

# 결합 연결구조 기반의 동적 개인 지식네트워크 설계

심정연<sup>†</sup>

## 요 약

클라우드와 빅데이터의 새로운 시대에서 필요한 데이터를 방대한 데이터 풀로부터 어떻게 찾아내고 활용하느냐는 매우 중요한 일이다. 이러한 빅데이터의 시대에는 무엇보다도 방대하고도 변화무쌍한 데이터를 잘 처리하고 유용한 정보를 신속하게 획득할 수 있는 진화된 형태의 효율적 지능적 지식시스템 설계를 필요로 한다. 따라서 본 연구에서는 진화된 지능 시스템 연구의 하나로서 구조적으로 재구성될 수 있는 동적 개인적 지식네트워크를 제안하고자 한다. 작은 공간에 큰 세계를 매핑하여 효율적으로 처리할 수 있는 인간 두뇌의 기능과 이 안에서 일어나는 뉴로다이나믹스 메커니즘에 착안하여 구조적 유연성을 갖는 지능 시스템을 설계하였다. 서로 다른 네트워크의 구조적-기능적 결합이 가능하도록 개인 지식네트워크를 구조화하고 핵심 영역에 속하는 공통 노드를 찾아 결합을 하며 재구성하는 기능을 부여하였다. 또한 시스템이 재구성된 지식네트워크로부터 최적 경로를 추출하며 추출된 경로를 가지고 추론 프로세스를 진행하는 기능 갖도록 구상하였다.

**주제어** : 지식의 결합 연결 구조, 개인 지식네트워크, 뉴로 다이나믹스

## Dynamic Personal Knowledge Network Design based on Correlated Connection Structure

JeongYon Shim<sup>†</sup>

### ABSTRACT

In a new era of Cloud and Big data, how to search the useful data from dynamic huge data pool in a right time and right way is most important at the stage where the information is getting more important. Above all, in the era of s Big Data it is required to design the advanced efficient intelligent Knowledge system which can process the dynamic variable big data. Accordingly in this paper we propose Dynamic personal Knowledge Network as one of the advanced Intelligent system approach. Adopting the human brain function and its neuro dynamics, an Intelligent system which has a structural flexibility was designed. For Structure-Function association, a personal Knowledge Network is made to be structured and to have reorganizing function as connecting the common nodes. We also design this system to have a reasoning process in the extracted optimal paths from the Knowledge Network.

**Keywords** : correlated connection structure, personal knowledge network, Neuro dynamics

<sup>†</sup> 정 회 원: 강남대학교(교신저자)

\* 논문접수: 2015년 10월 8일, 심사완료: 2015년 11월 24일, 게재확정: 2015년 11월 25일

## 1. 서론

인간의 두뇌는 수 백만년 동안 인류가 지구상에 존재하면서 살아남기에 적합하도록 진화되어 온 최상의 시스템이다. 방대한 실제세계의 영역을 작은 두뇌의 영역으로 매핑하여 처리할 수 있는 효율적인 시스템일 뿐만 아니라 가상처리능력으로 창조적인 세계를 만들어 낼 수 있는 고도로 지능화된 메커니즘을 가지고 있다. 최근 연구에 따르면 이러한 기능을 위한 뉴로 다이내믹스 기능이 존재하여 영역별 분산기능과 각 기능간의 연관 통합 기능이 함께 이루어지고 있는 것으로 알려져 있다[1]. 이러한 뉴로 다이내믹스는 정보가 폭주하고 있는 빅데이터 시대에서 유용하게 쓰일 수 있는 기능이다.

현재 우리는 인터넷 세계에서 폭주하고 있는 정보 홍수 환경에서 유용하고 필요한 정보를 효율적으로 처리해야 하는 빅데이터 시대를 맞이하고 있다. 복잡하고도 변화가 빠른 방대한 데이터와 많은 자원들 속에서 필요한 정보와 기능을 효율적으로 추출하고 이용할 수 있어야 한다. 특히 스마트폰을 활용한 클라우드 컴퓨팅 환경에서는 스마트폰이 최소의 구조적 플랫폼을 가지고 있으면서 인터넷에 흩어져 있는 데이터와 자원들을 필요할 때마다 연결하여 사용하는 개념을 기본으로 하고 있다. 이는 인간의 두뇌가 방대한 주변 세계의 신호를 필요에 따라 선택하고 적은 영역의 뇌공간에 매핑하여 집중처리하는 메커니즘과 흡사하다. 또한 뉴로다이내믹스 개념은 주어진 구조 안에서 분산과 통합처리를 가능하게 하고 필요에 따른 기능 결합을 가능하게 한다. 이러한 뇌의 작은 공간으로의 매핑과 뉴로다이내믹스 기능은 클라우드 컴퓨팅 환경에서 효율적 지능 시스템을 설계하는데 좋은 해결책을 제시할 수 있다.

따라서 본 논문에서는 뇌의 뉴로다이내믹스 기능을 모방하여 서로 다른 네트워크의 구조적-기능적 결합이 가능한 동적으로 재구성되는 동적 개인 지식네트워크를 설계하고자 한다. 제안된 동적 개인 지식네트워크는 핵심 영역에 속하는 공통 노드를 찾아 결합을 하며 재구성하는 기능을 가지고 있다. 또한 제안 시스템은 재구성된 지식네트워크로부터 최적 경로를 추출하며 추출된 경로를 가지고 추론 프로세스를 진행하게 된다.

## 2. 인식(Cognition)과 뇌 안의 뉴로 다이내믹스 (Neuro dynamics)

일반적으로 인식(Cognition)은 뇌 안에서 일어나는 네트워크 현상이라고 알려져 있다. 단순히 하나의 뉴런이나 시냅스에서 일어나는 것이 아니라 방대한 숫자의 뉴런 요소들이 서로 연결되어 아주 복잡한 패턴을 형성함으로써 이루어진다. 현대 인지 과학 중 가장 영향력 있는 연구로 PDP (Parallel Distributed Processing) 모델은 분산된 네트워크를 거치며 병렬 처리하는 기법을 사용한다. 이 네트워크에서 노드들의 역할은 글자, 단어, 이미지 형태나 모터의 명령어를 나타는 개념적 혹은 인지적 표현의 엔티티이며 이러한 개념적 인지적 형태의 엔티티들이 어떻게 서로 연관되어 있는가에 대한 지식이 노드들 간의 가중치 값으로 부호화된다. 구조적으로 안정된 상태가 될 때까지 학습 알고리즘에 의하여 반복 처리됨으로써 가중치 값의 부호화는 결정된다. PDP는 협력적 처리과정을 보여주는 아주 강력하고 효율적인 모델로 패턴인식과 같은 특정한 분야에서 아주 좋은 계산적 결과를 얻어내고 있다. 그러나 강력한 컴퓨팅 결과에도 불구하고 이 모델의 실질적인 뉴런의 프로세스는 네트워크 구조나 다이내믹스에 있어 한계점을 보이고 있다.

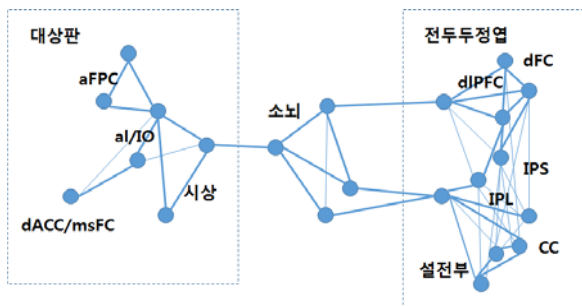
최근 들어 병렬적인 뉴럴 컴퓨팅 방식인 PDP 연구와 더불어 뇌를 구성하고 있는 방대한 범위의 네트워크의 다이내믹스, 계층적 구조와 분산구조 기반의 처리에 대한 관심이 높아지고 있다. 특히 대뇌 피질을 구성하고 있는 계층적 구조와 전두엽에서 일어나는 융합(Integration)에 의한 결정(Decision Making)구조가 관심의 대상이 되고 있다. 또한 이곳에서는 중앙 집중적 처리와 분산처리가 함께 일어나고 있다. 인식의 물리적 기초는 서로 다른 영역의 인식이나 행동기능을 가진 서브 유닛들이 조합된 방대한 인식 뉴럴네트워크의 집합이라고 알려져 있다. 인지 영역에서는 필요에 따라 동적으로 각각의 기능 네트워크들이 서로 연관되어 통합 처리함으로써 특정 인지 영역, 즉 각성, 언어의 이해, 기억과 감정, 얼굴이나 물체 인식 등의 처리를 수행한다. 분산되어 있는

뉴럴 네트워크들을 유연하게 연결하는 협동 체제의 다이내믹스가 특징이다. 뇌 안에 있는 네트워크 노드들의 멀티 기능적 특징은 빠르게 구성요소들을 기능에 맞게 재구성한다는 것이다.

또한 뇌의 구조와 연결 형태는 개인적인 다양성을 가진다. 뇌의 연결 패턴이 인식과 연관되어 있다고 가정하면 이는 뇌의 네트워크의 인식성능은 개인에 따라 다르게 나타남을 의미한다. 이미 임상실험에서 개인적 인식차이는 입증되었다.

햄슨(Hampson)은 두 개의 다른 네트워크의 핵심 영역이 워킹메모리(Working Memory) 안에서 서로 결합됨을 발견하였고 부어맨(Boorman)은 행동 테스트뿐만 아니라 구조적 기능적으로 결합하는 연구에서 구조적 연결, 기능적 연결 관점에서의 개별적 다양성의 결합은 시각운동성 연관성에 기초한 모터동작을 선택하는 작업을 요구한다고 주장하였다. 이는 특정 구조나 기능적 연결에서 개인적 다양성이 다양한 행동을 유발한다는 사실을 뒷받침한다. 구조-기능 결합성은 개인에 따라 다르게 나타나는 인식성능과 연결되어 있다. 인식 동작과 연합 패턴의 개인적 차이는 구조적 요소의 서로 다른 결합에 의한 정신적 프로세스에 기인한다. 구조적 재배선(rewiring), 뉴런구성 특성이나 연결의 변화는 인식 결과의 차이를 가져올 수 있음을 의미한다[1].

다음 <그림 1>은 기능적 연결에 따라 진행되는 작업-제어 네트워크를 보이고 있다. 이 그래프에서는 전체 22개의 뇌 영역들 간의 기능적 결합을 보이고 있다. 기능적 결합을 위해서 구조적으로 영역의 노드가 영역의 노드에 연결된 모습이다.




<그림 1> 기능적으로 연결된 작업-제어 네트워크

### 3. 동적 개인 지식네트워크 설계

#### 3.1 개인지식네트워크의 개념구조

개인 지식네트워크(Personal Knowledge Network) 계층적 분산 통합 구조로 구성되어 있다[2]. 개인 지식 네트워크는 <그림 2>에서 보이고 있는 바와 같이 입출력 계층, PDP 학습계층, 기호적 연결 개념 계층을 가진다. 입출력 계층(I/O layer)에서는 데이터 처리에 필요한 입력데이터와 그의 결과들이 출입한다. PDP 학습계층(PDP Learning layer)은 인식(Perception)을 위한 계층으로 3층의 완전 연결된 Feed forward 네트워크이며 BP(Backpropagation) 알고리즘에 의해 학습되며 학습 후 개념에 대한 인식에 쓰인다. PDP 학습 모듈은 기능적 분산구조를 나타낸다. 최상위 계층은 기호적 개념 추론 계층 (Symbolic Conceptual Reasoning layer)으로 하위계층인 PDP 학습계층과 입출력 계층과 연결되어 기능적으로 분산되어 있는 개념을 관계성에 따라 연결하여 추론하는 통합적 기능을 수행한다. 기호적 개념 계층에서는 연결된 노드를 따라 진행되는 논리적인 추론 과정이 일어난다. 개인 지식네트워크의 전체 구성은 계층 구조와 분산구조가 결합된 기능-구조의 통합적 특징을 보이고 있다.




<그림 2> 개인 지식네트워크의 구조

본 논문에서는 개인 지식네트워크의 구조 중 기호적 개념 계층의 구조와 기능에 초점을 맞추어 서술하고자 한다.

기호적 개념 추론 계층은 개념을 나타내는 지식 노드들이 그들의 연관성에 따라 연결되어 있는 구조를 가지고 있다<그림3>. 이 네트워크의 특징은 개념의 방향성을 나타내는 방향성 그래프

로 표현되어 있다.  $S_i \rightarrow S_j$ 의 방향성 그래프는 'If 원인이나 조건 Then 결과'의 인과관계의 관계성을 나타낸다.



<그림 3> 기호적 개념 추론 네트워크를 구성하는 지식네트워크 구조

이 구조는 추후 다른 네트워크와의 결합과정에 따라 재구성되기도 한다. 기호적 개념 추론 계층의 네트워크 구조는 재구성 프로세스를 통해 어떤 특정 기능을 위해 일시적으로 결합·재구성되기도 하고 재구성 과정에서 구조 자체가 변화하기도 한다.

개인지식네트워크를 구성하고 있는 각각의 지식노드들은 자체 에너지(Self Energy)를 가지고 있고 자체 에너지는 기억의 중요도에 따라 값이 유연하게 조정되어 네트워크 재구성시 구조적 형성에 일정한 역할을 담당한다. 자체에너지 값은 다음 (식1) 과 같이 표현되며 특정한 자극에 의하여 값이 변화된다. 특정한 자극은 중요도의 증가, 잦은 호출 빈도수, 증거 확보에 따른 강화 신호일 수도 있고 중요도의 감소, 낮은 호출빈도수, 상반된 증거확보 등 억제신호의 형태일 수도 있다. 자체 에너지 변화 값은 (식2)로 계산된다.

$$E_{S_i} = P(S_i) \tag{식1}$$

자체에너지  $E_i$ 는 지식  $S_i$ 가 나타날 확률  $P$ 의 값으로 표현된다.

$$E_{i(c)} = f\left(\frac{E_{i(c-1)} + \delta_{i(c-1)}}{2.0}\right) + \theta_{i(c-1)} \tag{식2}$$

$$\delta_{i(c-1)} = f\left(\frac{I_{i(c-1)} + V_{i(c-1)}}{2.0}\right)$$

$$f(x) = \begin{cases} 1.0 & \text{if } f(x) \geq 1.0 \\ x & \text{if } -1.0 \leq f(x) \leq 1.0 \\ -1.0 & \text{if } f(x) \leq -1.0 \end{cases}$$

$E_{i(c)}$ : 변화된 자체에너지 값

$I_{i(c-1)}$ : 전단계 중요도  $-1.0 \leq I_{i(c-1)} \leq 1.0$

$V_{i(c-1)}$ : 전단계 참조빈도수  $-1.0 \leq V_{i(c-1)} \leq 1.0$

$\theta_{i(c-1)}$ : 노드 필터링 게이지  $-1.0 \leq \theta_{i(c-1)} \leq 1.0$

지식노드의 자체에너지는 지식이 나타날 확률 값을 시작점으로 하여 시간이 지날수록 그의 값이 점진적으로 변화, 조정된다. 특히 이 시스템에서는 노드 필터링 게이지 값,  $\theta_{i(c-1)}$ 이 특별히 네트워크 재구성을 위하여 설계되었다.  $\theta_{i(c-1)} \geq 0.0$ 의 값은 강화신호를 의미하는데 지식노드들 사이에 강화신호가 주어지면 관계성 값을 높여 연관성을 강하게 만든다. 반대로  $\theta_{i(c-1)} \leq 0.0$ 인 값은 억제신호로 자체 에너지가 0.0에 수렴할 수 있게 만들어 노드 간 연관성을 약화시킨다. 노드의 자체에너지가 0.0이 되면 연결강도 역시 0.0이 되어 네트워크와의 연결이 단절된다. 이와 같이 노드 간 연결과 단절 효과를 줄 수 있으므로 필터링 게이지 값은 네트워크의 구조를 변화시키는 재구성 과정에서 매우 중요한 역할을 하게 된다.

지식노드와 지식노드는 연관성에 따라 연결되는데 연결 강도를 나타내는 관계성은 다음 (식3)으로 계산한다.

$$R_{ij} = P(j|i) \tag{식3}$$

여기서  $R_{ij}$ :  $i$ 노드와  $j$ 노드사이의 관계성

$P(j|i)$ :  $i$ 노드에서  $j$ 노드로 연결되는 확률을 의미한다.

관계성 값 역시 자체에너지 변화와 마찬가지로 노드 간 관계성 변화에 따라 유연하게 바뀌며 네트워크 재조정이나 지식의 추출과 추론 과정에 중요한 값으로 쓰인다. 관계성 값 계산에도 역시 관계 필터링 게이지 값을 도입한다. 관계성 변화 값은 (식4)에 의하여 계산된다.

$$R_{ij(c)} = R_{ij(c-1)} + \xi_{ij(c-1)} \tag{식4}$$

$\xi_{i(c-1)}$ : 관계 필터링 게이지  $-1.0 \leq \xi_{i(c-1)} \leq 1.0$

### 3.2 연관 기억 행렬 (Associative Memory Matrix)

기호적 개념추론 계층을 이루고 있는 네트워크의 유연한 처리를 위해서는 이를 효율적으로 수행할 수 있는 특정 구조가 필요하다. 이 네트워크를 기초로 수행할 수 있는 주요 기능은 추론패스의 추출, 다른 네트워크와의 기능적 결합과 재구성이다. 본 연구에서는 이러한 목적의 특정 구조로서 연관기억 행렬을 다음과 같이 설계하였다.

<표 1> 연관기억 행렬

*	$S_1$	$S_2$	...	$S_i$	...	$S_n$
$S_1$	$E_{1(c)}$	$R_{12(c)}$	...	$R_{1i(c)}$	...	$R_{1n(c)}$
$S_2$	$R_{21(c)}$	$E_{2(c)}$	...	$R_{2i(c)}$	...	$R_{2n(c)}$
⋮	...	...	...	...	...	...
$S_i$	$R_{i1(c)}$	$R_{i2(c)}$	...	$E_{i(c)}$	...	$R_{i(c)}$
⋮	...	...	...	...	...	...
$S_n$	$R_{n1(c)}$	$R_{n2(c)}$	...	$R_{n(c)}$	...	$E_{n(c)}$

연관기억 행렬 값은 자체 에너지 값,  $E_{ii(c)}$ ,와 관계성 값,  $R_{ij(c)}$ , 로 구성되어 있다. 연관 기억 행렬 값은 상태에 따라 (식2) 와 (식4)의 식에 의해서 변화할 수 있으며 네트워크 재구성에 관여한다.

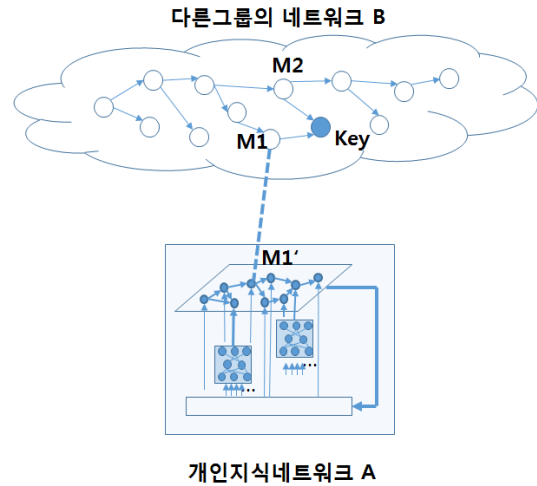
### 3.3 결합 연결에 의한 개인 지식네트워크의 재구성

개인 지식네트워크의 기호적 개념추론 계층을 이루고 있는 네트워크의 구조는 특정한 기능적 결합이 필요할 경우 재구성될 수 있다. 일반적으로 두 네트워크를 결합하여 특정기능을 사용하기 위해서는 특정기능을 가진 노드와 같은 공통 노드가 개인 지식네트워크 내에 있어야한다. 공통 노드를 연결점으로 두 네트워크는 직접 접속이 될 수 있다.

그림4는 특정기능을 가진 노드와 같은 공통 노드가 개인 지식네트워크 내에 없는 경우 두 네트워크사이의 기능적 연결을 위해 결합하는 방법을 나타내고 있는 그림이다.

<문제> 개인지식네트워크 A에서는 다른 그룹의 네트워크 B의 'Key' 노드가 가진 기능을 쓰려고 한다. 그러나 개인 지식네트워크A에는 'Key'노


드와 완전히 일치하는 노드가 없다. 다만 네트워크 B에서 'Key'노드와 연결된 1차 연결점 [M1,M2]의 리스트만 제시된 상황이다.



<그림 4> 결합연결

제시된 문제에 따르면 개인 지식네트워크 A가 네트워크 B에 접속하려고 하나 A네트워크 내 노드 'Key'와 완전히 일치하는 노드가 없어 직접 접속이 어려운 상황이다. 그러나 이 상황에서 제안 시스템은 주어진 1차 연결점 리스트를 이용하여 공통 노드를 찾아가는 기법으로 간접 접속을 시도하여 결합 연결 과정을 수행한다. 노드 'Key' 기능의 중요도가 높을 경우 개인 지식 네트워크 A의 기호적 개념추론계층에 네트워크 재구성이 일어난다. 향후 수월한 접속을 위해 M1-Key노드를 추가한다. M1-Key노드가 추가되면 네트워크가 재구성되어 구조가 바뀔과 동시에 연관기억행렬 요소들도 수정된다. 이 경우 Key 노드에 대해서는 자체에너지 값  $E_{k(c)}$  대신 네트워크 B로의 포인팅을 의미하는 'B'로 마크한다. 네트워크 B로의 접속신호를 만나면 네트워크 B의 Key노드로 접속하여 네트워크 B의 연관 지식 행렬로 점프할 수 있다.

재구성과정은 지식 네트워크를 구성하는 노드를 추가 수정 삭제하여 구조를 변경하는 작업이다. 구조변경은 연관메모리 행렬을 이용하여 구현할 수 있다. 노드가 추가된 경우에는 추가된 만큼 행과 열의 개수를 증가시키고 자체 에너지 값과 관계성 값을 부여한다. 구조 수정은 연관메모리 행렬 값을 변화시킴으로써 구현할 수 있고 삭제



<그림 5> 개인지식네트워크A의 재구성

는 해당 노드의 자체에너지 값과 관계성 값에 0.0을 대입함으로써 삭제효과를 얻을 수 있다.

앞서 언급된 문제제시에서는 Key 기능과 직접 매치되지 않는 경우의 해결점을 제시하고 개인지식네트워크 A의 재구성기법에 대하여 서술하였으나 실제적으로 어떠한 형태로든 연결 결합과정을 통해 B 네트워크에 접속되면 B네트워크에 연결된 노드의 모든 자원을 사용할 수 있다는 장점이 있다. 다만 개인 지식네트워크 A가 네트워크 B에 접속하는 것은 일시적 연결이다. 접속에 의한 일시적 연결의 장점은 개인 지식네트워크에 모든 자원과 거대한 네트워크를 구축할 필요 없이 기본 접속 포인트만 확보하고 있으면서 필요할 때 이 접속 포인트를 가지고 연결하여 다른 네트워크의 자원을 충분히 사용한 후 되돌려주는 것이기 때문에 개인 네트워크에는 최소한의 구조와 디바이스를 가지고 있으면서 외부의 자원을 확보하여 사용할 수 있는 것이다. 제안 시스템에서의 재구성 개념은 이러한 접속 포인트를 확보하는 과정에 초점이 맞추어져 있다. 접속 포인트를 확보하여 재구성하는 이유는 개인네트워크 내에 직접 접속 포인트가 없는 경우 매번 접속할 때마다 수행해야하는 연결 포인트를 찾기 위한 탐색과정을 줄여 효율성을 높이기 위함이다.

### 3.4 최적 추론 경로 추출 알고리즘과 추론

연결 결합 재구성에 의한 구조적 변화는 연관 기억 행렬 구조와 값의 변화 형태로 세팅된다. 시스템은 구조적 변화로 세팅된 연관 기억 행렬로부터 추론을 위한 최적 경로 (Optimal Path)를 추출한다.

추출 원리는 검색 노드를 시작점으로 하여 연결된 노드 중 가장 에너지가 높은 노드를 스위칭하면서 연결해가는 방식이다.

추출방법에는 전 방향으로 전진하는 전방향 (Forward Chaining) 추출과 후방향으로 진행되는 후방향(Backward Chaining) 추출이 있다. 지식네트워크는 방향성 그래프로 표현되기 때문에 논리적 추론을 위해서는 원인-결과를 나타내는 방향이 매우중요하다. 따라서 추론패스를 추출할 때는 전방향 추출과 후방향 추출 모두 고려되어야 한다.

노드를 선택하여 스위칭할 때 전방향 추출에서는 (식5)를 후방향 추출에서는 (식6)을 사용한다.

$$SELECT = \arg \text{MAX}_j (E_{ii(c)} + R_{ij(c)}) \quad (\text{식5})$$

$$SELECT = \arg \text{MAX}_j (-(E_{ii(c)} + R_{ij(c)})) \quad (\text{식6})$$

추론패스를 추출하는 알고리즘은 다음 알고리즘 1과 같다.

최적화된 추론 패스가 얻어지면 이를 기반으로 링크를 따라가면서 추론(reasoning)을 진행하면 된다. 추론과정 중 의사결정(Decision Making)도 가능하다.

알고리즘 1: 추론경로추출알고리즘

연관행렬 Associative Matrix : A[i][j]

노드의 개수 : n

STEP 1: Initialize Associative Matrix A[i][j]

\\* Assign Self Energy E[i] and Relation R[i][j] to A[i][j]

\\* Calculate Self Energy SelfEnergy;

\\* Calculate Relation Value RelationVal;

\\* Initialize A[i][j]

for (i=1; i<=n; i++)

for (j=1; j<=n; j++)

if (i==j)

A[i][j]=E[i];

A[i][j]=R[i][j];



STEP 2 : Extract the optimal related Path

FORWARD\_CHAINING:

```

i=index /*index: index of starting node
print i ;
store i to Queue PATH[];
while(not EOF){
    Max=0.0
    for (j=1;j<=n;j++){
        Tenergy=A[i][i]+R[i][j]
        if ((A[i][j] > 0.0) AND
            ( Max < Tenergy)){
            Max=Tenergy;
            MaxIndex=j }
    }
    print MIndex;
    store MIndex to Queue FPATH[];
    i=MIndex; }
    
```

BACKWARD\_CHAINING:

```

i=index /*index: index of starting node
print i ;
store i to Queue PATH[];
while(not EOF){
    Max=0.0
    for (j=1;j<=n;j++){
        Tenergy=(A[i][i]+R[i][j]) * (-1.0)
        if ((A[i][j] > 0.0) AND
            ( Max < Tenergy)){
            Max=Tenergy;
            MaxIndex=j }
    }
    print MIndex;
    store MIndex to Queue BPATH[];
    i=MIndex; }
    
```

### 4. 실험

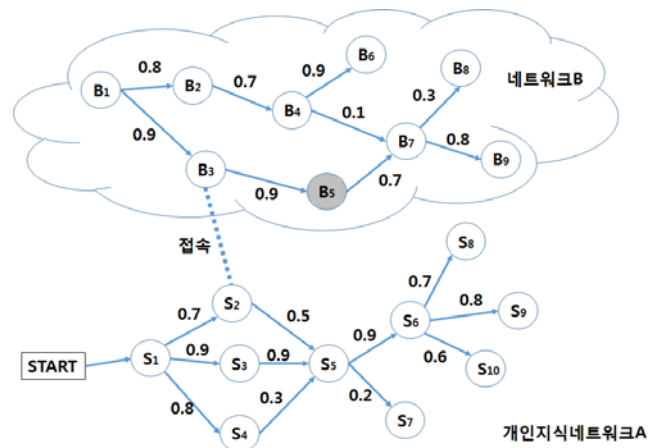
본 실험에서는 <그림6>과 같이 10개의 가상 지식노드로 구성되어 있는 개인지식네트워크 A와 9개의 가상 지식노드로 구성되어 있는 다른 네트워크 B에 대하여 연결 결합에 따른 추론패스 추출에 관점을 맞추어 테스트하였다. <표2>와 <표3>은 각각 네트워크B와 개인지식네트워크A의 자

체 에너지 값과 관계성 값이 표기된 연관기억행렬을 보인 것이다. 다음은 결합연결을 위한 문제와 조건을 제시한 것이다.

[문제: 개인지식네트워크A에서 다른 네트워크B에 접속하여 B5노드의 기능을 사용하려고 한다.

조건 : B5에 직접 연결되어 있지 않고 B5의 1차 연결점 (B5: B3,B7)의 정보만 주어진 상태이다.]

이 문제를 해결하기 위한 1단계 처리는 개인지식네트워크를 구성하고 있는 노드들 중 1차 연결점인 B3, B7과 일치하는 노드가 있는지를 검색한다. 이 경우에는 B3=S2라는 사전정보에 의해서 일치점을 찾았다. 만일 일치점을 찾지 못한 경우에는 일치점을 찾을 때까지 네트워크B에 2차, 3차 연결점을 요청하여 같은 과정을 반복한다.



<그림 6> 개인지식네트워크A와 네트워크B의 구조

<표 2>네트워크B의 연관기억행렬

	B1	B2	B3	B4	B5	B6	B7	B8	B9
B1	1.0	0.8	0.9	0.0	0.0	0.0	0.0	0.0	0.0
B2	-0.8	1.0	0.0	0.7	0.0	0.0	0.0	0.0	0.0
B3	-0.9	0.0	1.0	0.0	0.9	0.0	0.0	0.0	0.0
B4	0.0	-0.7	0.0	1.0	0.0	0.9	0.1	0.0	0.0
B5	0.0	0.0	-0.9	0.0	1.0	0.0	0.7	0.0	0.0
B6	0.0	0.0	0.0	-0.9	0.0	1.0	0.0	0.0	0.0
B7	0.0	0.0	0.0	-0.1	-0.7	0.0	1.0	0.3	0.0
B8	0.0	0.0	0.0	0.0	0.0	0.0	-0.3	1.0	0.0
B9	0.0	0.0	0.0	0.0	0.0	0.0	-0.8	0.0	1.0

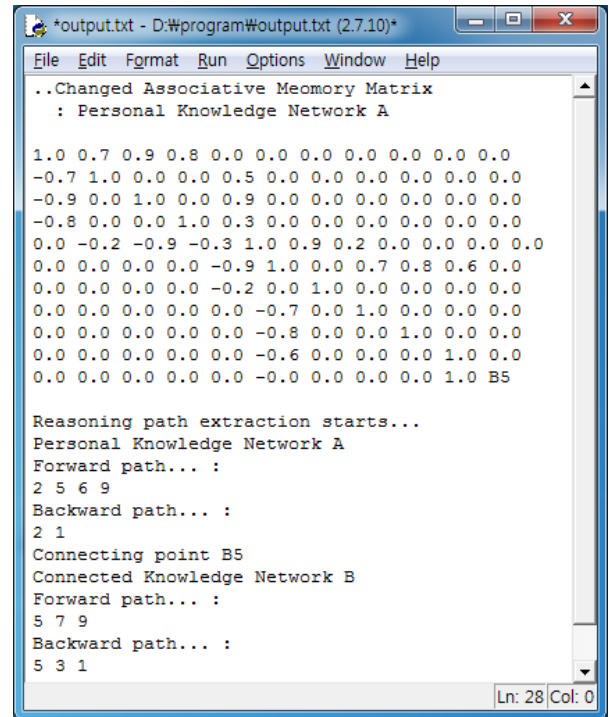
<표 3> 개인지식네트워크A의 연관기억행렬

	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
S1	1.0	0.7	0.9	0.8	0.0	0.0	0.0	0.0	0.0	0.0
S2	-0.7	1.0	0.0	0.0	0.5	0.0	0.0	0.0	0.0	0.0
S3	-0.9	0.0	1.0	0.0	0.9	0.0	0.0	0.0	0.0	0.0
S4	-0.8	0.0	0.0	1.0	0.3	0.0	0.0	0.0	0.0	0.0
S5	0.0	-0.2	-0.9	-0.3	1.0	0.9	0.2	0.0	0.0	0.0
S6	0.0	0.0	0.0	0.0	-0.9	1.0	0.0	0.7	0.8	0.6
S7	0.0	0.0	0.0	0.0	-0.2	0.0	1.0	0.0	0.0	0.0
S8	0.0	0.0	0.0	0.0	0.0	-0.7	0.0	1.0	0.0	0.0
S9	0.0	0.0	0.0	0.0	0.0	-0.8	0.0	0.0	1.0	0.0
S10	0.0	0.0	0.0	0.0	0.0	-0.6	0.0	0.0	0.0	1.0

<그림 7>은 결합연결에 의하여 동적으로 변화된 개인지식네트워크A의 변화된 연관지식 행렬을 보이고 있다. 재구성되면서 11번째 행과 열이 추가되고 A[11][11]에 'B5'가 마크되었음을 확인할 수 있다. 자체에너지 표기란에 마크된 'B5'는 네트워크 B로의 연결포인트를 의미한다. 결합연결시 이 마크 포인트를 따라 네트워크 B로 이동한다. 또한 <그림 7> 하단에 결합 연결기능에 의하여 연결된 네트워크에서 추론 패스를 추출한 결과가 출력되었다. 이 결합구조에서는 공통 노드가 S2==B3이기 때문에 추론패스 추출의 시작 노드는 S2가 된다. S2로부터 시작하여 개인지식네트워크A와 네트워크B에서 전방향 추론 패스와 후방향 추론 패스가 각각 추출되었음을 알 수 있다. 시스템에서는 추출된 추론패스를 바탕으로 추론과 의사결정, 사용자와의 문답과정 기능을 수행할 수 있다.

본 실험의 목적은 주어진 개인지식네트워크에서의 한정된 추론에서 벗어나 다른 네트워크를 연결하여 다른 네트워크의 자원까지 사용하는 범위의 확장에 의미가 있다.

실험 결과 결합연결과 확장된 범위에서 추론패스의 추출이 원활히 이루어짐을 알 수 있었다.



<그림 7> 재구성후 변화된 개인지식 네트워크A의 연관기억 행렬 값과 추론패스 추출결과

## 5. 결론

본 논문에서는 인간 두뇌의 뉴로다이나믹스 개념을 도입하여 구조적으로 재구성될 수 있는 지능 시스템을 제안하였다. 서로 다른 네트워크의 구조적-기능적 결합이 가능한 동적으로 재구성되는 동적 개인 지식네트워크를 설계하였고 핵심 영역에 속하는 공통 노드를 찾아 결합을 하며 재구성하는 기능을 부여하고 재구성된 지식네트워크로부터 최적 경로를 추출하며 추출된 경로를 가지고 추론 프로세스를 진행하도록 하였다. 실험 결과 만족할만한 재구성 정도와 재구성 네트워크로부터 유연한 추출 결과를 산출함을 알 수 있었다. 실제 응용 영역에서 제안 시스템은 클라우드 컴퓨팅환경에서의 지식처리 시스템 플랫폼으로 유용하게 사용될 수 있으리라 기대된다.



## 참 고 문 헌

- [1] Olaf Sporns (2011). *Networks of the Brain*. The MIT Press, Massachusetts.
- [2] J.Y Shim, *Personal Knowledge Network Reconfiguration based on Brain like function using Self Type Matching Strategy, Vol. 5326, Springer, 2008.*
- [3] Michael A. Arbib, Jeffery S. Grethe Young, *Computing the brain : a guide to Neuroinformatics, Academic Press, 2001.*
- [4] John R. Anderson, *Learning and Memory, an intelligent approach, 2nd-ed, Wiley-InterScience, 2006.*
- [5] E. Bruce Goldstein, *Sensation & Perception, BROOKS/Cole, 1999.*
- [6] Ritar Carter, *Mapping the Memory, Ulysses Press, 2006.*
- [7] Charls T. Meadow, Bert R. Boyce, Donald H. Kraft, Carol Barry, *Text Information Retrieval System, 3rd ed. Academic Press, 2007.*
- [8] Thomas M. Cover, Joy Thomas, *Elements of Information Theory, 2nd ed. Wiley Publishing Co, 2000.*
- [9] James W. KALAT, *Biological Psychology, Wadworth Publishing Co. 2009.*



## 심 정 연

1989 고려대학교  
컴퓨터학과(이학사)  
1991 고려대학교  
컴퓨터학과(이학석사)

1998 고려대학교 컴퓨터학과(이학박사)  
1995-2002 용인송담대학교 교수  
2003-현재 강남대학교 교수  
관심분야: 인공지능, 기계학습, 지식공학시스템,  
ICA, 데이터마이닝

E-Mail: mariashim@kangnam.ac.kr