

# 트래픽 파라메타 압축을 이용한 ATM 연결수락제어

이진이†

요약

본 논문에서는 연결수락 제어를 사용자가 전송하는 트래픽 파라메타(셀 개수의 분산값과 평균값)를 압축하여 망에 신고하는 방법을 제안하고, 압축방법에 의한 연결수락제어의 성능을 분석 비교한다. 트래픽 파라메타 압축방법은 K-means, CL(Competitive Learning), Fuzzy ISODATA, FNC(Fuzzy Neural Clustering)를 사용한다. 제안한 트래픽 파라메타의 압축에 의한 연결수락제어는 퍼지 매핑함수(Fuzzy Mapping Function)에 의해 신고한 트래픽 패턴을 추정하고, 전방향 구조의 신경망을 사용하여 연결의 수락/거절을 결정한다. ON-OFF 트래픽 모델 환경에서 컴퓨터 실험을 통하여 여러 가지 압축방법들을 사용한 연결수락제어의 성능을 Fuzziness값에 따라 비교하였고, 그 결과 FNC 방법이 우수함을 알 수 있었다. 또한 연결수락제어의 성능을 높이기 위해서 관측 프레임의 셀 분산값이 크면 Fuzziness값을 작게 선정하고, 작으면 상대적으로 크게 선정해야 함을 알 수 있었다.

## ATM Connection Admission Control Using Traffic Parameters Compression

Jin-Yi Lee†

ABSTRACT

This paper proposes a connection admission control method based on the compression of traffic parameters. We evaluate and compare the performance of the proposed method according to typical compression methods, K-means, CL (Competitive Learning), Fuzzy ISODATA and FNC (Fuzzy Neural Clustering) algorithm. These algorithms are used to compress a number of traffic parameters (variance and mean of observed cell stream). The proposed CAC first estimates the characteristics of input traffic pattern using Fuzzy Mapping Function, and then it decides whether input traffic should be accepted or rejected, using a feedforward Neural Network. We simulate to compare the performance of connection admission control according to used compression methods. The simulation results show that the CAC using FNC algorithm outperforms other methods. To more improve CAC performance, we also found that, if variance of a frame is high, fuzziness value(F) should be small; otherwise, if variance of a frame is low, fuzziness value should be large.

**키워드** : 연결수락제어(Connection Admission Control), 데이터압축(Data Compression), 퍼지매핑함수(Fuzzy Mapping Function), 퍼지니스값(Fuzziness Value), 신경망(Neural Networks)

### 1. 서론

B-ISDN을 실현하기 위한 ATM망은 ATDM을 사용하는 특수한 형태의 패킷형 데이터 전달 방식으로 음성, 영상 및 데이터 등의 서로 다른 이질적인 트래픽 특성을 갖는 멀티미디어 서비스에 효과적으로 대처할 수 있는 유용성을 지닌 통신방식이다[1]. ATM 망에서는 많은 서비스가 망 자원을 경쟁적으로 이용하여 트래픽의 혼잡이 발생하면 한정된 망 자원의 공정한 분배와 서비스 성능 면에서 효과적인 혼잡제어가 필수적이다. 이를 위해 연결수락제어, 사용자 파라메타 제어, 망 파라메타 제어, 우선 순위제어, 폭주제어, 트래픽 셰이핑(traffic shaping)등과 같은 여러 등급의

제어와 효과적인 망 자원 관리 방법 등이 필요하다[2,3]. 연결수락제어는 트래픽의 통계적 특성을 나타내는 트래픽 파라메타와 트래픽 종류에 따른 서비스 품질 그리고 망 자원을 근거로 연결의 수락여부를 결정하는데, 해석적으로는 다루기 어려운 비선형적인 트래픽 소스의 특성 때문에 접근하기 어려울 뿐만 아니라, 연결수락여부를 결정하는데 시간을 요하여 실시간 처리에 부담을 갖게 된다. 그래서 이러한 문제들을 해결하기 위한 방안으로 크게 통계적 분석에 의한 수학적 분석에 의한 방법[4], 신경망에 의한 방법[5,6], 퍼지 이론을 응용한 방법[7,8], 퍼지와 신경망을 융합한 방법[9-11] 등이 있다.

수학적 분석방법은 트래픽 패턴의 통계적 특성을 분석하여 얻은 트래픽 패턴의 모델링에 의한 방법으로 수학적으로 복잡할 뿐만 아니라, 실제 망상에서는 무수한 서로 다른

※ 본 연구는 2000년도 청운대학교 학술연구조성비 지원에 의하여 연구되었음.

†정회원 : 청운대학교 전자공학과 교수

논문접수 : 2000년 10월 18일, 심사완료 : 2001년 5월 7일

형태의 패턴들이 흐르기 때문에 특정 모델로 단정하기는 어렵다. 신경망에 의한 방법은 신경망의 고유특성인 학습기능을 이용하여 CAC에서 수락할 수 있는 패턴과 거절해야 할 패턴들을 미리 학습한 후 입력 패턴이 들어오면 판정 기준값(보통 CLR)에 근거하여 수락 거절을 판정하는 방법이다. 이 방법은 학습시에 사용하지 않은 패턴에 대해서는 재학습을 해야 하므로 신속한 판정에 문제가 된다. 퍼지이론에 의한 방법은 트래픽 패턴을 몇 개의 부류로 나누어 각 부류의 연결 개수에 따른 CLR(cell loss ratio)의 분포를 퍼지추론으로 추정하여 수락 거절을 판단하는 방법으로 다중화 이득이 높지만 이 방식 또한 재학습을 필요로 한다. 퍼지 신경망에 의한 방법은 퍼지 소속 함수값 과 학습으로 CAC 판정이 이루어지며 특정 모델링에 의하지 않는 장점과 학습시에 사용하지 않은 패턴에 대해 판정할 때 퍼지 소속 함수 값을 사용하여 판정하므로 재학습이 필요치 않아 실시간 처리에 도움이 된다.

본 연구는 무수한 트래픽 패턴을 트래픽 파라메타로 표현하고 그 트래픽 파라메타를 압축하여 기존의 VQ(vector quantization) 방식으로 CAC를 수행하며, 트래픽의 모델링 및 재학습이 필요하지 않는 방법이다. 이 때 무수한 트래픽 파라메타를 압축하기 위해서 기존의 데이터 압축방법을 사용하고 각각의 압축 방법에 의한 표준 패턴을 사용할 때 연결 수락제어의 성능을 평가 비교한다. 트래픽 파라메타 압축은 K-means[12], CL(Competitive Learning)[13], Fuzzy ISODATA[14], FNC(Fuzzy Neural Clustering)[15] 알고리즘을 사용한다. 2장에서는 퍼지와 신경망을 융합한 연결수락제어 알고리즘에 대해 기술하고, 3장에서는 데이터 압축의 기본 원리 및 대표적인 방법들에 대해 기술한다. 4장에서는 시뮬레이션을 통하여 트래픽 파라메타 압축방법에 따른 연결 수락제어의 성능을 분석 비교한다. 5장은 결론에 관하여 기술한다.

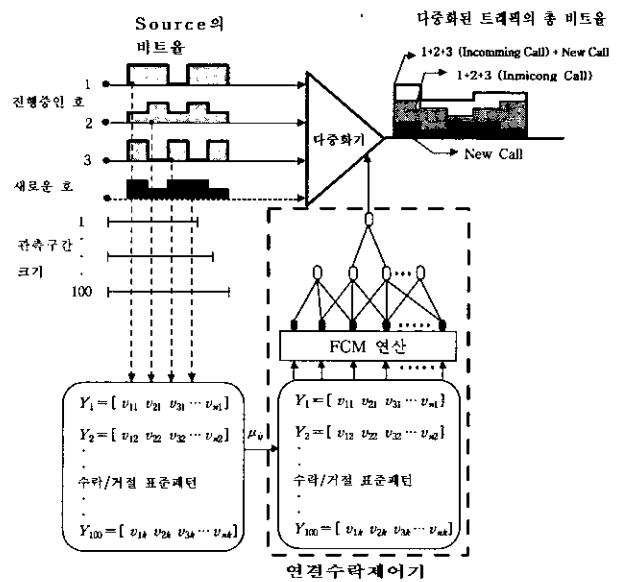
2. 파라메타 압축을 이용한 연결수락제어

본 논문에서 제시하는 연결 수락제어 방식은 퍼지와 신경망을 융합한 방식으로 트래픽 파라메타를 압축하여 전송하고, 연결 수락 제어 결정은 퍼지 매핑함수에 의해 연결을 요구하는 입력 트래픽 패턴을 추정하고, 그 추정된 패턴을 신경망으로 판정하는 방법이다. 이 방법은 신경망 학습시 사용한 트래픽 패턴이 아닌 이질적인 트래픽 패턴에 대해서는 재학습을 해야 하는 기존의 신경망에 의한 문제를 해결 할 수 있다.

2.1 퍼지 신경망 연결수락제어

신경망의 구조는 입력층, 은닉층, 출력층이 각각 하나의 층을 갖는 전 방향 구조의 신경망으로 오류 역 전파 알고


리즘을 사용하여 학습한다. 트래픽 호원(source)에서 연결을 요구하는 새로운 호가 발생하면 이미 서비스 중인 호와의 중첩된 패턴의 구간 별 셀 수의 평균값과 분산 값을 표준 패턴의 값(압축 파라메타로 구성된 일종의 코드벡터)과 비교하여 소속 함수 값을 측정하고, 그 값을 연결수락 제어기에 신고한다. 연결 수락 제어기에서는 이 전송된 값과 압축된 트래픽 표준패턴의 값으로 트래픽 패턴의 추정치를 계산하고, 그 값을 신경망의 입력으로 하고, 이때의 신경망 출력을 임계치와 비교하여 수락/거절을 판정한다. (그림 1)은 퍼지 신경망 연결수락제어기를 나타낸다.



(그림 1) 파라메타 압축을 이용한 퍼지 신경망 연결 수락제어 시스템

퍼지 매핑함수(fuzzy mapping function)에 의한 입력 트래픽 패턴과 추정된 트래픽 패턴과의 관계를 블록도와 식으로 나타내면 다음과 같다.

$$X' = F(O_i, X) \tag{1}$$



(그림 2) 퍼지 매핑 관계

사용자 터미널 측에서 연결 수락제어기에 전송할 소속 함수값은 식 (2)으로 계산되고, 식 (3)이 전송 파라메타를 나타낸다.

$$\mu_{ij} = \left\{ \sum_{k=1}^L \left[ \frac{d(X_i, Y_j)}{d(X_i, Y_k)} \right]^{\frac{1}{F-1}} \right\}^{-1} \tag{2}$$

$$O_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{iL}] \tag{3}$$

연결수락 제어기에서는 전송 파라메타와 트래픽 압축 표준패턴을 사용하여 식 (4)에 의해 입력 트래픽 패턴을 추정


하고 식 (5)를 신경망의 입력으로 하여 그 출력에 따라 수락/거절을 판정한다.

$$\hat{x}_{ij} = \frac{\sum_{n=1}^L [(\mu_{ij})^F y_n]}{\sum_{n=1}^L [(\mu_{ij})^F]} \quad (4)$$

$$\hat{X}_i = [\hat{x}_{i1}, \hat{x}_{i2}, \hat{x}_{i3}, \dots, \hat{x}_{iN}] \quad (5)$$

F 는 퍼지니스를 나타내며 1 이상의 값을 갖는다.

(그림 3)은 수락/거절을 판단해야 할 새로운 호의 셀 스트림 패턴 X 와 압축된 트래픽 표준 패턴과 퍼지 매핑 관계를 이용하여 추정된 패턴 X'을 나타낸 것이다.



(그림 3) 입력 트래픽 패턴과 퍼지 매핑에 의한 추정 트래픽과의 관계

입력 트래픽 패턴은 퍼지 매핑 함수인 식 (4)와 식 (5)에 의해 추정패턴을 생성한다. (그림 3)은 3개의 파라메타로 압축된 벡터공간에서 하나의 추정패턴을 생성하는 과정을 예로 든 것이다.

2.2 트래픽 파라메타

중첩된 셀 스트림의 분석구간을 지수함수적 길이의 타임슬롯으로 나누고 그 구간별 관측된 셀 수의 평균값과 분산값을 트래픽 파라메타로 하여 특정 트래픽 모델과는 무관한 연결 수락제어가 가능하도록 하였다. 중첩된 셀 스트림 S의 길이 m 인 관측구간의 셀의 분산값  $VOC_S$ (variance of counts)는 다음과 같이 정의한다[16].

$$VOC_S(m) = \frac{var[N_S(i+1, i+m)]}{m} \quad (6)$$

$$m = 1, 2, 4, \dots, 2^n \quad (7)$$

여기서, i는 타임슬롯이고,  $N_S(i)$ 는 트래픽 스트림 S의 슬롯 i에 도착하는 셀의 개수를 표시한다.  $N_S(i, j)$ 는 슬롯 i와 j의 구간내에 도착하는 셀 개수를 나타낸다. 파라메타 수를 제한하기 위하여 지수 함수적으로 간격을 증가시

켜 그 구간에 대한  $VOC_S$ 를 사용한다.

3. 트래픽 파라메타의 압축방법

데이터 압축방법은 여러 가지가 있다. K-means 알고리즘과 LBG 알고리즘은 먼저 입력벡터와 같은 차원을 갖는 L-레벨 초기 코드북을 Euclidian Cub 방법으로 작성한 다음 주어진 평균 왜곡변화의 임계값이 특정값 이하가 될 때까지 반복 수정하여 작성한다. 이 두 방법의 차이는 K-means 알고리즘에서 코드북의 크기는 처음에 정해지지만, LBG 알고리즘은 전체 평균왜곡이 규정치 이하가 될 때까지 코드북 크기를 늘여 가면서 원하는 성능의 코드북을 작성한다. 이들 방법들과는 다르게 퍼지소속 함수값으로 여러 집단에 소속하는 정도를 계산하여 압축하는 방법이 있다. 이것이 퍼지 클러스터링 방법(Fuzzy ISODATA)[14]이다. 그 외 신경망의 학습기능을 이용하여 코드북을 작성하는 방법으로 CL, KSFM, FSCL[17]이 있고, 퍼지와 신경망의 기능을 융합한 퍼지 학습 클러스터링 방법[15]이 있다.

3.1 데이터 압축의 기본이론[12]

N 차 벡터  $X=[x_1, x_2, \dots, x_N]$ 를 L 개의 코드벡터  $Y_j=[y_{j1}, y_{j2}, \dots, y_{jN}]$ ,  $1 \leq j \leq L$  중 하나로 대응시키는 벡터 양자화  $q(\cdot)$ 는 다음과 같이 나타낸다.

$$q(X) = Y_j \quad \text{if } X \in C_j \quad (8)$$

여기서  $C_j$ 는 벡터 X가 속한 j 번째 집단(cluster)의 영역이다.


최적 벡터 양자화기는 평균왜곡  $E\{d[X, \hat{X}]\}$ 이 최소가 된다. 여기서  $\hat{X}$ 은 X가 양자화된 코드벡터이다. 이를 위한 필요조건은 첫째, 다음의 최근접 이웃 선택 규칙(nearest neighbor selection rule)을 만족해야 한다.

$$q(X) = Y_j \quad \text{iff } d(X, Y_j) < d(X, Y_k), \quad j \neq k, \quad 1 \leq j \leq L \quad (9)$$

즉, 양자화기는 입력 벡터 X에 대해 왜곡이 가장 작은 코드벡터  $Y_j$ 를 선택한다. 둘째, 각 집단  $C_j$ 의 중심벡터(코드벡터)  $Y_j$ 는 집단내의 입력벡터와 평균 왜곡  $D_j$ 를 최소로 하는 벡터이다. 즉,

$$D_j = E[d(X, Y_j) | X \in C_j] = \int_{X \in C_j} d(X, Y_j) p(X) dX \quad (10)$$

입력 벡터 X가 2 차원 인 경우, 18 레벨로 벡터 양자화하는 것을 (그림 4)에 나타내었다. 집단  $C_j$  내의 모든 입력 벡터 X는 코드벡터  $Y_j$ 로 양자화된다.



(그림 4) 2차원 공간의 분할

3.2 K-means 알고리즘

먼저 입력벡터와 같은 차원의 L레벨 초기 코드북을 작성한 다음 임계 평균 왜곡치가 주어진 값이하가 될 때 까지 코드북을 반복수정하여 작성한다. 입력 트래픽 패턴과 표준트래픽패턴(코드벡터)의 거리는 평균자승오차법을 사용한다.

단계 (1) 초기화단계

L(코드북 레벨), N(입력 벡터차원), ε(평균왜곡 D변화의 임계값), m(반복횟수)=0, D(-1)=∞ (초기 전체 평균왜곡), n(입력벡터개수)를 정한다.

단계 (2) 초기 코드북 작성단계

초기 코드벡터(  $Y_j(0)$  )의 값을 정한다. 입력벡터의 성분들의 최대크기와 최소크기를 고려하여 랜덤하게 설정하거나, 초기 입력벡터의 값으로 L개의 코드북을 작성한다.

단계 (3) 입력벡터(  $X_i, 1 \leq i \leq n$  )를 다음 식을 만족하면 클러스터  $C_j$  로 분류

$$X_i = C_j, \text{ if } d[X_i, Y_j(m)] \leq d[X_i, Y_k(m)] \text{ all } j \neq k \quad (11)$$

단계 (4) 각 클러스터의 중심 벡터를 계산하여 코드벡터를 다시 선정

$$Y_j = Cent(C_j(m)), 1 \leq j \leq L \quad (12)$$

단계 (5) 전체 평균왜곡  $D(m)$ 을 계산

$$D(m) = E[d(X_i, Y_j)] \quad (13)$$

단계 (6)  $\frac{D(m-1) - D(m)}{D} (m) \leq \epsilon$  (14)

을 만족하지 않으면 단계 (3)을 행하고 만족하면 끝낸다.

3.3 CL(competitive learning) 알고리즘

CL의 구조는 입력층, 은닉층, 출력층으로 구성되며 입력층에서는 입력 트래픽 패턴, 즉 구간별 평균값과 분산값이

입력된다. 은닉층에서는 입력벡터와 입력층과 은닉층 뉴런 사이의 연결강도를 계산한다. 출력층에서는 은닉층에서 계산한 거리를 비교하여 최소거리의 뉴런을 택하여 승자로 결정하고 이 승자 뉴런만 학습한 후, 종료되며 입력층과 은닉층의 연결강도가 트래픽 패턴의 압축패턴이 되고 L 개를 모아 L 레벨의 표준 패턴(코드북)이 작성된다.

$$Y = [y_{ij}], \quad i=1, \dots, L \quad j=1, \dots, k \quad (15)$$

CL 방법은 승자만을 학습시키는 알고리즘으로 연결강도  $W_i(n)$ 는 다음 식으로 수정된다.

$$Y_i(n+1) = Y_i(n) + \epsilon(n)(X - Y_i(n))Z_i \quad (16)$$

$$Z_i = \begin{cases} 1, & \text{if } d(X, Y_i(n)) \leq d(X, Y_j(n)), j \neq k, 1 \leq j \leq L \\ 0, & \text{otherwise} \end{cases} \quad (17)$$

$$\epsilon(n) = A e^{(-n/T)} \quad (18)$$

여기서,  $d$ 는 벡터의 거리,  $\epsilon(n)$ 은 학습률을 나타내며 패턴들이 클러스터 중심으로 접근함에 따라 감소하는 지수함수형을 취한다.

3.4 퍼지 ISODATA 알고리즘

퍼지 군집화(clustering) 방법은 통계적 기법으로써 단순 클러스터링(crisp clustering)방법을 확장한 개념이다. 단순 군집화방법은 명확한 경계선을 넣어서 데이터집합을 몇 개의 군집으로 분류하는 것이지만 실체는 군집들의 경계부에 존재하는 데이터를 어느 한 개의 군집에만 완전히 소속시키기에는 무리가 있는 경우가 많다. 그래서 소속 함수값을 {0, 1}의 두 개의 값에서 [0, 1]로 확장해서 중간상태도 인정해 경계부의 데이터는 여러 군집에 약간씩 소속하게 한 것이 퍼지 군집화 기법이다. 이 알고리즘에 의한 코드북 작성의 과정은 다음과 같다.

단계 (1) 초기화 단계

결정된 L개의 클러스터의 초기 중심벡터  $Y_j$  를 설정하고 모든 입력벡터가 L개의 중심벡터에 소속되는 정도인 소속값을  $1/L$ 로 초기화한다.

단계 (2) 소속함수값 계산

모든 입력벡터들이 모든 집단의 중심벡터에 소속되는 소속정도  $\mu_{ij}(new)$ 를 식 (2)으로 새로 계산한다. 여기서  $\mu_{ij}$ 는  $i$  번째 입력벡터의  $j$  번째 중심벡터에 대한 소속값이고  $d(X_i, Y_j)$ 는 벡터의 거리를 나타낸다.

단계 (3)  $\max[|\mu_{ij} - \mu_{ij}(new)|] < \delta$  이면 끝낸다. 그렇지 않으면 단계 4)로 간다. 여기서  $0 < \delta < 1$ 이다.

단계 (4) 새로운 중심벡터  $Y_j(new)$ 를 다음 식으로 구한다.

$$Y_j(new) = \frac{\sum_{i=1}^n [(\mu_{ij})^F X_i]}{\sum_{i=1}^n [(\mu_{ij})^F]} \quad (19)$$

여기서  $i=1, \dots, n$  (입력벡터의 개수),  
 $j=1, \dots, L$  (중심벡터의 수 =  $L$  레벨)

단계 (5) 단계 (2)를 수행한다.

### 3.5 퍼지 신경망 클러스터링 알고리즘

CL 방법은 어떤 목적함수의 값을 최소로 하지 않고 학습하지만, 분리율을 최대로 하는 것과 입력 벡터와 뉴런의 결합강도들 사이의 거리를 최소화하는 것이 그 목표이다. 이들 두 가지 기준을 고려하여 퍼지 신경망 클러스터링 알고리즘의 퍼지 목적함수를 다음 식으로 정의한다.

$$\min Z(U, Y) = \sum_{i=1}^N \sum_{k=1}^L \{tmv^F - (\mu_{ik})^F\} d(x_i, y_k) \quad (20)$$

여기서, 다음을 만족한다.

$$\sum_{k=1}^L \mu_{ik} = 1; \forall i(i=1, \dots, N) \text{ 이고} \quad (21)$$

$$\mu_{ik} \in [0, 1]; \forall i, k (k=1, \dots, L)$$

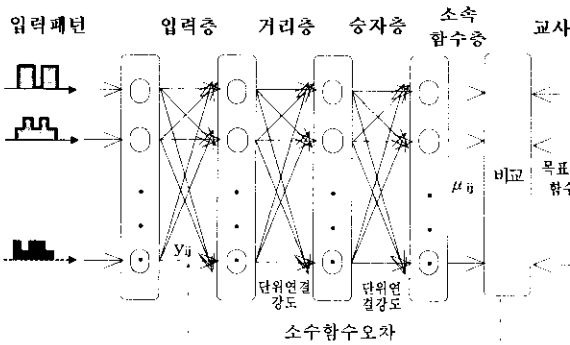
퍼지 신경망 클러스터링 알고리즘은 식 (16)에 퍼지소속 값이 포함된 다음 식이다.

$$y_j(n+1) = y_j(n) + \varepsilon(n) \{ (tmv^F - \mu_{jk}^F)(x_i - y_j(n)) Z_j \} \quad (22)$$

$$Z_j = \begin{cases} 1, & \text{if } d(X_i, Y_j(n)) \leq d(X_i, Y_k(n)), j \neq k, 1 \leq j \leq L \\ 0, & \text{otherwise} \end{cases} \quad (23)$$

여기서  $tmv$ 는 목표 소속값(target membership value)을 나타내며  $\mu_{ij}$  는 퍼지 소속 함수값을 낸다.

(그림 5)는 퍼지 신경망 클러스터링의 구조를 나타낸다.



(그림 5) 퍼지 신경망 클러스터링 구조

뉴런의 연결강도를 초기화한 다음 입력층에서는 트래픽 패턴을 입력한다. 거리층에서는  $d(x_i, y_j)$  를 계산하여 소속 값 층으로 전 방향 전송하고, 소속 값 층에서는  $\mu_{ij}$  를 계산

하여 출력한다. 비교부에서는 목표 소속값과 실제 출력의 차이값인 오차를 역전파하고, 식 (22)에 따라 뉴런의 결합 강도를 새로 정한다. 학습이 끝난 후 입력층과 거리층의 연결강도가 트래픽 파라메타의 압축패턴이 된다.

## 4. 연결 수락 제어기의 성능비교

퍼지 신경망을 이용한 연결수락제어기 성능을 트래픽 파라메타 압축방법에 따라 평가 비교한다. 트래픽 패턴은 기존의 ON-OFF 모델을 사용하여 발생하며, 신경망 학습 단계에서는 오류 역전파 알고리즘을 사용하여 거절패턴과 수락패턴을 학습한다. 학습시 사용한 수락 패턴과 거절패턴을 기존의 데이터 압축방법을 사용하여 압축하고 CAC의 운영단계에서는 50개의 학습시 사용한 패턴과 78개의 학습시 참여하지 않은 패턴에 대해 수락/거절 실험을 한다.

### 4.1 트래픽 발생환경

- 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 )
- ON 의 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 : 1 )
- 신경망 학습알고리즘 : 오류 역전파 알고리즘

### 4.2 신경망 학습단계

- 중첩된 셀 스트림은 2<sup>9</sup>개의 타임슬롯 (관측프레임 : 512 셀 슬롯)으로 나누고 타임슬롯 당 평균 셀 수와 분산값을 트래픽 파라메타로 사용
- 링크의 용량을 고려하여 셀손실율이  $10^{-2}$  이하인 진행중인 패턴을 발생
- 진행중인 호와 중첩하여 QoS 요구 ( $10^{-2}$  CLR)를 초과하는것(거절패턴)과 이하인 패턴(수락패턴)을 50개 발생하여 표준 패턴으로 사용하고 신경망을 학습
- 학습에 참여하지 않은 패턴은 출력링크의 용량을 고려하여 호의 지속시간의 변화와 도착률을 변화시켜 78개를 발생 테스트 패턴으로 사용한다.


### 4.3 파라메타 압축

- 표준패턴 50개를 4가지의 압축 알고리즘으로 1/2로


압축하여 25×10 크기의 코드북을 작성하고 78개의 테스트 패턴에 대해 호 수락/거절 실험을 한다.

4.4 시뮬레이션 결과 및 검토


트래픽 파라메타 압축방법에 의한 연결수락제어의 성능을 비교하기 위하여 (그림 6)은 셀손실율이 0.01이하인 수락패턴 40개, 0.01이상인 거절패턴 38개의 테스트 패턴을 나타낸다. (그림 7)은 테스트 패턴의 셀 손실율을 나타낸다. (그림 7)의 수락/거절패턴의 분류는 ON-OFF 모델에 의해 발생된 패턴 중 CLR 값을 0.01을 기준으로 하여 분류한 것이다. (그림 8) 트래픽 파라메타를 압축한 표준패턴을 작성할 때 K-means 알고리즘을 사용하여 78개의 테스트 패턴으로 연결수락제어를 실시한 결과를 나타낸 것이다. ○ 표시는 수락한 패턴을 나타내며, × 표시는 거절된 패턴을 나타낸다. 이 때 사용된 퍼지니스 값 F=1.8 이다. (그림 9)는 경쟁학습(CL) 방법을 사용하여 압축 표준 패턴을 작성한 후 연결 수락제어를 실시한 결과를 나타낸다(F=1.8). (그림 10)은 데이터 압축의 성능이 우수한 퍼지 클러스터링(clustering) 방법을 사용하여 압축 표준패턴을 작성하여 연결 수락제어를 실시한 결과를 나타낸 것이다(F=1.8). (그림 11)은 경쟁학습에 의한 데이터 클러스터링 방법에 퍼지 소속함수값을 도입하여 클러스터링의 중심벡터를 결정할 때 목표 소속 함수값과 구해진 소속 함수값의 차이를 학습시키는 퍼지 신경망 학습 방법을 이용한 연결 수락제어의 실시결과를 보인 것이다. (그림 10)과 (그림 11)의 결과가 (그림 8)과 (그림 9)에 비해서 (그림 6)의 테스트 패턴에 근접함을 알 수 있다. (그림 10)에서 (그림 15)는 각각의 방법에 퍼지니스 값을 다르게 선정 한 경우의 수락제어 결과를 나타낸 것이다.




○ : accept × : reject  
(그림 6) 테스트 패턴 구분




(그림 7) 테스트 패턴의 셀 손실율




○ : accept × : reject  
(그림 8) K-means (F=1.8)




○ : accept × : reject  
(그림 9) CL (F=1.8)





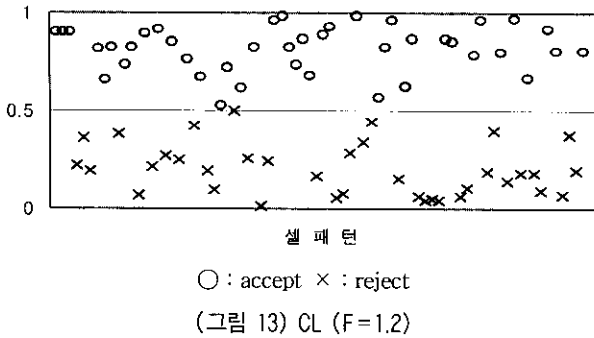
○ : accept × : reject  
(그림 10) 퍼지 ISODATA (F=1.8)



○ : accept × : reject  
(그림 11) 퍼지 신경망 클러스터링 (F=1.8)



○ : accept × : reject  
(그림 12) K-means (F=1.2)



성능평가지수를 다음과 같이 정의한다.

- 정상평가지수 I =  $\frac{\text{수락된 스트림의 패턴 수}}{\text{실행가능한 스트림 패턴 수}}$
- 정상평가지수 II =  $\frac{\text{거절된 스트림의 패턴 수}}{\text{실행불가능한 스트림 패턴 수}}$
- 오류평가지수 I =  $\frac{\text{거절된 스트림의 패턴 수}}{\text{실행가능한 스트림 패턴 수}}$
- 오류평가지수 II =  $\frac{\text{수락된 스트림의 패턴 수}}{\text{실행불가능한 스트림 패턴 수}}$

<표 1> 수락/거절의 성능비교(1/2 압축일때)

성능 지수	K-means		CL		Fuzzy ISODATA		Fuzzy Neural	
	F=1.2	F=1.8	F=1.2	F=1.8	F=1.2	F=1.8	F=1.2	F=1.8
정상평가 지수 I	22 40	22 40	24 40	22 40	26 40	26 40	26 40	28 40
정상평가 지수 II	20 38	18 38	21 38	20 38	24 38	26 38	31 38	29 38
오류평가 지수 I	18 40	18 40	16 40	18 40	14 40	14 40	14 40	12 40
오류평가 지수 II	18 38	20 38	17 38	18 38	14 38	12 38	7 38	9 38

<표 1>은 표준 데이터의 메모리를 1/2 로 압축하여 메모리 양을 1/2로 줄인 상태에서 연결 수락 제어를 실시한 결과를 보이고 있다. 표준 파라메타의 압축으로 인한 성능저하를 퍼지니스 값을 통한 추정으로 성능을 향상시킴을 알 수 있다. 또한 퍼지와 신경망을 융합한 퍼지 신경망 클러스터링에 의한 표준 파라메타의 압축방법이 작으나마 성능이 나옴을 알 수 있다. 이는 다른 클러스터링 방법과는 다르게 퍼지 목적 함수값을 최소로 하면서 학습이 이루어지기 때문이다. 그 다음은 퍼지 ISODATA 방법이 양호한 성능을 나타내는데, 이것은 crisp 방법보다 파라메타 압축시에 경계부에 존재하는 파라메타를 어느 하나의 클러스터에 완전히 소속시키는 것 보다 소속 함수 값을 사용하여 여러 클러스터에 약간씩 소속되게 함으로써 클러스터링 오차를 줄이는 퍼지 클러스터링 방법이 좀 더 우수함을 볼 수 있다. 또한 서비스 특성(오류 평가 지수 I 을 최소로 하는 것이 목적일 경우 또는 오류 평가 지수 II 를 최소로 하는 것이 목적일 경우)과 주어진 압축 방법에 따라 연결수락제어의 성능을 최적으로 할 수 있는 최적 퍼지니스 값을 선정하는 방법이 필요한데, 여기서는 관측 프레임 당 셀 개수의 통계적 특성을 나타내는 파라메타로서 분산 값을 기준하여 실험한 결과 관측 프레임당 셀 개수의 분산 값이 큰 경우에는 퍼지니스 값을 적게 선정하고 분산 값을 적은 경우에는 상대적으로 큰 값을 선정함으로써 약간의 성능 향상을 볼 수 있었다(FN 경우, 관측 프레임의 분산값 22.2 일 때 F=1.2일 때 와 F=1.8일 때 비교하면 정상평가 지수 I 에서 2개 차이). 따라서 관측 프레임 전체에 대해 일괄적으로 하나의 퍼지니스 값을 정하기 보다는 관측 프레임의 통계적 특성에 따라 적응적으로 퍼지니스 값을 정하는 것이 필요하다. 참고적으로 <표 2>는 파라메타를 압축하지 않고 수락제어를 실시한 결과를 나타낸다.

<표 2> 수락거절의 성능평가(압축을 하지 않았을 때)

성능 지수	K-means		CL		Fuzzy ISODATA		Fuzzy Neural	
	F=1.2	F=1.8	F=1.2	F=1.8	F=1.2	F=1.8	F=1.2	F=1.8
정상평가 지수 I	35 40	38 40	36 40	39 40	36 40	40 40	38 40	40 40
정상평가 지수 II	33 38	32 38	32 38	30 38	35 38	33 38	34 38	30 38
오류평가 지수 I	5 40	2 40	4 40	10 40	4 40	0 40	2 40	8 40
오류평가 지수 II	5 38	6 38	6 38	8 38	3 38	5 38	4 38	0 38

### 5. 결 론

본 논문은 퍼지 신경망을 이용한 연결 수락제어를 제안하고, 그 성능에 큰 영향을 주는 트래픽 파라메타 압축방법에 따른 연결 수락제어의 성능을 분석 비교하였다. 그 결과

퍼지 신경망에 의한 트래픽 파라메타 압축 코드북을 갖는 연결 수락 제어가 가장 좋은 성능을 보였다. 퍼지 연결 수락제어방식은 트래픽 파라메타로서 셀 스트림의 평균값과 분산값을 직접 측정하여 사용하기 때문에 트래픽 변화를 즉각 수용할 수 있을 뿐 아니라, 특정 트래픽 모델과 무관한 연결 수락제어가 가능한 장점을 갖고 있다. 그러나 이 방식은 더욱 정확한 트래픽을 예측하기 위해서는 long-term 분석이 필요한데 이 때는 압축 파라메타의 차원이 증가되는 문제와 함께 최적 압축 파라메타를 찾는 데 시간이 요하여 실시간 처리에 부담이 되는 점은 여전하다. 또한 퍼지 신경망 연결 수락제어의 성능 향상을 위해 퍼지니스값, 프레임별 분산값, 관측 프레임의 길이, 관측 창 크기의 관계를 트래픽의 특성에 따라 총체적으로 결정할 수 있는 방법의 연구가 필요하다.

참 고 문 헌

[1] 이진이(역), 「ATM 개론 -설계와 성능평가-, 21세기사, 2000년 5월.  
 [2] ATM Forum, ATM Forum traffic management specification version 4.0, AF-TM 0056.000, Apr. 1996.  
 [3] ATM Forum, ATM Forum traffic management specification version 3.0, AF-TM 95-0013R4, Jun. 1995.  
 [4] R.Guerin, H.Ahmadi, and M.naghshineh, "Equivalent Capacity and Its Application bandwidth Allocation in High Speed Networks," IEEE JASC, sep., '86.  
 [5] A. Hiramatsu, "ATM Communications network control by neural networks," IEEE Tran. on neural networks, Vol.1, No.1, '90.  
 [6] T. Takahashi and A. Hiramatsu, "Integrated ATM traffic control by distributed neural networks," IEEE JASC, Vol.9, 1991.  
 [7] 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.

[8] C. J. Chang and R. G. Cheng, "Traffic control in an ATM network using fuzzy set theory," IEEE INFOCOM '94.  
 [9] 이진이, 유재택, 이광형 외, "ABR 서비스에서의 퍼지 트래픽 제어방식", 한국정보처리학회 논문지 제3권 제7호, '96년 12월.  
 [10] 유재택, 이광형 외, "ATM 망에서의 퍼지 신경망을 이용한 호 수락 제어 방식", 한국정보처리학회 논문지 제4권 제8호, '97년 8월.  
 [11] 이진이, "신경망과 퍼지 패턴 추정기를 이용한 ATM의 호 수락 제어", 한국정보처리학회 논문지 제6권 제8호, '99년 8월.  
 [12] R. M. Gray, "Vector quantization," IEEE ASSP Mag., Vol.1, pp.4-29, April 1984.  
 [13] Stanley C, et al., "Competitive learning algorithm for vector quantization," Neural Networks 4, 1990.  
 [14] H. J. Zimmermann, Fuzzy set theory and its applications, second edition, Kluwer academic publishers. 1995.  
 [15] Fu-Lai Chung and Tong Lee, "Fuzzy Learning Vector Quantization," Proceedings of IJCN, 1993.  
 [16] Richard G. Ogier, T. Plotkin, and Irfan Khan, "Neural network methods with traffic descriptor compression for call admission control," IEEE INFOCOM '96.  
 [17] De Sieno. D., "Adding a conscience to competitive learning," In IEEE International Conference on Neural Networks, pp. 1117-1124, 1988.



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