

신경회로망 예측기법을 결합한 Dynamic Rate Leaky Bucket 알고리즘의 구현

正會員 이 두 헌*, 신 요 안**, 김 영 한***

An Implementation of the Dynamic Rate Leaky Bucket Algorithm Combined with a Neural Network Based Prediction

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

※본 논문은 1996년도 숭실대학교 교내 학술 연구비 지원의 결과임.

요 약

ATM(asynchronous transfer mode)을 이용한 B-ISDN의 출현은 다양하고 새로운 멀티미디어 통신 서비스를 가능하게 하였다. 그러나 다양한 트래픽 자원들의 버스트성 때문에 이들 트래픽을 동시에 서비스하는데 혼잡제어(congestion control)라는 새로운 문제에 당면하고 있다. 이를 위하여 UPC/NPC(user parameter control/network parameter control)에 대한 연구가 활발히 진행되고 있는데, 트래픽 상태와 버퍼의 점유 상태에 따라 토큰 생성율을 동적으로 변화시키는 DRLB(dynamic rate leaky bucket) 알고리즘이 UPC/NPC 메커니즘의 좋은 예가 될 수 있다. 그러나 DRLB 알고리즘은 토큰 생성율이 현재 망의 상태에 기반을 두고 있기 때문에, 버스티한 성격을 지닌 트래픽 자원 하에서는 효율성이 떨어지고 실시간 구현에 문제가 있다는 단점이 있다. 본 논문에서는 토큰 생성율을 현재 상태에 기반을 두고 결정하는 DRLB 알고리즘의 단점을 개선하기 위해서 신경회로망의 예측기법을 이용하여 토큰 생성율을 미리 예측하여 보다 유연하고 효율적으로 혼잡제어를 수행하는 새로운 알고리즘을 제안하고, 이의 성능을 컴퓨터 시뮬레이션을 통하여 확인하였다.

*SK Telecom
SK Telecom

**숭실대학교 전자공학과
Dept. of Electronic Eng., Soong Sil University

***숭실대학교 정보통신공학과
Dept. of Information & Telecommunication Eng., Soong Sil University

論文番號:96292-0914

接受日字:1996年 9月 14日

ABSTRACT

The advent of B-ISDN using ATM(asynchronous transfer mode) made possible a variety of new multimedia services, however it also 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 state of network. In this paper, we propose a more plastic and effective congestion control algorithm by combining the DRLB algorithm and neural network based prediction to remedy the drawbacks of the DRLB algorithm, and verify the efficacy of the proposed method by computer simulations.

I. 서 론

광대역종합정보통신망(broadband integrated services digital network, B-ISDN)은 데이터, 음성, 비디오 등과 같은 다양한 특성의 멀티미디어 트래픽들의 전송과 처리를 체계적으로 제공하기 위하여 구축되었다. B-ISDN에서의 신호 전송 방법으로는 다양한 속도를 갖는 서비스의 정보를 셀이라 불리는 일정한 크기의 패킷으로 전송하는 비동기 전달 모드(asynchronous transfer mode, ATM)가 사용된다[1]. ATM은 사용자와 망 사이에서 흐름 제어를 사용하지 않고 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. CCITT에서는 ATM 망에서 이러한 트래픽에 대한 사용자-망 접면(user-network interface)에서 수행되는 사용자변수제어(user parameter control, UPC)와 망-노드 접면(network-node interface)에서 수행되는 망변수제어(network parameter control, NPC)를 제안하고 있다. UPC/NPC는 망 자원의 사용에 있어서 사용자가 호 설정시 결정된 사항을 준수하는지의 여부를 감시한다[2].

UPC/NPC 알고리즘은 정확성, 신속성, 선택성, 단순성 등과 같은 성능 요구 사항들을 모두 만족시켜야 하며, 호수락제어(call admission control)를 통하여 연결된 호가 협약된 트래픽 파라미터들을 준수하는지를 감시하고, 만약 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 조치는 위반 셀들을 폐기시키는 것이고, 다른 조치로는 위반 셀에 표시를 하여 이 후에 망 내의 혼잡 상태가 발생하였을 때 선택적으로 폐기하기 위하여 우선 순위를 낮추어 망으로 진입시키는 방법 등이 있다. 이러한 기능을 수행하는 시스템으로 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 유무, 위반된 셀의 처리, 그리고 형태에 따라 여러 가지 시스템으로 구분된다[3]-[8].

LB 알고리즘의 기본 동작은 다음과 같다[3]. 입력 버퍼의 길이는 한 호의 접속 동안 일정하게 유지되고 토큰은 결정적이며 주기적으로 생성된다. 따라서 토큰 발생율은 LB 알고리즘의 제어 변수가 된다. 토큰 풀의 길이를 초과하는 토큰은 손실되고 토큰이 시스템에 있을 때 도착하는 셀들은 저장된 토큰 수만큼 즉시 서비스를 받고 망으로 진입한다. 반대로 토큰 풀의 크기가 0일 때 도착하는 셀들은 입력 버퍼 길이만큼 대기하여야 한다. 이때 입력 버퍼 길이를 초과하는 셀들은 폐기된다. 이와 같은 기본 동작에 비추어 볼 때, 토큰 생성율에 의하여 접속된 트래픽의 평균 비트율을 제어할 수 있으며, 입력 버퍼 및 토큰 풀 길이에 따라 최대 비트율과 버스트 주기를 제어할 수 있음을 알 수 있다.

본 논문에서는 간단한 카운터로 구성되며 일반적

으로 가장 많이 사용되고 있는 LB 알고리즘을 기본적인 UPC 메커니즘으로 설정하였고, VRLB(variable rate leaky bucket) 알고리즘의 한 종류인 DRLB(dynamic rate leaky bucket) 알고리즘[9]을 고려하였다. 이 알고리즘은 토큰 발생율이 일정한 기존의 LB 알고리즘과는 달리, 현재의 트래픽의 상태(ON/OFF 트래픽 모델에서의 ON 또는 OFF 상태)와 버퍼 점유 상태에 따라 토큰 생성율을 동적으로 변화시켜 보다 효율적으로 UPC 메커니즘을 구현한다. 하지만 이 알고리즘은 현재 트래픽의 상태를 알고 있다는 가정 하에 토큰 생성율을 변화시키기 때문에 실제 실시간, 고속으로 동작해야 하는 ATM 망에서 구현 시 문제가 된다. 즉, 이 알고리즘은 현재의 트래픽에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로 이에 따른 처리 지연이 발생하며, 실시간 구현이 어렵게 된다.

따라서 본 논문에서는 매 표본 시간마다 신경회로망을 이용하여 다음 단계의 토큰 생성율을 미리 예측함으로써 실시간 동작에 유리한 새로운 VRLB 알고리즘을 제안한다. 즉 제안된 방법은 신경회로망을 이용하여 과거의 트래픽과 망의 버퍼 상태 등을 고려하여 동적으로 현재의 토큰 생성율을 미리 예측하게 된다. 이러한 신경회로망 적용의 장점은 효과적인 학습 능력과 예측 능력으로 연결된 트래픽 특성을 예측하고 적절히 제어 조치를 취할 수 있으므로 실시간 구현상의 용이함과 간결성을 얻을 수 있다는 것이다.

본 논문의 구성은 다음과 같다. 2 장에서는 우리가 고려할 DRLB 알고리즘[9]에 대하여 간략히 기술하고, 3 장에서는 신경회로망을 이용한 토큰 생성율 예측 알고리즘을 제안하며, 4 장에서는 시뮬레이션 결과와 고찰을, 그리고 마지막으로 5 장에서는 결론을 내리도록 한다.

II. DRLB(Dynamic Rate Leaky Bucket) 알고리즘

이상적인 UPC는 협약을 준수하는 트래픽들에 대하여는 투명해야 하지만, 반대로 협약을 어기는 트래픽들에 대하여는 적절한 조치를 취해야한다. 기본적인 LB 알고리즘은 tagging과 폐기 조치를 통하여 셀 손실율과 최대 셀율을 만족시킨다. 그러나 ATM 망

의 통계적 특성을 극대화하기 위해서는 사전에 협의된 평균 셀율 역시 지켜져야 한다. 이를 위하여 Dual LB 알고리즘 등의 여러 알고리즘들이 연구되었으나, LB를 구성하는 카운터 등의 구성 요소들이 증가하는 단점이 발생한다[9][10]. 또한 Isochronous 트래픽 등에 대해서는 일정한 셀 지연 변이(cell delay variation)를 유지하기 위해 별도의 spacer를 두기도 한다[11]. 본 논문에서는 토큰 생성율 예측에 초점이 맞추어져 있으므로 셀 지연 변이 특성은 고려하지 않았다.

앞에서 언급된 성능 척도들을 만족시키면서 구성 요소의 추가를 없애는 방식으로 VRLB(variable rate leaky bucket) 알고리즘이 연구되었다. 기존의 LB 알고리즘에서는 입력 트래픽이 버스티한 경우에는 토큰이 효율적으로 사용되지 못한다. 예를 들면, 긴 OFF 구간에서는 토큰 풀이 꽉 차게되며 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 policer 통과 시 평균 지연이 증가되며 위반 트래픽의 검출과 적절한 제재에 걸리는 반응 시간 또한 증가하게 되므로 실시간 전송이 요구되는 ATM 망에는 적절하지 못하다. LB 알고리즘은 최대 셀율은 쉽게 제어할 수 있지만 긴 반응 시간과 나쁜 선택성 때문에 평균 셀율의 제어에 많은 어려움이 따르게 된다. 이를 개선하기 위하여 특정 상황에서 동적으로 토큰을 생성시킴으로써 위와 같은 사례를 미연에 방지하여 사전에 협약된 평균 셀율까지도 만족시켜줄 수 있는 VRLB 알고리즘 가운데 하나가 바로 DRLB(dynamic rate leaky bucket) 알고리즘이다.

DRLB 알고리즘은 트래픽의 ON/OFF 상태와 LB 알고리즘의 버퍼 점유 상태에 따라 토큰 생성율을 동적으로 변화시킴으로써 비교적 정확한 조치가 가능하게 된다. 아래 그림 1은 DRLB 알고리즘을, 그리고 그림 2에서 DRLB 알고리즘의 대기화 모델을 나타내고 있다.

DRLB 알고리즘에서 동적인 토큰 생성율의 원칙은 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. 입력 버퍼가 가득 차 셀이 손실되는 상태에서의 토큰

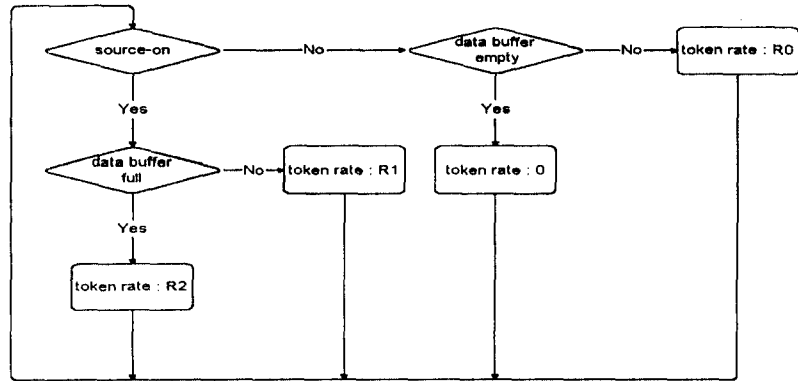


그림 1. DRLB(dynamic rate leaky bucket) 알고리즘.
Fig. 1 DRLB(dynamic rate leaky bucket) algorithm.

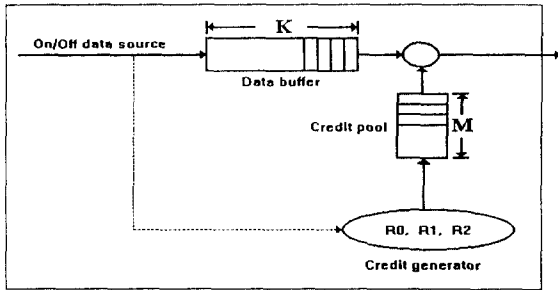


그림 2. DRLB 알고리즘의 대기화 모델.
Fig. 2 Queuing model of the DRLB algorithm.

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. DRLB 알고리즘에서는 동일한 QoS를 만족시키는데 필요한 입력 버퍼와 토큰 풀의 크기가 줄어들고 위반 트래픽을 검출하는 반응 시간도 줄어들게 된다. 하지만 앞서 서론에서 언급된 것처럼 이 알고리즘은 현재의 트래픽에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로 이에 따른 처리 지연이 발생하며, 실시간 구현이 어렵게 된다. 따라서 본 논문에서는 앞서 언급된 DRLB 알고리즘에 신경회로망 예측 기법을 결합함으로써 기존의 LB알고리즘에 대한 DRLB 알고리즘의 장점과 함께 과거의 트래픽으로부터 현재의 토큰 생성율을 예측함으로써

다음 순간 망으로 입력되는 트래픽에 대한 처리를 순조롭게 할 수 있는 적응적인 알고리즘을 제안한다. 다음 장에서는 제안된 알고리즘을 기술하기로 한다.

Ⅲ. 신경회로망을 이용한 토큰 생성율 예측 알고리즘

DRLB 알고리즘은 앞서 언급한 바와 같이 기존 LB 방법의 단점들을 보완하기는 하였으나, 이 방법 역시 기존의 LB와 마찬가지로 토큰 생성율의 결정이 현재 시점의 망의 상태에 기반을 두고 있기 때문에, 멀티미디어와 같은 VBR 트래픽이 주된 신호원이 되는 B-ISDN에서는 갑자기 변화하는 망의 상태에 능동적이고 유연하게 대처할 수 없게 된다. 그러므로 미래의 토큰 생성율을 예측하여 미리 결정할 수 있다면 B-ISDN에서의 UPC 구현에 있어서 상당한 이득을 가져올 것이다[12][13]. 본 논문에서는 토큰 생성율의 예측을 위하여 신경회로망을 이용한 새로운 알고리즘을 제시한다.

신경회로망은 주어진 입력 패턴과 목표 출력 패턴의 쌍으로 이루어진 샘플 패턴에 대한 학습을 통하여 임의의 입력 패턴과 출력 패턴 사이의 복잡한 비선형 관계를 근사하며, 이 가운데 특히 은닉층에 시그모이드(sigmoid) 활성화 함수를 사용하는 다중계층 퍼셉트론(multi-layered perceptron, MLP)은 우리가 관심있는 대부분의 비선형 함수를 원하는 정확도를 만족시키며

근사할 수 있음이 증명되었다[14]-[16]. 이전 트래픽과 버퍼 상태를 이용하여 미래의 토큰 생성율을 예측하고자 하는 문제는 결국 비선형 입력-출력 매핑 문제가 되며, 우리는 MLP의 우수한 함수 근사 능력을 이러한 예측 문제에 효과적으로 적용하고자 한다.

본 논문에서는 아래 그림 3과 같이 한 개의 은닉층을 갖는 2 계층 MLP를 이용하였으며, 출력 신호 y 는 아래 식과 같이 표현된다.

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

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. 활성화 함수 $\sigma(\cdot)$ 는 다음 식 (2)와 같이 (0, 1) 범위의 값을 출력으로 하는 단조 증가 함수인 시그모이드 함수를 사용하였으며, 학습을 위해서는 현재 널리 사용되고 있는 학습 알고리즘인 오차 역전파(error back-propagation) 알고리즘[13]을 이용하였다.

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




그림 3. 다중계층 퍼셉트론.
Fig. 3 Multi-layered perceptron.

신경회로망을 이용하여 DRLB 알고리즘의 토큰 발생율을 예측하는 방법으로 크게 다음 그림 4와 같은 두 가지 방법을 고려할 수 있다. 먼저 (a)의 방법은 우리가 예측하려 하는 시간 t 이전의 정보를 이용하여 시간 t 에서의 트래픽의 상태 \hat{y}_t 와 입력 버퍼의 상태 \hat{C}_t 를 예측하고, 이를 DRLB 알고리즘에 입력하여 이 알고리즘에 따라 시간 t 에서의 토큰 발생율에 대한 예측값 \hat{g}_t 를 구하는 방법이다. 이에 반해 (b)의 방법에서는 이러한 과정을 합하여 신경회로망이 시간 t 이전의 정보를 이용하여 직접 DRLB 알고리즘의 시간 t 에서의 토큰 발생율에 대한 예측값 \hat{g}_t 를 구하는 방법이다. 본 논문에서의 접근 방법은 (b)의 방법으로서, 이는 (a)의 경우와는 달리 DRLB 알고리즘을 미리 동작시켜 얻은 토큰 생성율을 신경회로망 학습을 위한 목표 출력으로 직접 이용할 수 있고, 별도로 DRLB 알고리즘을 수행하여야 하는 과정을 생략하여 좀 더 쉽게 구현할 수 있기 때문이다.




그림 4. 신경회로망을 이용하여 토큰 생성율을 예측하는데 사용 가능한 두 가지 방법.

Fig. 4 Two possible schemes for prediction of token generation rates using a neural network.




그림 5. 신경회로망을 이용한 UPC의 블록다이어그램.
Fig. 5 Block diagram of UPC using a neural network.

그림 5에서는 위의 그림 4(b)의 접근 방법에 기반을 두고 본 논문에서 제안하는 신경회로망 기반의 토큰 생성을 예측기를 구체적으로 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 이용 가능한 정보를 이용하여 수행된다. 이러한 과정은 매 표본 시간 Δ 마다 이루어지며, 이때 신경회로망으로의 입력도 한 셀 구간 만큼씩 이동된다. 신경회로망 학습 시 신경회로망과 DRLB 알고리즘으로의 입력은 각각 다음 식 (3)과 (4)와 같다.

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

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

여기서 $y_{t-i\Delta}$ ($i=0, 1, 2, \dots, p$)는 시간 $t-i\Delta$ 에서의 실제 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.

IV. 시뮬레이션 결과 및 고찰

시뮬레이션에 사용된 입력 트래픽은 다양한 메커니즘의 성능 비교에 이용되는 ON/OFF 모델을 사용하였다. 이 모델은 최대 셀율, 평균 셀율, 평균 피크 구간 등이 서로 독립적인 변화가 허용되므로, 정지 화상이나 음성 등 여러 가지 트래픽을 모델링하는데 사용된다[17]. 그림 6에 시뮬레이션에 사용된 ON/OFF 트래픽 모델을 나타내었다. ON 구간당 셀의 수는 평균 $E[X]$ 인 기하분포로 나타내어지고, OFF 구간은 평균 $E[S]$ 인 지수분포로 가정하였다. ON 구간에서의 셀과 셀 사이의 시간 간격은 Δ 로 주어진다. 본 시뮬레이션에서 사용된 아래의 구체적인 파라미터 값들은 패킷화된 음성 모델을 가정하여 정해졌다[17]-[19].

$$E[X] = 22(\text{개}), \quad E[S] = 650(\text{msec}), \quad \Delta = 16(\text{msec})$$

위의 파라미터들을 이용한 평균 셀율 λ 는 아래와 같이 계산된다[17].

$$\lambda = \frac{E[X]}{\alpha^{-1} + \beta^{-1}} = \frac{1}{\Delta + \frac{\alpha\Delta}{\beta}} \approx 21.95(\text{cells/sec}) \quad (5)$$




그림 6. 시뮬레이션에 사용된 ON/OFF 트래픽 모델.
Fig. 6 ON/OFF traffic model used for the simulation.

본 논문에서 사용된 신경회로망은 한 개의 은닉층을 갖는 2 계층 MLP이며, 입력층 노드는 22개, 은닉층 노드는 10개, 그리고 출력층 노드는 1개이다. 신경회로망의 22개 입력으로 우리가 예측하려는 시간 t 바로 직전 시간 $t-\Delta$ 부터 과거 20 셀 구간만큼의 과거 트래픽과, $t-\Delta$ 에서의 데이터 버퍼 내의 셀 수, 그리고 $t-\Delta$ 에서의 토큰 풀 내의 토큰 수를 이용하였으며, 제안된 알고리즘은 이들 입력을 이용하여 다음 시점에 필요한 토큰 생성율을 예측한다.

학습을 위한 목표 출력값은 앞서 언급된 대로 실제 DRLB 알고리즘을 이용하여 결정된 시간 t 의 토큰 생성율 g_t 이다. 이 토큰 생성율은 DRLB 알고리즘에서 $0, R_2, R_0, R_1$ 가운데 하나이며, 신경회로망에의 적용을 용이하게 하기 위하여 0~1 사이의 구간을 4 등분하여 각각 0.125, 0.375, 0.625, 0.875로 하여 목표 출력으로 사용하였다. 본 예측 문제의 경우 각 입력에 따라 위의 4 가지 토큰 생성율 가운데 하나를 선택하는 "패턴 분류"의 문제로 인식될 수 있고, 이러한 경우 출력 노드의 개수가 분류하고자 하는 경우의 수(우리의 예는 4)와 같은 신경회로망을 사용하는 것이 일반적인 방법이라 할 수 있다. 하지만, 우리는 추후 연구 과제로서 본 논문에서와 같은 이산적인(discrete) 토큰

생성율이 아니라, 연속적으로 변화하는 토큰 생성율을 다루어야 하는 경우로의 확장 용이성을 고려하여 하나의 출력 노드를 갖는 “함수 근사” 문제로 접근하였다.

신경회로망 학습시 학습 데이터 패턴의 개수는 $4000 \times \Delta$ 만큼의 구간으로 정했다. 사용된 모델의 셀 손실율은 10^{-2} , 10^{-6} 인 두 경우에 대하여 고려하였다. 그림 7과 8은 학습이 완료된 후 새로이 형성된 동일한 테스트 트래픽을 가했을 때 셀 손실율 10^{-6} 의 경우에 대하여 DRLB 알고리즘을 적용한 경우와 신경회로망을 적용한 경우에 대한 토큰 생성율의 변화를 나타내었다. 그림에서 보는 바와 같이 신경회로망을 이용하여 토큰 생성율을 미리 예측했을 경우에도 DRLB 알고리즘과 거의 유사한 토큰 생성율을 생성함을 알 수 있다.




그림 7. DRLB 알고리즘 적용 시 테스트 데이터에 대한 토큰 생성율의 변화.

Fig. 7 Token generation rates of DRLB algorithm for test data.




그림 8. 신경회로망 적용 시 테스트 데이터에 대한 토큰 생성율의 변화.

Fig. 8 Token generation rate of neural network for test data.

표 1에서는 UPC가 끝난 후의 평균 셀율과 셀 손실율을 순수한 DRLB 알고리즘과 신경회로망을 이용하여 토큰 생성율을 예측한 경우에 대하여 서로 비교하였다. 신경회로망을 이용한 토큰 생성율 예측의 경우를 DRLB 알고리즘과 비교했을 때, 평균 셀율의 측면에서 두가지 목표 셀 손실율에 대해 이상적인 값을 잘 만족함을 알 수 있고, 셀 손실율의 측면에서는 목표 셀 손실율이 10^{-2} 일 때 신경회로망을 이용하는 경우가 목표에 더욱 근접하는 결과를 보이나, 10^{-6} 일 때는 신경회로망을 이용하는 경우 약간 저하됨을 알 수 있다. 하지만 표 1과 그림 7, 8의 결과로부터 제안된 신경회로망 기반의 토큰 생성율 예측 방법이 DRLB 알고리즘에서 필요한 현재의 트래픽의 상태를 알고 있다는 가정을 제거하면서 매우 효과적으로 사용될 수 있으리라 기대된다.

표 1. DRLB 알고리즘과 신경회로망의 성능 비교.

Table 1. Performance comparison of DRLB algorithm and neural network.

목표 셀 손실율	DRLB 알고리즘		신경회로망 예측	
	셀 손실율	평균 셀율	셀 손실율	평균 셀율
10^{-2}	1.862×10^{-2}	19.513	1.551×10^{-2}	19.575
10^{-6}	5.684×10^{-6}	21.993	2.558×10^{-5}	21.992




그림 9. 신경회로망의 학습 곡선.

Fig. 9 Learning curve of the neural network.

마지막으로 그림 9는 신경회로망 학습 시 성능 지표로 사용된 평균자승오차(mean square error, MSE)의 변화를 나타내는 학습 곡선이며, 매우 빠른 수렴 특성을 보임을 알 수 있다. 여기서 사용된 MSE ϵ^2 는 아래 식 (6)과 같이 정의되며, 이 식에서 L 은 학습 패턴의 개수, $g^{(l)}$ 과 $\hat{g}^{(l)}$ 은 각각 $l(l=1, \dots, L)$ 번째 패턴에 대한 (0~1 사이의 값으로 정규화된) 목표 토큰 생성율과 실제 신경회로망의 출력으로 얻은 토큰 생성율을 나타낸다.

$$\epsilon^2 \equiv \frac{1}{L} \sum_{l=1}^L (g^{(l)} - \hat{g}^{(l)})^2 \quad (6)$$

V. 결 론

본 논문에서 사용된 UPC 메커니즘은 기존 LB 알고리즘의 단점인 토큰의 비효율적인 사용과 policer 통과 시의 지연을 극복한 DRLB 알고리즘에 신경회로망의 예측 능력을 결합한 알고리즘으로서, 망으로 입력되는 트래픽들을 기반으로 하여 신경회로망을 학습시킴으로써 다음 시점의 토큰 생성율을 예측한다. 이는 결국 미래의 트래픽을 예측하여 앞으로의 트래픽 변화에 대처할 수 있음을 의미한다. 그러나 이것은 이러한 예측이 정확하다는 가정 하에 성립되는 것이며, 이를 위하여 본 논문에서는 시뮬레이션을 통해 신경회로망을 이용하여 수행된 결과와 순수한 DRLB 알고리즘의 결과를 비교해 봄으로써 그 예측이 정확하였음을 보였다. DRLB 알고리즘은 현재의 트래픽에 의거하여 현재의 트래픽을 위한 토큰 생성율을 조절하므로 실제 실시간, 고속으로 동작해야 하는 ATM 망에서 구현 시 문제가 되며, 따라서 본 논문의 결과는 DRLB 알고리즘을 실제 ATM 망에서 사용하려는 경우 실시간 구현 상의 용이함과 간결성을 얻을 수 있다는 큰 장점을 가짐을 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 사용된 MLP와 오차 역전파 학습 알고리즘 외에 RBFN(radial basis function network)[20] 등과 같은 다른 신경회로망 모델들 및 conjugate gradient[20]와 같은 학습 알고리즘을 이용하는 것 역시 가

능하다. 하지만, 본 논문에서는 LB 알고리즘을 개선하기 위해 신경회로망이 사용될 수 있다는 가능성을 제시하는 것이 주목적이며, 따라서 여러 신경회로망 및 학습 알고리즘을 이용할 경우의 성능 비교 등은 추후의 다른 연구 방향이 될 수 있다고 생각된다.

본 논문에서 고려한 DRLB 알고리즘은 트래픽의 ON 또는 OFF 상태에 근거하여 이산적인(discrete) 토큰 생성율을 결정하므로, 비디오와 같은 VBR(variable bit rate) 신호에 대해서는 적용이 어렵게 된다. 즉, 몇 가지의 이산적인 토큰 생성율로의 매핑이 아닌, 입력 트래픽에 따른 연속적인 토큰 생성율을 정확히 예측하여 더욱 동적인 제어가 이루어지도록 하는 알고리즘의 개발이 필요하다. 이에 우리는 이러한 신호에 대해 본 논문의 결과를 확장하는 연구를 현재 진행 중이며, 이미 기초적인 결과를 발표하였다[21]. 우리가 [21]에서 제안한 CRLB(continuous rate leaky bucket) 알고리즘은 비디오 트래픽과 같은 VBR 신호원에 대해 현재 시간의 연속적인 트래픽의 최소값과 최대값의 범위에 따라 토큰 생성율을 선형적으로 매핑한다. 이렇게 생성되는 토큰 생성율은 현재의 트래픽에 기반을 두고 결정되기 때문에, DRLB 알고리즘에서처럼 과거의 입력 트래픽들과 과거의 입력 버퍼와 토큰 풀 상태를 신경회로망의 입력으로 하여 현재 트래픽에 대한 토큰 생성율을 예측한다. 실제 “Star Wars” 비디오 트래픽[22]을 이용한 시뮬레이션 결과, CRLB 알고리즘이 고정 토큰 생성율을 사용하는 LB 알고리즘에 비해 QoS로 사용된 셀 손실율의 측면에서 매우 우수함을 알 수 있었고, 필요한 토큰도 적게 요구함을 알 수 있었다. 이에 대한 앞으로의 연구 방향으로서 토큰 생성율의 선형 매핑 부분의 개선, 타 방법과의 좀 더 많은 실험적, 이론적 비교 연구가 고려되어야 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

