예측하였다. 다양한 트래픽 도착 분포(arrival distribution) 형태는 수학적인 해석이나 트래픽 관찰만으로는 예측이 어려우나 신경망을 이용한 트래픽 손실을 예측은 버퍼 단에서의 overflow에 의하여 발생되는 현재 셀 손실, 버퍼에서의 queuing cell의 위치, 그리고 토큰 폴에 남아있는 토큰 수를 측정하고 학습시킴으로써 다음 트래픽 손실율을 예측이 가능하게 된다. 이렇게 예측된 트래픽 손실율은 (그림 1)과 같이 자원 이용률과 QoS 향상을 위해 제어 파라미터인 토큰 발생률을 제어한다.

이러한 트래픽의 피드백 제어는 망 폭주 상황 정보를 Operation, Administration and Maintenance (OAM) 셀이나 시그널링에 의해 전파되어 UPC에서 트래픽 전송량을 조절하도록 지원되어야 한다. 본 논문의 예측

기로 사용된 신경 회로망은 하나의 은닉층(hidden layer)을 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.



(그림 1) Neural Leaky Bucket의 모델

2.2.1 Learning Process

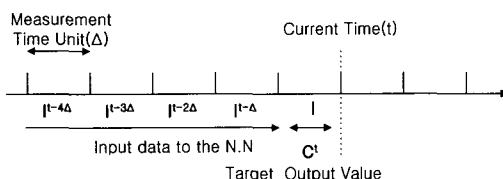
신경 회로망 입력 벡터로서 현재 시간(t)에서의 최근 패턴 추출 구간(Δ)을 제외한 4개의 과거 샘플 구간($t-\Delta, t-2\Delta, t-3\Delta, t-4\Delta$)에서의 도착 셀 수와 ($t-\Delta$) 번째 구간에서의 버퍼와 토큰 상태, 그리고 셀 손실율을 (그림 2)와 같이 학습한다. 신경망의 출력과 목적 패턴의 차이값이 임의의 한계 값이 되도록 학습은 반복되며 실시간 학습을 위해 각 샘플 구간에서 한정적인 학습 iteration을 갖도록 하였다.

NLB에서 사용되는 신경망의 학습 과정은 off-line 학습과정에서 구한 고정된 학습 데이터와 계속 생신되는 on-line 학습 데이터를 함께 이용하고 있다.

Off-line 학습은 입력 트래픽의 예측 손실 정보를 얻기 힘든 무 손실의 CAC 협약 준수 트래픽의 손실 예측을 위해서 필요하며, 학습 데이터 추출은 off-line 학습 환경에서 셀 손실이 발생할 수 있도록 발생된 트래픽을 통해서 이루어지며, 학습 패턴 테이블의 임의 영역에 저장된다. 단, off-line 학습 정보는 on-line 시 일어지는 새로운 학습 패턴에 의해 생신되지 않도록 하며, off-line으로 수집되는 학습 패턴들은 BLB에서 발생할 수 있는 모든 셀 손실 상황을 포함하도록 구성되도록 한다. 이는 망으로 트래픽이 처음으로 입력되는 초기 상태에서부터 off-line 학습에서 구한 학습 패턴에 기반 하여 신경망이 on-line 학습 및 테스트 동작을 할 수 있도록 하기 위함이다. 그리고 on-line 학습과

함께 점차적으로 망으로 유입되는 트래픽이 증가할 수록 새로운 학습 패턴을 패턴 테이블에 저장하며, 실시간 학습을 진행하게된다. 학습 패턴 테이블 크기의 한계 때문에 패턴 테이블이 일정크기 이상이 되었을 때는 가장 오래된 on-line 학습 패턴을 새로운 패턴으로 갱신한다. 본 논문에서의 모의 실험은 패턴 테이블의 크기를 300개의 패턴을 저장할 수 있도록 하였다.

(그림 2)는 제안된 NLB의 신경망 학습 패턴 추출 구간을 나타내며, 현재 시간 t 를 기준으로 왼쪽은 과거 시점, 그리고 오른쪽은 미래 시점을 의미한다. 신경망 학습을 위한 입력 패턴은 $t-\Delta$ 에서 입력 베퍼 단의 셀 수와 토큰 풀의 토큰 수, 그리고 셀 손실율이며, 시간 t 에서의 셀 손실율을 목표 패턴으로 사용한다.



(그림 2) 제안된 신경망 학습 과정

① 신경망 입력패턴

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

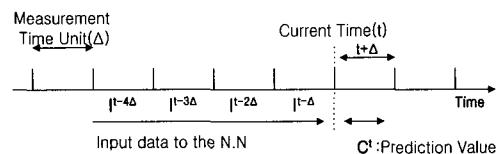
신경망 학습 패턴 추출을 위해서 패턴 추출 구간 (Δ) 간격마다 학습 패턴을 수집한다. 현재 시간 t 에서 수집된 학습 패턴은 다음 패턴 추출 구간($t+\Delta$)에서의 목표 패턴과 함께 쌍을 이루며 학습되어지며, 이전 패턴 추출 구간($t-\Delta$)에서 수집된 학습 패턴 정보가 바로 현재 t 에서의 목표 패턴과 쌍을 이루며 학습된다. 따라서 현재 시간 t 에서의 목표 패턴 C_t (셀 수)는 $t-\Delta$ 에서의 과거 학습 패턴 $[I^{t-\Delta}, \dots, I^{t-\Delta}, B^{t-\Delta}, T^{t-\Delta}, C^{t-\Delta}]^T$ 과 함께 학습 패턴 테이블에 저장되고 이미 저장되어 있는 모든 학습 패턴들과 함께 각 Δ 에서 on-line 학습된다. $H(t-\Delta)$ 는 학습을 위한 입·출력 패턴을 나타내고 있다.

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

③ 정규화 과정

학습 패턴은 큐의 셀 수, 토큰 수, 과거 트래픽 도착율, 그리고 과거 셀 손실율이다. 이때 BLB의 입력 베퍼 단에서의 셀 수와 토큰 수는 각각 패턴 추출 구간에서의 최대 도착 셀 수, 그리고 토큰 풀의 크기로 각각 나누어짐으로써 정규화 된다. 이러한 정규화는 본 논문에서 발생하는 트래픽 모델과 전혀 다른, 즉 입력 베퍼의 크기와 토큰 풀의 크기가 전혀 다른 트래픽 발생 환경에서도 같은 결과를 얻기 위해 실행되며, 이렇게 정규화된 학습 패턴들이 실제 학습 패턴 테이블에 저장되고 on-line 학습되어진다.

2.2.2 Prediction Process



(그림 3) 신경망 셀 손실율 예측 프로세스

(그림 3)에서 신경망은 on-line prediction 과정에 의해 $t+\Delta$ 에서의 셀 손실율을 예측한다. 랜덤 확률 분포의 트래픽은 컴퓨터 시뮬레이션을 통해 발생되어지며, 이때 발생된 트래픽 분포 형태에 따라 각 source에서의 트래픽 손실 예측은 달라지게 된다.

```

if (K≤CLR≤0.3)
    α =  $\frac{(0.2 \cdot CLR) + (0.7K - 0.27)}{K - 0.3}$ 
else if (CLR>0.3)
    α = 0.7
else
    α = 1.01
end
token 발생 간격=α*(st_token)

```

여기서

CLR : $t+\Delta$ 에서의 예상 셀 손실율.

α : 토큰을 변화를 위한 가중치.

st_token : 기준 토큰 발생 간격(st_token)으로 Call setup에서 설정된다.

CLR은 Δ 마다 발생할 수 있는 셀 손실을 예측 값으로 매 구간마다 달라지게 된다. 이렇게 예측된 손실을은 신경망의 성능에 따라 0에 가까운 매우 작은 값(10^{-9})까지 예측되기 때문에 임의의 작은 예측치를 손실이 발생하지 않는 0의 상태로 판단하여 NLB의 토큰을 가변 판단 기준(K)으로 정한다. 본 논문에서는 10^{-3} 을 K로 하여 모의 실험을 수행한다.

① 예측 셀 손실을 증가

$t+\Delta$ 의 예측 셀 손실을 증가시 가중치 α 를 예측 손실율에 근거하여 변화시킴으로 해서 토큰 발생 간격을 줄인다. 줄어든 토큰 발생 간격은 토큰 발생 횟수를 증가시키고 망으로 전입하는 셀 수를 증가시킨다. 단, 토큰 발생률의 최대치가 최대 셀율을 넘지 않는 범위내에서 유지한다.

본 논문에서의 α 는 예측 셀 손실율이 K에서 0.3으로 증가할 때 0.9에서 0.7로 선형적으로 변하도록 하였다. 그리고, 토큰 발생률이 최대 셀률을 넘지 않도록 하기 위해서 예측 셀 손실율이 0.3 이상이더라도 α 는 0.7을 유지하도록 하였다.

② 예측 셀 손실을 감소

예측 셀 손실율이 증가한 후 점차 감소하여 0에 가까울수록 토큰 발생은 줄어들며, K 미만의 예측 셀 손실율일 때 α 에 의해 토큰 발생 간격은 증가한다. 본 논문에서는 $\alpha=1.01$ 을 사용하였다.

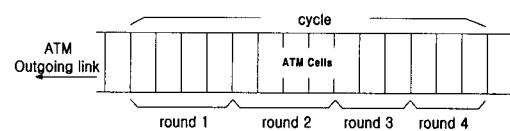
위와 같은 토큰 발생을 조절은 망 폭주 신호가 NLB에 도착하지 않는 경우에 해당되며 폭주 신호의 발생 시에는 계속적인 트래픽 진입을 억제시켜야 되므로 신경망에 의한 토큰을 가변은 하지 않고 정상적인 shaping 동작을 갖는 BLB 알고리즘에 의해 제어되도록 한다.(폭주 신호 전송 delay는 100 time slot으로 가정한다). 계속적인 망에서의 셀 손실이 발생하지 않으면 다시 신경망 트래픽 예측 기능을 가동시키고 트래픽 도착과 손실 상황에 따라 토큰 발생 주기를 가변화하여 트래픽이 전송될 수 있도록 한다.

3. PJ(Priority Jump) 스케줄링

ATM 망에서 다양한 특성을 갖는 트래픽들은 지연과 손실 민감에 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 Weighted Round Robin (WRR) 알고리즘을 개선한 DWRR과 DWEDF는 QoS 파라미터의 Peak Cell Rate (PCR)과 Mean Cell Rate (MCR)를 이용하여 가중치를 각 VCC에 부여함으로써 각 VCC들의 트래픽을 서비스한다. 가중치에 따른 scheduling 기법인 DWRR과 DWEDF에서는 각 round가 3개의 state 중 1개의 state를 갖게 된다. 또한 DWRR 알고리즘에서는 그림 4에서처럼 cycle과 round라는 단위를 정의하고 있다. cycle이란 ATM 출력에서의 time slot을 일정한 길이만큼 연결해 놓은 시간 단위를 말하며, 매 cycle의 첫 time slot에서 P와 M이 cycle 구간내 도착 가능한 각각의 최대 셀율과 평균 셀율로서 초기화된다.



(그림 4) DWRR의 사이클과 라운드

P와 M에 따라 서비스하는 DWRR과 DWEDF에서는 VBR과 CBR이 state 1에서 시작되어 state 2로 전이된 후 ABR 서비스를 지원하도록 하고 있다. 그리고 M과 P는 트래픽이 망으로 전송되기 전 VCC측에서 망과의 호수락 협상 과정을 위해서 CAC(Call Admission Control)에 의해 등록된 최대 셀율과 평균 셀율에 의한 것이다. 다음은 각 state에 대한 정의로서 state1부터 state3까지 존재한다.

state 1 [($P > 0, M > 0$), and 임시 버퍼에 셀이 있는 경우]

: 다음 round에서 source는 방문 받게 된다.

state 2 [($P > 0, M = 0$), and 임시 버퍼에 셀이 있는 경우]

: state 1 상태의 다른 source가 있는 한 state

2 상태의 source는 방문 받지 않는다.

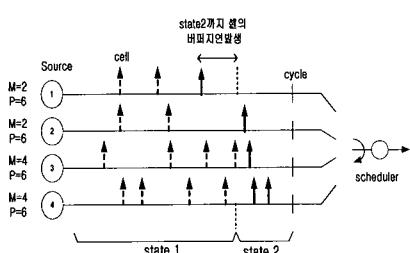
state 3 [$(P = 0, M = 0)$, or 도착한 셀이 없는 경우] :

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 도착하는 VBR 트래픽에 대하여 Invalid cell로 평가하고 tagging 기법을 이용하는 DWEDF_CLP와 트래픽을 폐기하는 DWEDF_BLOCK로 구분한다.

DWRR과 DWEDF에서는 state 1 상태의 VCC 연결이 없는 경우에 state 2 상태의 연결을 지원할 수 있도록 되어있다. 하지만 여러 개의 bursty 트래픽이 망으로 진입하고자 할 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 state 2 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 bursty 성의 차이가 많은 트래픽이 망으로 진입하는 경우에 더욱 커지게 된다.

불균등한 서비스의 예를 보이고 있는 (그림 5)에서 VCC 1과 2는 M=2이고 P=6이며, 다른 VCC 3과 4보다 M이 작기 때문에 스케줄러로부터 서비스를 받을 때 state 천이시 상대적인 불이등을 받을 수 있다. VCC 1은 M=2이므로 2개의 셀을 state 1에서 서비스 받을 수 있고 다음 셀이 도착하더라도 state 2에서 다른 VCC 2, 3, 4가 state 1의 서비스를 종결할 때까지 대기하게 된다.



(그림 5) DWRR과 DWEDF 셀 스케줄링

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 도착 셀의 지연정도에 따라 제어되는 PJ(Priority Jump)기능을 갖는 스케줄링을 고려할 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 VCC보다 먼저 서비스 받을 수 있는 권한을 부여하도록 하여 전체 도착 셀들의 지연 시간을 균일하도록 할 수 있다. (그림 5)의 예제의 경우 VCC 1이 state 1의 서비스가 끝나고 state 2의 서비스를 위해 대기하는 도중 지연이 PJ time을 초과하면 서비스가 가능하도록 하는 것이다.

- State 1에서는 Round-Robin 또는 EDF, 그리고 state 2에서는 EDF 기법을 사용하여 지연의 균등성(fairness)을 더 보장할 수 있다.

4. 시뮬레이션 및 성능 분석

4.1 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 변수값 초과시 입력되는 트래픽을 invalid cell로 평가하고 DWEDF_BLOCK에서처럼 Jumping Window에 의한 셀 폐기를 한다. 이는 실험의 간편성과 DWRR과 DWEDF의 차이점을 도시하기 위해서이다. 그리고 트래픽의 발생은 트래픽이 발생하는 ON 구간과 트래픽이 발생하지 않는 OFF구간으로 구분되는 Interrupted Poisson Process (IPP) 모델을 사용한다.

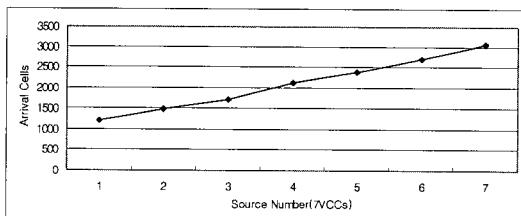
IPP 모델은 ON과 OFF 구간의 지수분포의 길이를 갖으며, ON 구간에서의 트래픽 발생은 Poisson 분포를 따르고 있다.

이러한 IPP 트래픽 모델을 갖는 7개의 트래픽 VCC를 <표 1>과 같이 서로 다른 트래픽 도착 량을 갖으며 서비스를 요구하도록 한다. 그리고 P를 일정하게 하기 위해 Peak rate를 동일하게 트래픽을 발생시켰으며, M을 가변화하여 M의 차이에 의한 스케줄링 시 받는 서비스 지연 문제를 가시화할 수 있도록 하였다.

〈표 1〉 Cell scheduling의 트래픽 조건

VCC Number	1	2	3	4	5	6	7
Peak rate (cells/sec)	400	400	400	400	400	400	400
Mean rate(cells/sec)	120	160	200	240	280	320	360
DWRR P	20	20	20	20	20	20	20
DWEDF M	6	8	10	12	14	16	18
Priority Jump(PJ)			20, 40 cell units				
사이클(Cycle)			100 cell time unit				
load			0.84				
링크 용량			2000 cells/sec				

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

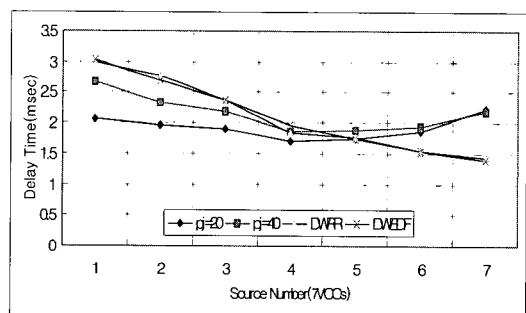


(그림 6) 각 VCC의 도착 트래픽

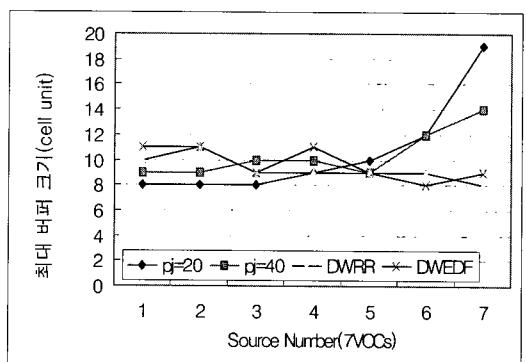
(그림 7)과 (그림 8)은 300,000 time slot unit동안의 simulation을 통해 얻은 결과로써 7개의 VCC가 서비스를 받기 위해 스케줄러에 도착하고 서비스를 기다리는 시간, 그리고 이때의 최대 큐 길이를 나타낸다. 제안된 PJ 스케줄링은 state 2로의 천이후 나머지 VCC들의 state 1 서비스 종결을 기다리는 VCC 트래픽중 PJ(Priority Jump) 시간인 20과 40 time slot unit을 초과한 셀들은 다른 VCC의 state1 서비스가 종결되지 않았더라도 서비스하도록 한다. 결과적으로 (그림 7)에서 보는바와 같이 트래픽 양이 낮은 VCC에서 DWRR과 DWEDF보다 더 낮은 셀 지연을 보이고 있다. 이는 각 망 이용자에게 균등한 서비스 제공에 관한 Fairness 문제에 있어서 제안한 알고리즘이 DWRR과 DWEDF보다 적절하며 동적으로 제어함을 의미한다. 반면 (그림 8)에서 제안하는 알고리즘에 의해 버퍼 크기량이 크게 나타난 VCC는 6, 7번으로 도착 트래픽 양이 많은 VCC이다. 즉, 도착 트래픽 양이 많은 VCC가 더 큰

버퍼 크기량을 요구하는 것으로 나타난다. 이것은 제안하는 알고리즘이 입력되는 모든 VCC에 대해서 유사한 지연을 갖도록 보장을 하기 때문에 VCC 6, 7 이상 대적으로 서비스를 적게 받게 되어 기존 방법보다 버퍼 크기 요구량이 커지게된다.

망 운영자 입장에서는 이러한 버퍼 크기 요구량이 증가할수록 불리하나, 기존 알고리즘에서처럼 망을 사용하고자하는 여러 사용자에게 동등한 지연을 보장하지 못하고 다른 이용자보다 많은 트래픽 전송을 하는 사용자가 더 작은 평균 버퍼 지연을 갖게 되면 unfairness 상태가 되며, 서비스 사용에 대한 Payment(과금)시에 형평성의 어려움을 갖게된다. 따라서 망 운영 측면에서 버퍼 크기가 다소 증가하더라도 균등성이 보장받도록 해야한다.



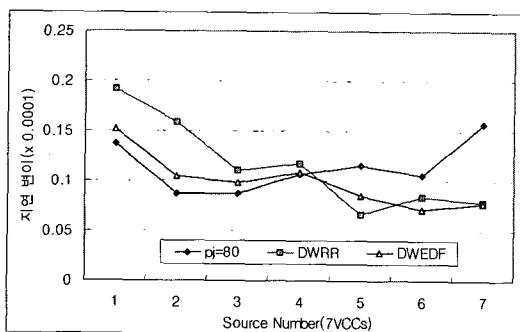
(그림 7) Cell Scheduling에서 버퍼 지연



(그림 8) Cell Scheduling에서의 최대 버퍼 크기

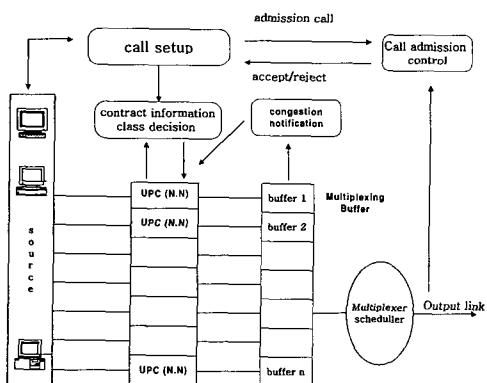
(그림 9)는 서비스를 받기 위해 버퍼 대기중인 셀들의 지연변이를 나타내고 있다. DWRR과 DWEDF에서의 지연변이는 유사한 기울기를 가지며, VCC7과 같이

트래픽 양이 많은 VCC에서 작게 나타남을 알 수 있다. 반면, PJ 스케줄링에서는 Jump 기능 사용으로 인해 트래픽 양이 많은 VCC에서 자연변이가 크게 나타남을 알 수 있다.



(그림 9) Cell Scheduling에서의 자연 변이

4.2 Neural Leaky Bucket 실험 및 성능



(그림 10) Neural Leaky Bucket의 실험 모델

본 논문에서 제안된 NLB의 실험을 위하여 IPP 모델로 트래픽을 발생시키고 NLB와 다중화기 스케줄러를 (그림 10)과 같이 하고 제안 알고리즘의 실험 모델로 설정하였다. 본 모의 실험은 WS Sparc-20 환경에서 MATLAB v5.1을 이용하였으며, trainbp() 함수를 사용하였다.

실험을 위해 Δ 은 각 케이스별로 200, 50, 50 time slot(case 1, 2, 3)으로 임의 설정하였으며, 이것은 트래픽 발생시 active time의 비례비와 시뮬레이션의 반복으로 결정한 것이다.

<표 2> 트래픽 파라미터

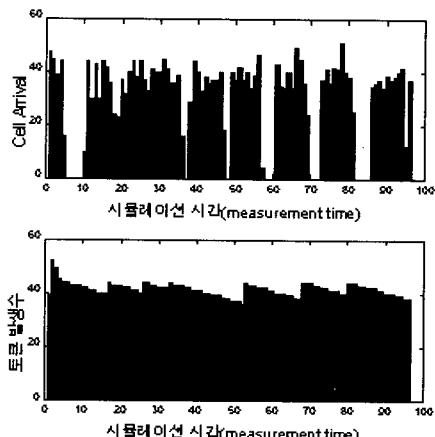
Case	Case 1	Case 2	Case 3
Modelling	VBR(IPP)	VBR(IPP)	VBR(IPP)
peak_rate	500cells/s	500cells/s	700cells/s
active_time	0.65sec	0.15sec	0.12sec
idle_time	0.35sec	0.15sec	0.18sec
st_token	5	6	5
입력버퍼(B) 토큰풀(M)	15, 10	15, 10	15, 10
링크 용량	2000cells/sec		

성능 비교와 실험 방법의 공정성을 위해서 BLB도 NLB와 같이 threshold를 갖는 상태에서 토큰을 가변 비교 실험을 하였다. NLB는 예측 손실율이 발생하는 시점에서부터 토큰 발생간격 주기가 줄어들도록 하여 토큰 발생이 증가하도록 하고, BLB는 입력 버퍼의 큐 크기가 80% 또는 90% 이상이 되는 시점에서부터 토큰 발생 간격 주기가 줄어들도록 한다. 큐 크기가 80% 또는 90% 이상이면 입력되는 VBR 트래픽 특징에 따라 셀 손실 가능성을 내포하고 있으므로 트래픽 흐름 제어가 시작되도록 한다. 이러한 threshold를 갖는 BLB의 두 가지 경우 (80%, 90%)에 대해 NLB와 함께 비교되어진다.

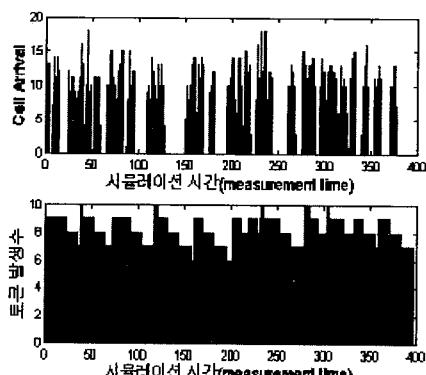
토큰 발생 간격은 손실 예상 시점에서 BLB, NLB 모두 90% ($\alpha=0.9$)로 감소하며, NLB의 경우는 0.3 이상의 손실율을 예측할 때, BLB의 경우는 손실이 시작되는 큐 크기가 100%일 때 토큰 발생 간격이 70% ($\alpha=0.7$)까지 감소하도록 하였다. 그리고 NLB에서 예측 셀 손실율이 30% 이상이더라도 토큰 발생 간격은 70%까지 감소하도록 하였다. 이러한 Threshold를 갖는 BLB도 NLB와 같은 다중화기 정보를 갖으며, 망 폭주 신호 도착시 NLB와 같이 토큰 을 가변을 통해 망으로 보내는 셀 수를 늘릴 수 있도록 하였다. 이 실험에서 사용된 threshold를 갖는 BLB는 단순히 본 논문에서 공정한 실험 비교를 위해 사용한 것이며, threshold의 크기와 토큰 을 가변 정도의 범위는 NLB와 동일하게 결정된다.

BLB와 NLB의 시뮬레이션은 모두 같은 시점에서부터 토큰을 가변을 시작하며, 20000 time slot동안의 시뮬레이션 결과 (그림 11, 12, 13)처럼 각 경우의 트래픽 도착 특징과 예측 손실율에 따라 토큰율이 가변됨을 볼 수 있다($K=0.001$). (그림 11, 12, 13)에서의 measurement time은 Δ 에 해당하는 것으로 시뮬레이션 시

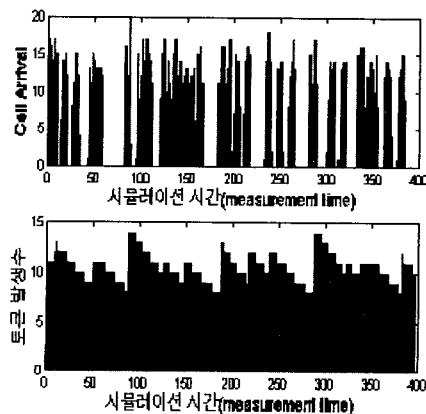
간동안의 모든 패턴 추출 구간별로 발생되어진 토큰 발생율을 나타낸다.



(그림 11) Case 1의 토큰 발생



(그림 12) Case 2의 토큰 발생



(그림 13) Case 3의 토큰 발생

제안된 알고리즘에서 트래픽의 도착 시점과 함께 증가하는 토큰의 수는 손실 확률 증가를 의미하게되며 트래픽의 active time 때 토큰 발생이 많게하고 예상 손실율이 없을 때는 토큰 발생율을 낮추고 버퍼에 의존한 체 shaping을 통한 bursty traffic의 셀 간격 유지를 한다.

<표 3> NLB와 BLB(80% case)의 비교

	case 1	case 2	case 3
셀 손실율	BLB	0.0035	0.0074
	NLB	0.0003	0.0074
버퍼지연	BLB	17.3(msec)	19.5(msec)
	NLB	10.8(msec)	17.9(msec)
총 발생 토큰수	BLB	4177	3459
	NLB	4067	3163

<표 4> NLB와 BLB(90% case)의 비교

	case 1	case 2	case 3
셀 손실율	BLB	0.0078	0.0095
	NLB	0.0003	0.0014
버퍼지연	BLB	20(msec)	19.6(msec)
	NLB	12.1(msec)	16.8(msec)
총 발생 토큰수	BLB	4315	3454
	NLB	4029	3315

이러한 토큰을 가변화로 인해 호 수락 제어(CAC)와 협상된 토큰 발생율이 매우 작거나 network caller가 트래픽 표시자(Traffic Descriptor)의 값을 정확하게 알지 못하더라도 NLB는 잘 적용할 수 있음을 뜻하며, network 자원과 QoS의 조건에 기반한 적응적인 토큰을 적용이 가능함을 보인다.

<표 3>과 <표 4>는 NLB와 threshold가 80% 또는 90%인 두가지 BLB의 경우를 각각 실험하고 성능 비교한 결과로서 셀 손실율과 버퍼 지연면에서 향상됨을 볼 수 있으며, 발생된 토큰의 수가 case 1, 2와 3에서 모두 작은 것을 알 수 있다. 따라서 NLB 알고리즘은 BLB에 비해 트래픽 QoS를 더욱 보장해줄 수 있으며, 망 다중화기나 스위치에서의 트래픽 전송 효율과 이용률 향상에 기여할 수 있음을 의미한다.

제안된 NLB 알고리즘은 도착 트래픽의 확률밀도 함수가 아니라 학습 목표 패턴인 셀 손실율을 실시간적으로 학습하고 있다. 그리고 신경망의 학습 패턴 입력으로 사용하는 $I^{t-\Delta}, \dots, I^{t-\Delta}$ 는 각 패턴 추출 구간에서 입력 버퍼에 도착한 셀 수를 의미하는 count process이며, $B^{t-\Delta}, T^{t-\Delta}, C^{t-\Delta}$ 는 $t-\Delta$ 에서의 셀 손실의 유발 정

보를 나타낸다. 따라서 모델링 트래픽이 아닌 video 트래픽과 같은 non-stationary 트래픽이 입력되는 경우 일지라도 제안하는 NLB는 $[B^{t-d}, T^{t-d}, C^{t-d}]^T$ 를 통해 셀 손실율을 예측할 수 있다. 이는 신경망의 셀 손실율 예측 기능에 필요한 학습 패턴 입력의 많은 부분을 토론 풀과 입력 버퍼, 그리고 과거 손실율에서 받아들이기 때문에 실제 video 트래픽에 대하여도 적용이 가능하며, 실제 non-stationary 트래픽에 대한 NLB 성능 실험은 차후 연구 과제로 남아있다.

5. 결 론

본 논문에서는 ATM망에서 신경망의 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 자연 균등성을 만족시킬 수 있는 PJ Cell scheduling을 제안하였다.

그리고 모든 트래픽에 대해 고정된 형태의 제어를 하는 BLB에 비해 균등성을 갖는 Cell Scheduler와 Neural Network을 이용한 Leaky Bucket은 버퍼의 효율성을 높이고 망의 QoS로 구별되는 셀 손실율과 버퍼 자연성능이 향상됨을 알 수 있었다.

NLB의 시스템 적용을 위해서 각 VC/VP에서는 추가적인 장치로 신경망 하드웨어가 필요하며, 이러한 실시간 학습을 위한 신경망은 하드웨어의 추가적인 부담감을 주고 있다. 그러나, 신경망을 이용한 트래픽 제어 기법은 on-line 학습을 위한 전용 coprocessor와 같은 고속 Hardware Device로 인해 ATM망에서의 고속 서비스를 그대로 유지할 수 있을 수 있으며, 본 논문에서 제안하고 있는 신경망의 셀 손실율 예측과 같은 알고리즘을 이용하여 CAC에서의 호 수락 결정이나 LCC(Link Capacity Control)에서 망의 link 용량 예측식에 이용될 수 있는 상호 연동의 장점이 있다.

참 고 문 현

- [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 SUPERCOM 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 SUPERCOMM 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*, Vol.43 No.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*, Vol.29 No.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.

김 영 철

e-mail : yckim@chonnam.chonnam.ac.kr
1981년 2월 한양대학교 전자공학과
졸업(학사)

1987년 5월 Univ. of Detroit, Elec-
trical Eng.(공학석사)

1993년 5월 Michigan State U.
Electrical Eng.(공학박사)

1993. 8~현재 전남대학교 전자공학과 부교수

관심분야 : ATM트래픽 제어, 신경망 구현 및 응용,
VLSI/ ASIC



서 현 승

e-mail : hsseo@neuron.chonnam.ac.kr
1998년 2월 조선대학교 전자공학
과 졸업(학사)

1998년 8월~현재 전남대학교 대
학원 전자공학과 석사과정
관심분야 : ATM 트래픽 제어, 네
트워크 통신, IP over ATM

변재영

e-mail : jypyun@dali.korea.ac.kr
1997년 2월 조선대학교 전자공학과
졸업(학사)

1999년 2월 전남대학교 대학원 전
자공학과(공학석사)

1999.3~현재 고려대학교 대학원
전자공학과 박사과정

관심분야 : ATM 트래픽 제어, 네트워크 통신

