

# 신경회로망을 이용한 ATM 연결 수락 제어를 위한 효율적인 학습패턴 처리 기법

권 오 준<sup>†</sup>·전 형 구<sup>††</sup>·권 순 각<sup>†</sup>·김 태석<sup>†</sup>·이 정 배<sup>†††</sup>

## 요 약

기존의 VOB(Virtual Output Buffer) 모델에서 신경회로망의 학습 패턴 처리를 위해 가상 셀 손실율이 도입되었다. VOB 모델은 신경망이 실제 셀 손실율 없이도 연결 수락 경계를 잘 찾을 수 있음을 보여주었다. 그러나 VOB 모델은 셀 손실율을 과다 평가하는 경향이 있어 결과적으로 망 자체의 이용률이 낮은 단점이 있다. 본 논문에서는 이러한 단점을 보완하는 방법으로 연결 수락 경계에서 셀 손실율의 평균에 대한 정보를 충분히 포함하는 셀 손실율 참조 곡선의 개념을 제안하였다. 그리고 제안된 셀 손실율 참조 곡선을 이용하여 가상 셀 손실율을 처리하는 방법을 제안하였다. 제안된 학습 패턴 처리 방법은 ATM 트래픽 중에 가장 대표적인 두 가지 호원에 대하여 실험하였다. 실험에 사용된 호원은 LAN 데이터의 트래픽 특성을 가지는 On-Off 트래픽과 비디오 화상 통신의 특성을 가지는 Auto-Regressive 트래픽이다.

## An Effective Training Pattern Processing Method for ATM Connection Admission Control Using the Neural Network

Oh-Jun Kwon<sup>†</sup>·Hyoung-Goo Jeon<sup>††</sup>·Soon-kak Kwon<sup>†</sup>·Tai-suk Kim<sup>†</sup>·Jeong-Bae Lee<sup>†††</sup>

## ABSTRACT

The virtual cell loss rate was introduced for the training pattern of the neural network in the VOB(Virtual Output Buffer) model. The VOB model shows that the neural network can find the connection admission boundary without the real cell loss rate. But the VOB model tends to overestimate the cell loss rate, so the utilization of network is low. In this paper, we use the reference curve of the cell loss rate, which contains the information about the cell loss rate at the connection admission boundary. We process the patterns of the virtual cell loss rate using the reference curve. We performed the simulation with two major ATM traffic classes. One is On-Off traffic class that has the traffic characteristic of LAN data and the other is Auto-Regressive traffic class that has the traffic characteristic of a video image communication.

키워드 : 신경회로망(Neural Network), 학습패턴(Training Pattern), ATM 연결 수락 제어(ATM Call Admission Control)

## 1. 서 론

비동기식 전송 모드(ATM : Asynchronous Transfer Mode)는 광대역 종합 통신망(B-ISDN)의 핵심 기술로써 다양한 특성과 서비스 품질(QoS : Quality of Service)을 지니는 트래픽을 통계적 다중화(Statistical Multiplexing)를 통하여 유연하게 수용할 수 있는 장점을 지니고 있다. ATM에서의 통계적 다중화는 여러 사용자가 동시에 생성한 셀을 효율적으로 처리함으로써 망자원의 효율적 운용을 가능케 하지만, 동시에 많은 셀이 생성되는 경우 셀을 제대로 처리하지 못하고 과도한 셀손실(cell loss)과 셀지연(cell delay) 현상이 발생하게 된다.

연결 수락 제어(CAC : Call Admission Control)는 새로

원 호원의 접속을 허락/거부하는 비교적 단순한 기능을 수행하지만 여러 트래픽 제어 중에서 어려운 분야의 하나로서 인식되고 있다. 각 호원마다 상이한 트래픽 특성을 지니고 있으며 요구하는 QoS도 다르기 때문에 이를 모두를 만족시키기는 연결 수락 제어기를 구성하기가 쉽지 않기 때문이다. 연결 수락 제어는 통신망의 자원을 충분히 이용하는 범위내에서 최대한 많은 호원을 받아들여야 하므로 QoS 보장이라는 측면과 상충된다. 특히 이질 호원이 존재하는 상황에서는 호원들의 간섭 현상에 의해서 셀 손실이 많이 발생하게 되는데, 특정 호원의 버스蒂한 성질에 의해서 다른 호원의 QoS까지 보장하지 못하게 된다. 이때 간섭이 발생하는 시점은 물론 간섭의 정도를 특정한 수식 모델로 유도하기가 어렵다. 즉 현재 통신망의 상태의 안정성 여부를 정확하게 판단할 수 있는 근거가 불확실하기 때문에 새로운 호원의 접속 여부를 판단한다는 것은 상당히 어

† 정 회 원 : 동의대학교 컴퓨터·영상공학부 교수

†† 정 회 원 : 동의대학교 정보통신학과 교수

††† 총신회원 : 선문대학교 컴퓨터정보학부 부교수

논문접수 : 2001년 3월 15일, 심사완료 : 2001년 11월 8일

려운 문제이다. 일반적으로 연결 수락 제어 모델에서 사용자가 요구하는 QoS 중에서 가장 중요한 것은 셀손실과 셀지연이며, 대부분 셀손실에 중점을 두고 모델을 제안하고 있다.

지금까지 해석적 분석 방법에 기반한 많은 연결 수락 제어 모델이 제안되었다[1-5]. 이들 모델에서는 최대비트율, 평균비트율, 평균 버스티 구간등 호원의 트래픽 특성을 나타내는 여러 가지 파라미터들을 사용하여 새로운 호원의 접속을 결정하는 수식을 결정한다. 그러나 이러한 수식들은 막대한 계산량을 요구하며 방법 자체가 소프트웨어적으로 구현할 수 밖에 없으므로 연산 장치의 고속성이 요구된다. 또한 특정 호원의 특성에 국한된 모델을 구성함으로써 새로운 특성을 지니는 호원의 출현에 대한 대처 능력이 떨어진다. 이러한 문제점으로 해결하기 위하여 최근에는 신경망을 이용한 연결 수락 제어 모델에 관한 연구가 많이 이루어지고 있다[6-8]. 신경망은 현재의 망 상태를 아무런 근사화 과정없이 학습함으로써 해석 모델의 단점을 보완해 줄 수 있는 좋은 수단이 될 수 있다. 특히 Hiramatsu의 VOB (Virtual Output Buffer)모델[7]은 가상 셀 손실율(virtual cell loss rate)을 신경망의 새로운 학습 패턴으로 채택함으로써 기존의 신경망 모델과 구별되는 특징을 가지고 있다. 그러나 VOB 모델은 망 자원의 최대 이용이라는 측면에서 약점을 가지고 있다. 본 논문에서는 VOB 모델에 기반한 신경망 제어기의 성능 향상을 위하여 셀 손실을 참조 곡선이라는 개념을 도입하고, 이를 이용한 가상 셀 손실을 정보의 처리 기법을 제안한다. 제안하는 처리 기법은 LAN 호원과 화상 전화 호원이 존재하는 ATM 환경하에서 시뮬레이션을 수행하였다.

## 2. 호원 모델링

ATM망에는 저속 및 고속 LAN 데이터의 특성을 지니는 호원은 물론 음성, 화상 데이터등의 멀티미디어 데이터의 특

성을 지니는 호원들도 존재한다. 기존의 논문들이 연결 수락 제어 모델의 성능을 검증하기 위하여 ON-OFF 특성을 지니는 LAN 데이터만을 주로 고려한 반면, [8]에서는 LAN 호원은 물론 화상 회의, 화상 전화등의 데이터를 표현하는 화상 전화 호원까지 사용함으로써 신경망 모델의 신뢰성을 높이려고 하였다. 본 논문에서는 [8]에서와 같이 LAN 호원과 화상 전화 호원을 모두 고려하였다. 사용된 호원의 트래픽 특성을 정리하면 <표 1>과 같다.

## 3. 신경망에 기반한 ATM 연결 수락 제어 모델

### 3.1 신경망 모델의 특징

기존의 해석적 모델에서는 새로운 호에 대한 연결 수락 여부를 결정하는 함수(decision function)를 호원의 트래픽 특성, 다중화 기기에서의 동작 상황 등 시스템에 영향을 끼칠 수 있는 많은 파라미터를 가지고 인위적으로 생성하지만, 신경망 모델에서는 신경망이 ATM 다중화 기기의 동작을 끊임없이 모니터링하고 주어진 패턴을 바탕으로 학습함으로써 결정 함수를 자연적으로 형성해 나가게 된다. 그리고 이런 결정 함수의 정확도에 의해서 신경망이 형성하고 연결 수락 경계면(connection admission boundary)의 정확도가 결정된다. 신경망 모델에서 가장 중요한 이슈는 임의의 트래픽 특성을 지니는 이질 호원이 존재하는 ATM 망에서 최대한 빠른 시간안에 각각의 호원들이 요구하는 QoS를 만족시킬 수 있는 연결 수락 경계면을 형성하는 것이다. 따라서 신경망의 예측 능력을 극대화하기 위하여 어떤 정보를 신경망의 입출력으로 사용할 것인지, 학습 패턴을 어떻게 구하고, 이를 효율적으로 관리할 것인지를 종합적으로 고려하여야 한다.

신경망에 기반한 연결 수락 제어 모델의 일반적인 장점은 다음과 같다. 첫째, 신경망은 다중화 기기에서의 동작을 관측하여 근사화 과정없이 패턴 그 자체를 사용함으로써 자연스럽게 트래픽의 입력 정도에 따른 망 상태를 적응적으로 학

<표 1> 호원의 트래픽 모델링 파라미터

항 목	LAN 데이터	화상 전화 데이터
트래픽 모델링	ON-OFF ON 주기 : Exp(4746TS) OFF 주기 : Exp(42714TS) 셀 발생 주기 14TS	Auto-regressive $\lambda(n) = a\lambda(n-1) + bw(n)$ $w(n) = Nor(\eta, 1)$ $a=0.8781, b=0.1108$ $\eta=0.572$
평균비트율/호(출력 링크에 정규화된 값)	0.00731	0.0277
입력 트래픽 부하	0~100 erl 평균 부하(50 erl)	0~50 erl 평균 부하(25 erl)
입력 부하 변경		100초마다 변화
호 지속 시간		지수분포(평균 50초)
목표 셀 손실율	$10^{-3}$	$10^{-4}$

습할 수 있다. 둘째, 신경망은 구조가 간단하며 가중치(weight)값 개선의 절차 등에서 대규모 복잡성을 내포하고 있다. 또한 해석적 방법에 기반한 연결 수락 제어 모델들은 소프트웨어 모듈로 구성할 수밖에 없지만, 신경망에 기반한 연결 수락 제어 모델들은 뉴로칩(neuro-chip)을 이용한 하드웨어 구현이 용이하여 실시간 계산이 가능하다. 셋째, 신경망은 수집된 패턴을 바탕으로 연결 수락 경계면을 형성하는데, 신경망의 extrapolation 능력에 의하여 학습하지 않은 영역에 대해서도 어느정도 연결 수락 경계면을 형성할 수 있다. 즉 학습에 의한 일반화가 가능하다. 네째, 신경망 모델은 입력 호원의 트래픽 특성에 무관하게 모델이 구축되기 때문에, 새로운 호원이 출현하였을 때 모델의 재구성이 쉽다.

### 3.2 기존의 연결 수락 제어 모델 분석

신경망을 이용한 연결 수락 제어에 관한 연구는 Hiramatsu [6]에 의해 처음으로 시도되었으며, 그 후 다른 연구자들에 의해서 다양한 연결 수락 제어 모델이 제안되었다. 지금까지 제안된 많은 모델 중에서 특히 대표적인 모델로는 LPT(Leaky Bucket Table)모델[6], 비균등 패턴 테이블 영역 할당 모델[8], VOB(Virtual Output Buffer)모델[7] 등이 있다.

#### 3.2.1 LPT 모델과 비균등 패턴 테이블 영역 할당 모델

신경망은 ATM 다중화기기에서의 셀 손실을 정보를 주기적으로 수집하게 되고, 이를 학습 테이블에 저장한다. LPT 모델[6]에서 제안된 신경망 학습을 위한 패턴 관리 방법인 LPT 관리 방식은 출력 버퍼에서 수집된 셀 손실율을 목표 셀 손실율과 비교하여 두 개의 테이블(Good Table, Bad Table)에 각각 수용하는 방식이다. Bad 테이블의 사용은 온라인상에서 자주 발생하지 않는 높은 셀 손실율을 가지는 패턴(high-loss-rate pattern)을 효율적으로 관리하게 해준다. LPT 모델에서는 망 상태를 식 (1)과 같이 접속된 호원의 갯수  $\vec{n}$ 으로 표현하였으며, 신경망은 접속 여부를 판단하는 값  $d$ 를 직접 출력한다. 따라서 신경망은 식 (2)와 같은 관계식을 학습하게 된다.  $k$ 는 트래픽 특성이 서로 다른 호원 클래스의 갯수이다.

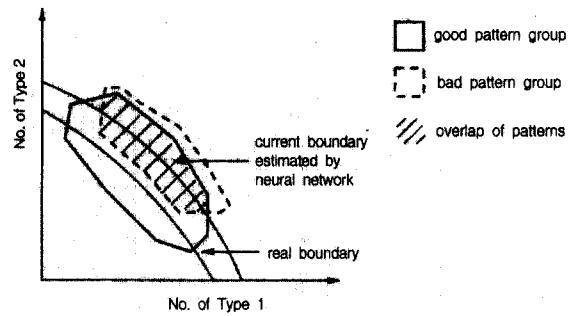
$$\vec{n} = (n_1, n_2, \dots, n_k) \quad (1)$$

$$d = f(\vec{n}) \quad (2)$$

접속을 요청하는 호원이 있을 때 신경망은 현재의 망 상태 변수를 입력으로 하여 0에서 1사이의 실수값을 출력하는데, 식 (3)을 이용하여 이 값이 0.5보다 작을 때만 접속을 허락한다.

$$R(t) = \begin{cases} \text{accept} & \text{if } d < 0.5 \\ \text{reject} & \text{if } d \geq 0.5 \end{cases} \quad (3)$$

일반적으로 신경망은 서로 다른 패턴들의 집합을 구별하도록 학습한다. 따라서 이를 패턴 집합의 경계면에 많은 학습 패턴이 존재할수록 신경망의 패턴 구별 능력은 증가하게 된다. 이런 신경망의 특성에 착안하여 비균등 패턴 테이블 영역 할당 모델[8]은 LPT 모델의 패턴 관리 방식을 개선하여 연결 수락 경계면에 가까운 패턴을 더 많이 확보하는 정책을 취하였다. 이 모델은 각 테이블을 세부 영역으로 나누어 연결 수락 경계면에 가까운 패턴을 위한 영역을 다른 영역보다 넓게 책정하고 중첩적으로 관리하였다. 비균등 패턴 테이블 영역 할당 모델은 LPT 모델에 비해 연결 수락 경계면을 찾는 시간을 약 60% 정도 단축시킬 수 있었다.



(그림 1) 2개의 이질 호원이 존재하는 ATM망에서 신경망 패턴의 분포와 연결 수락 경계면

위의 모델들은 신경망의 입력으로 현재 접속된 호원의 갯수 정보를 사용하였다. 그럼에도 불구하고 연결 수락 경계면을 충분히 파악할 수 있음을 보여 ATM 연결 수락 제어 분야에서 신경망의 적용 가능성을 보여주었다.

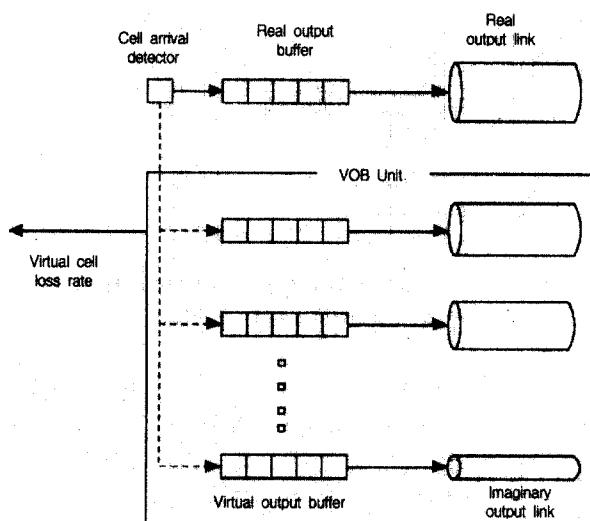
그러나 위의 모델들은 호원의 목표 셀 손실율을 직접 표현하지 못하는 문제점을 가지고 있다. 즉 동일한 접속 호원 수에 대해서 호원의 목표 셀 손실율을 만족시키는 패턴과 그렇지 못한 패턴이 존재함으로써 신경망의 올바른 결정을 방해하게 되는 것이다. 이런 문제는 (그림 1)과 같은 패턴 분포로 인해 신경망이 형성하는 연결 수락 경계면은 실제 경계면보다 높게 책정되게 되는 결과를 초래한다. 이때 사용자는 과도한 셀 손실율을 경험하게 되며 QoS를 제대로 보장받지 못하는 과잉 밀집 현상이 발생하게 된다. 또한 신경망이 실제 연결 수락 경계면을 찾는데 상당히 시간이 소요되게 됨으로써 연결 수락 제어기로서의 신뢰성이 낮아지게 된다[7, 9].

#### 3.2.2 가상 셀 손실율을 이용한 연결 수락 제어 방법

앞 절에서 설명된 기존 모델의 문제점을 해결하기 위한 방법으로 가상 출력 버퍼(VOB : Virtual Output Buffer)과 가상 셀 손실율(virtual cell loss rate)이라는 새로운 개념을 제안되었다[7].

(그림 2)는 VOB 모듈의 구조를 나타내고 있다. 실제

ATM망에서는 하나의 출력 버퍼가 존재하고 있으며, 이 출력 버퍼에서의 셀 손실율이 기존 신경망 모델의 중요한 평면 정보이다. VOB 모듈에서는 실제 출력 링크를 시뮬레이션하는 가상의 출력 링크가 존재하는데 이를 출력 링크는 실제 출력 링크보다 같거나 작은 처리 용량을 가진다. 실제로 가상 출력 링크는 출력 버퍼에 도착하는 셀의 갯수, 현재 처리를 기다리는 셀의 갯수, 그리고 손실이 발생한 셀의 갯수와 같이 3개의 정수형 데이터를 처리할 수 있는 카운터로써 구현된다. 가상 출력 링크에서의 처리 용량의 시뮬레이션은 펄스 발생기(Pulse Generator)에서 발생한 펄스의 간격에 의해 조정이 가능하여 하드웨어 구현이 용이하므로 VOB 모듈을 도입하였을 경우 발생할 수 있는 부담을 줄일 수 있다.



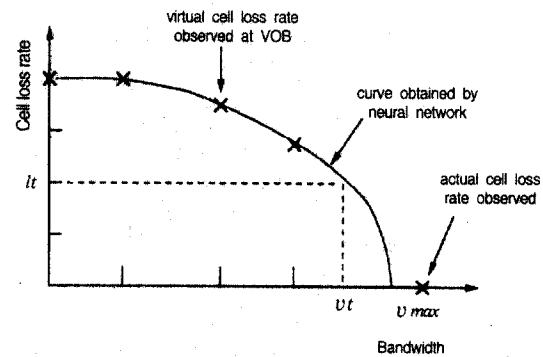
(그림 2) VOB 모듈의 구조

가상 셀 손실율은 가상 출력 버퍼에서 발생한 셀 손실율을 의미한다. 실제 출력 링크에서는 셀 손실이 발생하지 않더라도 가상 출력 링크의 처리 용량이 떨어짐에 따라서 셀 손실이 발생할 수 있다. (그림 3)은  $\vec{n}$ 의 호원이 접속되어 있다고 가정할 때, 가상 출력 링크의 처리 용량과 가상 셀 손실율과의 관계를 나타내고 있다. 그림에서 볼 수 있듯이, 망 상태  $\vec{n}$ 에 대하여 목표 셀 손실율  $I_v$ 를 만족시키기 위해서는 적어도  $v_x$ 의 링크 용량이 필요함을 알 수 있다. 따라서  $x$ 축에 해당하는 링크용량  $v$ 를 입력원으로 하였을 때  $y$ 축에 해당하는 평균 셀 손실율  $I_a$ 를 출력원으로 하는 함수 관계가 형성된다. 즉 식 (4)와 같은 관계식을 학습하는 신경망을 구성할 수 있다.

$$I_a = f(\vec{n}, v) \quad (4)$$

실제로 셀 손실율은  $1 \sim 10^{-8}$  정도 사이에서 다양하게 분

포되어 있다. 신경망이 이러한 범위를 학습하기 위해서는 일련의 변환 과정이 필요하게 된다. 식 (5)의 함수  $F_I$ 은  $1 \sim 10^{-8}$ 의 셀 손실율  $I_x$ 를  $1 \sim 0$ 의 값  $I_y$ 로 변환시키는 수식이다. 신경망은 이 로그 변환된 값을 이용함으로써 넓은 영역의 셀 손실율 값을 다룰 수 있다.



(그림 3) 가상 셀 손실율과 대역폭과의 관계

$$I_y = F_I(I_x) = \begin{cases} 0 & \text{if } I_x < 10^{-8} \\ 1 + \frac{1}{8} \log_{10}(I_x) & \text{otherwise} \end{cases} \quad (5)$$

$$I_x = F_I^{-1}(I_y) = 10^{8(I_y - 1)}$$

그러나 식 (5)에 의한 변환된 가상 셀 손실율값을 신경망이 학습하면 다음과 같은 문제가 발생한다. 신경망은 궁극적으로 가상 셀 손실율  $I_x$ 의 평균을 로그 변환한 값인  $\log(I_a)$ 을 학습하여야 한다. 그러나 신경망은 실제로 로그 함수에 의해 변환된 가상 셀 손실율의 평균  $\log(I_a)$ 을 학습하게 되므로 가상 셀 손실율의 평균에 낮은 값을 학습하게 된다. 예를 들어  $10^{-2}$ 과  $10^{-8}$ 의 셀 손실율이 발생하였다면, 신경망은 이상적으로  $0.7123L^1$ 을 학습하여야 하지만, 실제로는  $0.3750L$ 을 학습하게 된다(식 (6), 식 (7) 참조). 이 차이는 (그림 4)에서와 같이 연결 수락 경계면에서의 신경망 출력값이 지나치게 낮은 결과를 초래하게 된다.

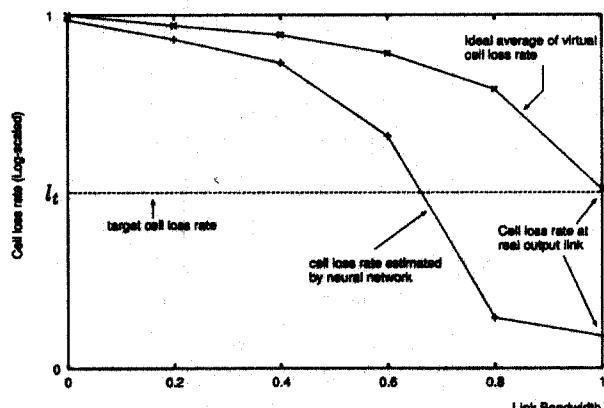
$$1 + \frac{1}{8} \log_{10}\left(\frac{10^{-2} + 10^{-8}}{2}\right) = 0.7123L^1 \quad (6)$$

$$\frac{\left\{1 + \frac{1}{8} \log_{10}(10^{-2})\right\} + \left\{1 + \frac{1}{8} \log_{10}(10^{-8})\right\}}{2} = 0.3750L \quad (7)$$

Hiramatsu는 셀 손실율 곡선상의 차이를 해소하기 위하여 식 (9)와 같은 학습 방법을 제안하였다.  $y$ 는  $[\vec{n}, v]$ 의 입력에 대한 신경망의 출력값으로 출력 링크  $v$ 에서의 셀 손실율의 예측값을 의미한다.  $y$ 는  $1 \sim 10^{-8}$ 의 범위를 가지는 셀 손

1)  $1 \sim 10^{-8}$ 의 범위를 가지는 셀 손실율과 로그 변환된 셀 손실율과의 표기상 혼동을 피하기 위하여, 로그 변환된 셀 손실율은 'L'을 사용한다. 예를 들어  $10^1, 10^{-4}, 10^{-8}$ 의 셀 손실율은 각각 1L, 0.5L, 0L과 같은 의미로 사용한다.

실을 값으로 변환된 다음, 가상 셀 손실을  $l_v$ 와 가중치 합을 수행한다. 이 결과는 다시 로그 변환시켜 신경망의 학습 시그널  $z$ 를 생성한다. 식 (9)와 같은 학습 방법을 이용하면 신경망의 출력값  $y$ 가 궁극적으로 (그림 4)에서의 이상적인 셀 손실을 평균 곡선과 유사하다는 것을 시뮬레이션을 통하여 입증되었다[7].

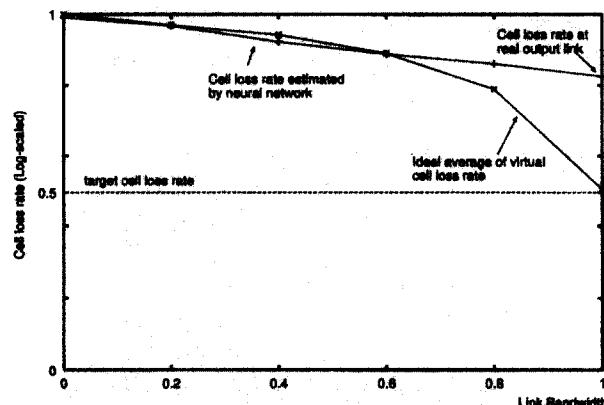


(그림 4) 이상적인 셀 손실을 평균 곡선과 신경망이 학습한 셀 손실을 곡선

$$l_e = F_l^{-1}(y) \quad (8)$$

$$z = F_l((1-a)l_e + al_s) \quad (9)$$

그러나 본 연구에서 수행한 LAN 호원과 화상 전화 호원이 존재하는 ATM망에서 목표 셀 손실율이  $10^{-4}$ 일 때의 실험 결과에 의하면, 연결 수락 경계면에서의 셀 손실을 예측 값이 0.5L 부근에서 크게 벗어나 0.82L을 표시하고 있다(그림 5) 참조). 이것은 접속된 호원의 수가 적더라도 수용 가능한 호원의 접속을 거부한 것과 같은 의미를 지니고 있으며, 네트워크의 이용률이 낮은 원인이 된다.



(그림 5) Hiramatsu가 제안한 학습 방법을 사용하였을 경우, 신경망이 예측한 셀 손실 곡선(LAN 호원 30, 화상 전화 호원 13, 목표 셀 손실율  $10^{-4}$ )

결과적으로 가상 셀 손실율은 신경망의 성능을 향상시키는

데 좋은 입력원이 될 수 있다. 그러나 Hiramatsu가 제안하는 학습 방법을 그대로 이용하여서는 실제 상황에서 좋은 성능을 기대하기 힘들다. 따라서 가상 셀 손실율 패턴을 이용하는 신경망의 성능을 높일 수 있도록 효율적인 패턴 처리 기법에 대한 추가적인 연구가 필요하다.

#### 4. 셀 손실을 참조 곡선에 기반한 ATM 연결 수락 제어 모델

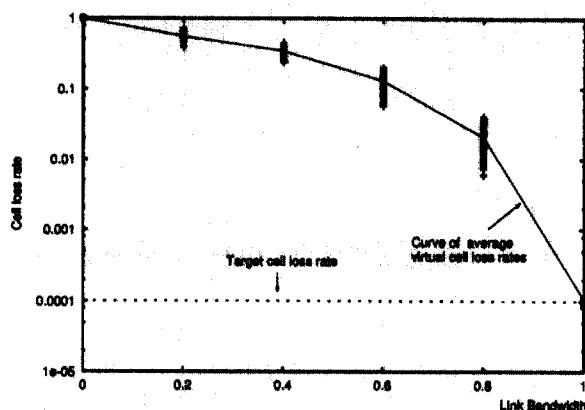
##### 4.1 셀 손실 참조 곡선의 의미 및 특성

Hiramatsu가 [7]에서 제안하는 학습 방법의 목적은 신경망이 셀 손실을 평균 곡선(average curve of cell loss rate)을 근사화시키는 것이다. 즉 가상 셀 손실율을 사용하는 신경망 모델에서 가장 중요하게 고려해야 할 것은 로그 변환된 셀 손실율 패턴을 사용하여 셀 손실을 평균 곡선을 찾아내는 것이다. Hiramatsu의 학습 방법은 앞 절의 실험 결과에서 보였듯이 LAN 호원과 화상 전화 호원이 존재하는 실제 ATM망 환경 하에서는 근사화 능력이 떨어진다. 본 논문에서는 학습 방법을 통해 셀 손실율 평균 곡선을 근사화하는 방법 대신, 수집된 가상 셀 손실율 패턴에 셀 손실율 값의 평균에 관한 정보를 충분히 포함할 수 있도록 처리하는 방법을 제안한다.

셀 손실율 평균 곡선은 입력 상태  $\vec{n}$ 에 따라서 다양한 모양을 가질 수 있다. 그러나 이 중에서 연결 수락 경계면에서 형성될 수 있는 셀 손실율 평균 곡선은 연결 수락 제어에 가장 큰 영향을 끼친다는 점에서 중요하게 다루어야 한다. 왜냐하면 연결 수락 경계면에서 형성되는 셀 손실율 평균 곡선은 실제 출력 버퍼에서의 셀 손실율이 목표 셀 손실율과 일치할 확률이 다른 연결 수락 영역보다 높기 때문이다. 본 논문에서는 연결 수락 경계면에서 목표 셀 손실율을 만족시키는 셀 손실율 평균 곡선을 셀 손실율 참조 곡선(cell loss rate reference curve)이라고 정의한다. 셀 손실율 참조 곡선은 가상 셀 손실율 패턴을 처리하기 위한 사전 정보로써 이용되게 된다. 참조 곡선의 구체적인 생성 방법은 다음과 같다.

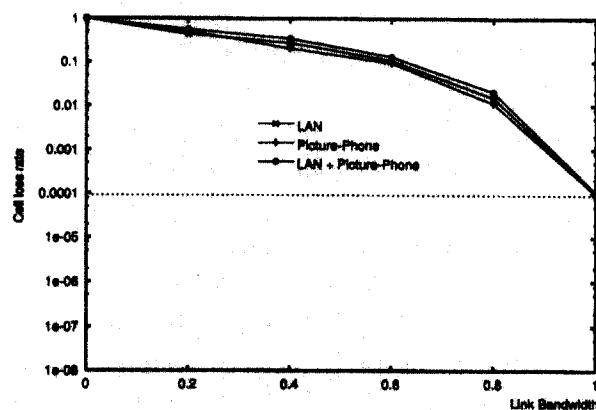
1. 임의의 호원이 존재하는 ATM망에서 이들의 연결 수락 경계면을 구한다.
2. 연결 수락 경계면에서 형성되는 셀 손실율 패턴 중에서 목표 셀 손실율을 만족시키는 셀 손실율 패턴을 수집한다.
3. 2에서 구한 셀 손실율 패턴의 평균을 구하여 하나의 곡선을 추출한다.

(그림 6)은 목표 셀 손실율이  $10^{-4}$ 일 때의 셀 손실율 참조 곡선을 생성하는 예를 보이고 있다. 그림에서 볼 수 있듯이 가상 출력 링크의 처리 용량이 증가함에 따라서 가상 셀 손실율의 분산도 커지고 있음을 알 수 있다. 그러나 목표 셀 손

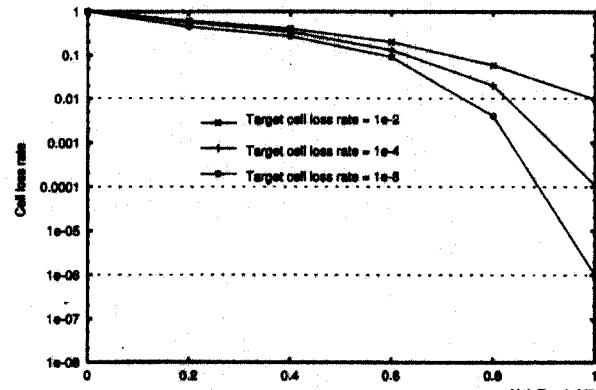
(그림 6) 목표 셀 손실을  $10^{-4}$  을 만족시키는 가상 셀 손실을 패턴과 평균 곡선

실을  $10^{-4}$  을 만족시키는 패턴만을 수집하였으므로, 실제 출력 링크에서의 셀 손실율은  $10^{-4}$ 에 거의 고정되어 있는 것을 볼 수 있다.

위의 방법은 셀 손실을 참조 곡선을 구하기 위한 일반적인 방법을 기술하고 있다. 그러나 위의 방법대로 셀 손실을 참조 곡선을 구하게 된다면, 망에 존재하는 호원이 달라질 때마다 다시 셀 손실을 참조 곡선을 구해야 하는 문제점이 발생한다.



(그림 7) 호원의 종류에 따른 셀 손실 참조 곡선



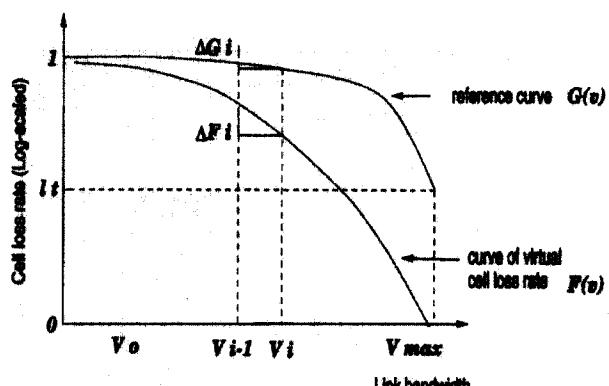
(그림 8) 목표 셀 손실율에 따른 셀 손실을 참조 곡선

생한다. 더욱이 호원 클래스가 증가할수록 연결 수락 경계면을 구하는 것은 힘든 작업이다. 따라서 셀 손실을 참조 곡선은 호원의 종류에 상관없이 일정한 값을 가지는 특성을 가지고 있어야 유용하게 사용될 수 있다.

본 논문에서는 ATM망에서 가장 대표적인 호원으로 알려진 LAN 호원과 화상 전화 호원을 이용하여, 각각의 호원이 독립적으로 존재하는 경우와 함께 존재할때의 셀 손실을 참조 곡선을 구하고 이들의 차이를 비교하는 실험을 수행하였다. (그림 7)에 나타나 있는 바와 같이 셀 손실을 참조 곡선은 호원의 종류에 상관없이 비교적 일정한 값을 가지는 것을 알 수 있다. 따라서 LAN 호원이 존재하는 망에서 추출된 셀 손실을 참조 곡선은 수정없이 화상 전화 호원이 존재하는 망이나 이를 호원이 같이 존재하는 망에도 바로 적용할 수가 있게 된다. 반면 셀 손실을 참조 곡선은 (그림 8)과 같이 호원의 목표 셀 손실율에는 영향을 받게 된다. 이런 경우에는 특정 호원을 이용하여 목표 셀 손실율에 따른 셀 손실을 참조 곡선을 미리 구해놓는다면, 호원의 종류에 상관없이 가상 셀 손실을 처리의 사전 정보로써 쉽게 이용할 수 있다.

#### 4.2 셀 손실을 참조 곡선을 이용한 가상 셀 손실율의 처리

(그림 9)는 가상 출력 링크의 처리 용량과 셀 손실율과의 관계를 나타내고 있다.  $x$  축은 가상 출력 링크의 처리 속도를 의미하며 실제 출력 링크의 속도  $V_{max}$  를 기준으로 정규화된 값을 가진다.  $y$  축은  $1 \sim 10^{-8}$  까지의 셀 손실율값을 로그 변환한 것이다.  $G(v)$ 는 목표 셀 손실율이  $I_t$  일 때 생성된 참조 곡선을 의미한다.  $F(v)$ 는 VOB 모듈에서 수집되어진 임의의 가상 셀 손실율 곡선을 의미한다.



(그림 9) 참조 곡선을 이용한 가상 셀 손실율 패턴의 처리

본 논문에서 제안하는 패턴 처리 방법은 다양하게 수집되는 셀 손실 곡선을  $G(v)$  곡선의 기울기 정보를 추가하여 평균적으로 이상적인 셀 손실 평균 곡선에 근사화시키는 것이다. 식 (10)은 가상 출력 링크  $V_t$  에서의 셀 손실율 값  $F_t$  를

$G(v)$ ,  $F(v)$  두 곡선의 기울기 성분을 이용하여  $F'_i$ 로 변환하는 식을 나타낸다.  $F_0$ 는 최소 처리 용량을 가지는 출력 링크  $V_0$ 에서의 셀 손실율이며, 패턴 테이블에는  $F_i$  대신 변환된  $F'_i$ 를 저장한다. 만약  $(F_0, F_1, \dots, F_{\max})$ 의 셀 손실 곡선이 수집되면 식 (10)에 의해서  $(F'_0, F'_1, \dots, F'_{\max})$ 의 곡선으로 변형된다.

$$F'_i = \begin{cases} F_0 & \text{if } i=0 \\ F_{i-1}' - ((1-\alpha)\Delta G_i + \alpha\Delta F_i) & \text{otherwise} \end{cases} \quad (10)$$

식 (10)에서는  $\alpha$ 를 달리함으로써  $F(v)$ ,  $G(v)$  곡선의 영향력을 조정할 수 있다. 패턴 처리 기법을 적용하면 로그 변환된 가상 셀 손실율의 평균  $\overline{\log(l_v)}$ 은 변형된 가상 셀 손실율의 평균  $\overline{\log(l'_v)}$ 으로 변환되게 된다. 이때 적절한  $\alpha$  값에 의해  $\overline{\log(l'_v)} \approx \overline{\log(l_v)}$ 의 목적을 달성할 수 있게 된다. 즉 패턴 처리 기법은 아래 식 (11)과 같은 효과를 기대할 수 있게 되며, 이때 신경망은 호원의 연결 수락 경계면을 정확하게 찾을 수 있게 된다.

$$\overline{\log(l_v)} < \overline{\log(l'_v)} \approx \overline{\log(l_v)} \quad (11)$$

위에서 언급하였듯이  $\alpha$  값의 선택은 신경망의 예측 성능을 좌우하게 되므로 주의 깊게 선택되어져야 한다. 만약  $\alpha=0$ 을 사용하게 되면 신경망은 가상 셀 손실율만을 그대로 학습하게 된다. 반면  $\alpha=1$ 을 사용하게 되면  $F_0$  와  $G(v)$  곡선의 기울기에 의해서 처리된 패턴이 생성된다. 접속된 호원의 수가 적더라도  $F_0$ 의 값이 높은 값을 가지면 신경망의 출력값은 높은 값을 가지게 되므로 망의 이용률이 떨어지게 된다.

## 5. 결 론

본 논문에서는 트래픽 특성이 서로 다른 이질 호원이 존재하는 ATM망에서의 연결 수락 제어를 위한 신경망 모델에 대한 효율적인 학습 패턴 처리 기법을 제안하였다. 제안된 방법에서는 VOB모델에서 채택하였던 가상 셀 손실율이라는 개념을 이용하여 신경망이 연결 수락 경계면을 최대한 빨리 찾게 함으로써 호원의 QoS를 만족시킴은 물론 네트워크 이용률을 극대화시키고자 하였다. 이를 위하여 수집된 가상 셀 손실율로부터 얻은 셀 손실율을 참조 곡선을 이용하였다. 즉, 학습 방법을 통해 셀 손실율 평균 곡선을 근사화하는 방법 대신, 수집된 가상 셀 손실율 패턴에 셀 손실율 값의 평균에 관한 정보를 충분히 포함할 수 있도록 하였다.

ATM망에서 가장 대표적인 호원으로 알려진 LAN 호원

과 화상 전화 호원을 이용하여, 각각의 호원이 독립적으로 존재하는 경우와 함께 존재할 때의 셀 손실율 참조 곡선을 구하고 이들의 차이를 비교하는 실험을 수행하였다. 실험 결과에 따르면 셀 손실율 참조 곡선은 호원의 종류에 상관없이 비교적 일정한 값을 가지는 것을 알 수 있었다. 따라서 LAN 호원이 존재하는 망에서 추출된 셀 손실율 참조 곡선은 수정 없이 화상 전화 호원이 존재하는 망이나 이를 호원이 같이 존재하는 망에도 바로 적용할 수가 있게 된다.

향후 연구로는 다양한 트래픽 호원이 존재하는 실제 ATM망에 대해서 제안된 학습 패턴 처리 방법을 신경망 모델에 적용한 시뮬레이션을 수행하는 연구가 필요하다.

## 참 고 문 헌

- [1] H. Heffes, Lucantoni, "A Markov modulated characterization of packetized voice and data traffic and related statistical multiplexer performance," IEEE Journal on Selected Area in Communications, Vol.4, pp.856-868, Sept. 1986.
- [2] Andrea Baiocchi, Nicola Blefari Melazzi, Marco Listanti, Aldo Roveri, and Roberto Winkler, "Loss Performance Analysis of an ATM Multiplexer Loaded with High-Speed ON-OFF Sources," IEEE Journal on Selected Area in Communications, Vol.9, No.3, pp.388-393, April, 1991.
- [3] D. Anick, D. Mitra, M. M. Sondhi, "Stochastic Theory of a Data-Handling System with Multiple Sources," The Bell Syst. Tech. Journal, Oct. 1982.
- [4] Yasuhiro Miyao, "Bandwidth Allocation in ATM Networks That Guarantee Multiple QOS Requirements," IEEE ICC'93, 1993.
- [5] G. Ramamurthy and R. S. Dighe, "Distributed Source Control : A Network Access Control For Integrated Broadband Packet Networks," IEEE INFOCOM '90, 1990.
- [6] A. Hiramatsu, "ATM Communications Network Control by Neural Network," IEEE Transactions on Neural Networks, Vol.1, No.1, pp.122-130, Mar. 1990.
- [7] A. Hiramatsu, "ATM Call Admission Control using a Neural Network trained with a Virtual Output Buffer Method," Proc. ICNN'94, Vol.6, pp.3611-3616, 1994.
- [8] 강주홍, 김치하, "다중 퍼셉트론을 이용한 ATM망에서의 연결수락제어", 정보과학회논문지, 제23권 제12호, pp.1225-1237, 1996.
- [9] 시스템공학연구소, "ATM망에서의 연결 수락 제어를 위한 신경망 모델 개발", SERI '97 최종연구보고서, 포항공대, 1997.

### 권 오 준

e-mail : ojkwon@dongeui.ac.kr  
1986년 경북대학교 전자공학과 졸업  
(공학사)  
1992년 충남대학교 대학원 전산학과  
(이학석사)  
1998년 포항공과대학교 대학원 전자계산  
학과(공학박사)  
1986년~2000년 한국전자통신연구원 선임연구원  
2000년~현재 동의대학교 컴퓨터·영상공학부 조교수  
관심분야 : 신경망 응용, 패턴 인식, 지능정보 처리, 정보통신  
서비스 및 정보 보호

### 전 형 구

e-mail : hgjeon@dongeui.ac.kr  
1987년 인하대학교 전자공학과(학사)  
1992년 연세대학교 대학원 전자공학과  
(공학석사)  
2000년 연세대학교 대학원 전기 및 컴퓨터  
공학과(공학박사)  
1987년~2001년 한국전자통신연구원 선임연구원  
2001년~현재 동의대학교 정보통신공학과 전임강사  
관심분야 : CDMA 셀 설계, 이동 통신 시스템, 멀티미디어 트래  
픽 제어

### 권 순 각

e-mail : skkwon@dongeui.ac.kr  
1990년 경북대학교 전자공학과(공학사)  
1992년 한국과학기술원 전기및전자공학과  
(공학석사)  
1998년 한국과학기술원 전기및전자공학과  
(공학박사)  
1998년~2001년 기술신용보증기금 기술평가센터 차장  
2001년~현재 동의대학교 컴퓨터·영상공학부 전임강사  
관심분야 : 영상통신, 영상처리, 영상정보 보호

### 김 태 석

e-mail : tskim@dongeui.ac.kr  
1981년 경북대학교 전자공학과(공학사)  
1989년 일본게이오대학 계산기과학전공  
(공학석사)  
1993년 일본게이오대학 계산기과학전공  
(공학박사)

1993년~1994년 일본게이오대학 객원연구원  
1993년~1994년 일본국제전전화연구소 인공지능실 기술고문  
1994년~현재 동의대학교 컴퓨터·영상공학부 부교수  
관심분야 : 정보시스템, 자연어처리, 멀티미디어교육 컨텐츠

### 이 정 배

e-mail : jblee@email.sunmoon.ac.kr  
1981년 경북대학교 전자공학과(공학사)  
1983년 경북대학교 대학원 전자공학과  
(공학석사)  
1995년 한양대학교 대학원 전산공학과  
(공학박사)  
1982년~1991년 한국전자통신연구원 선임연구원  
1996년~1997년 Dept. of Electrical & Computer Eng.,  
U.C. Irvine 객원교수  
1991년~2002년 부산외국어대학교 컴퓨터공학과 부교수  
2002년~현재 선문대학교 컴퓨터정보학부 부교수  
관심분야 : 컴퓨터 네트워크, 실시간 시스템, 인터넷 응용