

ATM 망에서 VBR 신호에 대한 신경회로망 예측 기법 기반의 Continuous Rate Leaky Bucket 알고리즘

정희원 이 두 현*, 신 요 안**, 김 영 한**

A Neural Network Prediction Based Continuous Rate Leaky Bucket Algorithm for VBR Signals in ATM Networks

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

요 약

최근 들어 ATM 망에서 다양한 트래픽 자원들의 버스트성 때문에 이들을 동시에 서비스하는데 혼잡 제어라는 문제에 당면하고 있으며, 이를 위하여 트래픽 상태와 버퍼의 점유 상태에 따라 토큰 생성율을 동적으로 변화시키는 DRLB (dynamic rate leaky bucket) 알고리즘과 같은 사용자변수제어/망변수제어 방법에 대한 연구가 활발히 진행되고 있다. 하지만 DRLB 알고리즘은 토큰 생성율이 현재 망의 상태에 기반을 두고 결정되기 때문에 버스티한 성격을 지닌 트래픽에 대해서는 효율성이 떨어지며, 또한 이산적인 트래픽에 대해 이산적인 토큰 생성율을 결정하므로 비디오 트래픽과 같은 VBR (variable bit rate) 신호에 대해 적용될 수 없다는 단점이 있다. 본 논문에서는 기존의 DRLB 알고리즘을 연속적인 토큰 생성율을 발생하도록 확장하고, 연속적으로 변화하는 VBR 트래픽에 대해 신경회로망 예측 기법을 이용하여 과거의 트래픽과 망의 상태에 따라 연속적인 토큰 생성율을 예측할 수 있는 CRLB (continuous rate leaky bucket) 알고리즘을 제안하고, 이의 성능을 모의 실험을 통하여 확인하였다.

ABSTRACT

The advent of ATM (asynchronous transfer mode) has created a problem of congestion control due to bursty nature of various traffic sources. To tackle this problem, UPC/NPC (user parameter control/network parameter control) have been actively studied and DRLB (dynamic rate leaky bucket) algorithm, in which the token generation rate is changed according to states of data source and buffer occupancy, is a good example of the UPC/NPC. However, the DRLB algorithm has drawbacks of low efficiency and difficult real-time implementation for bursty traffic sources because the determination of token generation rate in the algorithm is based on the present network states. Also the algorithm only determines discrete token generation rates for discrete traffic sources, thus cannot deal with VBR (variable bit rate) signals such as video traffics. In this paper, we propose the CRLB (continuous rate leaky bucket) algorithm that is a more effective congestion control algorithm by extending the DRLB algorithm to continuous VBR traffics and by exploiting neural network prediction to predict continuous token generation rates based solely on the past traffics and network states, and verify the efficacy of the proposed method by computer simulations.

I. 서 론

데이터, 음성, 비디오 등과 같은 다양한 특성의 멀

티미디어 트래픽의 전송과 처리를 체계적으로 제공하는 광대역종합정보통신망 (B-ISDN)에서, 신호 전송 방법으로 다양한 속도의 정보를 "셀"이라 불리는 일정한

* SK 텔레콤 디지털사업본부(david@sktelecom.com) 정희원, ** 숭실대학교 정보통신전자공학부(yashin@logos.soongsil.ac.kr, ytkim@dcn.soongsil.ac.kr) 정희원
논문번호 : 98001-0105, 접수일자 : 1998년 1월 5일

* 본 논문은 1997년도 한국과학재단 핵심전문연구과제 (971-0905-036-2) 지원의 결과임.

크기의 패킷으로 전송하는 비동기전달모드 (asynchronous transfer mode, ATM)가 사용된다[1]. ATM은 사용자와 망 사이에서 통계적 다중화에 의하여 여러 발신자들의 트래픽을 전송하기 때문에, 각 발신자들이 연결 설정 시의 협약을 위반할 경우 다른 트래픽에 심각한 영향을 미칠 수 있으므로 모든 트래픽에 대한 감시 제어가 필요하다. 하지만 기존의 제어 방법들은 느린 동작 속도, 많은 계산량 때문에 ATM 망과 같은 고속 환경에는 적합하지 않으며, 따라서 효과적인 혼잡 제어 알고리즘의 개발 필요성이 대두되고 있다 [2-4]. 새로운 혼잡 제어 방법은 망이 바람직하지 않은 혼잡 상태까지 도달되는 것을 방지하는 예방 제어이어야 하며, 이를 위해 ITU-T에서는 사용자망 접면 (user-network interface)에서 수행되는 사용자변수제어 (user parameter control, UPC)와 망노드 접면 (network-node interface)에서 수행되는 망변수제어 (network parameter control, NPC)의 사용을 제안하고 있다.

UPC/NPC는 망 자원의 사용에 있어서 사용자가 연결 설정 시 결정된 사항을 준수하는지의 여부를 감시하는 역할을 수행하며, 만약 연결된 호가 협약된 파라미터들을 위반하면 같은 망 자원을 공유하고 있는 다른 연결들의 QoS (quality of service)를 악화시킬 수 있기 때문에 적절한 제재 조치를 취함으로써 망 내에서 일어나는 체증을 예방하는 역할을 수행한다. 위반 셀에 대한 가장 간단한 조치로서 위반 셀들을 폐기시키는 방법을 고려할 수 있고, 다른 조치로는 위반 셀에 표시 (tagging)를 하여 이후 망 내에 혼잡 상태가 발생하였을 때 선택적으로 폐기하기 위하여 우선 순위를 낮추어 망으로 진입시키는 방법 등이 있다. 이러한 기능을 수행하는 시스템으로서 유한한 크기의 입력 버퍼와 유한한 크기의 토큰 풀을 갖는 LB (leaky bucket) 알고리즘이 널리 쓰이고 있으며, 기본적인 LB 시스템은 토큰 풀의 길이 및 입력 버퍼의 유·무, 위반된 셀의 처리, 그리고 형태에 따라 여러 가지 시스템으로 구분된다[3-8].

기본적인 LB 알고리즘은 협약 위반 셀의 폐기와 tagging을 통하여 셀 손실율과 최대 셀율을 만족시킨다. 하지만 ATM 망의 통계적 특성을 극대화하기 위해서는 사전에 협의된 평균 셀율 역시 지켜져야 하며, 기본적인 LB 알고리즘의 경우 긴 반응 시간과 나쁜 선택성 때문에 평균 셀율의 제어에 많은 어려움이 따르게 된다. 따라서 이러한 문제점을 해결하기 위해 dual LB 알고리즘 등의 여러 알고리즘들이 연구되었으나, 이들 방법은 LB를 구성하는 카운터 등의 구성 요소

가 증가하는 단점이 발생한다[9].

앞서 언급된 여러 성능 척도를 만족시키면서 구성 요소의 증가를 없애는 방안으로서 VRLB (variable rate leaky bucket) 알고리즘이 연구되었다. 특히, 트래픽 및 망의 상태에 따라 동적으로 토큰율을 변화시키는 DRLB (dynamic rate leaky bucket) 알고리즘이 VRLB 알고리즘의 좋은 예라 할 수 있다[9]. DRLB 알고리즘은 트래픽의 ON/OFF 상태와 LB 알고리즘의 버퍼 점유 상태에 따라 토큰 생성율을 동적으로 변화시킴으로써 여러 성능 척도에 대해 정확한 제어가 가능하게 된다. 또한, 이 알고리즘은 동일한 QoS를 만족시키는데 필요한 입력 버퍼와 토큰 풀의 크기가 줄어들고 위반 트래픽을 검출하는 반응 시간도 줄어들게 되는 장점을 갖는다. 하지만 DRLB 알고리즘은 현재의 트래픽과 망의 상태에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로 이에 따른 처리 지연이 발생하며, 따라서 실시간 구현이 어렵게 된다. 이러한 문제점을 해결하기 위해, 우리는 DRLB 알고리즘에 신경회로망 예측 기법을 결합하여 과거의 트래픽과 망의 상태를 이용하여 현재의 토큰 생성율을 예측함으로써 DRLB 알고리즘의 장점과 함께 실시간 처리에 보다 적합한 적응적인 알고리즘을 제안하였다[10].

한편 DRLB 알고리즘의 또 다른 단점으로 지적될 수 있는 것은, ON/OFF 트래픽과 같은 이산적인 (discrete) 트래픽에 대해 이산적인 토큰 생성율을 결정하므로 비디오 트래픽과 같은 VBR (variable bit rate) 신호에 대해 적용될 수 없다는 점이다. 본 논문에서는 참고문헌 [10]의 연구 결과를 바탕으로 하여 신경회로망 예측 기법을 결합한 DRLB 알고리즘을 연속적으로 변화하는 트래픽에 대해 연속적인 토큰 생성율을 결정하도록 확장하여 비디오 신호와 같은 VBR 트래픽에 대해서도 적용 가능하도록 한 CRLB (continuous rate leaky bucket) 알고리즘을 제안하고, 이의 성능을 실제 비디오 트래픽을 이용한 모의 실험을 통해 확인하기로 한다.

본 논문의 구성은 다음과 같다: 2 장에서는 DRLB 알고리즘과 참고문헌 [10]에서 예측기로 사용된 다중계층 피셉트론 (multi-layered perceptron) 신경회로망에 대해 간략히 기술하고, 신경회로망 예측 기반의 DRLB 알고리즘에 대하여 설명한다. 3 장에서는 VBR 트래픽에 대한 신경회로망의 예측 기반의 CRLB 알고리즘을 제안하며, 4 장에서는 시뮬레이션 결과와 고찰을, 그리고 마지막으로 5 장에서는 결론을 내리도록 한다.

II. 신경회로망 예측 기반의 DRLB 알고리즘

2.1 DRLB 알고리즘

일반적인 LB 알고리즘에서는 망으로 입력되는 트래픽을 수용하는 데이터 버퍼와 생성된 토큰 중 남아 있는 토큰을 저장하는 토큰 풀 두 종류의 버퍼를 이용하며, 입력 데이터는 토큰 풀에 토큰이 있는 경우에만 이를 소비하고 망으로 진입할 수 있게 된다. 따라서, 토큰 생성율이 일정한 기존의 LB 알고리즘에서는 입력 트래픽이 버스티한 경우에 토큰이 효율적으로 사용되지 못한다. 예를 들어, 트래픽의 긴 OFF 구간에서는 계속적으로 토큰이 발생하고 이들이 소비되지 않으므로 토큰 풀이 차게되며 이후 생성된 토큰은 소멸된다. 반대로 긴 ON 구간에는 도착되는 입력 셀들을 전송하기 위하여 더욱 많은 토큰이 필요하게 된다. 그러므로 버스티한 트래픽의 QoS를 만족시키려면 더욱 큰 입력 버퍼와 토큰 풀이 필요하게 되고, 이것은 평균 지연, 위반 트래픽의 검출과 적절한 제재에 걸리는 반응 시간의 증가를 유발하여 실시간 전송이 요구되는 ATM 망에는 적절하지 못하다. 참고문헌 [9]에서 제안된 DRLB (dynamic rate leaky bucket) 알고리즘은 트래픽의 ON/OFF 상태와 LB의 버퍼 점유 상태에 따라 토큰 생성율을 동적으로 변화시킴으로써 위에서 언급된 고정 토큰 발생을 LB 알고리즘의 단점을 제거하는 방법이다.

그림 1은 DRLB 알고리즘의 대기화 모델을 도시하며, 고정 토큰 생성율이 아닌 R_0, R_1, R_2 로 표기된 다중 토큰 생성율을 사용하는 점을 제외하고는 기존의 LB 알고리즘의 대기화 모델과 동일하다.

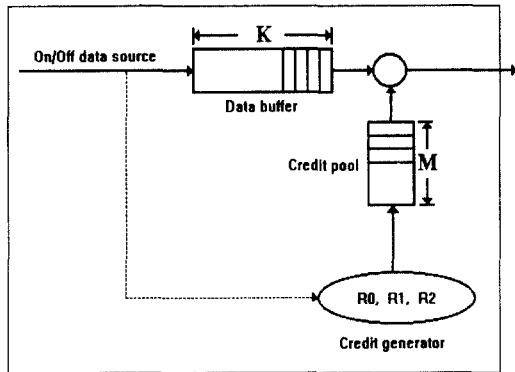


그림 1. DRLB 알고리즘의 대기화 모델.
Fig. 1 Queuing model of the DRLB algorithm.

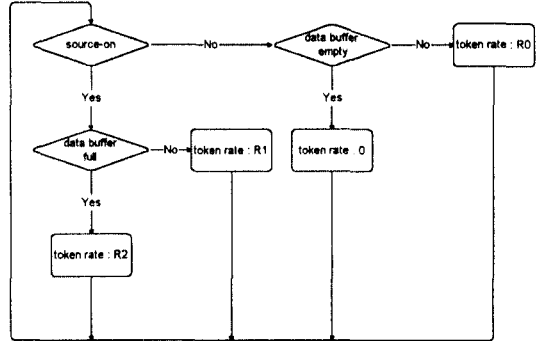


그림 2. DRLB 알고리즘.
Fig. 2 DRLB algorithm.

그림 2는 DRLB 알고리즘에서 사용되는 동적인 토큰 생성율 원칙을 도시하며, 이를 정리하면 다음과 같다. 입력 트래픽의 ON 구간에서의 토큰 생성율 (R_1)은 OFF 구간에서의 토큰 생성율 (R_0)보다 크며, 각 경우의 평균 토큰 생성율은 같게 유지한다. 셀 손실 상태에서의 토큰 생성율 (R_2)은 앞의 두 경우보다 더 작게 변화된다. 그러므로 긴 OFF 구간에서는 토큰의 손실이 줄어들게 되며 전체적으로 토큰을 더욱 효율적으로 사용할 수 있게 된다. 하지만 앞서 언급된 대로 이 알고리즘은 현재의 트래픽에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로 이에 따른 처리 지연이 발생하며, 따라서 실시간 구현이 어렵게 된다. 이러한 문제점을 해결하기 위해, 우리는 DRLB 알고리즘에 신경회로망 예측 기법을 결합하여 과거의 트래픽과 망의 상태를 이용하여 현재의 토큰 생성율을 예측함으로써 DRLB 알고리즘의 장점과 함께 실시간 처리에 보다 적합한 적용적인 알고리즘을 제안하였으며[10], 다음에는 제안 방법에서 예측기로 사용된 다중계층 퍼셉트론 신경회로망에 대하여 설명하도록 한다.

2.2 다중계층 퍼셉트론

참고문헌 [10]에서 예측기로 사용된 신경회로망은 그림 3과 같이 하나의 은닉층을 갖는 2 계층 다중계층 퍼셉트론 (multi-layered perceptron)[11]이다.

그림 3에서 출력 신호 \hat{z} 은 아래 식과 같이 표현된다.

$$\hat{z} = \sigma \left(\sum_{m=0}^{N_H} v_m h_m \right) = \sigma \left(v_0 + \sum_{m=1}^{N_H} v_m \sigma \left(\sum_{k=0}^M w_{km} x_k \right) \right) \quad (1)$$




그림 3. 하나의 은닉층을 갖는 다중계층 퍼셉트론.
Fig. 3 A multi-layered perceptron with one hidden layer.

여기서 입력은 N_I 개, 은닉층 노드는 N_H 개, 출력층 노드는 1개이며, N_I 개의 입력은 x_1, \dots, x_{N_I} 로 표기되며, $x_0 \equiv 1$ 이다. 또한 은닉층 노드 출력은 h_1, \dots, h_{N_H} 로 표기되며, $h_0 \equiv 1$ 이다. 학습에 의해 개선되는 뉴런 간 연결 강도는 입력층-은닉층의 경우 w_{km} ($k = 0, \dots, N_I, m = 1, \dots, N_H$)로 표현되며 이는 k 번째 입력과 m 번째 은닉층 노드 사이의 연결 강도를 나타낸다. 또한 은닉층-출력층의 경우 v_m ($m = 0, 1, \dots, N_H$)은 m 번째 은닉층 노드 출력 h_m 과 출력층 노드 사이의 연결 강도이다. 활성 함수 $\sigma(\cdot)$ 는 다음 식 (2)와 같이 (0,1) 범위의 값을 출력으로 하는 단조 증가 함수인 시그모이드 함수를 사용하였으며, 학습을 위해서는 현재 가장 널리 사용되고 있는 오차 역전파 (error back-propagation) 알고리즘[11]을 이용하였다.

$$\sigma(u) \equiv \frac{1}{1 + e^{-u}} \quad (-\infty < u < +\infty) \quad (2)$$

2.3 신경회로망 예측 기법을 이용한 DRLB 알고리즘

그림 4에서는 참고문헌 [10]에서 제안된 신경회로망 예측 기반의 DRLB 알고리즘을 나타내고 있다.

우리가 예측하고자 하는 시간 t 에서의 DRLB 알고리즘의 실제 토큰 생성율은 g_t 이고, 신경회로망에 의하여 예측되는 토큰 생성율은 \hat{g}_t 이다. 매 표본 시간을 Δ 라 할 때, g_t 에 대한 예측은 한 단계 전인 시간 $t - \Delta$ 까지 우리가 사용 가능한 정보를 이용하여




그림 4. 신경회로망 예측 기반의 DRLB 알고리즘.
Fig. 4 A neural network prediction based DRLB algorithm.

수행된다. 이러한 과정은 매 표본 시간 Δ 마다 이루어지며, 이때 신경회로망으로의 입력도 한 셀 구간만큼씩 이동된다. 신경회로망 학습 시 신경회로망의 입력은 식 (3)과 같고, 원래 DRLB 알고리즘의 입력은 (4)와 같다.

$$H(t - \Delta) = [y_{t-p\Delta}, \dots, y_{t-\Delta}, C_{t-\Delta}, T_{t-\Delta}] \quad (3)$$

$$[y_t, C_t] \quad (4)$$

여기서 $y_{t-i\Delta}$ ($i = 1, \dots, p$)는 과거 시간 $t - i\Delta$ 에서의 트래픽, C_t 와 $C_{t-\Delta}$ 는 각각 시간 t 와 $t - \Delta$ 에서의 입력 버퍼 상태, $T_{t-\Delta}$ 는 $t - \Delta$ 에서의 토큰 풀의 상태를 나타낸다. 신경회로망 학습을 위한 목표 출력은 식 (4)의 입력에 따라 결정된 시간 t 에서의 DRLB 알고리즘의 토큰 생성율 g_t 이다.

제안된 알고리즘에서 사용된 신경회로망은 앞서 그림 3과 같은 2 계층 다중계층 퍼셉트론이며, 입력층 노드는 $N_I = 22$ 개, 은닉층 노드는 $N_H = 10$ 개, 그리고 출력층 노드는 1 개이다. 신경회로망의 22 개 입력으로서, 식 (3)에서와 같이 과거 20 셀 구간의 트래픽 $y_{t-20\Delta}, \dots, y_{t-\Delta}$ (즉, $p = 20$)과 $C_{t-\Delta}$, 그리고 $T_{t-\Delta}$ 를 이용하였으며, 학습을 위해서 오프라인 형태의 오차 역전파 알고리즘[11]을 이용하였다.

패킷화된 음성 신호와 같은 ON/OFF 트래픽[12]에 대한 모의 실험 결과, 신경회로망을 이용하여 토큰 생성율을 미리 예측했을 경우에도 DRLB 알고리즘과 거의 유사한 토큰 생성율을 생성함을 알 수 있으며, 평균 셀율과 목표 셀 손실율 측면에서도 원래의 DRLB 알고리즘과 거의 유사한 성능을 보임을 알 수 있었다. 따라서, 제안된 신경회로망 기반의 토큰 생성율 예측 방법이 DRLB 알고리즘에서 필요한 현재의 트래픽의

상태를 알고 있다는 가정을 제거하면서 매우 효과적으로 사용될 수 있음을 알 수 있었다.

III. VBR 트래픽에 대한 신경회로망의 예측 기반의 CRLB 알고리즘

우리가 참고문헌 [10]에서 제안한 신경회로망 예측 기법을 결합한 DRLB 알고리즘은 원래의 DRLB 알고리즘의 단점인 현재 트래픽 정보에 대한 의존을 제거하였지만, 이와 마찬가지로 ON/OFF 트래픽에 대해 이산적인 토큰 생성율을 결정하는데 이용할 수밖에 없다는 단점이 있다. 하지만 비디오와 같은 VBR 트래픽들은 향후 B-ISDN에서 전체 트래픽의 상당한 부분을 차지할 것으로 여겨지며, 따라서 이러한 트래픽들에 대한 효과적인 제어 방법의 개발이 매우 중요하다 할 수 있다. 따라서 본 절에서는 앞서 언급된 신경회로망 예측 기법을 결합한 DRLB 알고리즘을 연속적으로 변화하는 트래픽에 대해 연속적인 토큰 생성율을 결정하도록 확장한 CRLB (continuous rate leaky bucket) 알고리즘을 제안하기로 한다.

제안된 알고리즘의 동작 원리는 다음과 같다. ON/OFF 트래픽에 대한 DRLB 알고리즘에서는 과거 트래픽, 과거 입력 버퍼 상태 및 과거 토큰 풀 상태에 따라 이산적인 토큰 생성율이 결정된다. 하지만 CRLB 알고리즘에서는 먼저 현재 시간 t 의 연속적인 트래픽 y_t 의 최소값 $y_{t, \min}$ 과 최대값 $y_{t, \max}$ 의 범위에서 토큰 생성율 ("TGR") g_t 를 y_t 에 대한 단조 증가 함수로 정의한다. 즉,

$$g_t(y_t) \equiv f(y_t) \tag{5}$$

$$\frac{df(y_t)}{dy_t} > 0 \quad (y_{t, \min} \leq y_t \leq y_{t, \max}) \tag{6}$$

본 논문에서는, 단조 증가 함수로서 아래 식 (7)과 그림 5와 같은 선형 함수를 이용하여 토큰 생성율을 미리 정한 $R_{\min} \sim R_{\max}$ 의 범위에 매핑하였다.

$$g_t(y_t) = \frac{R_{\max} - R_{\min}}{y_{t, \max} - y_{t, \min}} \cdot (y_t - y_{t, \min}) + R_{\min} \tag{7}$$

이렇게 (선형적으로) 단조 증가하며 변화하는 토큰 생성율을 사용할 경우 고정된 토큰 생성율을 사용하는 기존의 LB 알고리즘보다 전체적으로 토큰을 더욱 효율적으로 사용할 수 있게 된다.




그림 5. 입력 트래픽과 토큰 생성율 사이의 선형 매핑.
Fig. 5 A linear mapping between input traffic and token generation rate.

위와 같은 방법으로 생성되는 토큰 생성율은 여전히 현재의 트래픽에 기반을 두고 결정되기 때문에, 우리는 과거의 입력 트래픽, 입력 버퍼와 토큰 풀 상태를 신경회로망의 입력으로 하여 현재 트래픽 y_t 에 대한 토큰 생성율 g_t 를 예측하고, 이렇게 예측된 값 \hat{g}_t 를 현재 트래픽 y_t 의 제어를 위해 사용한다.

다음 그림 6에서는 제안된 알고리즘의 구성을 도시한다. 여기서, "CRLB" 블록은 입력 버퍼, 토큰 풀, 그리고 식 (7)의 선형 매핑으로 구성된다. 앞서 언급된 대로, 현재 시간 t 에서 식 (7)에 의해 결정되는 실제 토큰 생성율은 g_t 이고, 신경회로망에 의해 예측되는 토큰 생성율은 \hat{g}_t 이다. 신경회로망 학습은 매 표본 시간 (Δ) 마다 이루어지며, 이때 신경회로망으로의 입력도 한 Δ 구간 만큼씩 이동된다. 본 논문에서 표본 시간 Δ 는 비디오 트래픽의 기본 시간 단위인 1 slice (약 1.4 msec)에 해당한다.




그림 6. 제안된 신경회로망 예측 기반의 CRLB 알고리즘.
Fig. 6 Proposed neural network prediction based CRLB algorithm.

신경회로망 학습 시 신경회로망으로의 입력은 DRLB 알고리즘에서와 유사하게 다음 식 (8)과 같다.

$$H(t-\Delta) = [y_{t-p\Delta}, \dots, y_{t-\Delta}, C_{t-\Delta}, T_{t-\Delta}] \quad (8)$$

여기서 $y_{t-i\Delta}$ ($i = 1, \dots, p$)는 과거 시간 $t-i\Delta$ 에서의 트래픽, $C_{t-\Delta}$ 는 시간 $t-\Delta$ 에서의 입력 버퍼 상태, $T_{t-\Delta}$ 는 $t-\Delta$ 에서의 토큰 풀의 상태를 나타낸다. 현재 시간 t 의 토큰 생성율 g_t 는 신경회로망의 목표 출력이 되며, -1 과 $+1$ 사이의 값으로 다시 선형적으로 정규화되어 사용된다. 예측을 위해 사용된 신경회로망은 그림 3과 같은 2 계층 다중계층 퍼셉트론이고, 학습을 위해서 모멘텀 (momentum) 항 [11]이 추가된 오프라인 형태의 오차역전파 알고리즘을 사용하였다. 앞서의 DRLB 알고리즘과는 달리, CRLB 알고리즘의 경우 목표 출력 g_t 가 -1 과 $+1$ 사이의 값을 갖게 되므로, 뉴런 활성화 함수 $\sigma(\cdot)$ 로서 $(-1, +1)$ 범위의 값을 출력으로 하는 식 (9)의 hyperbolic tangent 함수를 사용하였다.

$$\sigma(u) \equiv \tanh(u) = \frac{e^{+u} - e^{-u}}{e^{+u} + e^{-u}} \quad (-\infty < u < \infty) \quad (9)$$

IV. 모의 실험

제안된 알고리즘의 성능은 컴퓨터 모의 실험을 통하여 평가되었다. 모의 실험에 사용된 VBR 신호는 실제 비디오 트래픽으로서, intra-frame 8×8 DCT (discrete cosine transform)를 이용하여 부호화된 영화 "Star Wars" 데이터이다[13]. 이 데이터는 slice 레벨로 표현되어 있으며, 30 개의 slice가 하나의 프레임 (frame)을 구성하고 1 초당 24 프레임의 전송율을 갖는다. 따라서, 하나의 slice는 약 1.4 msec 분량의 정보를 나타낸다. 원래의 데이터는 bytes/slice 단위로 표시되나, 실제 모의 실험에서는 ATM 셀 (53 바이트)을 가정하여 cells/slice 단위로 변환하여 사용하였다.

예측을 위해 사용된 신경회로망의 입력 벡터의 크기는 7로서, 식 (8)에서 시간 t 이전의 5 개 과거 입력 트래픽 $y_{t-5\Delta}, \dots, y_{t-\Delta}$ (즉, $p=5$), 시간 $t-\Delta$ 에서의 $C_{t-\Delta}$ 및 $T_{t-\Delta}$ 로 구성된다. 여기서, 신경회로망 학습과 테스트는 매 표본 시간 Δ 마다 이루어지며, 이때 신경회로망으로의 입력도 한 Δ 구간만큼씩 이동된다.

제안된 CRLB 알고리즘 내의 신경회로망 예측기를 위하여 각각 다른 1 "페이지 (page)"의 데이터를 학습과 테스트에 사용하였다. 다음 그림 7은 학습 및 테스트에 사용된 데이터의 일부 (각 페이지의 초기 200 프레임)를 도시하고 있다. 여기서, 하나의 페이지는 2,850 프레임 혹은 85,500 slice로 구성되며 약 2 분 분량의 비디오 신호에 해당된다. 앞서 언급한 것처럼 신경회로망 학습과 테스트는 매 표본 시간 Δ 마다 이루어지며, Δ 를 1 slice로 정의하였다. 또한, 현재 시간 t 의 트래픽에 대해 과거 시간 $t-5\Delta, \dots, t-\Delta$ 의 5개 데이터를 신경회로망 입력의 일부로 사용하므로, 결국 학습과 테스트 각각에 85,495개의 데이터 벡터를 사용한 것이 된다.

신경회로망 예측기로서 사용된 다중계층 퍼셉트론에서, 은닉층 뉴런의 개수는 20 개로 정하였으며, 출력층 뉴런은 1 개이다. 식 (7)에 의해 결정되는 현재 시간 t 의 토큰 생성율 g_t 는 신경회로망 학습 및 테스트 시의 목표 출력이 되며, 앞서 언급된 대로 -1 과 $+1$ 사이의 값으로 다시 선형적으로 정규화되어 사용되었다. 신경회로망 학습 시 사용된 학습율과 모멘텀 상수는 각각 0.01, 0.2로 정하였다. 여기서 사용된 은닉층 뉴런의 개수, 학습율, 모멘텀 상수 등은 신경회로망 학습이 가장 잘 이루어지는 값들을 여러 차례의 실험을 통하여 구하여 사용하였다.

식 (7)과 같은 입력 트래픽과 토큰 생성율 사이의 선형 매핑에서 입력 트래픽의 최소값 $y_{t,\min} = 6$ (cells)이고 최대값은 $y_{t,\max} = 56$ (cells)이며, 이러한 입력 트래픽에 대해 $R_{\min} = 7.198$ 부터 $R_{\max} = 59.5$ (cells/slice)까지의 범위에서 토큰 생성율을 매핑하였다.

그림 8은 신경회로망 학습 시 성능 지표로 사용된 평균자승오차 (mean squared error, MSE)의 변화를 나타내는 학습 곡선이며, 매우 빠른 수렴 특성을 보임을 알 수 있다. 여기서 1 "epoch"은 전체 학습 패턴의 1회 사용을 의미한다. 또한 MSE $\overline{\epsilon^2}$ 는 아래 식 (10)과 같이 정의되며, 이 식에서 $L \equiv 85,495$ 은 학습 패턴의 개수, $g^{(\ell)}$ 과 $\hat{g}^{(\ell)}$ 은 ℓ ($\ell = 1, \dots, L$)번째 패턴에 대하여 $-1 \sim +1$ 사이의 값으로 정규화된 목표 토큰 생성율과 실제 신경회로망의 출력으로 얻은 토큰 생성율을 각각 나타낸다.

$$\overline{\epsilon^2} \equiv \frac{1}{L} \sum_{\ell=1}^L (g^{(\ell)} - \hat{g}^{(\ell)})^2 \quad (10)$$





그림 7. 성능 평가를 위해 사용된 데이터, (a) 신경회로망 학습을 위한 페이지의 초기 200 프레임, (b) 신경 회로망 테스트를 위한 페이지의 초기 200 프레임.
Fig. 7 Data for performance evaluation, (a) first 200 frames of the page used for neural network training, and (b) first 200 frames of the page used for neural network test.

표 1에는 신경회로망 학습 및 테스트를 위해 사용된 비디오 트래픽 데이터에 대해 식 (7)로 결정된 토큰 생성율의 통계적인 특성을 정리하였으며, 이들 두




그림 8. 신경회로망의 학습 곡선.
Fig. 8 Learning curve of the neural network.

표 1. 신경회로망 학습 및 테스트 데이터에 대한 토큰 생성율의 통계적인 특성.

Table 1. Statistical characteristics of the token generation rates for neural network training and test data.

	학습 데이터의 토큰 생성율 (cells/slice)	테스트 데이터의 토큰 생성율 (cells/slice)
평균	20.60	22.03
표준편차	7.71	5.55
최소값	8.86	6.74
최대값	48.13	46.83

데이터 사이에 약간의 통계적인 차이가 존재함을 보여준다.

다음 표 2는 제안된 알고리즘의 학습이 완료되어 모든 연결 강도를 고정 후 테스트 페이지에 대하여 제안 알고리즘을 적용했을 경우의 셀 손실율과, 학습 데이터에 대한 평균 토큰 생성율인 20.60 (cells/slice) 으로 토큰 생성율을 고정한 기존의 LB 알고리즘에 적용시켰을 때의 셀 손실율을 비교하였다. 여기서 QoS 요소로서 셀 손실율 이외에 셀 지연을 들 수 있으나, 유한 셀 버퍼에 의해 최대 셀 지연이 제한되고 전체 종단간 셀 지연에서 UPC에 의한 셀 지연의 영향이 상대적으로 적으므로 본 논문에서는 QoS 요소로서 셀 손실율만을 고려하였다. 이 결과로부터 우리는 제안된 CRLB 알고리즘을 적용하였을 경우 고정 토큰 생성율의 LB 알고리즘보다 셀 손실율 면에서 월등히 우세함을 알 수 있으며, 또한 CRLB 알고리즘의 경우에

위의 셀 손실을 얻는데 사용된 토큰의 개수가 고정 토큰 생성율의 경우보다 적음을 역시 알 수 있었다. 이러한 결과는 신경회로망 적용 시의 장점인 효과적인 트래픽 특성 예측을 통한 실시간 구현상의 용이함과 동시에, 매우 우수한 제어 성능 역시 가능함을 보여주는 결과라 할 수 있다.

표 2. 테스트 데이터에 대한 셀 손실율 비교.
Table 2. Comparison of cell loss rates for test data.

$R_{min} \sim R_{max}$ (cells/slice)	CRLB 알고리즘	고정 토큰 생성율 LB 알고리즘
7.198 ~ 59.5	8.013×10^{-5}	6.937×10^{-3}

V. 결 론

본 논문에서는 신경회로망 예측 기법을 기반으로 하여 ATM 망에서의 실시간 구현 및 이용이 가능하며, 또한 비디오 신호와 같은 VBR 트래픽에 대해 효과적으로 사용될 수 있는 LB 알고리즘 방법인 CRLB (continuous rate leaky bucket) 알고리즘을 제안하였다. 제안된 알고리즘은 신경회로망 예측 기법을 이용하여 과거의 트래픽과 LB의 상태에 따라 현재의 트래픽에 대한 토큰 생성율을 미리 예측하므로써, 앞으로의 트래픽 변화에 대처할 수 있는 방법이다.

대부분의 VRLB (variable rate leaky bucket) 알고리즘들이 현재의 트래픽에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로써 실제 실시간, 고속으로 동작해야 하는 ATM 망에서 구현 시 문제가 되며, 따라서 본 논문의 결과는 실제 ATM 망에서 사용하려는 경우 실시간 구현상의 용이함과 간결성을 얻을 수 있다는 장점을 갖게됨을 알 수 있다. 또한 신경회로망 VLSI 기술의 발달로 실제 하드웨어의 구현 시 상당히 빠른 처리 시간을 가질 수 있으며, 이것은 신경회로망을 이용한 트래픽 제어가 실시간, 고속으로 동작해야 하는 ATM 망에 매우 적합하다고 할 수 있다.

본 논문에서 제안한 CRLB 알고리즘은 우리가 이미 제안한 신경회로망 예측 기반의 DRLB 알고리즘에서처럼 토큰 생성율의 예측을 위해 과거의 트래픽과 데이터 버퍼 및 토큰 풀의 상태를 이용한다는 점에서는 유사하나, DRLB 알고리즘이 ON/OFF 트래픽에 대해 이산적인 토큰 생성율을 결정하는 것과는 달리 연속적인 입력 트래픽과 역시 연속적인 토큰 생성율을 단

조 증가 함수를 이용하여 매핑하고 이를 신경회로망이 예측하도록 함으로써 비디오 신호와 같은 VBR 트래픽에도 적용 가능하도록 확장한 방법이다. 실제 비디오 트래픽을 이용한 모의 실험한 결과, 본 제안 방법이 고정 토큰 생성율을 사용하는 LB 알고리즘에 비해 QoS로 사용된 셀 손실율의 측면에서 매우 우수함을 알 수 있었고, 필요한 토큰도 적게 요구함을 알 수 있었다.

제안된 예측 알고리즘 입력의 일부로서 5 개의 과거 트래픽을 이용하였으며, 이는 실험에 의하여 결정된 값이다. 실제, 제안 알고리즘에서는 과거 입력 트래픽의 개수, 신경회로망의 구조 및 학습 파라미터, 시간 지연 간격 (과거 입력 데이터를 Δ 단위로 취할 것인지 아니면 이의 정수배 단위로 취할 것인지 등) 과 같은 여러 요소가 복잡하게 상호 작용하며, 본 논문에서 사용된 5 개보다 적은 과거 트래픽을 이용할 경우에도 우리가 실험하지 못한 여러 파라미터 조합에 대해 본 논문의 결과와 유사한 결과를 얻을 가능성이 존재한다. 하지만 이러한 문제는 일반적인 신경회로망의 응용 문제에서 자주 접하게 되는 문제이며 이에 대한 명확한 이론적 해결책이 아직 없는 것이 사실이다. 본 논문의 초점은 이러한 여러 요소의 조합에 대한 비교 평가가 아니라, 신경회로망과 적절한 트래픽-토큰 생성율 매핑을 이용하여 VBR 트래픽에 대한 UPC를 효과적으로 수행할 수 있다는 점을 보이고자 함에 주안점을 맞추고 있으며, 따라서 추후 연구 방향으로서 이러한 여러 요소의 조합에 대한 성능 비교와 이를 통한 최적의 조합을 결정하는 연구를 고려할 수 있다. 또한 토큰 생성율의 선형 매핑 이외의 매핑을 통한 성능 변화를 비교·분석하는 연구와, 제안 알고리즘 성능에 대한 이론적인 분석 및 타 방법과의 좀 더 많은 비교 연구가 수행되어야 할 것으로 생각된다.

참 고 문 헌

1. CCITT Study Group XVIII, "Broadband aspects of ISDN," *Blue Book Recommendation I.121 Vol. III.7*, Geneva, 1989.
2. 이병기, 강민호, 이종희, *광대역 정보통신*, 교학사, 1995.
3. A. W. Berger, "Performance analysis of a control throttle where tokens and jobs queue," *IEEE Jour. Sel. Areas in Commun.*, Vol. 9, No. 2, pp. 165-170, February 1991.

4. A. W. Berger, "Over load control using rate control throttle: selecting token bank capacity for robustness to arrival rates," *IEEE Trans. Automatic Control*, Vol. 9, No. 2, pp. 216-219, February 1991.

이 두 현(Du-Hern Lee) 정희원
 현재: SK텔레콤 디지털사업본부
 한국통신학회논문지 21권 8호 참조
5. H. J. Chao, "Design of leaky bucket access control schemes in ATM networks," *Proc. Int'l Conf. on Commun.*, Vol. 1, pp. 0180-0187, Denver, USA, 1991.

신 요 안(Yoan Shin) 정희원
 현재: 송실대학교 정보통신전자공학부 조교수
 한국통신학회논문지 23권 7호 참조
6. M. Butto, E. Cavallero and A. Tonietti, "Effectiveness of leaky bucket policing mechanism in ATM networks," *IEEE Jour. Sel. Areas in Commun.*, Vol. 9, No. 3, pp. 335- 342, April 1991.

김 영 한(Young-Han Kim) 정희원
 현재: 송실대학교 정보통신전자공학부 조교수
 한국통신학회논문지 21권 3호 참조
7. CCITT Study Group XVII, "B-ISDN ATM functional characteristic," *Draft Recommendation I.150 Report R 23-E*, Geneva, February 1990.
8. Y. H. Kim, B. C. Shin and C. K. Un, "Performance analysis of leaky-bucket bandwidth enforcement strategy for bursty traffics in an ATM network," *Computer Networks and ISDN Systems*, Vol. 25, pp. 295-303, 1992.
9. J. Y. Lee and C. K. Un, "Performance of dynamic rate leaky bucket algorithm," *Electr. Letters*, Vol. 29, No. 17, pp. 1560-1561, August 1993.
10. 이두현, 신요안, 김영한, "신경회로망 예측기법을 결합한 dynamic rate leaky bucket 알고리즘의 구현," *한국통신학회논문지*, 제22권, 제2호, pp. 259-267, 1997년 2월.
11. S. Haykin, *Neural Networks - A Comprehensive Foundation*, IEEE Press, 1994.
12. H. Heffs and D. Lucantoni, "A Markov modulated characterization of packetized voice and data traffic and related statistical multiplexer performance," *IEEE Jour. Sel. Areas in Commun.*, Vol. 4, No. 6, pp. 856-868, 1986.
13. M. W. Garrett, M. Vetterli, "Congestion control strategies for packet video," *Proc. 4th Int'l Workshop on Packet Video*, Kyoto, Japan, August 1991.