

신경망과 퍼지 패턴 추정기를 이용한 ATM의 호 수락 제어

이 진 이[†]

요 약

본 논문에서는 퍼지 패턴 추정기를 구성하여 신경망 학습시에 훈련되지 않은 새로운 종류의 호가 발생할 때, 재학습을 하지 않고 그 호의 수락/거절을 효과적으로 행할 수 있는 IFVQ-NNCAC(Inverse Fuzzy Vectorquantizer-Neural Networks Call Admission Control)를 제안한다. 이 방식은 연결을 요구하는 호의 입력 트래픽 패턴이 발생하면, 그 입력패턴은 수락/거절 표준패턴(코드북), 퍼지 소속 함수값, 그리고 FCM(Fuzzy-C-Means)연산을 이용하여 학습화한 패턴을 발생한 후, 그 패턴을 신경망의 입력으로 하여 호 수락/거절을 결정한다. 이 방식은 셀 스트림의 평균과 분산값을 트래픽 파라메타로 사용함으로써 트래픽 모델과는 무관한 호 수락제어가 가능하며, 입력패턴(프레임별 관측패턴)과 표준패턴의 멤버십 함수값을 CAC에 신고하는 트래픽 파라메타로 사용하는 새로운 방법이다. 신경망은 오류 역전파 알고리즘을 사용하여 표준패턴으로 학습한다. 시뮬레이션을 통하여 기존의 신경망 방식과 제안된 방식의 Fuzziness 값의 설정에 따른 호 수락/거절 오류를 비교하여 제안된 방식이 우수함을 보였다.

Call Admission Control in ATM by Neural Networks and Fuzzy Pattern Estimator

Jinyi Lee[†]

ABSTRACT

This paper proposes a new call admission control scheme utilizing an inverse fuzzy vector quantizer(IFVQ) and neural net, which combines benefits of IFVQ and flexibilities of FCM(Fuzzy-C-Means) arithmetics, to decide whether a requested call not to be trained in learning phase to be connected or not. The system generates the estimated traffic pattern for the cell stream of a new call, using feasible/infeasible patterns in codebook, fuzzy membership values that represent the degree to which each pattern of codebook matches input pattern, and FCM arithmetics. The input to the NN is the vector consisted of traffic parameters which are the means and variances of the number of cells arriving in the intervals. After training(using error back propagation algorithm), when the NN is used for decision making, the decision as to whether to accept or reject a new call depends on whether the NN output is greater or less than decision threshold(+0.5). This method is a new technique for call admission control using the membership values as traffic parameter which declared to CAC at the call set up stage, and this is valid for a very general traffic model in which the calls of a stream can belong to an unlimited number of traffic classes. Through the simulations, it is founded the performance of the suggested method outperforms compared to the conventional NN method.

* 본 연구는 1997년도 충남산업대학교 학술연구조성비 지원에 의하여 연구되었음.

† 정 회 원 : 청운대학교 전자공학과 교수
논문접수 : 1999년 1월 7일, 심사완료 : 1999년 7월 7일

1. 서 론

통신망은 음성신호를 전송하는 것이 주 목적인 공중 전화망과 컴퓨터간의 문자 위주의 데이터의 전송을 목적으로 하는 패킷 교환망으로 발전되어 오다가 동화상 정보, HDTV 등 멀티미디어의 정보통신 등에 대한 요구가 급격하게 증가됨에 따라 B-ISDN이 출현하게 되었고, 이를 실현하기 위한 정보 전달기술로 ATM 기술이 효과적인 것으로 알려져 있다.

ATM망에서는 요구 대역폭이나 서비스 요구사항이 서로 다른 다양한 호들이 망자원들을 공유하고, 고속의 셀 전송 특성 때문에 망에서의 폭주상태가 발생할 수 있다. 또한 예측할 수 없는 트래픽의 변화로 인해 요구값 이상의 셀 전송 지연 및 셀 손실이 발생 할 수도 있다. 따라서 사용자가 요구하는 서비스 품질을 유지시키고 망 자원을 효과적으로 공유하기 위해서 정보 전송단계에서 트래픽제어가 필요하다. 이에 따라 ITU-T에서는 다음과 같은 트래픽 제어 요소를 L371[1]로 권고하였다.

트래픽 제어는 망의 폭주상태를 예방하기 위하여 망이 취하는 일련의 조치들을 말하며, 이것의 기능으로 폭주제어, 연결 수락제어, 사용자/망 파라메타제어, 우선 순위제어, 트래픽 셀률조정 등이 있다. 망에 연결될 호의 수락여부를 결정하는 연결 수락제어는 사용자 호가 요구한 서비스 품질을 보장하면서 망 자원의 이용 효율을 극대화한다는 상반된 조건을 만족시켜야 하기 때문에, 사용자의 서비스 품질요구가 특정한 수준 이상으로 유지 될 수 있을 때만 새로운 호의 연결 요구를 수락한다. CAC(call admission control)에서는 사용자가 선언한 트래픽 표현자를 이용해서 새로운 호의 특성을 알 수 있는데, 트래픽 특성 선언을 위하여 어떤 트래픽 표현자를 사용할 것인지에 관한 문제[2]가 연구의 주제가 되기도 한다.

ATM에서 연결요구에 대한 제어방법으로 예방제어가 많이 연구되고 있으며, 사용자 단말이 신고한 트래픽 표현자와 현재의 트래픽을 분석한 후 미래의 트래픽을 예측하여, 서비스 품질에 따라 호 수락 여부를 결정한다. 트래픽 예측 방법으로 수학적 모델에 기초한 해석방법[3], 출력링크를 실제로 측정하여 트래픽을 예측하는 방법[4], 각 호의 대역폭 할당을 위해 미리 구해진 등가 대역폭을 이용하는 방법[5], 트래픽 표현자의 불확실성을 고려한 가능성과 퍼지 셀을 이용하는 방법[6] 등이 있다.

또한 신경회로망의 학습기술을 이용하는 호 수락 제어 방법이 많이 연구되고 있다. A. Hiramatsu는 다중화에 의해 발생하는 비트변동에 따른 수락제어[7]와 대역폭 할당에 따른 연결 수락제어[8]에 신경망을 사용하였고, P. Tran-Gia와 O. Gropp가 버스트 수준에서의 연결 수락제어에 신경망을 이용하였다[9]. A. Hiramatsu 방법은 패턴 테이블을 작성한 후, 이 들을 이용하여 신경 회로망을 학습함으로써 주어진 트렁크 용량에 손실이 발생하는 경우와 발생하지 않는 경우 한쪽에 편중하지 않고 균등하게 학습하는 방법이다.

신경회로망의 학습 방법에는 오프라인 학습방법과 온라인 학습방법이 있다. 오프라인 학습 방법은 실제 시스템이나 입력 트래픽 모델에서 얻은 입력패턴으로 신경망을 학습시킨 후, 학습 없이 운영을 하는 방식이다. 반면에 온라인 학습은 학습과 운영을 병행하는 방법인데, 이 방식은 실제상황과 신고한 트래픽 표현자 사이에 차이가 있기 때문에 실제상황에서 더 유리하다. 이러한 신경회로망을 이용하는 방법은 가입자가 선언하는 트래픽 표현자에만 의존하지 않고 호 수락제어기가 학습을 통하여 제어를 수행한다는 측면에서 이점을 갖고 있으나 새로운 서비스가 도착할 때는 신경망 제어기를 재학습해야 하고, 다양한 서비스 클래스를 동시에 지원하는 하는 데는 어려움을 갖고 있다. 이러한 신경망에 의한 호 수락제어는 입력 노드수(입력벡터의 차원)의 크기에 따라 성능의 차이를 나타내는데 입력노드 수가 많을수록 그만큼 많은 파라메타를 전송해야하므로 경로의 통신 오버헤드와 메모리의 요구가 증가하게 된다. 본 연구에서는 입력벡터의 차원과는 무관하고 단지 압축된 코드 벡터의 수에 따른 퍼지 소속함수값이 큰 순서로 몇 개만 선택하여 전송함으로써 통신 오버헤드의 제어가 가능하고 벡터양자화기의 성능을 개선한 퍼지벡터양자화기를 이용한 신경망호 수락제어(IFVQ-NNCAC : Inverse Fuzzy vectorquantizer-Neural Networks Call Admission Control)를 제안하여 분석한다. 역퍼지벡터양자화는 표준패턴 코드북(inside 패턴), 퍼지 소속 함수값과 FCM(Fuzzy-c means) 알고리즘으로 구성되며, 퍼지 소속 함수값과 FCM 알고리즘을 사용하여 신경망 학습시에 참여하지 않은 새로운 종류의 호(outside 패턴)가 연결을 요구할 때, 그 호에 대한 학습화한 패턴을 발생하여 신경망으로 수락/거절을 수행한다.

신경망의 입력으로 사용하는 트래픽 표현자로는 여러 종류의 파라메타가 가능한데, 트래픽 모델이 몇개

의 클래스로 나누어지고 그 클래스의 스트림들이 같은 트래픽 표현자를 갖는다면 각각의 클래스에 대해 하나의 입력도 가능하다[10]. 그러나 이러한 입력의 선택은 트래픽 클래스 수가 적다면 잘 동작하지만, 실제 망에서는, 수백개의 클래스들이 있을 수 있기 때문에 신경망은 매우 복잡하게 될 것이고, 각각의 스트림을 특징 지우기 위해서는 많은 변수들을 요구하게 된다. 따라서, 본 연구에서 이러한 점을 해결하기 위해 셀 수의 평균값과 분산값을 트래픽 파라미터로 선정하고 그것을 신경망의 입력으로 사용한다.

한편 ATM망의 여러 기능에 퍼지를 적용하여 성능을 향상시킨 연구가 있는데, 이러한 연구는 대부분 퍼지의 특유한 기능을 살려 망 상태의 복잡성을 퍼지집합이론과 퍼지논리를 사용하여 언어적 표현으로 나타냄으로써 퍼지추론에 의한 제어를 실시한다. CAC에 퍼지를 이용한 연구는 신경망에 기초한 퍼지 수락 제어기[11], 관측된 데이터를 사용하여 퍼지추론으로 얻은 셀 손실율의 가능성분포를 근거로 CAC를 구현한 것[12]과 호 수락제어기와 폭주제어를 결합한 퍼지 트래픽 제어기[13]가 있는데, 이 방법은 진행중인 호들에 대해 서비스 품질을 만족시키면서 시스템의 이용률을 극대화시키는 연구이다. 이 이외에도 광범위하게 퍼지논리 시스템이 트래픽 제어에 응용되고 있다.

본 논문의 구성은 다음과 같다. 2장에서는 퍼지패턴 추정기를 이용한 호 수락제어기와 호 수락 제어 알고리즘을 기술하고, 3장에서는 시뮬레이션을 통하여 특성을 분석하고, 4장에서 결론을 기술한다.

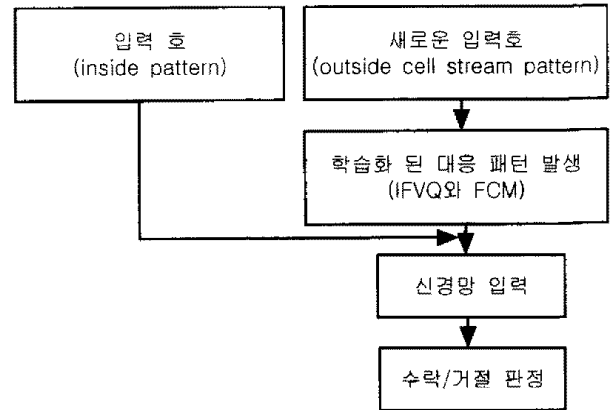
2. 퍼지패턴추정기를 이용한 신경망 호 수락제어

일반적으로 신경망을 이용하여 호 수락제어를 수행할 때 학습하지 않은 새로운 패턴(outside pattern)이 들어오면 기존의 신경망 호 수락제어기에서는 재학습을 해야함으로 학습시의 시간의 소모와 학습시의 안정성 등의 문제가 대두된다. 본 연구에서는 새로운 셀 스트림 패턴의 수락/거절을 표준 셀 스트림 패턴과의 퍼지소속함수값을 측정하여, 그 값들의 퍼지 평균값을 취하는 FCM 연산을 거쳐, 학습화한 패턴을 생성한 후 신경망으로 그 호의 수락제어를 실시한다.

2.1 새로운 호의 수락/거절 알고리즘

신경망의 학습에 참여하지 않은 새로운 호(outside

pattern)의 수락/거절 알고리즘의 순서도를 (그림 1)에 나타낸다.



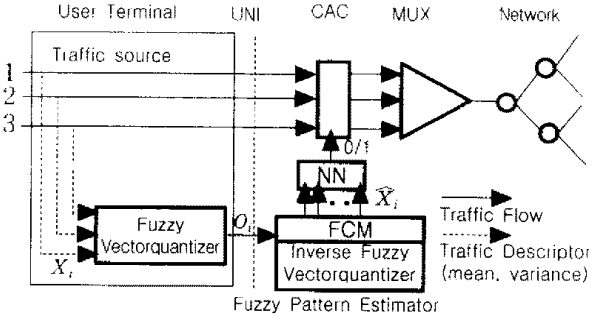
(그림 1) 퍼지 패턴 추정기에 의한 호의 수락/거절 알고리즘의 순서도

퍼지 벡터 양자화기는 표준 패턴의 코드북을 이용하여 새로운 호의 셀 스트림 패턴과의 퍼지 소속함수값(membership value)을 발생하며, 역 퍼지벡터 양자화기는 퍼지 벡터양자화기에서 발생한 퍼지 소속함수값과 FCM 연산식을 사용하여 학습화한 패턴을 생성한 후, 그 패턴을 신경망의 입력으로 사용하여 학습에 참여하지 않은 새로운 호의 수락/거절을 행한다. 한편 이렇게 생성된 패턴은 신경망 훈련시에 참가한 패턴의 정보를 포함하고 있어 결국 원래의 새로운 입력패턴이 학습에 참여한 패턴에 적용된 패턴이 된다. 이러한 방법은 신경망 학습시에 참여하지 않은 입력에 대해서는 재학습을 통하여 신경망의 연결강도를 적용시키는 것과는 달리 입력패턴을 학습시에 참여한 패턴과의 적응패턴을 생성함으로써 재학습시의 문제점을 해결할 수 있다.

2.2 퍼지 패턴 추정기-신경망 호 수락제어 시스템

새로운 입력패턴과 압축된 표준 패턴과의 유사도를 나타내는 O_i 는 각각의 표준패턴에 대응할 가능성 정도를 성분으로 하는 가중치 벡터이다. 대응 가능성 정도가 제일 큰 표준패턴이 새로운 호의 패턴과 가장 유사한 패턴이며, 코드북내의 다른 표준패턴과의 가능성 정도를 모두 고려한 학습화한 패턴을 생성하여 신경망의 입력으로 사용함으로써 호 수락제어를 효과적으로 수행하도록 한다. 이 때 사용자 단말측에서 서비스의 QoS에 따라 가능성 정도가 큰 표준패턴의 퍼지소속 함수값을 선별하여 전송함으로써 경로상의 파라미터 수를 줄일

수 있어 통신 오버헤드의 감소가 가능하다. (그림 2)의 퍼지 패턴 추정기-신경망 호 수락제어 구성도이다.



1, 2 : incoming calls 3 : requested call

(그림 2) 퍼지 패턴 발생기-신경망 호 수락제어 시스템

사용자 단말에서 호의 연결을 요구하면, 그 전에 진행중인 호와 연결을 요구하는 새로운 호가 중첩된 (aggregated) 스트림의 트래픽 파라메타인 입력벡터 X_i (관측구간별 셀 개수의 평균값과 분산값)와 코드북의 표준패턴 $Y_j (1 \leq j \leq L)$ 의 퍼지 소속함수값[14]들은 다음 식 (4)로 계산되고, 이들을 성분으로 하는 가중치 벡터 O_i 는 식 (5)로 나타낸다.

$$\mu_{ij} = \left\{ \sum_{k=1}^L \left[\frac{d(X_i, Y_j)}{d(X_i, Y_k)} \right]^{\frac{1}{F-1}} \right\}^{-1} \quad (4)$$

$$O_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{iL}] \quad (5)$$

$$d(X_i, Y_j) = \|X_i - Y_j\| = \frac{1}{N} \sum_{k=1}^N (x_{ik} - y_{jk})^2 \quad (6)$$

i 는 입력패턴의 순번, j, k 는 표준패턴의 순번, L 은 표준패턴의 개수를 각각 나타내며, 이 때 사용하는 Fuzziness(F)는 가능성의 정도를 나타내는 애매성 상수이다. 퍼지 벡터양자화기에서 전송된 O_i 와 FCM 연산식을 이용하여 학습화된 트래픽 파라메타를 식(7)으로 구하고, 이들 값을 성분 (\hat{x}_{ij})으로 하는 트래픽 파라메타 벡터 (\hat{X}_i)가 신경망 호 수락제어기에 입력되고, 그 출력값을 미리 설정된 임계치와 비교하여 도착한 새로운 호의 수락/거절을 결정하게 된다.

$$\hat{x}_{ij} = \frac{\sum_{j=1}^L [(\mu_{ij})^F y_{jk}]}{\sum_{j=1}^L [(\mu_{ij})^F]} \quad (7)$$

$$\hat{X}_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}] \quad (8)$$

F는 1 이상의 값이고, $(\mu_{ij})^F$ 는 지수함수적 증가를 나타낸다. 소속함수값 μ_{ij} 가 큰 값을 갖는 표준패턴은 학습화된 패턴을 생성할 때, 다른 표준패턴보다 상대적으로 크게 기여한다.

2.3 신경망 입력과 구조


호 수락제어를 위한 분류기 신경망 구조를 (그림 3)에 나타낸다. 신경망의 구조는 전방향 신경망 구조로서 입력층과 은닉층은 한개의 층을 사용하며, 출력층은 하나의 출력뉴런을 갖는다.

신경망의 입력들은 진행중인 호들과 연결을 요구하는 새로운 호로 구성된 스트림의 트래픽 파라메타이다. 본 연구에서 신경망 입력은 중첩된 셀 스트림 S의 평균과 분산값을 사용하며, 길이 m 인 간격동안의 셀 수의 분산값 VOC_S (Variance Of Counts)[15]는 다음과 같이 정의한다.

$$VOC_S(m) = \frac{var[N_S(i+1, i+m)]}{m} \quad (9)$$

$$m = 1, 2, 4, \dots, 2^n \quad (10)$$

여기서, i 는 임의의 시간슬롯이고, 스트림 S의 평균값과 분산값을 각각 λ_S 와 $VOC_S(m)$ 으로 나타낸다. $N_S(i)$ 는 트래픽 스트림 S의 슬롯 i 에 도착하는 셀들의 수를 표시하고, $N_S(i, j)$ 는 슬롯 i 와 j 의 간격 내에 도착하는 셀의 개수를 나타낸다. 신경망 입력의 수를 제한하기 위하여 지수함수적으로 증가하는 간격들에 대한 VOC_S 를 사용한다.



(그림 3) 신경망 구조

트래픽 파라메타 $X_i = [x_1, x_2, \dots, x_n] (1 \leq i \leq m)$

가 신경망에 입력되면 출력은 다음과 같다. 여기서 x_1 는 셀 스트림의 구간당 평균수 (λ_s)를 나타내며, x_2, \dots, x_n 는 $VOC_S(2^0), \dots, VOC_S(2^n)$ 을 각각 나타낸다.

$$Y = g_{out}(\sum_{j=1}^n W_j V_j + b_{out}) \quad (11)$$

$$V_j = g(\sum_{i=1}^n w_{ij} x_i + b_j) \quad (12)$$

$$g(x) = g_{out}(x) = \tanh(x) \quad (13)$$

여기서, W_j 는 은닉층 뉴런과 출력층 뉴런의 연결강도이고, w_{ij} 는 입력뉴런과 은닉 뉴런의 연결강도이다. $V_j, j = 1, \dots, J$ 은 j 번째 은닉뉴런에 대한 출력이다. b_{out} 과 b_j 는 각각 출력뉴런과 은닉뉴런들에 대한 바이어스값들이다. $g(x)$ 와 $g_{out}(x)$ 는 각각 은닉층 뉴런과 출력층 뉴런의 활성화 함수이다. 신경망은 입출력 패턴의 쌍 $[X_i, D_i]$ 으로 학습된다. 여기서 D_i 는 입력패턴 (X_i)에 대한 원하는 출력이다. 출력오차는 $e_i = D_i - Y_i$ 가 되며, Y_i 는 입력패턴 (X_i)에 대한 실제 출력을 나타낸다. 신경망은 오류 역전과 알고리즘을 사용하여, 오차함수를 최소로 하는 연결강도와 바이어스를 찾기 위해 학습되는데, 보통 식 (14)의 누적오차(cumulative error)와 식 (15)의 RMS(root mean square) 방법을 이용하여 오차를 측정한다.

$$J = \sum_{i=1}^m e_i^2 = \sum_{i=1}^m (D_i - Y_i)^2, \quad (14)$$

$$J_r = \frac{1}{m} \sqrt{\sum_{i=1}^m (D_i - Y_i)^2}, \quad (15)$$

3. 제안된 호 수락제어 방식의 성능 평가

본 연구에서 제안된 퍼지 트래픽 추정기를 이용한 신경망 호 수락 제어방식의 특성을 기존의 신경망 방법과 비교하기 위하여 학습에 참여하지 않은 새로운 호의 패킷을 발생하여 시뮬레이션을 수행하였다.

3.1 시뮬레이션 환경

- 트래픽 소스모델 : ON-OFF model
- 소스의 피크 레이트 : 1 cell/slot, CBR : 32 Kbps

- 링크용량 : 20 cell/slot
- 호의 평균지속시간 : 30 sec, 45 sec, 60 sec
- 호 도착율 : poisson 분포(2 calls/sec)
- ON의 평균지속시간 : 0.35 sec
- OFF의 평균지속시간 : 0.65 sec
- 발생시간 : 120sec, 150sec, 200sec
- QoS 요구 : 10^{-2} 의 셀 손실율(moving average)
- 버퍼는 고려하지 않음
- 2 계층 신경망 구조(입력노드 : 10개, 중간노드 : 2계층, 출력노드 : 1개)
- 신경망 학습알고리즘 : 오류 역전과 알고리즘


3.2 신경망 학습단계

- 중첩된 셀 스트림은 2^9 개의 time slot(관측프레임 : 512 cell-slot)으로 나누고 time slot 당 평균 셀 개수와 셀 개수의 분산값을 트래픽 파라메타로 사용
- 링크의 용량을 고려하여 셀손실율이 10^{-2} 이하인 진행중인 패킷을 발생
- 진행중인 호와 중첩하여(aggreated) QoS 요구(10^{-2} CLR)를 초과하는 것(거절패킷)과 이하인 패킷(수락패킷)을 50개 발생하여 표준 패킷으로 사용하고 신경망을 학습
- 학습에 참여하지 않은 outside 패킷은 출력링크의 용량을 고려하여 호의 지속시간의 변화와 도착율을 변화시켜 78개를 발생
- 역전과 알고리즘의 목표값을 수락패킷인 경우는 +0.9, 거절패킷이면 +0.1로 하는 분류기 신경망을 사용하며, 전체 입력패킷에 대한 평균 자승 오차의 값이 최소값으로 수렴할 때까지 학습한다.

3.3 시뮬레이션 결과 및 검토

새로운 호가 연결을 요구하면 이미 진행 중인 호와의 중첩된 셀 스트림의 관측구간별 셀 개수의 분산값과 평균값이 신경망에 입력되며 사용자 단말 측에서는 표준패킷과의 소속함수값을 CAC에 신고하고, CAC측에서는 표준패킷을 이용하여 중첩된 셀 스트림의 패킷을 추정한 트래픽 파라메타(소속함수값)를 신경망에 입력하여 그 출력이 0.5 보다 크면 수락, 이하이면 거절로 결정한다. 이때 퍼지니스값은 소속함수값과 함께 CAC에 보낸다. 기존의 신경망 방식에 의한 호 수락 제어 결과와 본 연구의 Fuzziness값 설정에 따른 호 수락 제어 결과를 나타낸다. (그림 4)와 (그림 5)는 각

기 기존의 신경망 방법과 본 연구의 퍼지 소속함수값을 트래픽 파라미터로 사용하는 방법의 호 수락제어 성능을 비교하기 위하여 관측구간별 셀 개수의 평균값과 분산값을 나타낸다.




(그림 4) 관측구간별 셀 개수의 평균값




(그림 5) 관측구간별 셀 개수의 분산값

(그림 6)은 셀 스트림의 관측 프레임별 테스트 패턴 78개에 대한 셀 손실율을 나타낸다. (그림 7)은 셀 손실율이 0.01 이하인 수락패턴 40개, 0.01이상인 거절패턴 38개의 테스트 패턴을 나타낸다.




(그림 6) 셀손실율(moving average)




(그림 7) 관측구간별 셀 스트림의 패턴

(그림 8)은 기존의 신경망에 의한 호 수락제어의 결

과를 나타낸다. (그림 9)는 본 연구의 F=1.2일 때 호 수락제어 결과를 나타낸다.




(그림 8) 기존신경망




(그림 9) F=1.2

(그림 10)와 (그림 11)은 F=1.5, F=1.8 일 때의 호 수락 제어의 결과이다.



(그림 10) F=1.5



(그림 11) F=1.8

기존의 신경망에서는 29개의 에러를 보이는 반면에 퍼지이론을 사용한 경우 에러가 9~10개를 보이고 있어, 본 연구의 호 수락제어가 효과적으로 수행됨을 보였다. Fuzziness 값에 따라서 호 수락제어의 결과에 큰 영향을(1 개 정도의 오차차이를 보임)보이지 않고 있지만 많은 패턴을 발생시 호 수락제어를 위한 최적의 Fuzziness 값의 선정이 필요하다. 또한 패턴 발생시 동일한 셀 스트림이라도 관측구간이나 창(window)의 크기에 따라 셀 손실율의 moving average 값이 다르게 나타나기도 한다(관측 프레임의 길이를 512 cell-slot으로 하고 창의 크기를 32 cell-slot, 16 cell-slot으로 했을 때 발생). 한편 본 연구는 long-term 관측구간을 moving window를 sliding 시키면서 직접 관측에 의한 트래픽특성을 파악함으로써 순간 트래픽 변동정보도 유지하고 있는 장점을 갖고 있다.

성능평가를 위해 성능평가지수를 다음과 같이 정의한다.

$$\begin{aligned} \cdot \text{정상평가지수 I} &= \frac{\text{수락된 스트림의 패턴 수}}{\text{실행가능한 스트림 패턴 수}} \times 100[\%] \\ \cdot \text{정상평가지수 II} &= \frac{\text{거절된 스트림의 패턴 수}}{\text{실행불가능한 스트림 패턴 수}} \times 100[\%] \\ \cdot \text{오류평가지수 I} &= \frac{\text{거절된 스트림의 패턴 수}}{\text{실행가능한 스트림 패턴 수}} \times 100[\%] \\ \cdot \text{오류평가지수 II} &= \frac{\text{수락된 스트림의 패턴 수}}{\text{실행가능한 스트림 패턴 수}} \times 100[\%] \end{aligned}$$

평가지수에 의한 기존의 신경망 방식과 본 연구의 CAC의 성능을 <표 1>에 나타내었다.

<표 1> 호 수락제어 성능비교[%]

성능지수 \ 방식	기존의 신경망	제안된 방식		
		F=1.2	F=1.5	F=1.8
정상평가지수 I	$\frac{23}{40}$ (57%)	$\frac{36}{40}$ (90%)	$\frac{39}{40}$ (97%)	$\frac{40}{40}$ (100%)
정상평가지수 II	$\frac{21}{38}$ (55%)	$\frac{34}{38}$ (89%)	$\frac{30}{38}$ (78%)	$\frac{30}{38}$ (78%)
오류평가지수 I	$\frac{17}{40}$ (42%)	$\frac{4}{40}$ (10%)	$\frac{8}{40}$ (20%)	$\frac{8}{40}$ (20%)
오류평가지수 II	$\frac{10}{38}$ (26%)	$\frac{6}{38}$ (15%)	$\frac{1}{28}$ (3%)	$\frac{0}{38}$ (0%)

정상평가지수 I, II에서 대략 2배, 오류평가지수 I에

서 대략 2배, 오류평가지수 II에서 대략 4배의 정도의 성능개선을 보이고 있다.

4. 결 론

본 논문에서는 사용자측에서 호 수락 제어기에 신고하는 트래픽 파라메타로 퍼지 소속 함수값을 사용하는 새로운 방법을 제시하고 기존의 신경망 방법과 성능을 비교하였다. 제안된 방식은 신경망 학습시에 훈련되지 않은 새로운 종류의 호가 발생할 때, 재학습을 하지 않고 연결을 요구하는 호의 수락/거절을 행할 수 있는 방법이다. 이것은 사용자측에서 호 수락 요청시, CAC측에서는 연결을 요구하는 호의 트래픽의 특성을 표준패턴과 퍼지 소속 함수값을 이용하여 추정함으로써, 기존의 방식에서 트래픽 파라메타로 사용하는 최대전송율, 평균전송율, burstiness로 트래픽의 특성을 나타내는 것과는 다르다. 실제 멀티미디어 서비스에서 트래픽 특성은 무수한 형태로 진행되기 때문에 특별한 모델의 규정이 어렵다. 이를 위해 본 연구에서는 직접 트래픽의 셀들의 흐름을 순간 순간 관측하여 관측구간별 셀 수의 분산과 평균값을 트래픽 파라메타로 사용하여, 특정한 트래픽 모델에 무관한 호 수락제어가 가능하도록 하였다. 향후 연구계획은 망상에서 존재하는 더욱 더 다양한 셀 스트림 패턴을 고려하여, 이들 패턴들의 트래픽 파라메타를 데이터 군집화 알고리즘을 사용하여 압축한 표준패턴 코드북을 작성하여, 호 수락제어를 실시하는 방법에 관한 것이다. 또한 측정구간(창의길이)의 길이에 따라 수락/거절패턴의 결정이 달라지므로 측정구간의 셀 개수의 분산값의 크기에 따른 관측구간의 길이를 결정하는 방법도 포함한다.

참 고 문 헌

- [1] ITU-T draft recommendation I.371, "Traffic control and congestion control in B-ISDN," Geneva, '92.
- [2] A.W.Berger and A.E.Eckberg, "A B-ISDN/ATM Traffic Descriptor and Its Use in Traffic and Congestion Control," IEEE GLOBECOM, '91.
- [3] Kang, S. H. and Sung, D.K., "A Trial Multi-layer Perceptron Neural Network for ATM Connection Admission Control," IEICE Trans. com-

mun. Vol.E76 B. No.3, March '93.

[4] R. Bollia, F.Davoli and A.Lombardo, "Adaptive bandwidth allocation by hierarchical control of multiple ATM traffic classes," IEEE INFOCOM '92.

[5] G.Gallassi, G.Rigolio and L.Fratta, "ATM : bandwidth assignment and bandwidth enforcement policies," IEEE GLOBECOM '89.

[6] J.M.Holtzman, "Copying with broadband traffic uncertainties : statistical uncertainty, fuzziness, neural networks," IEEE GLOBECOM '90.

[7] A. Hiramatsu, "ATM Communications network control by neural networks," IEEE Tran. on neural networks, Vol.1, No.1, '90.

[8] T. Takahashi and A. Hiramatsu, "Integrated ATM traffic control by distributed neural networks," IEEE JASC, Vol.9, 1991.

[9] P. Tran-Gia and O.Gropp, "Performance of a neural net used as admission controller in ATM system," IEEE GLOBECOM, '92.

[10] R.Guerin, H.Ahmadi, and M.naghshinch, "Equivalent Capacity and Its Application to bandwidth Allocation in High Speed Networks," IEEE JASC, sep., '86.

[11] R. G. Cheng and C. J. Chang, "A Neural-net Based Fuzzy Admission Controller for ATM Network," IEEE INFOCOM '96.

[12] Kiyohiko Uehara and Kaoru Hirota, "Fuzzy Connection Admission Control for ATM Networks Based on Possibility Distribution of Cell Loss Ratio," IEEE JSAC, Vol.15, No.2, Feb., 1997.

[13] C. J. Chang and R. G. Cheng, "Traffic control in an ATM network using fuzzy set theory," IEEE INFOCOM '94.

[14] H.P. Teseng, M.J.Sabin, and E.A. Lee, "Fuzzy vector quantization applied to hidden Markov modeling," Proc. ICASSP '87.

[15] R. G. Ogier and N. T.Plotkin, "Neural Network Methods with Traffic Descriptor Compression for Call Admission Control," IEEE INFOCOM, '96.

[16] 이진이, 이종찬, 이종석, "ATM 망에서 퍼지패턴 추정기를 이용한 신경망 호 수락제어에 관한 연구", Proceedings of KFIS Fall Conference '98, Vol.8, No.2.

[17] 이진이, 유재택, 이광형 외, "ABR 서비스에서의 퍼지 트래픽 제어방식", 한국정보처리 학회논문지 제3권 제 7호, '96년 12월.

[18] 유재택, 이광형 외, "ATM 망에서의 퍼지 신경망을 이용한 호 수락 제어 방식", 한국정보처리학회 논문지 제4권 제8호, '97년 8월.



이진이

e-mail : jinyi@cwunet.ac.kr

1985년 숭실대학교 전자공학과 졸업(공학사)

1988년 숭실대학교 대학원 전자공학과 졸업(공학석사)

1994년 숭실대학교 대학원 전자공학과 졸업(공학박사)

1995년~1998년 충남산업대학교 전자공학과 전임강사

1998년~현재 청운대학교 전자공학과 조교수

관심분야 : 고속통신망, 디지털 통신, 방송기술, 퍼지 신경망 응용