

다중 서비스 트래픽을 위한 신경회로망 기반의 ATM 호 수락 제어

正會員 이 두 헌*, 신 요 안*, 김 영 한**

ATM Call Admission Control Based on a Neural Network for Multiple Service Traffics

Du-Hern Lee*, Yoan Shin*, Young-Han Kim** *Regular Members*

본 논문은 1995년도 과학재단 핵심전문연구과제 (번호 951-0913-058-1) 지원에 의해 수행되었음

요 약

본 논문은 ATM (asynchronous transfer mode)을 기반으로 한 광대역종합정보통신망에서 서로 다른 QoS (quality of service)를 갖는 다중 트래픽을 위한 신경회로망 기반의 새로운 적응적 ATM 호 수락 제어 알고리즘을 제안한다. 제안된 방법은 기존의 신경회로망 기반의 호 수락 제어 방법인 Hiramatsu의 “리키 패턴 테이블 (leaky pattern table)” 방법[1, 2, 3]을 확장한 방법이며, 기존의 방법이 다중 트래픽에 대해서 단지 하나의 목표 QoS 만을 허락함으로써 효과적이고 유연한 호 수락 제어가 어려웠으나, 본 논문에서는 호 승인 요구 시 각 서비스의 승낙 여부에 따라 여러 개의 패턴 테이블을 구성하고, 각 서비스의 QoS를 각 서비스의 목표 QoS와 트렁크 용량을 고려하여 동시에 제어함으로써 이 단점을 극복하였다. 제안된 방법의 성능과 효율성은 서로 다른 트래픽 특성을 갖는 두 개의 서비스에 대해 QoS로서 두 개의 서로 다른 셀손실률을 고려한 컴퓨터 시뮬레이션을 통하여 확인되었다.

ABSTRACT

This paper proposes a new approach to adaptive call admission control based on a neural network for multiple service classes with different quality of service (QoS) in the ATM-based Broadband Integrated Services Digital Networks. The proposed method extends Hiramatsu's neural network based “leaky pattern table” method for the

*승실대학교 전자공학과

Department of Electronic Engineering

**승실대학교 정보통신공학과

Department of Information and Telecommunication
Engineering

論文番號: 96141-0503

接受日字: 1996年 5月 3日

single QoS[1, 2, 3] to deal with multiple services with different QoS by constructing multiple pattern tables based on each service's acceptance or rejection at the call set-up requests, and by simultaneously controlling each service's QoS according to the target QoS of the service and the trunk capacity. Computer simulation results on two service classes with different traffic characteristics and different cell loss rates as QoS, highlight good performance and effectiveness of the proposed call admission controller for multiple service classes.

기 호 목 록

t : unit time (1 msec)
 T_0 : control or sampling time (100 msec)
 cgr : call generation rate in a unit time
 ctr : call termination rate in a unit time
 m : number of cells the link can transmit in a unit time
 a : number of total cells generated in a control time
 l : number of cells lost in a control time
 n_j : number of connected calls in a control time for service class j
 dn_j : call increment in a control time for service class j
 $total_loss$: total cell loss rate in a control time
 avg_loss_j : cell loss rate in a control time for service class j
 $target_loss_j$: target cell loss rate for service class j
 NN_out : neural network output

I. 서 론

ATM (asynchronous transfer mode)에서의 QoS (quality of service) 제어에 대한 전통적인 접근 방법에서는 제어 알고리즘과 관측되어야 하는 모든 변수들을 결정하기 위하여 발생 가능한 모든 경우에 대한 자세한 분석이 필요하다[4]. 하지만 이러한 접근 방법으로는 능률적이고 유연한 ATM 트래픽 제어를 하기에는 여러 가지 어려운 점들이 있다. 예를 들면, 기존 서비스들의 뜻밖의 변동이나 새로운 서비스들을 수용하여 변동되는 트래픽 특성에 적절히 적용시킬 수 없다[1, 2, 3]. 호 수락 제어의 목표는 가능한 한 많은 호를 연결시키면서도 만약 새로운 호 설정에 의해 기존의 호들에 대한 QoS를 악화시키게 될 경우 새로운 호 설정 요구를 거절함으로써 이미 연결되어 있는 여러 호들의 서비스 품질을 유지하는 것이다. 이러한

제어의 핵심은 새로운 호 설정 요구에 대한 수락 후에 추측되는 QoS의 정확한 판단에 있다. 즉, 끊임없이 망의 상태 (예를 들면 전송 지연, 셀 손실률 등)를 감시하여 그것을 통해 새로운 호 설정 가능성을 판단해야 한다.

신경회로망 (neural network)은 여러 변수들이 상호 복잡적으로 관련된 매우 복잡한 입력-출력 특성을 갖는 미지의 시스템에서, 주어진 학습 데이터와 적응적인 학습 알고리즘을 통해 근사해에 도달할 수 있다는 특징을 갖는다[5]. 이러한 신경회로망의 "학습 능력"은 자율적으로 입력들을 선택하고 입력 데이터로부터 특정 변수들을 이끌어냄으로써 관측된 트래픽으로부터 자동적으로 QoS를 예측하는 데에 사용될 수 있으며, [1, 2, 3, 6]에서의 접근 방법이 바로 이러한 신경회로망의 적응적 학습 능력을 ATM에서의 호 수락 제어에 적용한 예가 될 수 있다. 특히 ATM 호 수락 제어를 위한 Hiramatsu의 방법[1, 2, 3]은 다중 서비스 클래스들의 트래픽을 주어진 트렁크 용량 (trunk capacity)에 대해 손실이 발생하는 경우와 발생하지 않는 경우로 분류하여 각각에 대한 "패턴 테이블 (pattern table)"을 작성 후, 이들을 이용하여 신경회로망을 학습함으로써 자주 발생하는 손실이 없는 경우에 편중되지 않고 균등하게 신경회로망을 온라인 학습할 수 있도록 하는 방법이다. 하지만 이 방법의 단점으로서 모든 서비스 클래스에 대해 유일한 QoS를 적용한다는 점을 들 수 있다.

신경회로망의 학습 방법에는 오프라인 학습 방법과 온라인 학습 방법이 있다[3, 5]. 오프라인 학습 방법은 실제 시스템이나 모델로부터 얻어진 데이터를 가지고 신경회로망을 학습시킨 후 실제 이용 시에는 더 이상의 학습이 이루어지지 않는 방법이다. 반면, 온라인 학습 방법은 실제 작동되는 시스템으로부터 얻어진 데이터를 이용하여 실시간으로 신경회로망의 학습과 이용을 병행하는 방법이다. 일반적으로 시물

레이션과 실제 상황 혹은 사용자 선언 트래픽 파라미터들 사이에 차이가 존재하기 때문에, 이러한 차이를 해결하기 위해 온라인 학습 방법을 이용하는 것이 더욱 바람직하다고 볼 수 있다[1]. 본 논문에서는 Hiramatsu의 방법을 확장하여 다중 서비스 클래스가 각기 다른 QoS를 갖는 경우에 대해 온라인 학습 방법을 이용한 신경회로망 호 수락 제어 방법을 제안하고, 이의 성능을 시뮬레이션을 통하여 입증하였다. 서론에 이어 본 논문은 2장에서 신경회로망을 이용한 Hiramatsu의 호 수락 제어 방법을 간략히 기술하고, 3장에서는 2장에서 기술된 호 수락 제어 알고리즘을 기초로 다른 QoS를 갖는 다중 서비스 클래스에 대한 확장된 호 수락 제어 알고리즘을 제안하며, 4장에서는 본 논문에서 사용한 알고리즘을 통한 컴퓨터 시뮬레이션 결과와 고찰, 그리고 마지막으로 5장에서는 결론을 내린다.

II. 신경회로망을 이용한 호 수락 제어-Hiramatsu의 리키 패턴 테이블 (Leaky Pattern Table) 방법

호 수락 제어의 목표는 망의 현재 상태 및 호 생성을 요구하는 서비스의 특성을 토대로 이미 연결된 서비스 품질을 보장하면서 새로운 호를 연결할 수 있는지 판단하여 연결을 수락 혹은 거절하도록 하는 것이다[4]. ATM망에서는 다양한 트래픽 특성의 서비스들이 효과적으로 제어되어야 하며, 이를 위해 유연하고 동적인 호 수락 제어가 필요하다. 이러한 유연한 제어를 위한 신경회로망 기반의 호 수락 제어기를 그림 1에 나타내었다[2]. 신경회로망은 최적의 호 수락 결정점을 동작 상태에서 적응적으로 학습하여 호 요구에 대해 수락여부를 결정하는데 필요한 제어값을 출력시킨다. 이를 위하여 사용자 단말기들은 데이터를 전송하기 전에 수락 제어기에 호 수락 요청을 하고 호의 트래픽 특성 (평균 비트율, 최대 비트율 등)과 요구되는 서비스 품질 (최대 셀손실률, 최대 셀지연률 등)을 알리면, 신경회로망 기반 수락 제어기는 요구된 호를 분류하고 요구 사항과 관측된 트래픽 데이터에 포함된 정보를 이용하여 수락 여부를 결정한다.

Hiramatsu에 의해 [1, 2, 3]에서 제안된 신경회로망을 이용한 호 수락 제어 방법은 매 시간 ATM 망으로

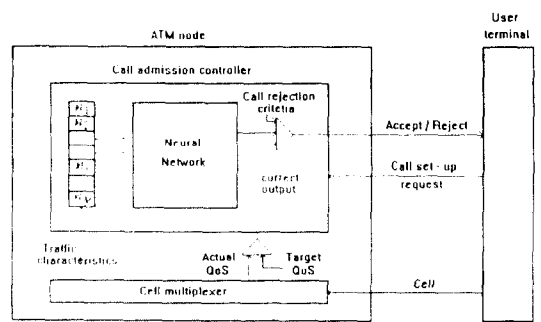


그림 1 신경회로망을 이용한 일반적인 호 수락 제어 알고리즘[1].

Fig. 1 A general call admission control algorithm using a neural network[1].

들어오는 다중 서비스 클래스 트래픽을 직접 신경회로망의 온라인 학습에 사용하지 않고, 주어진 트렁크 용량에 대해 손실을 발생하는 트래픽과 발생하지 않는 트래픽으로 분류하여 각각에 대한 패턴 테이블을 작성한다. 분류된 트래픽은 이러한 패턴 테이블을 개선하는데 사용되며, 이렇게 개선된 해당 테이블에서 다시 랜덤하게 선택된 트래픽 패턴이 신경회로망의 학습에 사용되게 된다. 이러한 방법을 통하여 넓은 시간에 걸쳐 있는 다양한 트래픽 특성을 고려한 학습이 가능해져, 결국 특정 시간에 밀집되어 들어오는 트래픽 특성에 대하여 학습이 지우치는 현상을 방지하여 어떠한 상황 변화에도 적응적으로 대응할 수 있는 간단하고 유연한 호 수락 제어를 구현할 수 있다.

신경회로망 학습 데이터 선택 시 오래된 패턴들의 영향을 효과적으로 없애기 위해 [1, 2, 3]에서는 "리키 패턴 테이블 (leaky pattern table)" 방법을 사용하였다. 이 방법은 새로 들어온 트래픽 패턴에 대해 해당 패턴 테이블이 모두 채워져 있지 않다면 새로운 트래픽 패턴을 해당 패턴 테이블의 맨 끝에 채워넣고, 해당 패턴 테이블이 모두 채워져 있다면 단순히 가장 오래된 트래픽 패턴을 버리고 새로운 트래픽 패턴을 삽입하는 대신 임의의 확률을 가지고 임의의 위치에 새로운 트래픽 패턴을 삽입하고 이미 있던 트래픽 패턴을 버리는 방법이다.

그러나 이 방법의 가장 큰 단점으로 지적될 수 있는 것은 각기 다른 QoS를 갖는 다중 서비스 클래스에

대한 호 수락 제어가 가능하지 않다는 점이다. 즉 [1, 2, 3]에서는 다중 서비스 클래스에 대해 단지 하나의 QoS (전체 셀손실률)만을 고려하여 이에 맞게 신경회로망을 최적화 하도록 알고리즘이 설계되었으나, 실제의 경우에 있어서는 각기 다른 서비스 클래스가 각기 다른 QoS를 갖는 경우가 일반적이라 할 수 있다. 예를 들어, 음성 신호와 텍스트 데이터 각각의 클래스는 서로 다른 목표 셀손실률 (예로 음성 신호는 10^{-4} , 텍스트 데이터는 10^{-6})을 가질 수 있으며, 이러한 경우에 대해 효과적으로 대처하는 호 수락 제어 알고리즘이 필요하다. 다음 3장에서는 [1, 2, 3]의 방법을 확장하여 각기 다른 QoS를 갖는 다중 서비스 클래스를 위한 효과적인 신경회로망 호 수락 제어 알고리즘을 제안한다.

Ⅲ. 다른 QoS를 갖는 다중 서비스 클래스에 대한 호 수락 제어

각기 다른 QoS를 갖는 다중 서비스 클래스에 대한 신경회로망을 이용한 호 수락 제어의 목표는 주어진 트렁크 용량을 효율적으로 이용하여 다중 서비스들의 서로 다른 QoS를 모두 만족시켜야 한다는 것이다. QoS로는 셀지연 시간과 셀손실률이 가능하며 일반적으로 셀지연 시간은 셀 버퍼의 크기를 제한하여 만족시키게 된다. 그러므로 호 수락 제어는 주어진 자원을 최대한 활용하면서 수락된 호의 셀손실률을 만족시킬 수 있도록 요구되는 호의 수락 여부를 결정하는 것이다. 이를 위하여 각 트래픽 클래스별로 트렁크 용량 등의 자원을 분할, 할당하고 할당된 범위 내에서 각 트래픽 클래스별로 호 요청을 셀손실률을 만족할 경우 수락하도록 제어하는 complete partitioning 방식의 자원 분배와 호 수락 제어가 제안되었다. 그러나 이 방식은 자원을 고정적으로 분할 시 부하가 높은 트래픽의 경우는 자원이 낭비되고 반대로 부하가 높은 트래픽의 경우는 호 거부율이 높아지는 단점이 있다. 이를 개선하는 방법으로 여러 가지 자원 분할 방법이 있을 수 있으며, 이들 방법의 공통적인 사항은 주어진 자원을 여러 클래스의 트래픽이 공유하도록 하는 complete sharing방법을 함께 사용하는 방식이다[7, 8].

본 논문에서는 호 수락 제어의 범위를 이러한 결정

에 의해 공유하도록 주어진 트렁크 용량을 M 개의 서비스 트래픽이 공유하는 경우를 고려하였다. 즉, 다른 트래픽 특성을 갖는 M 개의 서비스 클래스를 고려하여 ATM망의 주어진 트렁크 용량을 1로 정규화 하였을 때, 각 서비스 클래스들은 서로 부하가 동일할 경우 평균적으로 트렁크 용량의 $1/M$ 씩을 차지한다고 가정한다. 또한 각 서비스 클래스의 QoS로서 셀손실률을 고려하며, 셀손실은 아래에 정의되는 세 가지 유형의 가중치 $p_j^{(i)}(i=1, 2, 3, j=1, 2, \dots, M)$ 에 따라 각 서비스 클래스의 셀 손실되도록 제어하도록 한다.

- 각 서비스 클래스의 목표 셀손실률을 고려한 경우:

$$p_j^{(1)} = \frac{\text{target_loss}_j}{\sum_{k=1}^M \text{target_loss}_k}, (j=1, 2, \dots, M) \quad (1)$$

- 연결되어 있는 호의 개수를 고려한 경우:

$$p_j^{(2)} = \frac{n_j}{\sum_{k=1}^M n_k}, (j=1, 2, \dots, M) \quad (2)$$

- 위의 두 경우 모두를 고려한 경우:

$$p_j^{(3)} = \frac{\text{target_loss}_j}{\sum_{k=1}^M \text{target_loss}_k} \times \frac{n_j}{\sum_{k=1}^M n_k}, (j=1, 2, \dots, M) \quad (3)$$

가중치 $p_j^{(1)}$ 은 각 서비스 클래스의 목표 셀손실률에 비례하여 각 서비스 클래스의 셀손실률 계산에 가중치를 두며, 신경회로망을 각 서비스 클래스의 목표 셀손실률에 맞도록 적용시킨다. 반면 가중치 $p_j^{(2)}$ 는 실제로 연결되어 있는 각 서비스 클래스의 호의 개수에 비례하여 각 서비스 클래스의 셀손실률 계산에 작용하고, 따라서 해석적으로 결정되는 수락-거절 경계를 신경회로망이 학습하도록 적용시킨다. 마지막으로 가중치 $p_j^{(3)}$ 은 목표 셀손실률과 해석적 결정 모두를 고려함으로써 앞서의 두 가중치의 효과를 동시에 나타내도록 $p_j^{(1)}$ 과 $p_j^{(2)}$ 를 곱한 형태이다.

제안된 호 수락 제어 알고리즘은 매 표본 시간 ($T_0 = 100$ msec)마다 패턴 테이블의 개선과 신경회로망 학습을 온라인으로 수행하며, 이 때 M 개의 신경회로

망 입력은 매 표본 시간에서의 각 서비스 클래스의 연결되어 있는 호의 개수로 구성된다. M 개의 서비스 클래스에 대해 패턴 테이블은 각 서비스 클래스의 호 설정 요구에 대한 수락 (A) 혹은 거절 (R) 여부에 따라

$$(A, A, \dots, A), (R, A, \dots, A), \dots, (R, R, \dots, R) \quad (4)$$

등과 같이 총 2^M 개로 구분된다. 이러한 패턴 테이블들의 각 원소는 다음 식 (5)와 같이 신경회로망 입력으로서 해당 표본 시간에서의 M 개 서비스 클래스의 연결된 호의 개수 (새로운 호 증가 요구분 포함)와 신경회로망 목표 출력 (desired output) 계산을 위해 아래 식 (6)과 같은 M 개의 셀 손실률들로 이루어진다.

$$n_1 + dn_1, n_2 + dn_2, \dots, n_M + dn_M \quad (5)$$

$$avg_loss_1, avg_loss_2, \dots, avg_loss_M \quad (6)$$

위에서 j 번째 서비스 클래스의 셀손실률 avg_loss_j ($j=1, \dots, M$)는 식 (7)과 같이 앞서 구한 가중치 $p_j^{(i)}$ 를 전체 셀손실률에 곱하여 얻어진다.

$$avg_loss_j = p_j^{(i)} \times total_loss \quad (7)$$

매 표본 시간마다 패턴 테이블의 개선과 신경회로망 학습이 이루어지는데, 이 때 2^M 개의 패턴 테이블 가운데 하나를 랜덤하게 선택하고, 이 선택된 패턴 테이블 내에서 입력 데이터 역시 랜덤하게 선택하여 끊임없이 변화하는 트래픽 환경에 대한 신경회로망의 적응성을 더욱 높게 된다. 신경회로망은 앞서 언급된 대로 M 개의 입력 뉴런과 역시 M 개의 출력 뉴런을 가지며, 각 출력 뉴런의 목표 출력 값 d_j ($j=1, \dots, M$)는 실제 셀 손실률과 목표 셀손실률과의 관계로부터 다음과 같이 정의된다.

$$d_j = \begin{cases} 0 & \text{if } avg_loss_j < target_loss_j \\ 1 & \text{if } avg_loss_j \geq target_loss_j \end{cases} \quad (8)$$

위의 논의를 바탕으로 아래 그림 2는 매 표본 시간마다의 호 수락 제어 알고리즘의 시뮬레이션 과정을 도시한다.

제안된 호 수락 제어 알고리즘의 각 단계별 시뮬레

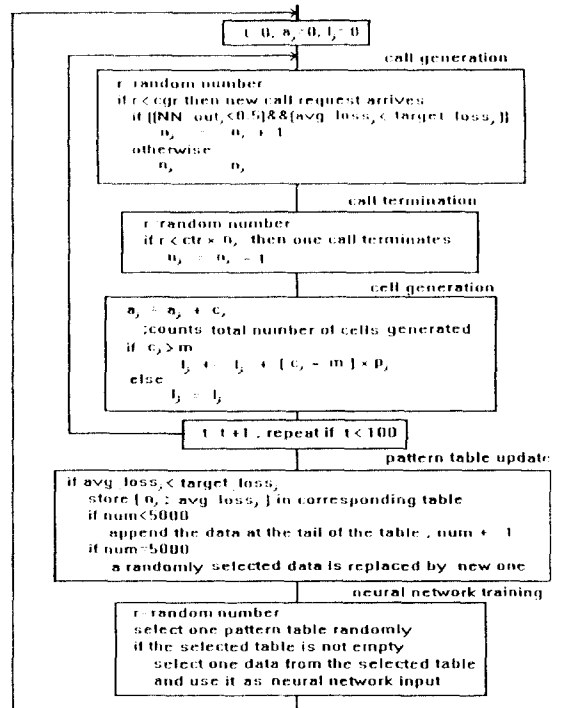


그림 2 제안된 호 수락 제어 알고리즘의 시뮬레이션 과정.
Fig. 2 The simulation sequence of the proposed call admission control algorithm.

이션 과정은 아래와 같다.

- 호 생성 단계: 시뮬레이션을 통하여 랜덤하게 발생하는 호 요구가 신경회로망을 이용한 제안된 호 수락 제어 방법에 의하여 적절히 수락 또는 제어되는 것을 살펴보기 위해 호발생은 랜덤하게 이루어지도록 하였다. 발생한 호는 신경회로망의 출력 값에 의해 수락이 결정되게 한다. 수락 시에만 전체 개설된 유형 j 의 호 n_j 가 1증가된다.
- 호 소멸 단계: 망에 연결된 각 서비스 클래스에 대한 호들의 망 접속 지속 시간은 평균 지속 시간이 100 sec인 지수분포를 갖는다고 가정하였다(표 1 참조). 매 시뮬레이션 단위 시간마다 n 개의 접속된 호에 대하여 계산된 호 지속 시간이 시뮬레이션 단위 시간보다 작을 경우 개설된 호의 수가 감소된다.
- 셀 생성 단계: 호 단위의 수락과 소멸 과정을 시뮬레이션한 후 신경회로망의 패턴 테이블의 개선과

학습을 위한 셀 단위의 동작을 시뮬레이션 과정에 포함시켰다. 먼저 시뮬레이션 단위 시간 동안 입력되는 셀의 개수와 손실되는 개수를 고려하기 위하여 셀 발생량과 트렁크 용량을 초과한 양에 대한 각 클래스별 손실률을 구하였다.

- 패턴 테이블의 개선 및 신경회로망 학습 단계: 대표본 시간마다 리키 패턴 테이블 방법에 의하여 입력 트래픽에 해당되는 패턴 테이블의 갱신이 이루어지고 이 패턴 테이블의 임의의 위치에서 선택된 패턴이 신경 회로망의 입력으로 사용된다. 본 논문에서 사용된 리키 패턴 테이블 방법을 그림 3에서 나타내었다.

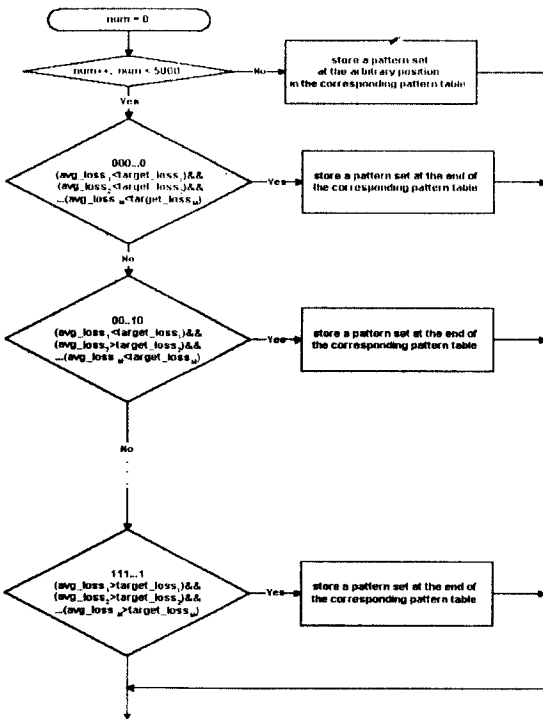


그림 3 본 논문에서 사용된 리키 패턴 테이블 방법.
Fig. 3 The leaky pattern table method used in this paper.

IV. 컴퓨터 시뮬레이션 결과 및 고찰

제한된 호 수락 제어 알고리즘의 성능을 평가하기 위해서, 다른 트래픽 특성을 갖는 두 개 ($M=2$)의 서

비스 클래스를 가정하고 이들 서비스 클래스에 각기 다른 목표 셀손실률을 QoS로 사용하여 그림1의 절차에 따라 컴퓨터 시뮬레이션을 수행하였다. 사용되는 패턴 테이블의 개수는 $2^M=4$ 이다. 시뮬레이션에 관한 세부적인 내용은 아래와 같다.

- 호 생성과 소멸 모델: 모든 호들은 랜덤하게 발생, 도착한다. 예를 들면, 각 서비스에 대한 호 생성률이 5 calls/sec이면, 시뮬레이션 단위 시간이 1 msec 이므로 단위 시간 당 평균 0.05개의 호가 발생한다고 생각할 수 있다. 호의 소멸 역시 랜덤하게 이루어진다. 만약 호 지속 시간이 100 sec이고 10개의 호가 연결되어 있다면, 평균적으로 단위 시간당

표 1. 시뮬레이션에 사용된 서비스 1과 2 트래픽의 통계적 특성.

Table 1. Statistical characteristics of service 1 and 2 traffics used in the simulation.

	서비스 클래스 1	서비스 클래스 2
평균 비트율 (트렁크 용량=1로 가정)	$v_1=0.001$	$v_2=0.01$
호 생성률	$n_1 v_1=0.5$	$n_2 v_2=0.5$
비트 변동률	$b_1=0.2$	$b_2=0.1$
호 지속 시간	평균 100 sec. 지수 분포	




그림 4 서비스 1의 호 생성률 (트렁크 용량을 1로 정규화).
Fig. 4 Call generation rate of service 1 (Trunk capacity is normalized to 1).




그림 5 서비스 2의 호 생성률 (트렁크 용량을 1로 정규화).
Fig. 5 Call generation rate of service 2 (Trunk capacity is normalized to 1).

10^{-4} 개의 호가 소멸된다. 서비스 클래스 1과 2에 대한 목표 셀손실률은 각각 10^{-4} , 10^{-6} 으로 설정하였다. 다음의 표 1은 서비스 클래스 1과 2의 통계적 특성을 정리하여 보여 주며, 그림 4, 5는 시뮬레이션에 사용된 각각의 서비스 클래스의 호 생성률변화를 나타낸다.

- 초기 패턴 테이블: 초기의 패턴 테이블은 모두 비어 있다. 즉 각 서비스 클래스에 대하여 초기에 연결되어 있는 호의 개수 n 은 0이다. 신경회로망은 임의의 작은 n 에 대하여도 셀손실률을 판단하는데, 초기의 새로운 호 설정 요구는 어느 시간까지는 모두 수락되다가 어느 정도 호의 개수가 증가하면 전체 연결된 호의 트래픽이 ATM망의 트렁크 용량을 넘게 되며 이 때부터 각 서비스 클래스에 대하여 셀손실이 발생하게 되고 새로운 호 설정 요구에 대하여 거절하는 경우가 발생한다. 각각의 패턴 테이블은 5,000개의 패턴들이 저장될 수 있도록 하였고, 5,000개의 패턴들이 모두 차게 되면 리키 패턴 테이블 방법에 의하여 패턴 테이블의 개선이 이루어진다.
- 신경회로망: 신경회로망 모델로는 여러 응용 분야에 널리 사용되고 있는 다중계층퍼셉트론 (multi-layered perceptron)[5]을, 그리고 학습 알고리즘으로는 backpropagation 학습 알고리즘[5]을 사용하였다. Backpropagation 학습 알고리즘은 gradient descent 방법의 하나로서 이 알고리즘의 단점 중의

하나는 국지 최소값(local minimum)에 빠질 염려가 있다는 것이다. 이를 개선하기 위하여 본 시뮬레이션에서는 모멘텀 항[5]을 추가하였고 연결 강도의 초기 값을 임의로 주어 신경회로망 학습 시 국지 최소 값에 빠지는 것을 방지하였다. 신경회로망은 2개의 입력층 뉴런, 8개의 중간층 뉴런, 그리고 2개의 출력층 뉴런을 가지며, 입력으로는 식 (5)와 같이 해당 제어 시간 내의 서비스 클래스 1과 2의 연결된 호의 개수를 그리고 목표 출력으로는 서비스 클래스 1과 2의 실제 셀손실률과 목표 셀손실률에 따라 식 (8)에서처럼 0이나 1을 이용하였다. 학습 알고리즘에서 학습률 $\eta=0.1$, 모멘텀 상수 $\alpha=0.6$ 을 사용하였다. 제어 주기는 표본 시간과 같으며 이 때마다 신경회로망에 의한 온라인 학습이 이루어진다.

- 결과: 다음의 그림 6-17는 3장에서 고려된 각 가치 $p_j^{(i)}$ ($i=1, 2, 3, j=1, 2$)를 이용할 경우의 시뮬레이션 결과를 보여준다. 이 결과에서 주의하여야 할 점은 ATM 호 수락 제어에 있어서 complete partitioning 방법이 많이 이용되고 있으며[7], 이 방법을 사용하면 대부분의 경우에 있어서 새로운 서비스를 요구하는 호들을 거절함으로써 정확하게 QoS를 만족시킬 수는 있지만, 전체 트렁크 용량의 이용을 극대화할 수가 없다는 것이다. 이와는 반대로 본 논문의 결과인 그림 6-17은 매우 동적으로 변화하는 ATM망에서의 트래픽들을 complete sharing 방법[8]을 이용하여 제어하기 때문에 전체 시스템의 트렁크 용량을 극대화 할 수 있다. 이를 뒷받침하기 위하여 학습이 끝난 신경회로망을 이용한 호 수락 제어 결정 경계와 해석적 방법에 의한 호 수락 제어 결정 경계를 함께 나타내어 비교하였다. 다음 그림에서 사용된 해석적인 방법에 의한 호 수락 제어의 결정 경계에 대한 식은 아래와 같다[1].

$$n_1 v_1 (1 + b_1) + n_2 v_2 (1 + b_2) = 1 \tag{9}$$

그림 6, 7, 10, 11, 14, 15는 각각의 서비스 종류에 따른 셀손실률을 나타내며, 그림 8, 9, 12, 13, 16, 17은 각기 다른 QoS를 갖는 다중 클래스에 대한 신경회로망을 이용한 호 설정 제어가 해석적인 방법과 실제로 얼마나 일치하는가를 보여주고 있다. 그림 8, 9,




그림 6 서비스 1의 셀 손실률, $p_j^{(1)}$ 사용.
Fig. 6 Cell loss rate for service 1 when using $p_j^{(1)}$.




그림 8 출력뉴런 1의 결정경계, $p_j^{(1)}$ 사용.
Fig. 8 Decision boundary from the first output neuron when using $p_j^{(1)}$.




그림 7 서비스 2의 셀 손실률, $p_j^{(1)}$ 사용.
Fig. 7 Cell loss rate for service 2 when using $p_j^{(1)}$.




그림 9 출력뉴런 2의 결정경계, $p_j^{(1)}$ 사용.
Fig. 9 Decision boundary from the second output neuron when using $p_j^{(1)}$.




그림 10 서비스 1의 셀 손실률, $p_j^{(2)}$ 사용.
Fig. 10 Cell loss rate for service 1 when using $p_j^{(2)}$.




그림 12 출력뉴런 1의 결정경계, $p_j^{(2)}$ 사용.
Fig. 12 Decision boundary from the first output neuron when using $p_j^{(2)}$.




그림 11 서비스 2의 셀 손실률, $p_j^{(2)}$ 사용.
Fig. 11 Cell loss rate for service 2 when using $p_j^{(2)}$.




그림 13 출력뉴런 2의 결정경계, $p_j^{(2)}$ 사용.
Fig. 13 Decision boundary from the second output neuron when using $p_j^{(2)}$.




그림 14 서비스 1의 셀 손실률, $p_j^{(3)}$ 사용.
Fig. 14 Cell loss rate for service 1 when using $p_j^{(3)}$.




그림 16 출력뉴런 1의 결정경계, $p_j^{(3)}$ 사용.
Fig. 16 Decision boundary from the first output neuron when using $p_j^{(3)}$.




그림 15 서비스 2의 셀 손실률, $p_j^{(3)}$ 사용.
Fig. 15 Cell loss rate for service 2 when using $p_j^{(3)}$.




그림 17 출력뉴런 2의 결정경계, $p_j^{(3)}$ 사용.
Fig. 17 Decision boundary from the second output neuron when using $p_j^{(3)}$.

12, 13, 16, 17에서 사선의 아래 부분은 새로운 호 설정 요구에 대한 수락률, 위 부분은 거절을 나타낸다.

예상했던 대로 가중치 $p_j^{(1)}$ 을 사용했을 때에는 각각의 목표 셀손실률에 가중치를 두었기 때문에 각 클래스가 각각의 목표 셀손실률에 매우 근접하나 트렁크 용량을 효율적으로 사용하지 못해 결정 경계가 이론적인 값에 상당히 벗어나며, 가중치 $p_j^{(2)}$ 을 사용했을 때에는 서비스 종류와 목표 셀손실률에는 상관없이 호가 많이 연결되어 있는 서비스 클래스에 대하여 셀손실률을 많이 주었기 때문에 각각의 목표 셀손실률에는 미치지 못하나 이론적인 값에 근접한 결정 경계를 얻을 수 있었으며, 가중치 $p_j^{(3)}$ 을 사용했을 때에는 각각의 목표 셀손실률과 함께 이상적인 결정 경계를 잘 근사하여 호 설정 수락 제어도 비교적 잘 이루어지고 있음을 알 수 있었다. 이 결과를 [9, 10]에서 우리가 제안한 방법을 신경회로망의 입력 데이터를 랜덤하게 선택하지 않고 새로운 호 증가 조건으로 신경회로망 출력만을 고려한 방법과 비교해 볼 때, 특히 각 클래스에 대한 셀손실률 면에서 상당한 진전을 보이면서도 결정 경계에 있어서도 해석적인 방법에 거의 근접함을 볼 수 있었다. 결국 complete sharing 방법에 기반을 두고 앞서 제안된 여러 가지 가중치를 이용할 경우, 본 제안 방법은 다른 QoS를 갖는 다중 서비스 클래스에 대해 목표 셀손실률과 정확한 판단 경계의 학습을 통한 효율적인 트렁크 용량의 이용을 동시에 만족하는 효과적인 호 수락 제어를 수행할 수 있음을 볼 수 있었다.

V. 결 론


본 논문에서는 ATM망에서 각각 다른 QoS를 요구하는 다중 서비스 클래스에 대한 호 설정 수락 제어에 있어서 Hiramatsu의 방법[1, 2, 3]을 확장한 신경회로망 기반의 새로운 제어 방법을 제안하였다. [1, 2, 3]의 방법은 여러 다른 QoS를 갖는 서비스 클래스들에 대해 유일한 QoS만을 허락하는 단점을 지니고 있으며, 본 논문의 제안 방법은 complete sharing 방법에 기반을 두고 전체 셀 손실률로부터 가중치를 이용하여 각 서비스 클래스에 해당하는 셀 손실률을 추정하고, 각 서비스 클래스의 호 수락/거절 여부에 따라 여러 개의 패턴 테이블을 사용하므로써 이러한 단점을

극복하였다. 특히, 가중치 $p_j^{(3)}$ 을 사용했을 때에는 다른 QoS를 갖는 다중 서비스에 대해 목표 셀 손실률과 함께 정확한 판단 경계의 학습을 통한 효율적인 트렁크 용량의 이용에 있어서 효과적인 호 수락 제어를 수행할 수 있음을 볼 수 있었다.

참 고 문 헌

1. A. Hiramatsu, "ATM communications network control by neural networks," *IEEE Trans. Neural Networks*, Vol. 1, pp. 122-130, 1990.
2. B. Yuhua & N. Ansari (Eds.), *Neural Networks in Telecommunications*, Ch. 4, Kluwer Academic Publisher, 1994.
3. T. Takahashi and A. Hiramatsu, "Integrated ATM traffic control by distributed neural networks," *IEEE Jour. Sel. Areas in Commun.*, Vol. 9. pp. 1131-1138, 1991.
4. 이병기, 강민호, 이종희, 광대역 정보 통신, 교학사, 1995.
5. J. Hertz, A. Krogh and R. G. Palmer, *Introduction to the Theory of Neural Computation*, Addison Wesley, 1991.
6. R. J. T. Morris, "Neural network control of communications systems," *IEEE Trans. Neural Networks*, Vol. 5, pp. 639-649, 1994.
7. 원영주, 이원우, 김영삼, 유근호, 김승희, "ATM 다원 트래픽 제어를 위한 이중 신경 회로망 모델," 대한전자공학회 추계종합학술대회 논문집, pp. 397-409, 1994.
8. Y. H. Kim and C. K. Un, "Analysis of bandwidth allocation strategies with access restrictions in broadband ISDN," *IEEE Trans. Commun.*, Vol. 5, pp. 771-781, 1993.
9. 이두현, 신요안, 김영한, "다른 QoS를 갖는 다중 서비스 클래스를 위한 신경망에 기반을 둔 ATM 호 수락 제어," 대한전자공학회 추계종합학술대회 논문집, pp. 73-76, 1995.
10. D. -H. Lee, Y. Shin and Y. -H. Kim, "A neural network based ATM call admission controller for multiple service classes with different QoS," *Proc.*

Int'l Conf. Neural Networks, Vol. 4, pp. 2142-2147,
Washington D. C., June 1996.



이 두 현(Du-Hern Lee) 정회원
1990년 3월~1995년 2월: 숭실대
학교 공과대학 전자
공학과(공학사)
1995년 3월~현재: 숭실대학교 대
학원 전자공학과 석
사과정
※ 관심분야: ATM 트래픽 제어,
신경회로망 응용

신 요 안(Yoan Shin) 정회원
현재: 숭실대학교 전자공학과 조교수
한국통신학회논문지 20권 12호 참조

김 영 한(Young-Han Kim) 정회원
현재: 숭실대학교 정보통신공학과 조교수
한국통신학회논문지 21권 3호 참조