

論文98-35S-3-1

# ATM 망에서 축약 분산 기억 장치를 사용한 호 수락 제어 (Call Admission Control for ATM Networks Using a Sparse Distributed Memory)

權 熙 容 \*\*, 宋 承 俊 \*, 崔 在 佑 \*, 李 仁 行 \*, 黃 熙 隆 \*

(Hee-Yong Kwon, Seung-Jun Song, Jae-Uo Choi, In-Haeng Lee, and Hee-Yeung Hwang)

## 요 약

본 논문에서는 축약 분산 기억 장치(Sparse Distributed Memory, SDM)를 사용한 신경망 호 수락 제어(Call Admission Control, CAC)를 제시한다. 호 수락 제어는 ATM 망 트래픽 제어의 핵심 요소이다. 이것은 ATM 네트워크 환경의 다양한 변화와 빠른 변화에 적응적이어야 한다. 기존의 ATM 호 수락 제어 방식은 가능한 모든 망 분석을 요구한다. 따라서 최적의 설계는 어렵다. 최근 신경망 방식이 이러한 문제를 해결하기 위해서 도입되었다. 그러나 이것 역시 적응적 제어를 제공하지 않았다. 이것은 부가적인 학습 데이터 테이블과 학습 시간을 요구하였기 때문이다. 우리는 CAC 기능 구현에 더 현실적인 SDM을 기반으로 한 신경망 호 수락 제어 방법을 제안하고, 이것을 기존의 신경망 호 수락 제어 방법과 비교했다. 제안된 방식은 급격한 변화에 적응적인 호 수락 제어를 제공한다. 실험 결과 SDM은 별도의 학습 테이블과 싸이클을 필요로 하지 않아, 빠른 적응력과 안정성을 가짐을 확인할 수 있었다.

## Abstract

In this paper, we propose a Neural Call Admission Control(CAC) method using a Sparse Distributed Memory(SDM). CAC is a key technology of ATM network traffic control. It should be adaptable to the rapid and various changes of the ATM network environment. Conventional approach to the ATM CAC requires network analysis in detail in all cases. So, the optimal implementation is said to be very difficult. Therefore, neural approach have recently been employed. However, it does not meet the adaptability requirements. Because it requires additional learning data tables and learning phase during CAC operation. We have proposed a neural network CAC method based on SDM that is more actual than conventional approach to apply it to CAC. We compared it with previous neural network CAC method. It provides CAC with good adaptability to manage changes. Experimental results show that it has rapid adaptability and stability without additional learning table or learning phase.

## I. 서 론

수 bps에서부터 수백 Mbps까지 넓은 대역폭을 갖

는 각종 서비스들을 종합적으로 제공하는 디지털 통신인 B-ISDN(broadband integrated services digital network) 의 ATM (asynchronous transfer mode) 방식에서, 원하는 서비스의 질을 유지하면서 시스템을 최대한으로 활용하기 위한 목적으로 호 수락 제어 (call admission control, CAC)가 필요하다. 호 수락 제어의 목표는 가능한 많은 호를 연결시키면서도 미리 설정된 서비스 품질 (quality of service, QoS)을 유지

\* 正會員, 湖西大學校 電子工學科

(Dept. of Electronics Engineering, Hoseo University)

\*\* 正會員, 安養大學校 컴퓨터學科

(Dept. of Computer Science, Anyang University)

接受日字:1997年12月15日, 수정완료일:1998年3月7日

시키는 것이다. 새로운 호 설정시, 기존의 호들에 대한 QoS를 악화시킨다면 이 새로운 호를 거절하고, 그렇지 않으면 수락한다. 이러한 제어의 핵심은 망의 상태에 대한 계속적인 감시를 통해 새로운 호의 설정 가능성 판단 기능과, 광범위하면서 다양하게 변화하는 ATM망 환경에 대한 제어기의 적응 기능이다.

기존의 ATM 호 수락 제어 방식은 모든 가능한 환경들에 대한 상세한 분석을 통해 제어기 및 관련 인자를 결정하여 설계되었다. 이러한 방식은 적합한 모델 설정이나 모든 가능한 경우를 분석하여야 하는 등 비현실적이기 때문에, 유연하면서도 효율이 좋은 ATM 트래픽 제어 기능을 구현하기가 곤란하다. 더욱이 이러한 방식은 새로운 서비스의 추가나 예기치 못한 환경 변화에 의한 트래픽 특성의 변화에 적응하기가 어렵다. 최근에 이 같은 문제를 해결하기 위해서 신경망이 도입되고 있다. 신경망은 입력과 그 입력의 특징이 되는 인자 추출을 스스로 행함으로써 복잡한 입력과 출력간의 관계를 근사해 낼 수 있다<sup>[1]</sup>. 이와 같은 학습 능력은 관측된 트래픽 데이터로부터 QoS를 예측하는 함수를 자동 생성하는데 이용될 수 있고, 이것은 다양한 유형의 통신 서비스와 변화하는 환경에 적응해 가는 ATM 호 수락 제어 시스템의 설계를 가능케 한다<sup>[2,3,4,5]</sup>. 기존의 신경망 ATM 호 수락 제어 시스템의 장점은 다음과 같다.

- 제어 시스템 설계시 트래픽 특성에 대한 정확한 정보를 필요로 하지 않는다(망 운용시 학습에 의해 습득).
- 관측된 자료에서 의미 있는 정보를 자동으로 추출한다.
- 학습이 진행됨에 따라 제어의 정확도가 향상된다.
- 제어기는 환경이나 요구사항, 성능 특성 등의 변화에 적응할 수 있다.

그러나 기존의 신경망 모델이 대부분 EBP (error back propagation)에 의한 MLP(multi layer perceptron) 신경망이기 때문에 위에서 제시된 신경망의 장점을 충분히 살리지 못하고 있다. EBP는 신경망 학습시 모든 자료가 함께 학습될 것을 요구한다. 즉, 새로운 자료의 추가 학습을 위해서 과거의 모든 자료가 함께 off-line으로 학습되어야 함을 의미한다. 그러나 급격하게 변화하는 ATM 트래픽에 대한 호 수락

제어는, 보다 빠른 적응 제어가 가능해야만 한다. 따라서 본 논문에서 보다 빠른 적응형 신경망 제어 방안을 제시한다.

본 논문에서는 QoS 인자로 셀 손실률과 활용률을 고려하였다. 셀 손실률은 단위 시간당 전송된 데이터의 총 합에 대한 링크 용량을 초과한 데이터의 비율로 정의하고, 활용률은 단위 시간당 링크 용량에 대한 전송된 데이터의 비율로 정의하였다. 사용한 트래픽은 호원의 버스트 성질을 잘 표현하는 ON-OFF 모델링된 고속의 데이터와 화상원을 가장 정확하게 모델링하는 것으로 알려진 AR(autoregressive process) 모델링된 화상 전화 서비스의 트래픽으로서<sup>[6] [7]</sup>, ATM망 환경 및 호원을 최대한 현실성 있게 모델링하였다. 또한 본 논문의 시뮬레이션에 사용한 호 수락 제어기는 기존 논문에서 사용했던 방법<sup>[3] [4]</sup>인 MLP (multi layer perceptron)와 본 논문에서 제안한 방법인 SDM(sparse distributed memory)이다. SDM은 호 입력의 수락·거절 결정 여부 자체에 학습과정이 포함되기 때문에 MLP와 달리 별도의 학습 싸이클이 필요하지 않아 간단하면서 빠르게 수락 여부를 결정하므로 실시간 제어의 적응력이 우수하다. 그리고, 이를 시뮬레이션을 통해 입증하였다.

이하 구성은 다음과 같다. II장은 실험에 사용된 ATM 트래픽 모델에 대해 서술하고, III장은 적응성이 뛰어난 SDM 신경망을 이용한 호 수락 제어 방식을 상세히 설명하고, IV장에서는 기존의 방법과 제안된 방법을 이용한 시뮬레이션 결과를 보이고, 마지막으로 V장에서 결론을 내린다.

## II. 시뮬레이션에 사용한 트래픽 모델

시뮬레이션에서 ATM 트래픽을 최대한 현실적으로 구현하기 위해서 미리 각 데이터 종류별로 분석된 IPP, MMPP, AR모델을 선택 사용하였다. ATM망이 전송할 트래픽은 저속 및 고속 데이터 전송, 음성, 정지 화상, 고해상도의 비디오에 이르기까지 다양한 트래픽 특성을 지니게 된다. 일반적으로 음성 및 데이터 호원의 경우 ON-OFF 과정(process)을 사용하고<sup>[8]</sup>, 대부분의 On구간과 Off구간은 각각 352ms와 650ms를 평균으로 하는 지수 분포로 모델링한다. 이런 신호원이 여러개 다중화 되었을 때에는 그 상관성(correlation)이 매우 큰 복잡한 모델로 나타난다. 이 경우,

여러 개의 음성 신호원의 중첩 또는 데이터 및 화상 신호원이 중첩된 상황을 모델링하는데 그림 1과 같은 2-state MMPP(markov modulated poisson process)를 사용한다<sup>[9] [10]</sup>. 신호가 존속하는 기간은 지수 분포, 신호의 발생은 poisson 분포에 따른다. 특히 2-state MMPP 모델에서 셀이 발생하지 않는 침묵구간을 포함하는 특수한 경우는 그림 2와 같은 IPP(interrupted poisson process) 모델로서 나타내어진다<sup>[10]</sup>.




그림 1. 2-State MMPP 모델  
Fig. 1. 2-State MMPP model.




그림 2. IPP 모델  
Fig. 2. IPP model.

비디오 원 데이터들은 망의 효율적 활용과 일정한 화질을 보장받기 위해서 VBR(variable bit rate)코딩을 통해 압축하여 전송한다. 이 경우 전 프레임과 현재 프레임간의 차이와 현재 프레임이 포함하는 새로운 화면 내용에 대한 데이터만을 포함한다. 연속적인 프레임들의 코딩된 데이터들 간에는 높은 상관관계 특성을 갖는 비디오 원을 모델링하기 위한 모델로서 AR을 이용하는 것이 가장 적합하다<sup>[6] [7]</sup>. 화상전화 서비스로부터 화상원을 모델링하기 위해 300 프레임의 실험 비디오 데이터로부터 화상원의 특성을 분석한 결과, 이러한 화상원을 모델링하기 위해 1차 AR모델이 제시 됐고, 이것은 화상전화 보다 움직임의 변화가 더 많은 화상회의 및 TV와 같은 화상원에 대해서도 잘 적용될 수 있음이 밝혀졌다<sup>[7] [11]</sup>. 1차 AR모델은

다음과 같이 정의된다.

$$\lambda(n) = a \lambda(n-1) + b \omega(n)$$

$\lambda(n)$ 은 n번째 프레임의 비트율, a와b는 상수, 그리고  $\omega(n)$ 은 평균  $\eta$ 와 분산(variance) 1을 갖는 가우시안 랜덤과정(gaussian random process)를 나타낸다.

### III. SDM을 사용한 호 수락 제어

본 논문에서 제안한 호 수락 제어 방식은 SDM을 신경망 모델로 하고 있다. SDM은 Kanerva가 제안한 신경망 모델로써 고차원 공간상의 연상 기억 장치이다<sup>[12]</sup>. 이것은 퍼셉트론 신경망으로 쉽게 구현할 수 있다. 동작은 RAM과 유사하다. 위치 주소는 입력 패턴이 되며, 위치는 임의로 지정한다. 메모리 내용은 계수기 기능을 하며, 0으로 초기화한다. 모든 동작은 참조 주소(패턴)와 위치 주소간의 해밍 거리를 계산하는 것으로 시작한다. 이 해밍 거리가 미리 정해진 반경 내에 있는 경우 선택 벡터는 1로 세트되고, 이 위치는 선택되었다고 한다. 이때 선택된 위치들의 모임을 선택된 집합이라 한다. 반경은 주어진 참조 주소에 대해 적은 양의 메모리 위치가 선택되도록 선정한다. 메모리에 기억시킬 때는 선택된 모든 데이터 계수기의 내용을 입력 데이터가 1이면(수락) 증가시키고 0이면(거절) 감소시킨다. 메모리에서 읽어낼 때는 선택된 데이터 계수기가 모두 합해진다. 이 합이 0보다 크면 출력은 1로, 아니면 0으로 한다. 따라서 데이터들은 기억 시에 선택된 위치들의 계수기에 분산되고, 읽기 시에 이 계수기들의 합이 평균화된다<sup>[12] [13]</sup>. 본 논문에서는 참조(위치) 주소와 계수기를 그림 3과 같이 구성하였으며, 그림 3은 구조와 읽기의 예이고 그림 4는 쓰기의 예이다.

여기에서, 참조(위치) 주소의 ( $n_0, n_1$ )는 사용자 수를 의미하는 상태 벡터이다. 이 2가지 유형을 가지는 상태 벡터는 실제적으로는 메모리의 주소로서 2진값이다. 실제 구현시 상태벡터의 비트 표현 방식은<sup>[2] [13]</sup>에서 설명하였다. 계수기는 해당 위치 주소가 나타내는 노드 상태 벡터의 출력 버퍼에서의 셀 손실률이 임계값 이하이면 증가, 이상이면 감소시킨다. 위에서 제시된 SDM은 호 수락 제어 기능을 다음과 같이 수행한다. ATM망 노드에서는 2개의 호 유형  $n_0, n_1$  각각에 대해 연결된 호의 수를 계수한다. 이때 셀 손실

를 L을 출력 버퍼에서 관측한다.

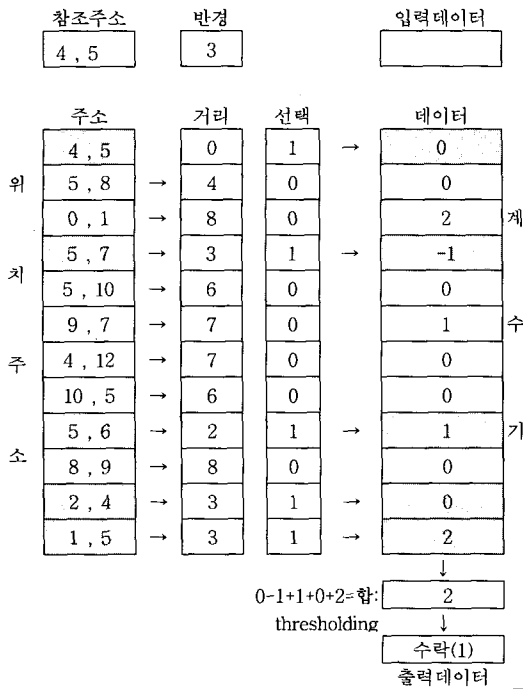


그림 3. SDM의 구조 및 읽기의 예  
Fig. 3. Read example from SDM and Structure.

새로운 호 설정 요구가 노드에 도착하면, 일단 호의 유형을 2가지 중의 하나로 분류한다. 가령 시간 t에서 유형1의 호가 도착되었다 하면, 시간 t에서 노드의 상태는 각 유형의 연결된 호의 수의 벡터로 표시되고, 제어가 수락하면 노드 상태는 (n0(t), n1(t)+1)로 표시할 수 있다. 이 벡터가 SDM의 입력(참조 주소)이 된다. 이 벡터에 대한 SDM의 출력 데이터 계수기는 결정값으로서, 입력된 연결 호들의 수의 조합이 호 수락 결정선의 위 혹은 아래 존재하는지의 여부를 결정하는데 사용된다. 이 값이 0보다 크면 호 설정 요구는 허가되고 아니면 거부된다. SDM은 시스템이 운용되는 동안 출력버퍼에서 관측되는 자료를 가지고 학습한다. 목표값은 미리 정해진 임계값과 최종 셀 손실률을 비교하여 생성한다. 가령 임계값을 L<sub>0</sub> 라하고, 시간 t에 관측된 셀 손실률을 L(t), 연결상태 벡터를 (n<sub>0</sub>, n<sub>1</sub>)라 하면, 이때의 목적값 v(t)는 다음 식에 의해 정해지고 이 값이 상태 벡터로 선택된 SDM의 데이터 계수기에 더해진다.

$$v(t) = \begin{pmatrix} 1, & \text{if } L(t) < L_0 \\ -1, & \text{if } L(t) > L_0 \end{pmatrix}$$




그림 4. SDM에 쓰기의 예  
Fig. 4. Write example to SDM.

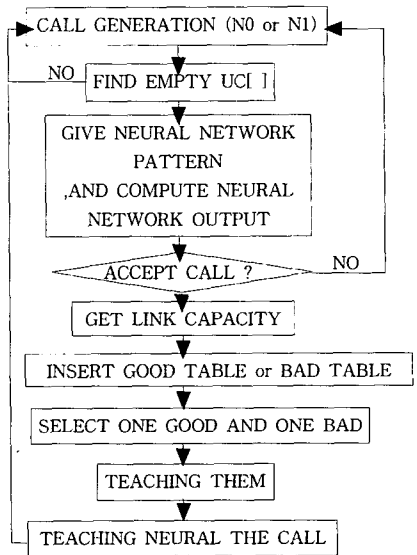


그림 5. MLP CAC 알고리즘  
Fig. 5. Algorithm of MLP CAC.

이상의 과정을 알고리즘으로 표현하면 그림 6과 같다. 참고로 그림 5는 MLP CAC의 알고리즘을 보인다. 여기서 UC [ ]는 트링크에 접속 가능한 채널이다.

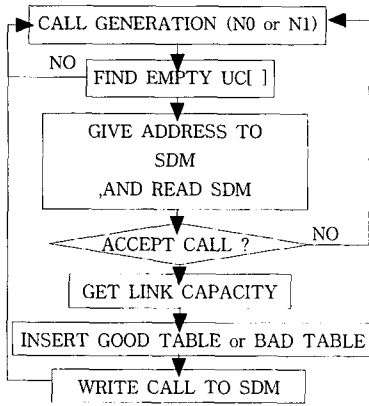


그림 6. SDM CAC 알고리즘  
Fig. 6. Algorithm of SDM CAC.

이 방식은 통신 환경이 변화하여 이전에 발생한 적이 없는 데이터(여기선 상태 벡터)가 발생하면 이전에 학습한 데이터와 상관없이 독립적으로 SDM에 기억된다. 따라서 새로운 환경에 적응력이 뛰어나다고 볼 수 있다. 또한 기존의 신경망을 이용한 방법과 비교 할 때, SDM은 계수기에 입력하는 것만으로 그 데이터에 대한 학습을 종료하므로 MLP와 같은 학습 주기와 적응 시간이 필요 없어 온라인 학습이 가능하며 적응 속도가 우수하다.

#### IV. 시뮬레이션

시뮬레이션은 터보C-3.0에서 작업하였다. 실험1에서는 제안된 방법과 기존의 방법의 성능 비교를 위해 각각에 대해 2개의 서비스 트래픽에 대한 학습과정, 셀 손실률, 활용률과 적응력을 실험하였고, 실험2에서는 제안된 방법의 확장성을 검증하기 위해 3개의 서비스 트래픽에 대한 실험을 보인다. 시뮬레이션 결과의 비교는 V.결론에서 보인다.

##### 1. 2가지 서비스 클래스에 대한 실험(실험1)

시뮬레이션 과정에서 단위 싸이클당 시간을 고려하여 초당 발생 비트를 고려할 수 있도록 반영하였다. 트래픽 특성이 동일한 호원들을 하나의 트래픽 클래스로 정의하고, 기존 신경망과 SDM 신경망의 입력 변수로서 ATM 노드의 출력 링크에 정규화 되지 않은 평균 부하로 표현되는 트래픽 클래스의 호원수를 사용하였다. 이때 호 발생은 실험 효과를 극대화하기 위해 클래스 0와 1 각각에 대해 6:4의 비율로 링크 용량을

초과할 수 있도록 랜덤하게 발생시켰다. 시뮬레이션에서 사용한 각종 인자는 표 1과 같다.

표 1. 실험1의 시뮬레이션 파라미터  
Table 1. Simulation parameter of Experiment-1.

	Class 0	Class 1
트래픽 모델링	IPP	MMPP
평균 비트율 (Mbps), 포아송 분포	1.925	15.33
평균 비트 변동률 (%)	1.18	0.68
on 기간동안 평균 데이터 발생 (Mbps)	12.6	20.4
off 기간동안 평균 데이터 발생 (Mbps)	0	5.5
trunk capacity (Mbps)	1360	
평균 호의 지속 시간, 지수분포(sec)	평균 650 (on) 평균 340 (off)	
단위 시간 (1싸이클 시간 가정)	100 msec	
trunk에 접속 가능한 사용자수	200 명	
SDM의 패킷 테이블	400 개	
MLP의 패킷 테이블	400 개	

##### 1) 성능 비교 실험

안정적인 성능을 보기 위해서 시뮬레이션을 5만 싸이클 실행시킨 후의 활용률과 셀 손실률을 보인다. 그림 7과 그림 8은 각각 싸이클에 대한 활용률과 셀 손실률의 변화를 보인다.




그림 7. 활용률 변화도  
Fig. 7. Utilization rate change.




그림 8. 셀손실률 변화도  
Fig. 8. Cell loss rate change.

##### 2) 학습 과정 비교 실험

2개의 클래스별 유저수를 의미하는 입력 호(n0, n1)에 대한 수락·거절의 결정의 변화를 보이는 학습 과

정을 비교하기 위해서 각 2만, 3만, 4만, 5만 싸이클에  
서의 결정 경계를 그림 9와 그림 10에서 보인다.

표 2. 성능 비교 결과  
Table 2. Performance of Experiment 1.

	MLP	SDM
활용률	81 %	82 %
에러율	4.8 E-4	3.67 E-5




그림 9. 실험1에서 MLP의 결정 경계(◆ : 수락, × : 거절)  
Fig. 9. MLP decision boundary of Experiment-1. (◆ : Accept, × : Reject).

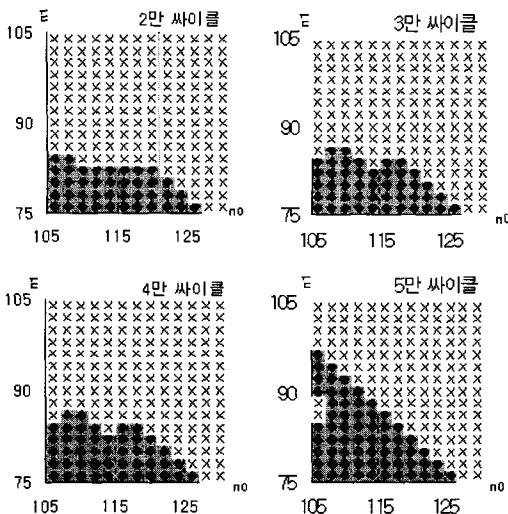


그림 10. 실험1에서 SDM의 결정경계(◆ : 수락, × : 거절)  
Fig. 10. SDM decision boundary of Experiment-1. (◆ : Accept, × : Reject)

3) 적응력 비교 실험

두가지 방법의 적응속도를 비교하기 위하여, 3만 싸이클에서 갑작스럽게 10% 증가한 트래픽을 입력시킨 뒤 활용률과 셀 손실률을 그림 11과 그림 12에서 보이고 변화된 결과를 표 3에서 보인다.




그림 11. 트래픽 10% 증가후 실험1의 활용률  
Fig. 11. Utilization rate of Experiment-1 with 10% traffic addition.




그림 12. 트래픽 10% 증가후 실험1의 셀손실률  
Fig. 12. Cell loss rate of Experiment-1 with 10% traffic addition.

표 3. 실험1의 MLP와 SDM 성능 변화  
Table 3. Performance changes of MLP and SDM after Experiment-1.

		MLP	SDM
적응력 실험전	활용률	81 %	82 %
	에러율	4.8 E-4	3.67 E-5
적응력 실험후	활용률	87.8 %	84 %
	에러율	6.4 E-3	3.4 E-4
변화비	활용률	0.084%증가	0.024%증가
	에러율	12.33%증가	8.26%증가

2. 3가지 서비스 클래스에 대한 실험(실험2)

실험2는 실험1과 같은 환경하에서 입력 호원을 3개의 클래스로 늘렸을 때 실험1 결과의 성능 유지 여부 비교를 위한 실험으로서 호 수락 제어가 일정하게 학습된 상태에서 전체 셀 손실률과 활용률을 계산한다. 실험2에서 사용한 각종인자는 표 4.에서 보이고 실험1에 대한 실험2의 비교는 표 5에서 보인다.

표 4. 실험2의 시뮬레이션 파라미터  
Table 4. Simulation parameter of Experiment-2.

	Class0	Class1	Class2
트래픽 모델링	IPP	MMPP	AR
평균 비트율 (Mbps), 포아송 분포	1.925	15.33	a=0.8781, b=0.1108 화면크기: 720*480
평균 비트 변동률 (%)	1.18	0.68	프레임: 30/sec 평균: 0.52Mbps/pixel
on 기간동안 평균 데이터 발생 (Mbps)	12.6	20.4	화상전화 데이터 : 5.39Mbps *1초당 데이터 발생 =720*480*30*0.52 = 5.39
off 기간동안 평균 데이터 발생 (Mbps)	0	5.5	*단위 사이클당 데이터 발생 = 0.539
trunk capacity (Mbps)	1360		
평균 호의 지속 시간, 지수분포(sec)	평균 650 (on) 평균 340 (off)		
단위 시간 (1사이클 시간 가정)	100 msec		
trunk에 접속 가능한 사용자수	200 명		
SDM의 패턴 테이블	400 개		
MLP의 패턴 테이블	400 개		

표 5. 실험2에 대한 성능  
Table 5. Performance of Experiment-2.

		MLP	SDM
실험2의 결과	활용률	76 %	89 %
	에러율	5.5 E-4	3.87 E-4
실험1에 대한 변화비	활용률	0.06% 감소	0.085% 증가
	에러율	0.14% 증가	9.54% 증가

각 3개의 클래스별 요구는 랜덤적으로 이루어지고, 각 클래스별 접속 요구 확률은 모두 같게 설정되었다.

### V. 결론

ATM 망 환경에 급격한 변화가 있을 경우 기존의 신경망 방식과 유사한 성능 수준을 유지하면서, 재 학습 없이 온라인 상태에서 새로운 환경에 적응하여, 제어 기능을 적응적으로 수행할 수 있는 SDM을 이용한 호 수락 제어 방법을 제시하였다.

시뮬레이션 결과는 다음과 같다. 학습 사이클에 따른 결정 경계를 보여주는 그림 9와 그림 10에서, n0는 클래스0의 유저의 갯수이고, n1는 클래스1의 유저의 갯수인데 사이클이 증가함에 따라서 특정 (n0, n1)

이 수락·거절의 반복 학습을 통해서 특정 영역으로 결정되어짐을 보이고 있다. 이것은 시스템이 안정 단계로 접근하고 있음을 의미한다. 각 3만 사이클에서 활용률과 셀 손실률의 변화를 그림 11와 그림 12에서 보이고 있는데, 여기서 SDM은 약 4만1천 사이클에서 현저하게 줄어든 셀 손실률을 보이나 MLP에서는 4만 9천 사이클까지 계속 줄어들고 있는 모습을 보이고 있다. 실험1에서 기존의 신경망을 이용한 호 수락 제어 방법 보단 SDM 신경망을 이용한 호 수락 제어 방법이 셀 손실률면에서 7.6% 낮아서 더 좋은 성능과 더불어 1000사이클(100초)이상 더 빠른 적응속도를 보였다. 실험2에서 클래스를 3개로 늘린 결과 활용률에서는 1%의 이내의 변화와 셀 손실률은 10% 미만의 변화를 보여서, 앞에서 제시한 기존의 제어기의 성능이 클래스에 민감하지 않음을 보였다. 이상으로 SDM은 별도의 학습 사이클이 필요치 않음으로 인한 빠른 적응력과 클래스 첨가에 대한 안정성을 보임을 확인할 수 있었다.

본 논문은 트래픽 발생 관련 함수를 부름으로서 수동적인 트래픽 발생을 사용하였다. 이러한 것에 대해 능동적이면서 리얼 타임 트래픽 발생 가능한 멀티 테스킹 프로그램과 하드웨어 트래픽 발생기·제어기의 구현 연구가 계속 되어져야 한다.

### 감사의 글

※ 본 논문은 1997년도 한국과학재단 핵심전문연구과제(971-0901-002-1) 지원에 의해 수행되었음.

### 참고 문헌

- [1] J.L. McClelland and D.E. Rumelhart, Parallel Distributed Processing, vol. 1: Foundations, Cambridge, MA, MIT Press, 1986.
- [2] HeeYong Kwon, "ATM Call Admission Control Using SDM", ICNN'97, vol. 2, pp. 1321-1325.
- [3] 강구홍, 김치하, "다층퍼셉트론을 이용한 ATM망에서의 연결수락제어", 정보과학회논문지(A) 23권, 12호, 1996
- [4] 이두현, 신요안, 김영한, "다른 QoS를 갖는 다중 서비스 클래스를 위한 신경망에 기반을 둔

ATM 호 수락 제어”, 전자공학회 추계종합 학술대회, 1995

[5] Phuoc T. and O. Gropp, “Structure and Performance of Neural Nets in Broad-band System Admission Control”, Neural Networks in Telecommunications, pp. 127-142, 1994.

[6] F. Yegenoglu, B. Habbari, and Y.Q. Zhang, “Motion-Classified Autoregressive Modeling of Variable Bit Rate Video”, IEEE Trans. on Circuits and Systems for Vide Tech, vol. 3, no. 1, pp. 42-53, Feb. 1993.

[7] B. Maglaris, D.Anastassiou, P.Sen, G.Karlsson, and J.Robbins, “Performance model of statistical multiplexing in packet video communications”, IEEE Trans. on Communi., vol. 36, pp. 834-844, July 1988.

[8] 강상혁, “ATM 트래픽 제어기술”, 전자공학회 지 제19권 제8호, 1992

[9] H. Heffes and D.M. Lucatoni, “A Markov modulated characterization of packetized voice and data traffic and related statistical multiplexer performance”, IEEE JSAC, vol. 4, no. 6, pp. 856-868, Sep. 1986.

[10] 성단근, “ATM 트래픽 엔지니어링”, 텔레콤, 제7권, 제2호, pp. 49-56, Nov. 1991

[11] P.Sen, B.Marglaris, N.Rikli, and D. Anastassou, “Models for Packet Switching of Variable-Bit-Rate Video Sources”, IEEE JSAC, vol. 7, no. 5, pp. 865-869, Jun. 1989.


[12] Pentti Kanerva, Sparse Distributed Memory, Cambridge, MA, MIT Press, 1988.

[13] Paolo Antognetti, Veljko Milutinovic, Neural Networks, Concepts, Applications, and Implementations, vol. IV, pp. 275-289, Prentice Hall, 1991.

저 자 소 개



**宋承俊(正會員)**  
 1973년 4월 17일생. 1996년 2월 호서대학교 전자공학과(공학사). 1998년 2월 호서대학교 대학원 전자공학과(공학석사). 주관심분야는 신경망, 컴퓨터 Interfacing



**權熙容(正會員)**  
 1960년 3월 10일생. 1983년 2월 서울대학교 전자계산기공학과(학사). 1985년 2월 서울대학교 전자계산기공학과(석사). 1993년 8월 서울대학교 전자계산기공학과(공학박사). 1986년 5월 ~ 1995년 8월 한국전기통신공사 연구개발원 연구원. 1995년 9월 ~ 현재 안양대학교 컴퓨터학과 조교수. 주관심분야는 신경망, 패턴인식



**李仁行(正會員)**  
 1973년 4월 22일생. 1997년 2월 호서대학교 전자공학과 졸업(공학사). 1997년 3월 ~ 현재 호서대학교 대학원 전자공학과 석사과정. 주관심분야는 신경망, 컴퓨터 응용



**崔在佑(正會員)**  
 1970년 8월 25일생. 1997년 2월 호서대학교 전자공학과 졸업(공학사). 1997년 3월 ~ 현재 호서대학교 전자공학과 석사과정. 주관심분야는 신경망, 컴퓨터 interfacing