

수정된 홉필드 신경망을 이용한 최단 경로 라우팅 알고리즘

(A Shortest Path Routing Algorithm using a Modified Hopfield Neural Network)

안 창 옥 [†] R. S. Ramakrishna ^{**} 최 인 찬 ^{***} 강 충 구 ^{****}
 (Chang Wook Ahn) (In Chan Choi) (Chung Gu Kang)

요 약 본 논문은 신경망을 이용한 최단 경로 문제를 풀기 위해 홉필드 신경망(Hopfield Neural Network)을 변형한 준최적 라우팅 알고리즘(suboptimal routing algorithm)을 다룬다. 이 알고리즘은 기존의 홉필드 신경망 알고리즘과는 달리 뉴런(neuron)의 진화를 위해 모든 주변 뉴런 정보뿐만 아니라, 상관 관계성이 높은 자신의 뉴런 정보도 동시에 이용함으로써, 수렴 성능 및 경로의 최적성을 향상하고자 하였다. 이 알고리즘의 수렴 속도는 홉필드 신경망을 이용하는 기존의 알고리즘보다 더 우수하며, 탐색 경로의 최적성도 높다는 것을 컴퓨터 시뮬레이션을 통해 확인한다. 이 결과는 거의 모든 출발지와 도착지 쌍에 대해 기존의 홉필드 신경망 기반의 최단 경로 탐색 알고리즘에 비해 네트워크 토폴로지에 비교적 덜 민감한 것으로 나타난다. 따라서, mobile ad-hoc network과 같이 네트워크 토폴로지가 시변하는 다중-홉 무선 패킷망(Multi-hop Packet Radio Network)에서의 경로 설정 알고리즘을 구현하는데 유용할 것으로 보인다.

키워드 : 홉필드 신경망, 최단 경로 라우팅, 조합 최적화

Abstract This paper presents a neural network-based near-optimal routing algorithm. It employs a modified Hopfield Neural Network (MHNN) as a means to solve the shortest path problem. It uses every piece of information that is available at the peripheral neurons in addition to the highly correlated information that is available at the local neuron. Consequently, every neuron converges speedily and optimally to a stable state. The convergence is faster than what is usually found in algorithms that employ conventional Hopfield neural networks. Computer simulations support the indicated claims. The results are relatively independent of network topology for almost all source-destination pairs, which may be useful for implementing the routing algorithms appropriate to multi-hop packet radio networks with time-varying network topology.

Key words : Hopfield Neural Network, Shortest Path Routing, Combinatorial Optimization

1. 서 론

컴퓨터 네트워크를 포함한 다양한 네트워크 환경에

본 연구는 한국과학재단 목적기초연구(과제번호 R01-1999-00239) 지원으로 수행되었음.

[†] 학생회원 : 광주과학기술원 정보통신공학과
cwan@kjist.ac.kr

^{**} 비 회원 : 광주과학기술원 정보통신공학과 교수
rsr@kjist.ac.kr

^{***} 비 회원 : 고려대학교 산업시스템정보공학과 교수
ichoi@korea.ac.kr

^{****} 비 회원 : 고려대학교 전자통신학과 교수
ccgkang@korea.ac.kr

논문접수 : 2001년 9월 10일

심사완료 : 2002년 5월 9일

서 출발지와 도착지간의 최적 경로를 탐색하는 라우팅 알고리즘은 시스템의 성능을 직접적으로 결정하는 매우 중요한 요소 기술이다. 이상적인 라우팅 알고리즘은 짧은 시간 내에 시스템의 수율을 극대화하는 동시에 평균 패킷 지연 시간은 최소화하는 최단 경로(Shortest Path: SP)를 찾는 것이다. 일반적으로 Dijkstra의 최단 경로 알고리즘을 통해 최적 경로를 계산할 수 있으나[1], 네트워크 노드의 수가 많거나 링크 비용 및/또는 네트워크 토폴로지가 동적으로 변하는 환경에서는 계산의 복잡도로 인하여 실시간 계산의 제약이 따른다. 이를 해결하기 위한 다수의 발견적(heuristic) 방법들 중에서 신경망을

이용하는 방법이 적합한 것으로 고려되고 있다[2-7].

한편, 최단 경로 문제는 제한 조합 최적화(constrained combinatorial optimization) 문제로 귀결되며, 이를 위한 새로운 시도로서 90년대 초반부터 홉필드 신경망(Hopfield neural network)이 부각되고 있다[3-6]. 홉필드 신경망 하드웨어의 뉴런들이 불과 수~수십 μ s 내에 수렴하는 빠른 계산 속도를 실현할 수 있기 때문에 더욱 더 매력적인 접근 방법으로 인식되고 있다. 홉필드 신경망을 이용하여 제약 조합 최적화 문제를 해결하기 위해서는 목적함수와 제약식을 동시에 표현하는 Lyapunov (Energy) 함수를 정의하고, 이를 최소화하는 형태의 무제약 최적화(unconstraint optimization) 문제로 변환한다[8,9]. 이때, 경로 상의 루프 방지, 또는 뉴런의 수렴 속도 증가를 위해 제약식으로 적용되는 항들의 설정이 라우팅 알고리즘의 우수성을 좌우하게 된다.

Hopfield와 Tank[9]는 제한 조합 최적화에 해당하는 Traveling Salesman Problem을 최초로 신경망을 이용하여 접근하였다. 그 후, Rauch와 Winarske[2]는 주어진 출발지-목적지 사이에서 최단 경로를 신경망을 이용하여 찾는 방법을 처음으로 제안하였으나, 일반적으로 최단 경로를 구성하는 노드의 수가 알려지지 않기 때문에 한계점을 지니고 있다. 이러한 문제점을 해결하기 위해 Zhang과 Thomopoulos는 모든 노드를 한번씩 경유하여 경로를 구성하는 알고리즘을 제안하였으나, 네트워크 링크 비용의 변화에 적응적으로 반응하기 위해서 신경망 내부의 접합(Synapse) 연결 저항 값을 지속적으로 변경해야 한다는 점과 경로가 모든 노드들을 한번씩 경유해야 한다는 문제점이 있다[3]. 한편, 기존의 이런 문제를 제거한 방식이 Ali와 Kamoun에 의해 제안되었지만[5], 이 알고리즘은 최단 경로 설정 문제에서 가장 배제해야 하는 루프 또는 부분 경로(partition)가 발생하는 문제점이 있다. 한편, Ali & Kamoun의 알고리즘에서 루프 존재의 가능성을 제거한 방식이 Park과 Choi에 의해서 제안되었다[7]. 하지만, 이 방식에서 뉴런의 수렴 성능이 네트워크 토폴로지에 민감하게 영향을 받는 문제점이 존재하고, 경로의 수렴 및 최적성 성능이 기존 알고리즘에 비해 개선되지 못했다. 한편, 기존의 어떤 알고리즘들도 수렴 성능 및 수렴 경로의 최적성 성능에 대해서 구체적인 비교 및 분석의 수행이 이루어지지 않고 있다.

본 논문에서는 [5] 및 [7]에서 고려한 홉필드 신경망 기반 최단 경로 알고리즘의 수렴 및 최적성 성능을 향상시키기 위해 새로운 수정 방안을 제안하고, 각 성능을 비교 및 분석한다. 본 논문의 2절에서는 전형적

인 홉필드 신경망을 이용하여 최단 경로 문제를 해결하는 접근 방법의 개요에 대해서 살펴보고, 각 방식이 지니고 있는 문제점에 대해 고찰한다. 3절에서는 제안하는 홉필드 신경망의 구조 및 라우팅 알고리즘에 대해 기술하고, 4절에서는 수치적 실험을 통하여 제안 알고리즘의 성능을 비교 및 분석한다. 마지막으로, 5절에서는 결론을 맺는다.

2. 홉필드 신경망을 이용한 최단 경로 알고리즘의 개요

2.1 홉필드 신경망의 개요

1984년에 제약식을 갖는 최적화(constrained optimization) 문제의 해결을 위해 신경망을 이용하는 기법이 Hopfield와 Tank[8,9]에 의해 처음으로 시도되었다. 그들은 이산 조합 최적화(discrete combinatorial optimization) 문제에 대해 보다 좋은 해를 얻을 수 있는 신경망 모델을 제안하고, 이러한 모델을 TSP(Traveling Salesman Problem)에 적용하여 모델의 유용성을 검증하였다. 그림 1은 전형적인 홉필드 신경망(Hopfield neural network: HNN) 계산 회로를 나타내는 것으로서, 이는 생물학적 신경망의 기본 요소에 대한 모델을 바탕으로 설계되었다.

각 뉴런(neuron)은 시그모이드(sigmoid) 단조 증가 함수를 갖는 연산 증폭기(operational amplifier)와 같은 비선형(nonlinear) 소자로 모델링 되며, 이때 번째 뉴런으로 U_i 가 입력되면 0과 1사이의 값을 갖는 V_i 가 출력된다. 그리고, 전형적인 시그모이드 함수는 논리 기호학(logistic) 함수로 식 (1)과 같이 표현된다[8].

$$V_i = g_i(U_i) = \frac{1}{1 + e^{-\lambda_i \cdot U_i}} \quad (1)$$




그림 1 홉필드 신경망의 구조

각 뉴런의 입력으로 다른 뉴런들로부터 접합(synapse) 연결로 모델링 되는 저항성(resistive) 연결을 통해 출력된 값이 재입력(feedback)된다. 즉, i 번째 뉴런이 j 번째 뉴런의 연결 여부는 이진 결정 변수에 해당하는 T_{ij} 로 나타낼 수 있다. 즉, 접합 연결이 존재하면 $T_{ij}=1$ 이며, 그렇지 않을 경우에는 $T_{ij}=0$ 이다. 따라서, 신경망의 구조는 신경망의 연결 행렬(connection matrix) $T=[T_{ij}]$ 에 의해 묘사될 수 있다. 그림 1에서 볼 수 있듯이 각 뉴런은 바이어스(bias) 역할을 하는 외부 전류(external current) I_i 를 받으며, 이는 신경망 내부로 사용자가 입력할 수 있는 유일한 정보를 나타낸다. 이상과 같은 모델을 기반으로 i 번째 뉴런의 역학적(dynamic) 특성은 식 (2)와 같이 나타낼 수 있다[8].

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} + \sum_{j=1}^N T_{ij} \cdot V_j + I_i \quad (2)$$

식 (2)에서 τ 는 홉필드 신경망 회로의 시상수(time constant)를 나타낸다. Hopfield는 신경망의 연결 행렬가 대칭적 구조를 가지며, 증폭기들의 이득(gain)이 충분히 크다면 식 (2)로 표현되는 뉴런의 역학적 특성은 식 (3)의 2차 Lyapunov(energy) 함수의 기울기 감소(gradient descent) 방향으로 진행되는 규칙에 따름을 증명했다[9].

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N T_{ij} V_i V_j - \sum_{i=1}^N I_i V_i \quad (3)$$

따라서, 식 (3)의 Lyapunov 함수에 대하여 식 (2)의 i 번째 뉴런의 역학적 특성을 나타내면 식 (4)와 같이 표현된다.

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} - \frac{\partial E}{\partial V_i} \quad (4)$$

2.2 홉필드 신경망 기반의 최단 경로 알고리즘

네트워크에서 출발지 노드 s 부터 목적지 노드 d 까지 최단 경로를 찾는 라우팅 문제는 네트워크 토폴로지를 N 개의 노드(node)와 L 개의 링크(link)를 지닌 방향성 그래프(directed graph) $G=(\bar{N}, \bar{A})$ 에서의 최단 경로 문제로 정의할 수 있다[4,5]. 이때, 각 링크 (i, j) 는 그에 상응하는 비용 C_{ij} 를 갖는데, 이는 노드 i 에서 노드 j 로 경로 설정시 소요되는 비용을 수치화한 값이다. 예를 들어, 컴퓨터 통신망의 경우에는 특정 패킷을 노드 i 에서 노드 j 로 전송했을 때 발생하는 큐잉 및 전송 지연 시간이 이에 해당하는 비용이 될 수 있다.

출발지 노드 s 에서 목적지 노드 d 를 연결하는 일련의 노드들을 방향성 경로(directed path) P^{sd} 라고 정

의하고, 이를 식 (5)와 같이 표현한다면 경로 P^{sd} 에서의 총 경로 비용 C_T 는 식 (6)과 같이 각 노드간 비용의 합과 같다[5,7].

$$P^{sd}: s \rightarrow i \rightarrow j \rightarrow k \dots r \rightarrow d \quad (5)$$

$$C_T = C_{si} + C_{ij} + C_{jk} + \dots + C_{rd} \quad (6)$$

따라서, 경로에 대해 총 비용을 최소화하는 경로를 찾는 것이 최단 경로 라우팅 알고리즘의 설계 목표이다.

Hopfield와 Tank[9]는 처음으로 홉필드 신경망을 이용하여 최단 경로 문제의 해를 찾기 위해 시도하였다. 그 후, Rauch와 Winarske[2]에 의해 주어진 출발지-목적지 사이에서 최단 경로를 신경망을 이용하여 찾는 방법이 처음으로 제안되었다. 이들은 $N \times M$ 의 2차원 배열 신경망 구조를 제안하였다. 여기서 N 은 전체 노드의 개수이고, M 은 경로에 포함되어 있는 노드의 개수를 의미한다. 여기서, (x, i) 쌍은 노드 x 가 경로상의 i 번째 노드임을 의미하고, 이때 뉴런의 출력은 V_{xi} 로 정의하며 식 (7)과 같이 표현된다.

$$V_{xi} = \begin{cases} 1, & \text{if node } x \text{ is the } i\text{th node to be visited in the path} \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

하지만, 일반적으로 최단 경로를 구성하는 노드의 수가 알려지지 않고, 또한 노드의 수를 특정 개수로 제한하기 때문에 준최적(suboptimal) 해를 찾을 확률이 매우 높게 된다.

이러한 문제점을 해결하기 위해 Zhang과 Thomopoulos[3]는 경로를 이루는 노드의 개수를 M 에서 전체 노드의 개수으로 수정한 알고리즘을 제안하였다. 이 알고리즘은 주어진 출발지-목적지에 대해, 처음과 마지막 행에 대한 뉴런의 상태를 고정시키고, 나머지 뉴런은 식 (8)의 Lyapunov 함수를 최소화하는 방향으로 진화해 간다.

$$E = \frac{\mu_1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N V_{ik} C_{ij} V_{j,k+1} + \frac{\mu_2}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N V_{ik} V_{jk} + \frac{\mu_3}{2} \left(\sum_{i=1}^N \sum_{j=1}^N V_{ij} - M \right)^2 \quad (8)$$

여기서 μ_1 항은 전체 비용을 최소화하도록 하며, μ_2 항은 신경망이 유효한 경로로 수렴하게 하는 제약 조건을 충족시키도록 하며, μ_3 항은 네트워크를 구성하는 모든 노드들을 단지 한번씩 경우하여 경로를 구성하도록 하는 역할을 한다. 하지만, 이 알고리즘의 단점은 링크 비용이 지속적으로 변할 경우에는 이의 변화에 적응적으로 대응하기 위해서 접합(synapse) 연결의 저항 값들을 지속적 변경해야 한다는 점이다. 또한, 네

트위크를 구성하는 모든 노드를 경유해야 하는 제한은 최적 경로 라우팅 문제에 해당되지 않는 조건이다.

실질적으로 신경망을 이용하여 최단 경로 문제를 다룬 최초의 시도는 Ali와 Kamoun[5]에 의해 이루어졌다고 볼 수 있다. 이들은 N 개의 노드가 존재하는 네트워크에서의 최단 경로 문제를 $N(N-1)$ 개의 뉴런을 갖는 홉필드 신경망을 이용하여 모델링 하였다. 제안된 신경망은 뉴런의 출력 V_{xi} 와 링크 연결(connection) 함수 ρ_{xi} 에 의해 특성화되며, 이들은 각각 식 (9)와 식 (10)과 같이 정의된다.

$$V_{xi} = \begin{cases} 1, & \text{if the arc from node } x \text{ to node } i \text{ exists in the shortest path} \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

$$\rho_{xi} = \begin{cases} 1, & \text{if the arc from node } x \text{ to node } i \text{ does not exist in the network} \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

그리고, 홉필드 신경망을 이용하여 최단 경로 문제를 풀기 위한 Lyapunov 함수를 식 (11)과 같이 제안하였다.

$$E = \frac{\mu_1}{2} \sum_{x=1}^N \sum_{\substack{i=1, \neq x \\ (x,i) \neq (d,s)}}^N C_{xi} V_{xi} + \frac{\mu_2}{2} \sum_{x=1}^N \sum_{\substack{i=1, \neq x \\ (x,i) \neq (d,s)}}^N \rho_{xi} V_{xi} + \frac{\mu_3}{2} \sum_{x=1}^N \left(\sum_{i=1, \neq x}^N V_{xi} - \sum_{i=1, \neq x}^N V_{ix} \right)^2 + \frac{\mu_4}{2} \sum_{i=1}^N \sum_{x=1, \neq i}^N V_{xi} (1 - V_{xi}) + \frac{\mu_5}{2} (1 - V_{ds}) \quad (11)$$

여기서 μ_1 항은 전체 비용을 최소화하도록 하며, μ_2 항은 연결 링크가 존재하지 않는 경로로 뉴런이 수렴하는 것을 방지하도록 하며, μ_3 항은 경로가 동일한 노드를 두 번 이상 경유하는 상황의 발생 가능성을 제거하도록 하며, μ_4 항은 뉴런의 수렴 속도를 증가시키도록 하며, μ_5 항은 목적지 노드와 출발지 노드 사이의 링크를 경로에 포함 시키도록 하는 역할을 한다. 이때 항의 설정은 Ali & Kamoun이 채택하고 있는 제약식을 만족시키기 위한 것이다. 하지만, 이 알고리즘은 최단 경로 설정 문제에서 배제되어야 하는 루프 또는 부분 경로(partition)가 발생하는 문제점이 있다.

한편, Ali & Kamoun 알고리즘의 루프 존재 가능성을 제거한 방식이 Park과 Choi[7]에 의해 제안되었다.

이는 식 (11)의 Lyapunov 함수에 $\sum_{x=1}^N \sum_{\substack{i=1 \\ i \neq x}}^N V_{xi} \cdot V_{ix}$ 항을 추가함으로써 링크 (x, i) 의 V_{xi} 와 링크 (i, x) 의 V_{ix} 가 동시에 'ON'되는 상황이 발생하는 것을 방지하도록

하였다. 하지만, 이는 네트워크 토폴로지에 따라 뉴런의 수렴 성능이 상당한 영향을 받게 되어서 기존의 알고리즘에 비해 수렴 성능을 거의 향상시킬 수 없었고, 경로의 최적성이 기존 알고리즘에 비해 열화되는 문제점을 지니고 있음을 4절의 모의 실험을 통해 알 수 있었다.

3. 수정된 홉필드 신경망을 이용한 제안 접근 방법

3.1 제안 알고리즘의 설계

최단 경로 설정 문제를 홉필드 신경망을 이용하여 정식화(formulation)하기 위해서는 최적 경로가 신경망의 최종 안정 상태에서부터 결정되도록 하는 적당한 방안을 도출해야 한다. 즉, 네트워크상에 N 개의 노드가 존재한다면 연결 행렬 및 비용 행렬은 대각 항이 존재하지 않는 $(N \times N)$ 행렬로 구성된다. 행렬의 각 요소(element)는 이는 입력과 출력 노드가 각각 i 와 j 인 뉴런에 해당하며, 각 뉴런은 (i, j) 로 표현된다. 따라서, 제안하는 신경망은 Ali & Kamoun[5]의 알고리즘과 동일하게 $N(N-1)$ 개의 뉴런이 필요하며 (i, j) 위치의 뉴런은 식 (12)에 정의된 V_{ij} 와 같이 정의되고, (i, j) 위치의 연결 함수는 식 (13)과 같이 정의된다.

$$V_{ij} = \begin{cases} 1, & \text{if the arc from node } i \text{ to node } j \text{ exists in the routing path} \\ 0, & \text{otherwise} \end{cases} \quad (12)$$

$$\rho_{ij} = \begin{cases} 1, & \text{if the arc from node } i \text{ to node } j \text{ does not exist} \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

그리고, 노드 i 와 노드 j 사이의 링크 비용은 0과 1사이의 실수로 정규화된 값을 가지며, 이를 C_{ij} 로 나타낸다. 그리고, 홉필드 신경망을 이용하여 최단 경로 문제의 해를 구하기 위해서는 신경망을 가장 낮은 에너지 상태로 유도하는 Lyapunov (Energy) 함수를 정의해야 한다. 이때, 안정 상태에 있는 뉴런의 번호 순서

	1	2	3	4	5	6
1	1	0	1	0	0	0
2	0	1	0	0	0	0
3	0	0	1	0	1	0
4	0	0	0	1	0	1
5	0	0	0	1	1	0
6	0	0	0	0	0	1

그림 2 6개의 노드로 구성된 네트워크에 대한 뉴런의 최종 출력 테이블

(sequence)에 따라 최단 경로를 결정하게 된다. 예를 들어, 6개의 노드로 구성된 네트워크에 대해 그림 2와 같이 뉴런이 진화했을 경우에 1→2→3→4→6의 순서로 경로가 설정된다.

위의 정의를 이용하여 최단 경로 라우팅 문제는 다음과 같은 제한 조합 최적화 문제로 정식화될 수 있다.

$$\begin{aligned} & \text{minimize} && \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N C_{ij} \cdot V_{ij} && (14-a) \\ & \text{subject to} && \sum_{\substack{j=1 \\ j \neq i}}^N V_{ij} - \sum_{\substack{j=1 \\ j \neq i}}^N V_{ji} = \begin{cases} 1, & \text{if } i = s \\ -1, & \text{if } i = d \\ 0, & \text{otherwise} \end{cases} && (14-b) \\ & && V_{ij} \in \{0, 1\} \end{aligned}$$

여기서 식 (14-a)는 경로를 구성하는 총 비용의 합을 목적 함수로 하여, 이를 최소화하고자 하는 것이다. 한편, 식 (14-b)는 특정 노드로 도착하는(incoming) 경로들의 수는 그 특정 노드를 출발하는(outgoing) 경로의 수와 같도록 하는 조건으로서, 출발지 노드에서 시작한 경로가 목적지 노드까지 도달이 가능하도록 하는 역할을 한다. 패킷 통신망의 관점에서 볼 때는 특정 노드에 입력되는 패킷의 수와 그 노드에서 출력되는 패킷의 수가 동일하여 트래픽 흐름이 보존(flow conservation)된다는 조건에 해당한다.

그리고, 홉필드 신경망을 이용한 라우팅 알고리즘을 설계하기 위해서 본 논문에서는 Lyapunov 함수를 제한식 (14)를 만족하고 동시에 수렴 속도를 증가시키면서 뉴런이 최적 경로로 수렴할 수 있도록 식 (15)와 같이 정의하고, 이를 최소화하는 방향으로 뉴런을 진화시킨다.

$$\begin{aligned} E = & \frac{\mu_1}{2} \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N C_{ij} \cdot V_{ij} + \frac{\mu_2}{2} \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N \rho_{ij} \cdot V_{ij} \\ & + \frac{\mu_3}{2} \sum_{i=1}^N \left(\sum_{\substack{j=1 \\ j \neq i}}^N V_{ij} - \sum_{\substack{j=1 \\ j \neq i}}^N V_{ji} - \gamma_i \right)^2 + \frac{\mu_4}{2} \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N V_{ij} \cdot (1 - V_{ij}) \\ & + \frac{\mu_5}{2} \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N V_{ij} \cdot V_{ji} + \frac{\mu_6}{2} \left[\sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N \left(\sum_{\substack{k=1 \\ k \neq i, j}}^N V_{ik} - 1 \right) \cdot V_{ij}^2 \right] \\ & + \frac{\mu_7}{2} \left[\sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N \left(\sum_{\substack{k=1 \\ k \neq i, j}}^N V_{kj} - 1 \right) \cdot V_{ij}^2 \right] \end{aligned} \quad (15)$$

식 (15)에서 각 항은 다음과 같은 역할을 수행한다. μ_1 항은 식 (14-a)의 목적 함수에 해당하며, 비용을 최

소화하는 경로를 찾을 수 있도록 한다. μ_2 항은 링크가 존재하지 않는 노드들이 경로에 포함되는 것을 제거하는 역할을 한다. μ_3 항은 식 (14-b)의 제한 조건에 해당한다. 식 (14-b)를 만족할 경우 '0'의 값을 갖고, 그렇지 않을 경우에는 Lyapunov 함수를 증가시키기 때문에 위의 형태와 같이 Lyapunov 함수에 포함할 수 있다. μ_4 항은 유효한 경로로 뉴런의 상태가 빠르게 수렴할 수 있도록 보조하는 역할을 한다. 여기서, 위의 μ_1, μ_2, μ_3 그리고, μ_4 항은 Ali & Kamoun[5]에 의한 제한된 부분이다. 한편, μ_5 항은 Park & Choi[7]에 의해 제안된 부분으로서, 경로상에서 루프의 발생 가능성을 제거하고, 또한 뉴런이 안정 상태로 빠르게 수렴하도록 한다.

한편, μ_6 와 μ_7 항은 본 논문에서 제안하는 부분으로서, μ_3 항을 보조하면서 경로상의 루프 발생 또는 분할(partition) 가능성을 제거한다. 그리고, 무엇보다도 뉴런의 상태가 최적 경로에 근접하게 수렴하도록 하며, 또한 기존의 알고리즘에 비해 수렴 속도를 증가시킬 수 있다.

3.2 제안 알고리즘의 동작 예

제안하는 μ_6 와 μ_7 항들이 뉴런의 입력 전압의 갱신 과정에 미치는 영향을 구체적으로 살펴보자. 예를 들어, 그림 3이 6개의 노드로 구성된 네트워크에 대한 n번째 반복 계산 후의 뉴런 출력 테이블을 나타낸다면, (n+1)번째의 뉴런의 출력 전압 V_{24} 을 구하기 위한 뉴런의 입력 전압 U_{24} 는 식 (15)의 Lyapunov 함수를 감소 시키는 방향으로 뉴런을 진화 시키면서 구한다.

To update U_{24} , use the 2-dimensional and own neuron's information

	1	2	3	4	5	6
1		0.11	0.03	V_{14}	0.42	0.18
2	V_{21}		V_{23}	V_{24}	V_{25}	V_{26}
3	0.11	0.03		V_{34}	0.25	0.59
4	0.00	0.04	0.67		0.32	0.01
5	0.14	0.52	0.37	V_{54}		0.14
6	0.07	0.00	0.14	V_{64}	0.03	

그림 3 6개의 노드로 구성된 네트워크에 대한 n번째 계산 후의 뉴런의 출력 테이블

먼저 μ_6 항에 대한 영향 살펴보자. 만약 $\sum_{k=2,4}^6 V_{2k}$ 가 0에 근접한 값이면, 즉 노드 2의 링크들 중에서 노드 2와 노드 4 사이의 링크를 제외한 링크들 중 어떠한 링크도 경로에 포함되고 있지 않는 경우를 의미하는데, 이때 $\left(\sum_{k=2,4}^6 V_{2k}-1\right)$ 은 -1에 가까운 값을 지니게 된다. 하지만, 이것이 - (노드 2 → 노드 4)의 링크를 제외한 다른 링크들이 경로에 포함되지 않는다 - 노드 2와 4 사이의 링크가 경로에 포함되는 것을 의미하지는 않는다. 왜냐하면, 소스와 목적지 노드를 연결하는 최단 경로는 네트워크 상의 모든 노드를 경유할 필요는 없기 때문이다. 이때, Lyapunov 함수 값에 영향을 주는 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 는 V_{24} 값에 의해 달라지게 되는데, 만약 V_{24} 가 1에 가까운 값이면, 즉 노드 2와 노드 4 사이의 링크가 경로에 포함되는 상황을 의미하는데, 이때 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 값이 -1에 근접한 값을 지니게 되어 Lyapunov 함수를 강제적으로 감소 시킴으로써 U_{24} 를 증가시켜서 V_{24} 가 1로 빠르게 수렴할 수 있도록 한다. 그러나, V_{24} 가 0에 가까운 값이면, 즉 노드 2와 노드 4 사이의 링크가 경로에 포함되지 않는 상황을 의미하는데, 이때 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 값이 0에 근접하게 되어 Lyapunov 함수 값을 거의 증가시키지 않기 때문에 U_{24} 의 증가도 거의 발생하지 않아서 기존 알고리즘 [5,7]의 수렴 속도를 유지한다.

만약 $\sum_{k=2,4}^6 V_{2k}$ 이 1에 근접한 값이면, 즉 노드 2의 링크들 중에서 노드 2와 4 사이의 링크를 제외한 링크들 중에서 특정 링크가 경로에 포함되고 있는 경우를 의미하는데, 이때 $\left(\sum_{k=2,4}^6 V_{2k}-1\right)$ 은 0에 가까운 값을 지니게 되고 V_{24} 은 1을 초과할 수 없기 때문에 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 값은 여전히 0에 근접한 값을 지니게 되어 Lyapunov 함수 값에 거의 영향을 미치지 않으므로 기존 알고리즘 [5,7]의 수렴 속도를 유지한다.

한편, $\sum_{k=2,4}^6 V_{2k}$ 가 1/2에 근접한 값이면, 즉 노드 2와 노드 4 사이의 링크를 제외한 링크들 중에서 어떤 링

크가 경로에 포함되는지 매우 불확실한 상태를 의미한다. 이때, $\left(\sum_{k=2,4}^6 V_{2k}-1\right)$ 은 -1/2에 근접한 값을 취해서 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 에 의해 V_{24} 가 큰 값을 갖는 경우에는 노드 2와 노드 4 사이의 링크가 경로에 포함되는 상황을 인지하고, Lyapunov 함수를 강제적으로 작아지게 하여 U_{24} 를 더욱 증가시켜서 수렴 속도의 극대화할 수 있다. 그리고, V_{24} 가 작은 값을 갖는 경우에는 $\left(\sum_{k=2,4}^6 V_{2k}-1\right) \cdot V_{24}^2$ 값이 매우 작은 값을 취하게 되어 Lyapunov 함수를 거의 변화시키지 않기 때문에 기존 알고리즘 [5,7]과 동등한 수렴 속도를 유지한다. 한편, V_{24} 가 1/2에 근접한 값을 갖는 경우에는 즉, 알고리즘의 동작에 있어 뉴런의 초기 상태를 의미하는데, 이때 V_{24} 의 값도 그렇게 작은 값을 갖지 못하게 되어 수렴 성능을 열화시킬 수 있는 가능성이 있지만, 이는 알고리즘이 동작 시작 시점에서만 발생하는 일시적인 현상이며, 또한 $\mu_1, \mu_2, \mu_3, \mu_4, \mu_5$ 에 비해 μ_6 이 Lyapunov 함수에 미치는 영향이 극히 미미하게 되어 수렴 속도의 심각한 성능 열화를 초래하지 않는다. 그리고, 위에 설명했던 모든 현상들이 조합적으로 발생하면서 신경망이 진화하기 때문에 전체적으로는 수렴 성능을 상당히 향상시킬 수 있다. 한편, μ_1 항은 μ_6 항과 동일한 맥락으로 설명이 가능하다. 단지 μ_6 항이 출력 링크들에 대해서 계산한 반면, μ_1 항은 입력 링크들에 대해서 계산한 것 뿐이다.

제안 알고리즘은 뉴런의 국소 정보가 수렴 속도를 보조하는 기존 알고리즘 [5,7]과는 달리 2차원의 모든 뉴런 정보를 바탕으로 수렴을 보조하므로 특정 뉴런의 잘못된 진화로 인해 준최적 경로로 수렴하는 경향을 바로 잡을 수 있도록 설계되었기 때문에 기존의 알고리즘에 비해 최적성 성능도 향상시킬 수 있다. 그리고, μ_6 항과 μ_1 항은 소스 노드와 목적지 노드를 제외한 노드들에서 경로의 입력은 반드시 경로의 출력을 만드는 μ_3 를 보조하며, 경로가 네트워크 상의 노드를 최대 1개만 경유하여 설정되도록 설계되었기 때문에 루프의 발생 및 경로 고립(분할) 현상은 발생하지 않는다.

3.3 수정된 홉필드 신경망의 구조

μ_6 과 μ_1 항은 기존의 홉필드 신경망 모델과는 달리 뉴런의 진화가 주변의 모든 뉴런의 정보 및 상관 관계




그림 4 수정된 홉필드 신경망 모델

성이 높은 자신의 뉴런 정보를 동시에 이용하고 있기 때문에 그림 1의 전형적인 홉필드 신경망 구조가 그림 4와 같이 수정되어야 한다. 또한, 그림 4의 수정된 홉필드 신경망 구조에 의해 i 번째 뉴런의 역학적 특성을 나타내는 식 (2)는 식 (16)과 같이 수정된다. 그리고, 식 (1), 식 (4), 식 (16)을 2차원 색인으로 표현하면 식 (17), 식 (18), 식 (19)와 같이 표현된다.

$$\frac{dU_i}{dt} = -\frac{U_i}{\tau} + \sum_{j=1}^N (T_{ij}^{(1)}V_j + T_{ij}^{(2)}V_jV) + I_i \quad (16)$$

$$V_{ij} = g_{ij}(U_{ij}) = \frac{1}{1 + e^{-\lambda_{ij}U_{ij}}} \quad (17)$$

$$\frac{dU_{ij}}{dt} = -\frac{U_{ij}}{\tau} - \frac{\partial E}{\partial V_{ij}} \quad (18)$$

$$\frac{dU_{ij}}{dt} = -\frac{U_{ij}}{\tau} + \sum_{k=1}^N \sum_{l=1}^N (T_{ij,kl}^{(1)}V_{kl} + T_{ij,kl}^{(2)}V_{kl}V_{ij}) + I_{ij} \quad (19)$$

그리고, Lyapunov 함수 (15)에 의해 (18)은 (20)과 같이 다시 표현할 수 있다.

$$\begin{aligned} \frac{dU_{ij}}{dt} = & -\frac{U_{ij}}{\tau} - \frac{\mu_1}{2} C_{ij} - \frac{\mu_2}{2} \rho_{ij} - \mu_3 \left\{ \sum_{k=1}^N (V_{ik} - V_{ki}) - \gamma_i \right\} \\ & + \mu_3 \left\{ \sum_{k=1}^N (V_{jk} - V_{kj}) - r_j \right\} - \frac{\mu_4}{2} (1 - 2V_{ij}) - \frac{\mu_5}{2} V_{ij} \\ & - \mu_6 \left(\sum_{k=1}^N V_{ik} - 1 \right) \cdot V_{ij} - \mu_7 \left(\sum_{k=1}^N V_{kj} - 1 \right) \cdot V_{ij} \end{aligned} \quad (20)$$

식 (20)을 식 (19)와 비교하면, 홉필드 신경망의 연결 계수(connection weight)와 바이어스(bias)는 각각 식 (21-a), (21-b)와 식 (22)와 같이 나타낼 수 있다.

$$T_{ij,kl}^{(1)} = \mu_3 \delta_{jk} + \mu_3 \delta_{li} - \mu_3 \delta_{ik} - \mu_3 \delta_{jl} + \mu_4 \delta_{ik} \delta_{jl} - \frac{\mu_5}{2} \delta_{jk} \delta_{il} - \mu_6 \delta_{ik} \delta_{jl} - \mu_7 \delta_{ik} \delta_{jl} \quad (21-a)$$

$$T_{ij,kl}^{(2)} = -\mu_6 \delta_{ik} - \mu_7 \delta_{jl} \quad (21-b)$$

$$I_{ij} = -\frac{\mu_1}{2} C_{ij} - \frac{\mu_2}{2} \rho_{ij} + \mu_3 \gamma_i - \mu_3 \gamma_j - \frac{\mu_4}{2} \quad (22)$$

여기서 δ_{ij} 는 Kronecker delta 함수이다. 그리고, 제안하는 신경망 알고리즘에서 식 (18) 또는 식 (20)의 미분 방정식을 해결하기 위해 오일러(Euler) 기법[10]을 사용하면 이 결과는 식 (23)과 같다.

$$U_{ij}(t + \Delta t) = U_{ij}(t) + \Delta t \left\{ -U_{ij}(t) - \frac{\partial E}{\partial V_{ij}} \right\} \quad (23)$$

따라서, 식 (23)에 의해 계산되는 U_{ij} 를 식 (17)에 대입하여 뉴런을 진화시키면 V_{ij} 를 얻을 수 있으며, 이로부터 최단 경로를 찾을 수 있다.

위에서 고려된 신경망 구조는 홉필드 신경망 구조가 수정되었음에도 불구하고, 기존의 알고리즘[5,7]이 갖는 장점을 유지하고 있다. 즉, 링크 비용 C_{ij} 와 연결 함수 ρ_{ij} 에 포함되어 있는 링크 상태의 변화, 네트워크 상의 혼잡 상황의 발생, 그리고 네트워크 토폴로지의 변화가 발생하더라도, 이에 대한 정보를 신경망 내부 구조의 수정 없이 신경망 외부에서 입력되는 바이어스 I_{ij} 만의 변경으로 완벽하게 반영할 수 있다는 사실이다.

4. 모의 실험 결과 및 분석

본 논문에서 제안하는 홉필드 신경망을 이용한 라우팅 알고리즘의 성능을 Ali와 Kamoun이 제안한 신경망 알고리즘 [5]과 Park과 Choi가 제안한 신경망 알고리즘 [7]의 성능과 비교하고, 이를 위해 다양한 형태의 네트워크 토폴로지를 고려한다. 그리고, Dijkstra 알고리즘 [1]에 결정된 최적 해와 제안 알고리즘에 의해 정해진 해를 비교하여 최적성(optimality)에 대한 성능 비교도 함께 수행한다.

신경망은 시간 간격 Δt 마다 각 뉴런의 출력 전압을 갱신하면서 진화한다. 그리고 각 뉴런의 시상수 τ 는 '1'로 설정하고, 신경망 동작의 단순화를 위해 $\lambda_{ij} = \lambda$, $g_{ij} = g$ 를 사용한다[9]. 또한, Δt 의 값은 10^{-4} 로 설정

한다. 한편, 시뮬레이션에서 중요한 변수 중의 하나는 뉴런의 초기 입력 전압으로서, 이는 일반적으로는 '0'의 값을 설정하지만, 대칭적 네트워크 토폴로지에 의한 신경망의 대칭성을 피하며 동시에 뉴런의 수렴에 도움을 줄 수 있도록 [-0.0002, 0.0002] 사이의 값을 설정한다[9]. 그리고, 반복적 계산의 진행은 신경망 내부의 모든 뉴런이 안정 상태에 도달했을 경우에 종료하며, 안정 상태로 간주되는 뉴런의 출력 전압의 변화 기준 ΔV_{th} 은 10^{-4} 으로 설정한다. 모든 뉴런이 안정 상태에 도달한 후, 각 뉴런의 출력 전압이 $V_{ij} \geq 0.5$ 이면 'ON' 상태, $V_{ij} < 0.5$ 이면 'OFF' 상태로 결정한다. 한편, Lyapunov 함수의 계수(coefficient)들은 각 요소가 미치는 영향을 고려하여 적절히 설정해야 하며, 이는 시스템의 성능과 밀접한 관계가 있기 때문에 매우 신중히 선택해야 한다. 본 논문에서는 $\mu_1, \mu_2, \mu_3, \mu_4$ 에 의해 영향을 주는 요소는 Ali와 Kamoun이 제안한 신경망 모델과 동일하기 때문에 Ali와 Kamoun에 의해 설정된 값을 사용한다. 한편, μ_5, μ_6, μ_7 은 큰 값을 사용할 경우 뉴런의 출력 전압의 흔들림(perturbation) 및 준최적 경로로의 수렴을 유발하게 된다. 따라서, 본 논문에서는 이러한 개념에 기반을 두고 실험적 결과를 통해 적정한 값의 μ_5, μ_6, μ_7 을 설정하였다. 이때 각 계수의 관계는 다음과 같은 조건을 만족해야 한다. μ_1 은 비교적 큰 값을 갖지만, 링크가 존재하지 않는 노드가 경로에 포함되는 상황을 방지하기 위해 μ_2 보다는 작은 값을 갖는다. 그리고, μ_3 은 소스 노드에서 출발한 경로가 목적지 노드를 향해 지속적으로 연결을 설정할 수 있도록 유도하는 역할을 하므로 μ_1 보다는 큰 값을 취하지만, μ_2 보다는 작은 값을 취해야 한다. 또한, $\mu_4, \mu_5, \mu_6, \mu_7$ 은 각 항이 미치는 영향이 비슷하므로 유사한 값이 설정되어야 하지만, μ_1 과 비슷한 값을 설정할 경우에는 준최적 경로로의 수렴 가능성이 매우 커지게 되므로 μ_1 보다는 상당히 작은 값으로 설정해야 한다. 본 수치적 실험을 위해 사용된 파라미터는 표 1과 같다.

표 1 수치적 실험 파라미터

Parameter	Symbol	Value
Time Constant	τ	1
Slope of Logistic Function	λ	1
Initial Input Voltage	U_{ij}	[-0.0002, 0.0002]
Incremental Time Step	Δt	10 ⁻⁴
Threshold Voltage	ΔV_{th}	10 ⁻⁴
Weighting Coefficients	μ_1	950
	μ_2	2500
	μ_3	1500
	μ_4	475
	μ_5	500
	μ_6	400
	μ_7	400

찾았을 뿐만 아니라, 경로 상에 루프가 발생하였다. 그리고, Park & Choi의 신경망 알고리즘은 또 다른 준최적 해에 수렴했음을 알 수 있다. 한편, 각 알고리즘의 제한 에너지와 목적 함수 값의 진화 경향은 각각 그림 7 및 그림 8과 같다.

그림 6와 그림 7로부터 Park & Choi 알고리즘은 Ali & Kamoun 알고리즘에 비해 빠르게 수렴하였고, 제안 알고리즘은 이들 두 알고리즘에 비해 빠르게 수렴하였다. 그리고, 그림 5와 그림 7로부터 제안 알고리즘은 최적 경로로 수렴했던 반면, Ali & Kamoun 알고리즘은 준최적 경로로 수렴하였으며, Park & Choi 알고리즘은 가장 최적성이 열악한 준최적 경로로 수렴했음을 알 수 있었다.

한편, 0~1 사이의 랜덤 비용을 가지며, 노드의 수가 6~20개 사이에서 랜덤한 200개의 랜덤 네트워크를 생성하여 수렴 속도와 경로의 최적성(route optimality)에 대해서 비교하였다. 이 실험을 결과를 요약하면 표 2와 같다.

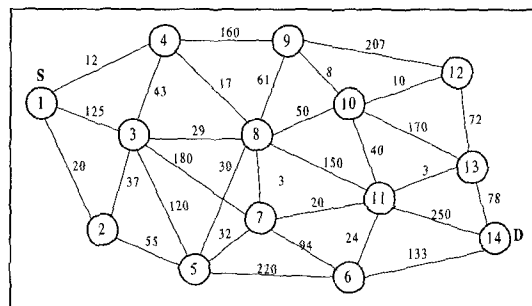




그림 5 예제 네트워크


한편, 그림 5처럼 14개의 노드로 구성된 예제 네트워크에 대해 각 알고리즘의 적용 결과 발견된 경로는 그림 6과 같다. 이때 각 링크의 비용은 0~1으로 정규화 된 값을 사용한다. 그림 6을 보면, 그림 5의 네트워크 형태에 대해서 제안 신경망 알고리즘은 최적 경로를 발견하는 Dijkstra 알고리즘 결과와 동일하였으나, Ali & Kamoun의 신경망 알고리즘은 준최적 경로를




(a) Ali & Kamoun 알고리즘



(b) Park & Choi 알고리즘



(c) 제안 알고리즘



(d) Dijkstra 알고리즘

그림 6 예제 네트워크에서의 최단 경로 탐색 결과

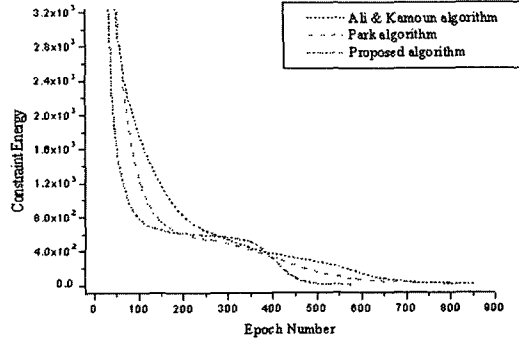


그림 7 예제 네트워크에서의 제한 에너지 진화 경향

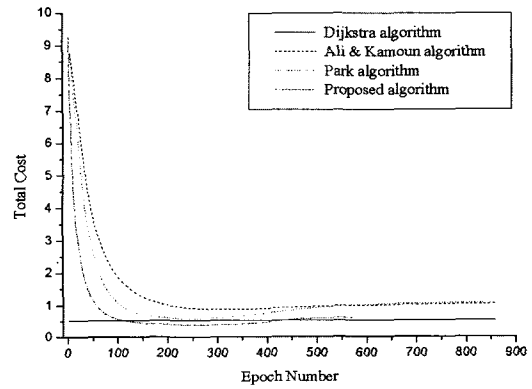


그림 8 예제 네트워크에서의 목적 함수 진화 경향

표 2 수렴 성능 및 경로의 최적성 비교

Algorithms Performance Measure		Ali & Kamoun	Park & Choi	Proposed
The number of iterations	Average	505.6742	504.7865	399.6922
	Standard Deviation	256.7508	283.6304	232.7412
Route optimality (%)		86.52	85.96	93.82

표 2에서 수렴 속도는 수렴시까지 반복 수의 평균과 표준 편차로 반영하였으며, 경로의 최적성은 10000개의 랜덤 토폴로지에 대해서 각 알고리즘에 의해 실제로 탐색한 경로가 최적 경로인 비율(%)로 나타낸다. 제안 알고리즘은 평균 400회의 반복 계산으로 신경망이 수렴했는데, 이는 평균 약 500회의 반복 계산 후에 신경망이 수렴하는 기존 두 알고리즘에 비해 약 20%의 수렴 속도를 증가 시켰음을 알 수 있다. 또한 제안 알고리즘의 표준 편차는 기존 두 알고리즘에 비해 가장 작은 값을 나타냈으며, 이는 네트워크 토폴로지에 대해 제안 알고리즘의 수렴 성능이 가장 강건한

(robust) 특성이 있음을 의미한다. 그리고, Park & Choi 알고리즘의 수렴 속도의 표준편차는 Ali & Kamoun과 제안 알고리즘에 비해 큰 값을 갖는데, 이는 Park & Choi 알고리즘은 네트워크 토폴로지에 따라 신경망의 수렴 성능이 가장 민감하게 영향을 받는 불안정을 의미한다. 한편, 제안 알고리즘에서 경로의 최적성은 약 94%로, Ali & Kamoun 알고리즘의 약 87%, Park & Choi 알고리즘의 약 86%에 비해 7~8%의 성능 향상을 보임을 알 수 있었다.

따라서, 제안 신경망 라우팅 알고리즘은 네트워크 토폴로지에 가장 영향을 받지 않으면서, 기존 Ali & Kamoun 알고리즘이나 Park & Choi 알고리즘에 비해 수렴 성능과 경로의 최적성을 동시에 향상시킨 것을 알 수 있다.

5. 결론

홉필드 신경망 기반의 최단 경로 알고리즘은 하드웨어를 통한 구현으로 실시간 계산이 가능하다. 또한, 링크 상태의 변화, 네트워크 내의 혼잡 상황 발생, 그리고 네트워크 토폴로지의 변화가 발생하더라도 이에 대한 정보를 신경망 내부 구조의 수정 없이 신경망 외부에서 입력되는 바이어스 I_i 만의 변경으로 완벽하게 반영할 수 있다. 따라서, 이와 같은 구현 방법은 트래픽 부하에 따라 노드의 혼잡 등으로 링크 비용이 변하는 컴퓨터 통신망이나 단말의 이동 등으로 인하여 네트워크 토폴로지가 지속적으로 변하는 Mobile Ad-hoc Network 등에서 효율적으로 최적 경로를 탐색하는데 활용이 가능하다. 이를 위해서 알고리즘의 수렴 성능이 네트워크의 토폴로지에 덜 민감해야 하며, 경로의 최적성도 우수해야 한다.

본 논문에서는 기존의 변형된 홉필드 신경망을 이용한 최단 경로 알고리즘의 수렴 성능과 경로의 최적성을 향상하기 위해 이를 수정한 새로운 알고리즘을 제안하였다. 이를 위해 기존의 홉필드 신경망 구조와는 달리 자신의 뉴런 정보를 갱신하기 위해서 모든 주변 뉴런의 정보뿐만 아니라, 상관 관계성이 가장 높은 자신의 뉴런 정보를 다시 이용함으로써 최적 경로에 빠른 속도로 수렴하도록 하였다. 다수의 랜덤 네트워크를 생성한 모의 실험의 결과, 제안하는 라우팅 알고리즘은 기존의 알고리즘에 비해 수렴 속도가 약 20%정도까지 향상되었고, 동시에 경로의 최적성은 평균 94%로 기존의 알고리즘에 비해 약 7~8%의 성능 이득을 얻었다. 특히, 제안 신경망 라우팅 알고리즘의

성능은 다른 기존의 방식보다 네트워크 토폴로지에 덜 민감하기 때문에 단말의 이동성으로 인하여 네트워크 토폴로지가 동적으로 변하는 Mobile Ad-Hoc 네트워크에서의 실시간 경로 설정에 유용할 것으로 사료된다.

참고 문헌

- [1] W. Stalling, *High-Speed Networks: TCP/IP and ATM Design Principles*, Prentice Hall, Inc., 1998.
- [2] H. E. Rauch and T. Winarske, "Neural Networks for Routing Communication Traffic," *IEEE Control Systems Magazine*, vol. 8, pp. 26-31, April 1988.
- [3] L. Zhang and S. C. A. Thomopulosm, "Neural Network Implementation of Shortest Path Algorithm for Traffic Routing in Communication Networks," *Proceedings of Joint Conference on Neural Networks*, p. 591, 1989.
- [4] S. L. Lee and S. Chang, "Neural Networks for Routing of Communication Networks with Unreliable Components," *IEEE Transactions on Neural Networks*, vol. 5, no. 5, pp. 854-863, September 1993.
- [5] M. K. M. Ali and F. Kamoun, "Neural Networks for Shortest Path Computation and Routing in Computer Networks," *IEEE Transactions on Neural Networks*, vol. 4, no. 6, pp. 941-954, November 1993.
- [6] J. E. Wieselthier, C. M. Barnhart and A. Ephremides, "A Neural Network Approach to Routing without Interference in Multihop Radio Networks," *IEEE Transactions on Communications*, vol. 42, no. 1, pp. 166-177, January 1994.
- [7] D. C. Park and S. E. Choi, "A Neural Network based Multi-destination Routing Algorithm for Communication Network," *Proceedings of Joint Conference on Neural Networks*, pp. 1673-1678, 1998.
- [8] D. W. Tank and J. J. Hopfield, "Simple Neural Optimization Networks: An A/D Converter, Signal Decision Circuit, and a Linear Programming Circuit," *IEEE Transactions on Circuits Systems*, vol. CAS-33, no. 5, pp. 533-541, 1986.
- [9] J. J. Hopfield and D. W. Tank, "Neural Computations of Decisions on Optimization Problem," *Biological Cybernetics*, vol. 52, pp. 141-152, 1986.
- [10] K. Atkinson, *Elementary Numerical Analysis*, John Wiley & Sons, Inc., 1993.



안창욱

1998년 8월 고려대학교 전자정보공학부 학사. 2000년 8월 고려대학교 전파공학과 석사. 2001년 3월 ~ 현재 광주과학기술원(K-JIST) 정보통신공학과 박사과정. 관심분야는 QoS 라우팅 프로토콜 설계/분석, Ad-Hoc 네트워크, Evolutionary Computing, Neuro-Fuzzy Computing



R.S. Ramakrishna

1966년 Univ. of Mysore, 전자공학과 박사. 1975년 Univ. of Nagpur, 전자공학과 석사. 1979년 Indian Institute of Technology (Kanpur), 전자공학과 박사. 1980년 ~ 1986년 Indian Institute of Technology (Bombay), 조교수. 1986년 ~ 1990년 Indian Institute of Technology (Bombay), 부교수. 1990년 ~ 1996년 Indian Institute of Technology (Bombay), 교수. 1996년 ~ 현재 광주과학기술원(K-JIST), 정보통신공학과 교수. 관심분야는 Computer Graphics, Evolutionary and Quantum Computing, Theoretical Computer Science



최인찬

1982년 2월 고려대학교 산업공학과 학사. 1984년 5월 아이오와 주립대학 산업공학과 학사. 1986년 5월 컬럼비아 대학 (미국, 뉴욕시) IE/OR 석사. 1988년 5월 컬럼비아 대학(미국, 뉴욕시) IE/OR M. Phil. 1990년 10월 컬럼비아 대학 (미국, 뉴욕시) 박사. 1988년 5월 ~ 1988년 9월 벨통신 연구소 (Bellcore) 연구원. 1995년 1월 ~ 1996년 12월 International Journal of Operations and Quantitative Management 편집위원. 1996년 3월 ~ 현재 고려대학교 공과대학 산업시스템정보공학과 교수. 관심분야는 IP, LP, NLP, Network Flow, 금융공학, 스케줄링



강충구

1987년 6월 Univ. of California (San Diego), 전자공학과 학사. 1989년 9월 Univ. of California (Irvine), 전자 및 컴퓨터 공학과 석사. 1993년 3월 Univ. of California (Irvine), 전자 및 컴퓨터 공학과 박사. 1991년 7월 ~ 1992년 5월 Aerospace Corp. 연구원. 1993년 4월 ~ 1994년 2월 Rockwell International 연구원. 1994년 3월 ~ 현재 고려대학교 정보통신대학 전파통신공학과 부교수. 2000년 8월 ~ 2001년 8월 Center of Wireless Communication (UC San Diego) 방문교수/연구원. 관심분야는 광대역 무선 전송 기술 및 매체접근제어 프로토콜 설계/구현, 광대역 무선 접속망 및 4세대 이동통신 기술, 유무선 통합망