

---

# 신경망을 이용한 무선망에서의 채널 관리 기법

노철우\* · 김경민\* · 이광의\*\*

## A Channel Management Technique using Neural Networks in Wireless Networks

Cheul-woo Ro\* · Kyung-min Kim\* · Kwang-eui Lee\*\*

### 요 약

채널은 무선망에 있어서 한정된 주요 자원 중의 하나이다. 다양한 채널 관리 기법들이 제시되어 왔으며, 최근 들어 가드채널의 최적화 문제가 부각되고 있다. 본 논문에서는 신경망을 이용한 지능적인 채널 관리 기법을 제안한다. 신경망의 학습 데이터 생성과 성능분석을 위하여 SRN(Stochastic Reward Net) 채널 할당 모델이 개발된다. 제안된 기법에서 신경망은 지도학습 방법인 역전파 알고리즘을 이용하여 최적의 가드채널 값  $g$ 를 계산하도록 학습한다. 학습된 신경망을 이용하여 최적의  $g$ 를 계산하고, 이를 SRN 모델에서 구해진 결과와 비교한다. 실험결과는 신경망에서 구한 가드채널 수와 SRN 모델로부터 구한 가드채널 수의 상대적 차이가 없음을 보여준다.

### ABSTRACT

The channel is one of the precious and limited resources in wireless networks. There are many researches on the channel management. Recently, the optimization problem of guard channels has been an important issue. In this paper, we propose an intelligent channel management technique based on the neural networks. An SRN channel allocation model is developed to generate the learning data for the neural networks and the performance analysis of system. In the proposed technique, the neural network is trained to generate optimal guard channel number  $g$ , using backpropagation supervised learning algorithm. The optimal  $g$  is computed using the neural network and compared to the  $g$  computed by the SRN model. The numerical results show that the difference between the value of  $g$  by backpropagation and that value by SRN model is ignorable.

### 키워드

역전파 학습 알고리즘, 신경망, 채널 할당, 채널 최적화, 무선망, Stochastic Reward Nets

## I. 서 론

인공 신경망(neural networks)은 간단한 기능을 갖는 다수의 처리기가 인접한 처리기와 정보를 주고받으면서 동작하는 형태로 연산을 분산 병렬 처리할 수 있게 함으로써 처리 시간을 단축시킬 수 있다[1]. 두 번째의 유용한 특성으로 인공 신경망의 적응적 학습 능력(adaptive learning

capability)을 들 수 있다. 사람이 직접 문제를 위한 해법을 구체적으로 프로그램 하는 것이 아니고 시스템으로 하여금 주어진 문제로부터 연결선의 가중치를 조정함으로써 스스로 문제의 해법을 발견하게 한다[2]. 세 번째 특성으로 결합 극복 능력을 들 수 있는데, 인공 신경망은 가중치나 처리기의 출력 값이 어떤 고장에 의해 변경되거나 소실되더라도 전체 성능이 급격히 저하되지 않는다는 특징

---

\* 신라대학교 컴퓨터 정보공학부

\*\* 동의대학교 멀티미디어공학과

을 갖는다. 즉 인공 신경망은 입력 공간과 출력 공간사이의 매핑의 특성에 따라 연상 기억, 필터, 변환, 분류, 인식 및 최적화 등의 다양한 기능 체계를 구성할 수 있으며 시각 처리, 음성 인식, 의료 진단, 패턴 분류 및 인식 등 기존 인공지능 분야에서 비교적 해결하기 힘든 잡음이나 변형된 정보의 처리에 매우 유용하다. 매핑은 학습 규칙(learning rule)에 의존하며, 학습에 있어 서로 연관된 입력과 출력에 올바르게 매핑되도록 하는 것을 학습 과정이라고 한다. 인공 신경망의 지도 학습 방법인 역전파(backpropagation) 학습 알고리즘은 다층 신경망 학습을 위한 이론적인 알고리즘이다[3]. 역전파 학습 알고리즘은 최소자승(least mean square)알고리즘의 비선형적인 확장이고 미분의 반죽 규칙(chain-rule)을 여러 번 반복적으로 적용하여 확률 근사치 프레임워크(stochastic approximation framework)와 관련 지음으로써 유도해낼 수 있다.

무선망에서 무선 자원인 채널 관리를 위한 채널 할당의 최적화 문제는 중요한 이슈가 되고 있다[4]. 본 논문에서는 역전파 알고리즘을 이용하여 이 문제를 해결하고자 한다.

무선망에서 발생하는 호는 핸드오프 호와 신규 호로 구분된다. 핸드오프 호의 분실률을 줄이기 위해서 핸드오프 호를 위해 고정된 수의 가드채널을 예약해둔다[5]. 가드채널 기법은 분실률을 줄일 수 있으나 신규 호의 차단율은 상대적으로 증가시키게 된다.

채널 할당의 최적화 문제는 분실률과 차단율을 함께 고려한 GoS(Grade of Service)를 최소화하기 위한 최적의 가드채널 수 계산으로 귀결되며, 역전파 학습 알고리즘을 이용하여 이를 계산한다.

본 논문은 II에서 무선망에서의 무선채널 관리기법과 채널 할당 모델을 설명하고, III에서는 역전파 알고리즘을 이용한 최적의 가드채널 계산방법을 기술한다. IV에서는 역전파 알고리즘을 이용한 방법과 채널 할당 모델로부터 계산한 최적의 가드채널 수를 비교하고, V에서 결론을 맺고 향후 연구 방향을 제시한다.

## II. 채널 관리 기법

### 2.1 무선망 성능 모델

본 논문에서는 무선망에서 단일 셀의 성능 모델을 고려한다. 셀의 채널 풀에는 S개의 사용 가능한 채널이 존재

하며, 신규 호와 핸드오프 호의 도착률은 각각  $\lambda_{in}$ ,  $\lambda_{oh}$ 인 포아송 프로세스이고 호 지속시간과 핸드오프 시간은 평균이 각각  $1/\mu_{vt}$ ,  $1/\mu_{vot}$ 인 지수분포를 따른다고 가정한다. 핸드오프 호가 발생했을 때 채널 풀에 사용가능한 채널이 있으면 핸드오프 호에 채널을 할당하고 그렇지 않은 경우 핸드오프 호는 분실된다. 반면 신규 호는 채널 풀에 사용가능한 채널이 g개 보다 많은 경우에 채널을 할당받고 그렇지 못한 경우 신규 호는 차단된다. 여기서 g는 핸드오프 호를 위한 보존 채널인 가드채널 수이다.

그림 1은 시점 t에서 사용 중인 채널 수를  $C(t)$ 라고 했을 때  $\{C(t), t > 0\}$ 인 birth-death 프로세스를 보여준다.




그림 1. 무선망 핸드오프의 마르코프체인  
Fig. 1. Markov chain of handoff in wireless networks

그림 1에서  $\lambda = \lambda_{vn} + \lambda_{vh}$ ,  $\mu = \mu_{vt} + \mu_{vot}$ 으로 정하며 birth-death 프로세스의 도착률  $\Lambda(n)$ 과 출발률  $M(n)$ 은 식(1)로 주어진다.

$$\Lambda(n) = \begin{cases} \lambda, & n = 0, 1, \dots, S - g - 1 \\ \lambda_{vh}, & n = S - g, \dots, S - 1; g > 0 \end{cases}$$

$$M(n) = n\mu, n = 1, \dots, S \quad (1)$$

위 식으로부터 해당 마르코프 체인의 안정상태 해를 구할 수 있으며 이는 2.3절 표 1에서 구하고자 하는 성능지표의 기본값이 된다[6].

### 2.2 SRN(Stochastic Reward Net)

SRN은 추계적 페트리 네트의 확장형으로 모델에 적절한 보상을 부여함으로써 원하는 성능지표를 쉽게 계산할 수 있는 모델링 도구이다[7]. 본 논문에서는 채널 할당을 위한 SRN모델을 개발하고 성능 분석을 수행한다. SRN 모델의 해를 구하기 위해 SRN 소프트웨어 도구인 SPNP[8]를 사용한다. SRN 모델은 다음 단계에 의하여 해석적-수치적으로 해를 구할 수 있다. 첫째, 모델로부터 도달성 그래프가 생성되며 둘째, 도달성 그래프는 마르코프 보상 모델로 변환된다. 셋째, 마르코프 보상 모델은 수치적으로 해를 구하며, 마지막으로 구해진 해의 기대값으로 성능지표를 계산한다.

### 2.3 채널 할당 SRN 모델




그림 2. 채널 할당 SRN 모델

Fig. 2. A SRN model of channel allocation

천이 VoiceNew와 VoiceHandOff의 발사는 각각 신규 호와 핸드오프 호의 발생을 나타낸다. 장소 VoiceP의 토큰 수는 핸드오프 호와 신규 호에 의해 사용 중인 채널 수를 나타낸다.

천이 VoiceHandOff와 VoiceNew에서 장소 VoiceP까지 다중 금지아크는 가드채널 방식을 모델링한다. 즉 장소 VoiceP에 사용 중인 채널 수가 S개라면 모든 채널이 사용 중임으로 천이 VoiceHandOff가 발사되지 않음으로 핸드오프 호가 분실되고 반면에 신규 호는 핸드오프 호를 위해 보존된 가드채널 g를 고려하여 사용 중인 채널 개수가 S-g 이상이면 차단된다.

신규 호 차단 확률  $P_b$ 와 핸드오프 호 분실 확률  $P_d$ 는 그림 2의 SRN에서 표 1과 같은 보상률을 적용하여 쉽게 구할 수 있다.

표 1. 분실/차단 확률 및 보상률

Table 1. Dropping/blocking probability and reward rate

구분	계산식
분실 확률 $P_d$	$P_d = \sum_{j \in N} r_d \pi_j$
분실 보상률 $r_d$	$r_d = \begin{cases} 1 & \text{if } \#(\text{VoiceP}) = S, \\ 0 & \text{otherwise} \end{cases}$
차단 확률 $P_b$	$P_b = \sum_{j \in N} r_b \pi_j$
차단 보상률 $r_b$	$r_b = \begin{cases} 1 & \text{if } \#(\text{VoiceP}) \geq S - g, \\ 0 & \text{otherwise} \end{cases}$

분실률과 차단율을 혼합한 성능지표로 사용되는 GoS는 식 (2)와 같이 계산된다[9].

$$GoS = P_b + \omega P_d \tag{2}$$

신규 호의 차단율과 핸드오프 호의 분실률은 상호 보완적이다.  $\omega$ 는 핸드오프에 대한 비중을 나타내기 위한 가중치 값으로 사용되며  $\omega > 1$ 의 값을 갖는다.

### III. 역전파 알고리즘을 이용한 무선망의 최적 가드채널 계산

전파 학습 방법은 인공 신경망의 지도 학습(supervised learning) 방법으로 이상적인 출력과 실제 출력 사이의 평균 제곱 오차에 해당하는 비용 함수(cost function) 값을 최소화하기 위하여 일반화된 델타(delta) 규칙을 사용한다. 이때 노드 사이의 연결 강도를 임의의 작은 값으로 초기화 한 후 학습 데이터를 입력층과 출력층에 반복적으로 제공함으로써 학습시킨다. 입력 데이터에 의하여 계산된 출력층 값과 기대하고 있던 값의 차이, 즉 오차 값을 하위층으로 전파시키는 방법으로 연결 강도를 재조정해 나가면서 신경 회로망 전체의 연결 강도가 수렴하여 총오차자승합(TSS : Total Sum of Square)이 매우 작아질 때까지 반복적으로 학습시킨다[10].

이것은 결국 신경망의 총오차자승합인 식 (3)을 최소화 하도록 연결 강도를 구하기 위하여 식 (4)의 반복식을 적용하는 것이다.

$$E(w) = \sum (t_k - o_k)^2 = (T - O)^T (T - O) \tag{3}$$

$$W(n+1) = W(n) + \Delta W(n) \tag{4}$$

여기서,  $t_k$ 는 주어진 입력에 대한 출력층 노드 k의 기대하고 있는 출력이고,  $o_k$ 는 식 (5)에 의해 현 시점에서 구해진 신경회로망의 실제 출력이다.

$$o_k = f\left(\sum w_{kj} o_j\right) \tag{5}$$

단  $w_{kj}$ 는 하위층의 노드 j와 상위층 노드 k 연결하는 연결 강도이고  $o_j$ 는 하위층 노드 j의 출력 값이다. 또한 전이 함수 f(x)는 식 (6)과 같다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

이때, 기대하고 있던 출력 값이 외부에서 주어질 수 있는 출력층의 노드와는 달리 은닉층의 노드는 그 노드의 기대 출력 값을 알 수 없는 문제를 해결하기 위해 출력 노드의 오차를 역으로 사용하여 은닉층의 노드들의 오차를 책임 분담하는 방법을 사용한다. 즉 역전파와 학습의 역전파 과정에서 구해지는 연결 강도의 변화량은 식 (7)과 같이 구한다.

$$\Delta W = \frac{-\partial E}{\partial W} = \alpha \delta_k o_k \quad (7)$$

$\delta_k$ 는 노드 k가 출력층 노드인 경우  $(t_k - o_k)f'(o_k)$  이다. 그리고  $\delta_j$ 는 노드 j가 은닉층 노드인 경우  $f'(a_j) \sum \delta_k w_{kj}$  이다. 여기서  $f'(a_k) = (1 - a_k) o_k$  이고  $\alpha$ 는 학습률이다.




그림 3. 가드채널 수 결정을 위한 신경망 구성도  
Fig. 3. The neural network block diagram for a guard Channel number decision

본 논문에서는 역전파 알고리즘을 이용하여 최적화된 가드 채널 수를 결정한다. 오류 역전파와 학습 구조는 그림 3과 같고 입력층 S는 전체 채널 수이고  $\omega$ 은 식 (2)의 가중치이고  $\lambda_m$ 는 신호 호 도착률이다.

그림 4는 가드채널 수를 결정하기 위한 역전파 알고리즘의 학습 알고리즘 구성도이다.

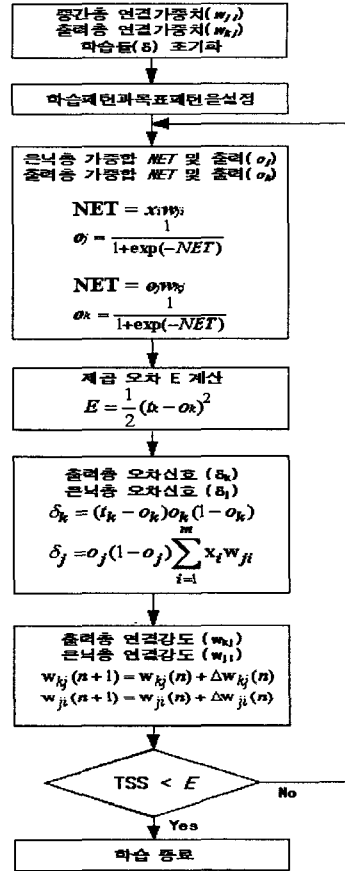


그림 4. 역전파 알고리즘의 구성도  
Fig. 4. Structure of the backpropagation algorithm

#### IV. 수치결과

최적화된 가드채널 값과 이에 따른 성능지표인 GoS의 수치결과를 구하기 위하여 다음 4단계를 수행한다.

단계1: 학습 데이터를 생성하기 위해 S,  $\omega$ ,  $\lambda_m$  값에 따른 최적의 가드채널 수를 SPNP를 이용하여 구한다.

단계2: 역전파 알고리즘을 이용하여 단계1에서 구한 학습 데이터를 학습시킨다.

단계3: 주어진 트래픽에 대응되는 S,  $\omega$ ,  $\lambda_m$  값으로부터 역전파 알고리즘의 학습 결과를 이용하여 최적의 가드 채널 값을 구한다.

단계4: 역전파 알고리즘 결과와 단계 3에서 구해진 결

과를 비교해서 역전파 알고리즘으로 작성된 값이 최적화 되었음을 보인다. 구해진 최적의  $g$ 를 갖는 GoS를 SRN 모델로부터 구한다.

그림 5는 단계1에서 구해진 결과에 따라 GoS를 최소화 하는  $g$ 값을 찾는 과정을 보여준다.




그림 5. 가드채널에 따른 GoS  
Fig. 5. GoS versus guard channel numbers

역전파 알고리즘에 학습 데이터로 418개를 적용하였고, 입력층 노드 수는 S인 전체 채널 수로 6개,  $\omega$  인 가중치로 노드 수는 2개,  $\lambda_{vn}$  인 신규 호 도착율의 노드 수 6개로 총 입력층 노드 수는 16개로 설정하였다. 은닉층 노드 수는 실험을 통하여 18개로 설정하였고 출력층 노드 수는 10개로 설정하였다. 그리고 학습률과 모멘텀은 각각 0.5와 0.9로 설정하여 학습한 결과는 표 2와 같다.

표 2. 역전파 학습 결과

Table 2. Result of the backpropagation learning

Epoch수	TSS
1030	0.089896

그림 6은 역전파 알고리즘의 Epoch 수에 따른 TSS 변화량을 나타내었다. 그림 6에서 초기 학습 과정에서 TSS가 진동하는 것을 확인할 수 있다. 그 이유는 418개의 학습 데이터 중에서 같은 가드 채널 수를 목표 값으로 설정하여 학습하는 과정에서 조기 포화 현상이 발생하였기 때문이다. 그러나 그림 6에서와 같이 조기 포화 현상에 해당하는 경쟁 단계를 벗어난 후세 단계에서는 안정성 있게 학습되었다.




그림 6. Epoch 수에 따른 TSS 변화량  
Fig. 6. Variance of TSS according to learning methods

418건 최적화 가드채널 수 데이터를 역전파 알고리즘으로 학습 시킨 후 임의 추출한 458건의 데이터에 대해서 SPNP로 구한 실제 가드채널 수와 역전파 알고리즘에서 구한 가드 채널 수를 비교해 보았다.

표 3. GoS 비교

Table 3. Comparison with the GoS

S	$\omega$	$\lambda_{vn}$	SPNP g (GoS) (A)	역전파알고리즘 g (GoS) (B)	차이 ( A-B /A)
13	3	8	2 (0.4560)	3 (0.4577)	0.00382
15	2	11	2 (0.5075)	3 (0.5082)	0.00146
17	1	19	3 (0.6513)	2 (0.6525)	0.00188
21	3	19	4 (0.5778)	3 (0.5782)	0.00058

458건 중 407건의 데이터가 정확히 인식되었고(89%), 인식되지 않은 경우도 표 3에서 나타난 것처럼 인식된 가드채널 수의 GoS와 계산된 가드채널 수의 GoS값이 거의 차이가 없음을 알 수 있다.

## V. 결 론

본 논문에서는 인공 신경망의 지도 학습 방법인 역전파 학습 알고리즘을 이용한 무선망에서의 채널 관리 기법을 제안하였다. 제안된 기법은 첫째, 학습 데이터의 생성과 성능분석을 위한 SRN 채널 할당 모델을 개발하였고, 둘째, 신경망의 지도 학습 방법인 역전파 알고리즘을 이용하여 최적의 가드 채널 값  $g$ 을 구하고 셋째, 구해진  $g$ 값

을 기반으로 개발된 SRN 채널 할당 모델에서 SRN 분석 도구인 SPNP를 이용하여 성능지표인 GoS를 구하였다. 제안된 기법은 89%의 비율로 최적의 g를 출력하였으며, 나머지 11%의 경우도 무시할 수 있는 오류범위 내에서 g를 생성하였다. 최적의 GoS와 비교하여 1% 미만의 오류를 갖는 g값을 생성하였음을 실험결과에서 보여주었다.

앞으로의 연구방향은 g 계산에서의 오류 수를 충분히 작게 줄이는 방향으로 진행될 필요가 있다. 이러한 방향에 따른 결과는 단순히 최적의 g를 산출하는 비율을 늘릴 뿐만 아니라, GoS 오류의 비율도 개선할 것으로 기대할 수 있다. 신경망을 이용한 방법은 학습이 종료된 후 입력에 대한 최적의 g값을 매우 빠르게 계산한다는 장점이 있어, 실시간으로 변하는 환경에서 g를 구해야 하는 채널 최적화 문제를 해결하는 적절한 방법으로 고려된다.

### 참고문헌

[1] R. Beale and T. Jackson, Neural Computing: An Introduction, Adam Hilger, pp.165-190, 1990.  
 [2] K. B. Kim, Y. H. Joo and J. H. Cho, "An Enhanced Fuzzy Neural Network," Lecture Notes in Computer Science, LNCS 3320, Springer, pp.176-179, 2004.  
 [3] R. Allen, "Several Studies on Natural Language and Backpropagationn," IEEE ICNN, Vol.2, pp.335-342, 1987.  
 [4] Guenter Haring, Raymond Marie, Ramon Puigjaner and Kishor Trivedi, "Loss Formulas and Their Application to Optimization for Cellular Networks", IEEE Transactions on Vehicular Technology, Vol.50, pp.664-673, 2001.  
 [5] N. D. Tripathi, J. H. Reed and H. F. Vanlandingham, "Handoff in cellular systems", IEEE Personal Communications, Vol.5, pp.26-37, 1998.  
 [6] Kishor S. Trivedi, Xiaomin Ma and S. Dharmaraja, "Performability modeling of wireless communication system," International Journal of Communication Systems, pp.561-577, 2003.  
 [7] G. Ciardo, A. Blakemore, P. F. Chimento, "Automated generation and analysis of Markov reward models using stochastic reward nets", Linear Algebra, Markov Chains,

Queueing Models, IMA Volumes in Mathematics and its Applications(C. Meyer & R. J. Plemmons, Eds), Vol.48, pp.145-191, 1993.

[8] G.Ciardo, K.S.Trivedi, "SPNP Users Manual, Version 6.0", Technical report, Duke Univ., 1999.  
 [9] Derong Liu, "A Self-Learning Call Admission Control Scheme for CDMA Cellular Networks", IEEE Transactions on Neural Networks, Vol.16, 2005.  
 [10] Philip D. Wasserman, Neural Computing Theory and Practice, Van Nostrand Reinhold, 1989.

### 저자소개



**노철우(Chul-woo Ro)**

1982년 동국대학교 전자계산학과 (석사)  
 1995년 서강대학교 전자계산학과 (박사)

1991 ~ 현재 : 신라대학교 컴퓨터정보공학부 교수  
 ※ 관심분야 : 이동통신시스템, RFID, 페트리넷모델링



**이광의(Kwang-Eui Lee)**

1992년 서강대학교 전자계산학과 (석사)  
 1997년 서강대학교 전자계산학과 (박사)

2001 ~ 현재 : 동의대학교 멀티미디어공학과 교수  
 ※ 관심분야 : 계산이론, 멀티미디어통신



**김경민(Kyung-Min Kim)**

2000년 신라대학교 컴퓨터교육과 (석사)  
 2004년 - 현재 신라대학교 컴퓨터정보공학부 박사과정

※ 관심분야 : 이동통신시스템, RFID, 페트리넷모델링