

퍼지 신경망을 이용한 ATM 망의 호 수락 제어 시스템의 설계

유재택[†] · 김춘섭^{††} · 김용우^{†††} · 김영한^{††††} · 이광형^{††}

요약

본 논문에서는 호 수락 제어 문제를 해결하기 위해 퍼지 논리 제어기의 장점과 신경망의 학습 능력을 이용한 ATM 망의 호 수락 제어 시스템을 제안하였다. ATM 망의 새로운 호는 현재 서비스 중인 호의 서비스 품질(QoS: quality of service)이 영향을 받지 않을 경우 망에 접속이 된다. 신경망 호 수락 제어 시스템은 입/출력 패턴의 학습으로 예측성 있게 호 수락/거절을 하는 시스템이다. 본 논문의 퍼지 신경망 호 수락 제어 시스템에서는 학습 속도 개선을 위해 학습율과 모멘텀 상수에 퍼지 추론을 적용하였다. 이 시스템은 시뮬레이션을 통해 기존의 신경망 방법과 퍼지 신경망 방법에서의 학습 횟수 측정으로 제안 알고리즘의 우수성을 검증하였다. 시뮬레이션 결과 퍼지 학습 규칙에 근거한 퍼지 신경망 CAC(call admission control) 방식이 종래의 신경망 이론에 근거한 CAC 방식보다 학습 속도면에서 약 5배의 속도 향상이 있었다.

Design of the Call Admission Control System of the ATM Networks Using the Fuzzy Neural Networks

Jae-Taek Yoo[†] · Choon-Seop Kim^{††} · Yong-woo Kim^{†††} ·
Young-Han Kim^{††††} · Kwang-Hyung Lee^{††}

ABSTRACT

In this paper, we proposed the FNCAC (fuzzy neural call admission control) scheme of the ATM networks which used the benefits of fuzzy logic controller and the learning abilities of the neural network to solve the call admission control problems. The new call in ATM networks is connected if QoS(quality of service) of the current calls is not affected due to the connection of a new call. The neural network CAC(call admission control) system is predictable system because the neural network is able to learn by the input/output pattern. We applied the fuzzy inference on the learning rate and momentum constant for improving the learning speed of the fuzzy neural network. The excellence of the proposed algorithm was verified using measurement of learning numbess in the traditional neural network method and fuzzy neural network method by simulation. We found that the learning speed of the FNCAC based on the fuzzy learning rules is 5 times faster than that of the CAC method based on the traditional neural network theory.

[†] 정회원: 멀티미디어 교육지원센터

^{††} 정회원: 숭실대학교 전자공학과

^{†††} 정회원: 핸디소프트

^{††††} 정회원: 숭실대학교 정보통신공학과

논문접수: 1997년 2월 4일, 심사완료: 1997년 7월 21일

1. 서 론

ATM은 다양한 특성의 트래픽을 통계적 다중화를 통해서 효과적으로 전송하는 정보 전달 방법이다. 그러나 다양한 송신원의 특성과 트래픽의 과부하로 셀 손실 및 셀 지연이 발생할 수 있다. 따라서 망의 링크 이용 효율을 극대화 시키면서 동시에 연결된 호의 서비스 품질((QoS:quality of service)을 보장하기 위해서는 망에서의 유연한 트래픽 제어가 필요하다. 트래픽 제어는 망의 폭주 상태를 예방하기 위하여 망이 취하는 일련의 조치들을 말하며 그 종류로는 혼잡제어(congestion control), 호 수락 제어(call admission control), 사용/망 파라메터 제어(usage /network parameter control), 우선 순위 제어(priority control), 트래픽 쉐이핑(traffic shaping) 등이 있다. 본 논문은 위의 트래픽 제어 중 호 수락 제어에 폐지 신경망을 적용하여 예측성이 있는 호 접속/수락 시스템을 다룬다.

호 접속 수락 제어는 접속을 요구하는 호의 특성을 망에서 보장할 수 있는 가를 판단하는 제어로서, 기존에 접속되어 있는 호의 서비스 특성을 지원하면서 새로 접속을 원하는 호의 요구 특성을 지원할 수 있으면 접속을 해 주는 것이다[1, 2]. ATM 망에서의 요구 호의 특성은 트래픽 파라메터와 서비스 품질 파라메터를 들 수 있다. ATM 트래픽 파라메터는 평균 비트율, 피크 비트율, 군집성 등이 있고 QoS 파라메터로는 전송 지연, 셀 손실률, 셀 지연 변이 등이 있다. 사용자는 망에 접속 요구시 이를 파라메터를 신고하게 되며 망은 트래픽 제어를 통해 사용자가 요구하는 서비스 품질을 제공할 수 있어야 한다. 이 파라메터들은 사용자의 요구 수준과 망 제어기 사이에 차이가 발생하는데 망 제어기는 사용자가 망을 이용하는 동안 서비스의 요구 수준을 지원해야 한다. 이를 위해 셀 손실률 등의 QoS를 고려한 호 수락 제어에 관한 기법이 많이 제안되었으나 기존의 접근들은 다양한 ATM 망 서비스의 예기치 못한 트래픽 특성을 대처하는데 어려움이 있었다[3, 4]. 호 수락 제어를 원활히 하기 위한 트래픽 제어는 사용자 파라메터 제어, 우선 순위 제어 등 여러 종류가 있다. 과부하 없는 트래픽 제어를 하기 위해서는 트래픽 흐름의 확률론적인 예측이 필요하다. 트래픽 예측에 신경망을 도입하면 접속을 원하는 호 수락 제어를 적응적으로 수행할 수

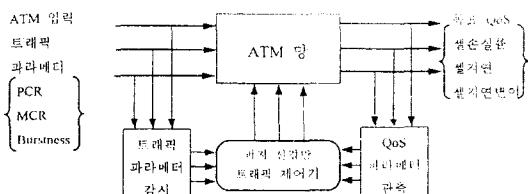
있다. 특히 역전파 알고리즘은 많은 입출력을 갖는 비선형 함수를 학습할 수 있어 호수학 제어의 트래픽 예측에 많이 사용이 된다[5].

본 논문은 트래픽 예측을 통한 호수학 제어에 신경망 학습에 퍼지를 적용한 논문으로서 신경망의 오프라인 학습 시에 걸리는 학습 횟수를 개선하는 논문이다. 본 논문에서는 기존의 신경망 시스템의 모멘텀 상수와 학습율에 퍼지 추론을 적용함으로써 신경망의 연결 강도(하증값)를 고속으로 계산할 수 있게 하였다. 제안된 방법은 훈련되지 않은 입력 값으로 호요청이 들어와도 빠른 학습을 통해 허락/거절을 빠르게 판단할 수 있음을 의미하며 오프라인에 의한 신경망 학습을 온라인적으로도 가능함을 보이는 결과이다.

본 논문의 구성은 다음과 같다. 2장에서는 ATM망에서의 신경망을 이용한 호수락 제어에 대해 알아보고 3장에서는 제안된 퍼지 신경망 호수락 제어 시스템을 설계하였다. 4장에서는 이의 모의 실험을 통해 제안 방식과 기존 신경망 방식의 성능을 비교하였고 5장에서는 그 결과에 대해 논하였다.

2. ATM 망에서의 신경망 호 수락 제어

ATM 망에서는 다양한 특성을 가진 트래픽을 효율적으로 서비스하기 위하여 접속을 요구하는 호에 대한 트래픽 특성을 정확히 파악하여야 한다. (그림 1)은 ATM 망의 특성을 나타내는 트래픽 파라메터와 QoS 파라메터의 관계를 도식적으로 나타낸 것이다. ATM 망은 사용자가 원하는 목표 서비스 품질을 만족시키기 위해 제어기를 통해 셀 손실 등이 일어나지 않도록 호 수락 제어, 사용 파라메터 제어 등 각종 제어를 하게 된다.

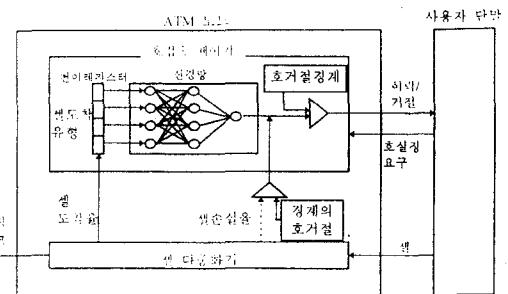


(그림 1) ATM 망의 트래픽 파라미터와 QoS 파라미터 관계
 (Fig. 1) The relation of Traffic parameter and QoS parameter of the ATM networks

호 수락 제어는 새로운 호의 설정 단계에서 최대 비트율, 평균 비트율, 군집성 등의 ATM 트래픽 특성과 함께 셀 손실률, 전송 지연, 셀 지연 변이 등과 같은 서비스 품질(QoS)을 사용자가 망에 신고하면 망은 이 신고 값에 따라 이미 서비스 중인 호에 지장이 없는 상황이라면 호 수락 여부를 결정하게 된다. 이 때 호의 연결 수락 판정 알고리즘이 매우 중요하며 이를 위해서는 트래픽의 통계적 특성 추정이 필요하다. 이러한 처리에는 보다 빠른 실시간 처리를 지원하고자 A. Hiramatsu는 호 수락 제어와 링크 제어에 신경망을 도입하였다[5]. 또한 연결 수락 제어에 고려되는 서비스 품질 파라미터는 셀 손실률, 전송 지연, 셀 지연 변이(cell delay variation) 등이 있으나 전송 지연과 셀 지연 변이는 적절한 우선 순위 제어와 버퍼링 시스템에 의해 해결하고 있고, 대부분의 연구에서는 셀 손실률에 초점을 맞추어 호 수락 거절 여부를 판단하고 있다.

신경망 호 수락 제어는 예측성 있는 트래픽 패턴을 알기 위해 과거 입력 호의 추이와 현재의 요구 호 특성을 참조한다. 신경망 호 수락 제어의 특징은 실제 상황과 같은 학습 패턴을 만들어 놓고 이를 역전파 등의 알고리즘을 사용하여 최적의 연결 강도를 계산하는 학습을 한 후, 이를 운용하여 호 허락/거절을 판단하는 것이다. 이 때 학습 패턴은 입력 패턴과 출력 패턴이 있게 되며 입력 패턴으로는 호의 평균 비트율, 피크 비트율, 군집성, 피크 전송 시간, 군집 지속 시간 등의 트래픽 파라미터와 도착 셀 수, 망의 버퍼 상태 등이 사용된다. 출력 패턴으로는 셀 손실율이 통상 사용된다. 신경망 호 수락 제어에 사용되는 신경망 구조는 입력층, 은닉층, 출력층으로 구성된다. 각 층의 노드 수는 시스템 설계에 가변적이며 학습 알고리즘은 오프라인 학습시 역전파 알고리즘이 주로 사용된다. (그림 2)는 A. Hiramatsu의 신경망 호 수락 제어기의 학습 단계의 구성을 보인다[5]. (그림 2)의 호 접속 제어기의 입력 값은 과거의 트래픽 추이를 참조하기 위해 셀 도착율을 시계열적으로 가졌으며 목표 출력을 얻기 위해 셀 손실률이 사용되었음을 보이고 있다. 목표 출력을 얻기 위해 사용된 출력 패턴은 실제 상황과 같도록 하기 위해 요구 수준 이내의 값과 요구 수준 밖의 값을 가질 수 있다.

신경망 구조의 출력층 뉴런에서는 신경망 연산을



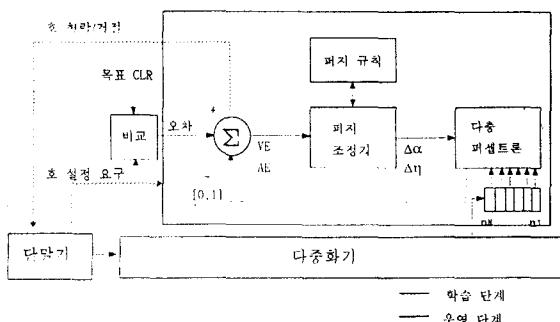
(그림 2) 일반적인 신경망 호 수락 제어기의 학습 단계의 구성
(Fig. 2) The composition of the learning stage in the general neural call admission controller

한다. 이들 연산에 사용하는 활성화 함수는 시그모이드(sigmoid) 함수가 대표적이다. 망에서는 요구 서비스의 종류, 요구 트래픽 파라미터, 요구 서비스 품질에 의해 같은 호의 유형을 정의할 수 있다. 호 수락 제어는 각각의 호 유형에 대한 연결 호들의 갯수를 계산하고 이들 갯수로부터 QoS를 평가한다. 그 결과 요구 QoS를 만족시킬 수 있으면 이를 수락하고 만족시킬 수 없으면 거절하게 된다. 이러한 신경망 호 수락 제어에서의 문제점은 실제와 같은 많은 학습 패턴들을 가지고 실험하기가 어렵다는 것과 학습 패턴에 없는 데이터가 들어올 때 이것을 판단하는데 오랜 학습 시간이 걸린다는 것이다[6]. 이러한 문제점들 때문에 기존의 신경망 호 수락 제어에서는 온라인 학습에 의한 호 수락 제어를 실시간적으로 적용할 수가 없었다.

3. 퍼지 추론에 의한 신경망 호 수락 제어

신경망 호 수락 제어기는 학습 단계와 운영 단계로 구분하여 동작한다. 학습 단계에서 역전파 알고리즘으로 목표값과 신경망 출력값과의 오차가 원하는 값이하가 되도록 퍼지 신경망 학습을 행한다. 이 후 운영 단계에서는 최종 학습된 하증치를 갖는 신경망의 출력을 호 허락/거절 기준치와 비교하여 임계값이하가 되면 호는 수락되고 그렇지 않으면 거절된다. (그림 3)은 퍼지 추론에 의한 신경망 호 수락 제어기의 학습 단계와 운영 단계의 모형이다. 퍼지 추론에 의한 신경망 호 수락 제어기는 다중 퍼셉트론의 출력

뉴런 값과 목표 셀 손실률을 이용한 목표값과의 오차값을 퍼지 조정기의 입력값으로 하여 퍼지 규칙에 의해 빠른 최적의 연결 강도를 구하는 시스템이다. 본 절에서는 제안하는 퍼지 추론에 의한 신경망 호 수락 제어기의 전반적인 설명을 하고 퍼지 조정기의 기능, 퍼지 규칙, 퍼지 소속 함수 등을 설계한다.



(그림 3) 퍼지 추론에 의한 신경망 호 수락 제어기의 학습과 운영 단계 모형

(Fig. 3) The model of the learning and operation stage in the neural call admission controller by the fuzzy inference

퍼지 추론에 의한 신경망 호 수락 제어기는 학습 단계의 학습 패턴으로 허락과 거절 패턴을 갖는다. (그림 3)의 동작 과정은 이전의 적재된 n개의 호(셀) 수와 현재의 입력 호 수, 버피 상태를 입력 받아 학습을 한다. 현재의 접속 호의 셀 손실률은 이 서비스의 목표 셀 손실률과 비교하여 오차를 생성한다. 이 오차값은 다중 퍼셉트론의 출력 뉴런값과 비교하여 수렴이 안되었을 경우 오차로 VE(Velocity of Error)와 AE(Accelerator of Error)를 생성한다. 퍼지 조정기에서는 VE, AE를 입력 변수로 하여 추론을 실시한다 [7]. 퍼지 조정기에서 퍼지 추론한 출력 변수는 비퍼지화 과정을 거쳐 학습율 변화량 $\Delta\alpha$ 와 모멘텀 변화량 $\Delta\eta$ 로 변환되며 이 값에 의해 신경망 뉴런의 연결 강도를 식 (1)에 의해 계산하게 된다. 이 연결 강도는 학습 과정 중에 신경망의 하중 값으로 작용을 한다. 학습 중 신경망 출력 뉴런의 활성화 함수 값이 목표 값에 수렴되었을 때는 학습을 끝내게 되고 수렴이 되지 않았을 때는 학습 과정을 반복하게 된다. 퍼지 추론에 의한 신경망 연결 강도의 신속한 변경은 출력 뉴

런의 오차가 빠르게 최소가 되도록 한다. 기존 신경망에서 출력 뉴런의 출력 값과 목표 값의 오차가 수렴되어갈 때 반복 학습이 계속될 경우 많은 학습 시간이 걸리나 퍼지 신경망의 경우 빠른 최적 연결 강도의 계산으로 짧은 학습 시간에 원하는 수렴 결과를 얻을 수 있다. (그림 3)의 퍼지 조정기는 (그림 4)의 퍼지 논리 제어기로 세분화할 수 있다. 퍼지 논리 제어기는 퍼지화기, 퍼지추론기, 퍼지 규칙, 비퍼지화기로 구성된다. 퍼지화기에서는 척도사상을 통하여 입력 변수값들이 적당한 언어적 값들로 변환되어 퍼지 집합의 명제로 사용된다. 전문가에 의한 퍼지 규칙 기반에서 퍼지 추론기는 퍼지화 입력의 응답에 대한 퍼지 추론을 행한다. 비퍼지화기에서는 추론된 출력 변수를 무게 중심법 등에 의해 비퍼지화 값을 산출하게 된다.



(그림 4) 퍼지 논리 제어기의 기능 블럭도
(Fig. 4) The block diagram of the function in fuzzy logic controller

퍼지 추론에 의한 호 수락 제어 모형에서는 학습 시 일반 멜타 규칙(GDR:Generalized Delta Rule)에서 퍼지 규칙화에 의한 학습율과 모멘텀 값의 크기에 따른 하중 계수 변화율이 퍼지 규칙화 되어서 사용된다. 역전파 학습 알고리즘에서 일반 멜타 규칙으로 하중값의 결정은 식 (1)과 같다.

$$\Delta W_{ji}(n) = \alpha \Delta W_{ji}(n-1) + \eta \delta_j(n) o_{UTi}(n) \quad (1)$$

여기에서 α 는 모멘텀 상수, η 는 학습율, $o_{UTi}(n)$ 은 i번쨰 뉴런의 출력, W_{ji} 는 은닉층의 j번째 뉴런과 출력층 i번째 뉴런의 연결강도, $\delta_j(n)$ 은 j번째 뉴런의 출력 오차로써 다음 식 (2)로 구해진다.

$$\delta_j(n) = e_j(n) \cdot f'(o_{UTi}(n)) \quad (2)$$

이 때 총 오차 전력 $E(n)$ 은 식 (3)과 같다. 여기에서 $d_j(n)$ 은 원하는 목표 값이다.

$$E(n) = \frac{1}{2} \sum_{j=1}^k e_j^2(n) = \frac{1}{2} \sum_{j=1}^k [d_j(n) - OUT_j(n)]^2 \quad (3)$$

역전파 학습 알고리즘에 의한 퍼지 제어에서는 빠른 수렴율을 얻기 위해서 오차면의 경사(gradient)에 해당하는 오차율(VE: Velocity of Error)과 수렴 속도에 관계된 2차 경사 정보를 의미하는 VE의 변화(AE: Accelerator of Error)를 사용한다[8]. 오차면 경사의 부호 변화는 VE의 부호 변화와 동일하다. 예를 들어, 어떤 상태에서 $E(n-2) \leq E(n-1)$ 이고, $E(n-1) > E(n)$ 이면 식 (4), (5)와 같이 쓸 수 있다.

$$VE(n-1) = E(n-1) - E(n-2) \geq 0 \quad (4)$$

$$VE(n) = E(n) - E(n-1) < 0 \quad (5)$$

(n-2)에서 n까지의 반복으로 부호 변화가 있음을 알 수 있다. 자세한 퍼지 역전파 학습을 위한 퍼지 규칙은 <표 1>, <표 2>와 같다. 예를 들어 퍼지 규칙 중 하나를 언어 변수로 나타내면 “만일 VE의 값이 0이

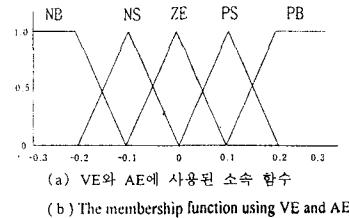
<표 1> 학습률 파라미터의 변화 $\Delta\eta$ 의 퍼지 제어 규칙
(Table 1) The rule of the fuzzy control by variation $\Delta\eta$ of the learning rate parameter

VE AE	NB	NS	ZE	PS	PB
NB	NS	NS	NS	NS	NS
NS	NS	ZE	PS	ZE	NS
ZE	ZE	PS	PS	PS	ZE
PS	NS	ZE	PS	ZE	NS
PB	NS	NS	NS	NS	NS

<표 2> 모멘텀 파라미터의 변화 $\Delta\alpha$ 의 퍼지 제어 규칙
(Table 2) The rule of the fuzzy control by variation $\Delta\alpha$ of the momentum parameter

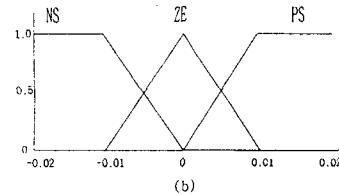
VE AE	NB	NS	ZE	PS	PB
NB	NS	NS	ZE	ZE	ZE
NS	NS	ZE	ZE	ZE	ZE
ZE	ZE	PS	PS	PS	ZE
PS	ZE	ZE	ZE	ZE	NS
PB	ZE	ZE	ZE	NS	NS

고, AE가 음수의 작은 값(NS)을 갖는다면, $\Delta\eta$ 는 양수의 작은 값(PS)을 갖는다.”와 같게 된다.



NB : Negative Big
NS : Negative Small
ZE : Zero
PS : Positive Small
PB : Positive Big

(b) The membership function using VE and AE

(b) $\Delta\eta, \Delta\alpha$ 의 소속 함수
(b) The membership function of the $\Delta\eta, \Delta\alpha$

(그림 5) 퍼지 입력 변수와 출력 변수에 사용된 소속 함수
(Fig. 5) The membership function using in the fuzzy input and output variable

퍼지 추론에 사용된 입력 변수와 출력 변수의 소속 함수는 (그림 5)와 같다. (a)는 퍼지 제어기의 퍼지 입력 변수 VE와 AE에 사용된 소속 함수를, (b)는 퍼지 제어기의 퍼지 출력 변수 $\Delta\eta, \Delta\alpha$ 의 소속 함수를 보이고 있다. VE와 AE의 전체집합은 $[-0.3, 0.3]$ 범위로 한정하였다. 이 범위 밖의 VE와 AE는 -0.3 과 0.3 으로 절단된다. 학습률 파라메터의 변화 $\Delta\eta, \Delta\alpha$ 는 ‘양으로 작음(PS)’, ‘0(ZE)’, ‘음으로 작음(NS)’을 나타내며 (그림 5)의 (b)에 표현된 소속 함수를 이용한 $\Delta\eta, \Delta\alpha$ 변화를 적당한 값으로 할당하게 된다.

4. 시뮬레이션

4.1 퍼지 신경망 학습 속도 개선 실험

시뮬레이션에 사용한 신경망 구조는 2층 구조로서 입력층에 70개의 노드, 은닉층에 10개의 노드, 출력층에 1개의 노드를 가진 다층 퍼셉트론(multilayer perceptron)이다. 각 노드의 활성 함수는 시그모이드 함수를 사용하였다. 활성화 함수 수식은 식 (6)과 같다.

$$f(x) = \frac{1}{1 + \exp(-\lambda x)} \quad (6)$$

모의 실험에 사용된 학습 데이터는 입력 흐수의 발생은 ATM 망의 입력 모델로 많이 사용되고 있는 MMPP(Markov-Modulated Poisson Process) 모델을 사용하였다. 입력 패턴은 입력 흐수와 버퍼 상태를 사용하였고 이 때 하나의 호는 하나의 셀로 가정하였다. 학습 패턴은 100개를 사용하였고 이 때 허락 경우와 거절 경우의 패턴을 고려하였다. 호의 수(패턴)는 1개에서 140개 사이에(그림 11 참조), 버퍼는 45 개에서 50개 사이에 랜덤하게 분포하도록 하였다. 출력 패턴은 ATM의 QoS 파라미터 중 셀 손실률을 사용하였고 10^{-3} 을 경계값으로 하였고 신경망 학습은 역전파 알고리즘을 사용하였다.

시뮬레이션 입력 트래픽에 사용된 MMPP 모델은 ATM의 통합 트래픽의 대표적인 모델로서 다양한 형태의 트래픽 소스를 포함한다. 각각의 송신원으로 테이터원의 경우 베르누이(Bernoulli) 모델, 음성원으로 IDP(Interrupted Deterministic Process), IPP(Interrupted Poisson Process)모델, 비디오원으로 1차, 2차 AR(Autoregressive) 모델이 사용되나 ATM은 이들 데이터가 통합된 멀티미디어 데이터가 주류를 이루므로 이들의 통합원인 MMPP 모델을 입력 트래픽원으로 사용을 하였다. 사용된 MMPP 모델은 2상태 MMPP를 사용하였고 파라미터는 도착율(λ)과 천이율(γ)을 나타내는 4개의 파라미터를 사용하였다[9]. 도착율은 폭주 구간 λ_1 , 비 폭주 구간 λ_2 의 포아송 프로세스에 의해 발생하고 상태 천이율은 폭주 구간 γ_1 , 비 폭주 구간 γ_2 의 지수 분포를 갖는다. 본 논문에 사용된 MMPP의 파라미터 값은 (표 3)과 같다.

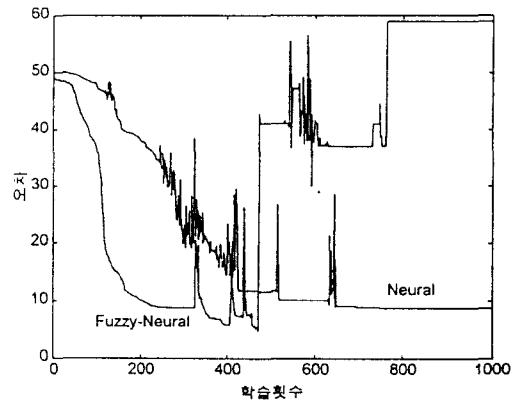
(표 3) 모의 실험의 적용 파라미터 값

Table 3) The applied parameter values in simulation

γ_1	γ_2	λ_1	λ_2
0.5	1.0	1	2

(그림 6)부터 (그림 10)은 제안된 퍼지-신경망 알고리즘의 모의 실험 결과를 보인다. (그림 6)은 모멘텀 $\alpha = 0$, 학습율 $\eta = 0.01$ 일 경우로 기존의 신경망 알고리즘은 학습 횟수 500에서 수렴하고 있다. 그러나 제안

한 알고리즘은 신경망 알고리즘 보다는 1/5의 학습 횟수인 100에서 수렴하고 있으나 학습 횟수가 계속 증가 할 수록 더 이상 수렴하지 않고 진동하면서 발산을 하고 있다.



(그림 6) $\alpha = 0, \eta = 0.01$ 일 경우의 수렴 결과

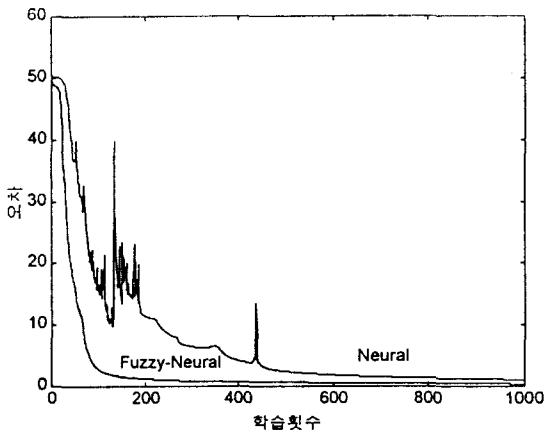
(Fig. 6) The results of the $\alpha = 0, \eta = 0.01$

(그림 7)은 초기 모멘텀(α)=0.1, 학습율(η)=0.01일 경우, 제안된 퍼지 신경망 알고리즘과 신경망 알고리즘 모두 수렴한 결과를 보인다. 이 결과에서 제안된 퍼지 신경망 알고리즘이 기존 신경망 알고리즘보다 빠르게 수렴하고 있는 것을 볼 수 있다. (그림 8)부터 (그림 10)까지의 모의 실험 결과는 초기 모멘텀과 학습율을 바꾸어 실험했을 때, 기존의 신경망 알고리즘 보다 신경망 퍼지 학습 알고리즘이 마찬가지로 빠르게 수렴함을 보이고 있다. 퍼지 신경망 알고리즘의 특징은 기존의 신경망 알고리즘과는 다르게 수렴시 진동 현상이 거의 발생하지 않으면서 수렴한다는 점이다. 이는 퍼지 신경망 알고리즘에서 진동이 발생할 것을 미리 예측하여 모멘텀과 학습율을 퍼지 규칙에 의해서 적절히 변경시켜주기 때문이다. (그림 7)에서 모멘텀(α)=0.1, 학습율(η)=0.01일 경우 퍼지 신경망은 학습 횟수가 100정도에서 수렴을 하였으나 기존 신경망의 경우는 500 정도에서 수렴을 하였고 그림 8의 모멘텀(α)=0.1, 학습율(η)=0.1일 경우도 거의 비슷하였다. 또한 (그림 9)의 모멘텀(α)=0.5, 학습율(η)=0.1일 경우도 퍼지 신경망은 학습 횟수가 100 정도에서 수렴을 하였다. 그러나 (그림 10)의 모멘텀(α)=

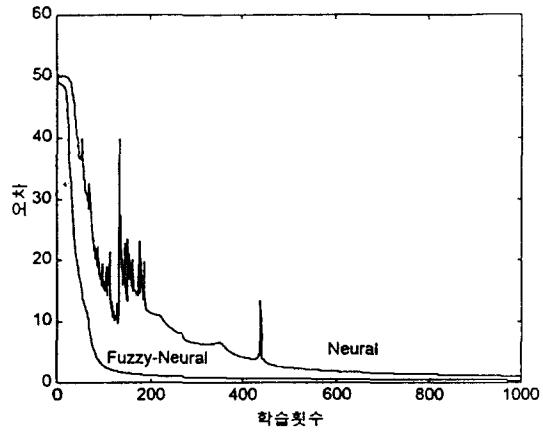
0.1, 학습율(η)=0.5일 경우에는 퍼지 신경망은 100정도에서 신경망은 220에서 수렴을 하여 기존 신경망 경우 학습율(η)를 높일 경우 신경망 학습 속도가 현격히 향상됨을 보였다.

실험 결과 퍼지 신경망은 초기 모멘텀, 학습율 값에 거의 영향을 안받으며 학습 횟수 100에서 수렴을 보였다. 그러나 기존 신경망 경우 학습율을 높혔을

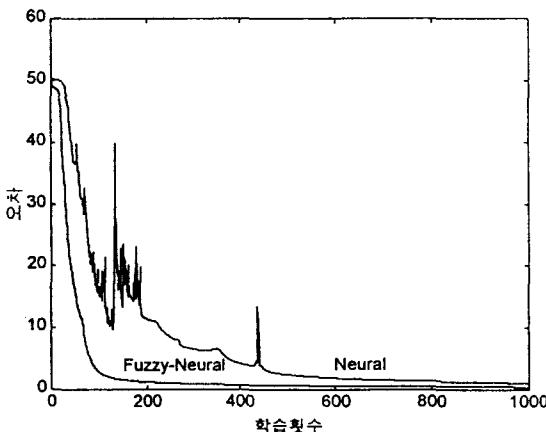
경우 학습 속도가 현격히 향상됨을 보여 학습 횟수에 큰 영향이 있음을 알 수 있었다. 또한 퍼지 신경망은 기존 신경망보다 매끄럽게 진동 없이 수렴하는 것을 보여 학습시 좀 더 안정적인 학습을 하고 있음을 알 수 있었다. 이는 퍼지 신경망의 경우 신경망의 경우 보다는 온라인 학습의 가능성이 더욱 높음을 보이는 결과이다.



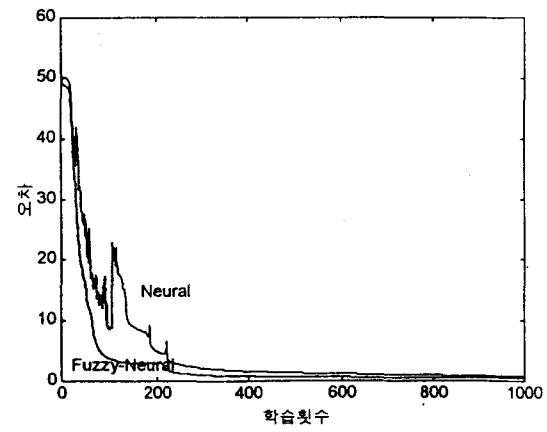
(그림 7) $\alpha = 0.1, \eta = 0.01$ 일 경우의 수렴 결과
(Fig. 7) The results of the $\alpha = 0.1, \eta = 0.01$



(그림 8) $\alpha = 0.1, \eta = 0.01$ 일 경우의 수렴 결과
(Fig. 8) The results of the $\alpha = 0.1, \eta = 0.01$



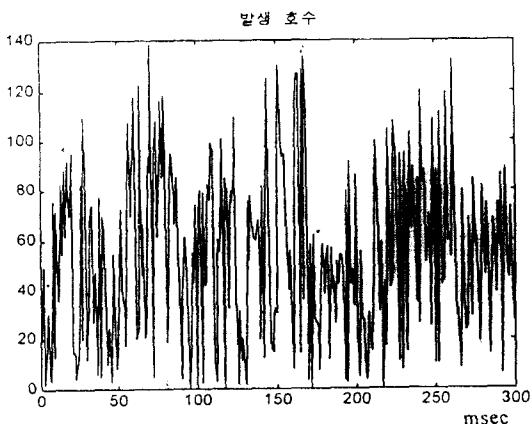
(그림 9) $\alpha = 0.5, \eta = 0.1$ 일 경우의 수렴 결과
(Fig. 9) The results of the $\alpha = 0.5, \eta = 0.1$



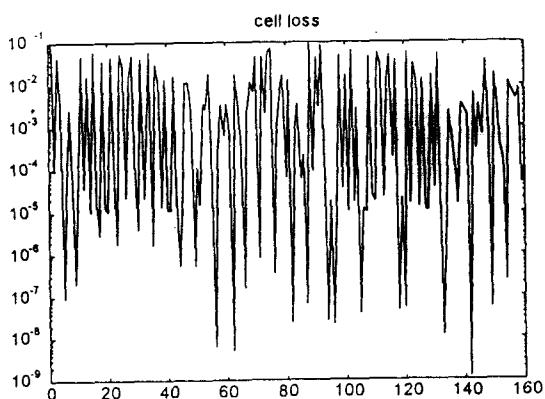
(그림 10) $\alpha = 0.1, \eta = 0.5$ 일 경우의 수렴 결과
(Fig. 10) The results of the $\alpha = 0.1, \eta = 0.5$

4.2 퍼지 신경망 허락 제어 실험

모의 실험에서는 입력이 하나의 입력 벡터[호수, 버퍼 상태]를 형성하여 100개의 벡터를 가진 학습 패턴을 사용하였다. 입력 패턴은 (그림 11)과 같다.



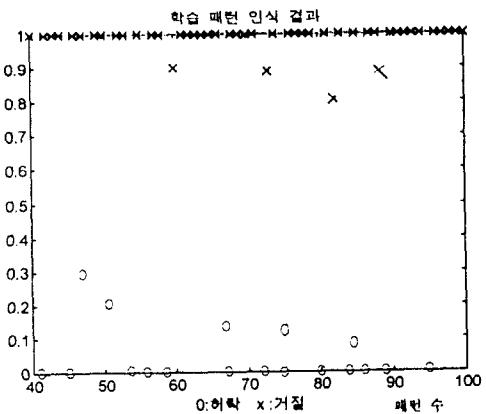
(그림 11) 입력 패턴의 송신원 발생 호수
(Fig. 11) The generation call number



(그림 12) 출력 패턴의 셀 손실률 발생 상황
(Fig. 12) The generation situation of the input pattern cell loss rate in the output pattern

출력 패턴은 연결 호의 셀 손실률을 사용하였고 셀 손실률의 허락 기준은 10^{-3} 으로 하였다. 여기에서의 10^{-3} 은 서비스에 따른 허용 셀 손실률을 나타내는 값으로서 실험에서의 가정값이다. 이 출력 패턴의 모양은 (그림 12)와 같다. (그림 13)은 서비스의 신경망 출력

값을 보인 것이다. 대부분의 출력값이 신경망 학습 후 매우 근사하게 [0,1]사이에 있음을 보였으며 0.5를 기준으로 두개의 구역으로 분할된 것을 볼 수 있다. 1과 0사이의 값들은 시그모이드 활성 함수의 출력 시 계산된 값들이 0과 1사이에만 존재한다는 것을 보인 것이다. 비록 모든 값들이 0과 1을 나타내지는 않았지만 만족할 만한 실험 결과를 얻었다.



(그림 13) 신경망 연결 수락/거절 출력 결과
(Fig. 13) The output results of the neural connection admission/rejection

5. 결 론

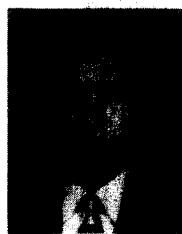
ATM 트래픽 링크의 사용 대역을 좀 더 효율적으로 이용하기 위해 퍼지 신경망 연결 수락 제어 방식을 제안하여 설계하였다. 기존의 신경망 방식보다 퍼지 신경망은 학습 속도면에서 현격한 성능 향상이 있음을 보였다. 퍼지 신경망을 이용한 연결 수락 제어는 다양한 트래픽과 버퍼의 상태를 입력 파라메터로 하여 그 시점에서 연결 요청이 들어오는 서비스의 접속 여부를 판단하는 기법이다. 본 논문에서는 실험을 위해 ATM의 입력 원으로 많이 사용 중인 MMPP 모델을 사용하였고 학습 패턴은 100개를 사용하여 허락/거절 상황을 고려하였다. 학습 속도 개선을 위해서는 학습율과 모멘텀을 이용한 퍼지 추론을 실시하였다. 시뮬레이션 결과, 학습 속도가 기존의 신경망 구조보다 퍼지 추론을 적용한 경우가 약 5배 정도 빠름을 알

수 있었다. 퍼지 신경망 역전파 학습에 의한 정상상태 평균 자승 오차가 신경망 역전파 학습에 의한 오차보다 확연히 더 적은 값을 나타냈다. 본 논문에서는 퍼지 신경망 연결 수락을 통해서 다양한 특성의 트래픽을 가진 호를 정확히 수락/거절할 수 있도록 퍼지 신경망을 적용하여 효율적인 호 접속 수락 방안을 제시 하였고 또한 학습에 참여하지 않은 입력 패턴에 대해서도 지능적으로 호 수락 제어를 신속하게 처리할 수 있는 가능성을 제시하였다.

참 고 문 헌

- [1] Youichi Sato, Ken-Ichi Sato, "Virtual Path and Link Capacity Design for ATM Networks", in Proc. of IEEE JASC. Vol. 9, No 1, pp. 104 - 111, Jan. 1991.
- [2] C. Liu, H. T. Mouftah, "Virtual Call Admission Control - A Strategy for Dynamic Routing over ATM Networks", in proc. of IEEE GLOBECOM '95, pp. 201~205, 1995.
- [3] H. T. Kung, A. Chapman, "The FCVC(Flow Controlled Virtual Channels) Proposal for ATM Networks", Intern. conf. on Network Protocols, pp. 116-127, 1993.
- [4] Simon Haykin, Neural Networks:A Comprehensive Foundation, Macmillan College Publishing Company, 1994.
- [5] Atsushi Hiramatsu, "ATM Traffic Control Using Neural Networks", Neural Networks in Telecommunications, Kluwer Academic Publishers, 1994.
- [6] R. G. Cheng, C. J. Chang, "A Neural-Net Based Fuzzy Admission Controller for an ATM Network", IEEE INFOCOM'96, pp. 777-784, 1996.
- [7] 이광형, 오길록, "퍼지 컴퓨터 이론 및 응용 (I) (II)", 홍릉과학출판사.
- [8] Choi, J. J., etc., "Fuzzy Parameter Adaptation in Neural Systems", IJCNN '92, Vol. 1, pp. 232-238, 1992.
- [9] Hehhes H. and Lucantoni D. M., "A Markov Modulated Characterization of Packetized Voice and Data Traffic and Related Statistical Multi-

plexer Performance", IEEE Trans. Communications, SAC-4. 6, pp. 856-868, 1986.



유 재 택

- | | |
|----------------|---------------------------|
| 1986년 | 숭실대학교 전자공학과
졸업(공학사) |
| 1988년 | 숭실대학교 전자공학과
졸업(공학석사) |
| 1989년~1993년 | 숭실대학교 전
자공학과 박사수료 |
| 1986년~1989년 | 동아컴퓨터(주)
시스템 앤지니어 |
| 1989년~1997년 2월 | 한국교육개발원 전산운영팀장 |
| 1997년 3월~현재 | 멀티미디어교육지원센터 책임전
문원(팀장) |
- 관심분야: ATM 트래픽 제어, 통신 프로토콜, 퍼지 신경망 신호처리, 멀티미디어 DB임



김 춘 섹

- | | |
|----------------|-----------------------------|
| 1996년 | 숭실대학교 전자공학과
졸업(학사) |
| 1997년 | 현재 숭실대학교 전자
공학과 석사과정 재학중 |
| 1997년 9월 1일~현재 | 멀티미
디어교육 지원센터 근
무중 |
- 관심분야: 퍼지 신경망, 통신프로토콜, 신호처리임



김 용 우

- | | |
|-------------|-------------------------|
| 1995년 | 숭실대학교 전자공학과
졸업(공학사) |
| 1997년 | 숭실대학교 전자공학과
졸업(공학석사) |
| 1991년~1994년 | 핸디소프트 연
구원 |
| 1997년~현재 | 핸디소프트 연구원 |
- 관심분야: 퍼지 신경망, 멀티미디어 통신, 프로그래밍 언어임.



김 영 한

1984년 서울대학교 전자공학과 졸업(공학사)
1986년 한국과학기술원 전기 및 전자공학과 졸업(공학석사)
1990년 8월 한국과학기술원 전기 및 전자공학과 졸업(공학박사)
1987년 1월~1994년 8월 디지콤정보통신연구소 대 이터통신연구부장
1994년 9월~현재 승실대 정보통신공학과 조교수
관심분야: ATM 네트워크 및 멀티미디어 통신 프로토콜임



이 광 형

1968년 서울대학교 공과대학 전자공학과 졸업(공학사)
1972년 서울대학교 전자공학과 졸업(공학석사)
1987년 중앙대학교 전자공학과 졸업(공학박사)
1973년~1982년 일본 동경대학 전자공학과 연구원
1993년~1995년 대한전자공학회 인공지능, 신경망, 퍼지시스템 연구회 위원장
1994년~현재 국제전기전자학회(IEEE Korea Council) 학술이사(Conference Committee)
1994년~1996년 대한 퍼지 및 지능 시스템 학회 국제 담당이사
1982년~현재 승실대학교 전자공학과 교수로 재직 중
관심분야: 지능 신호처리, 퍼지 신경망 음성인식 및 합성, 웨이브렛, 프랙탈 영상 부호화, 멀티미디어 통신처리, ATM 네트워크임.