

면역 알고리즘의 개선된 클론선택에 의한 퍼지 뉴로 네트워크와 교통경로선택으로의 응용

Fuzzy-Neural Networks by Means of Advanced Clonal Selection of Immune Algorithm and Its Application to Traffic Route Choice

조재훈* · 김동화* · 오성권**

Jae-Hoon Cho, Dong-Hwa Kim and Sung-Kwun Oh

* 국립 한밭대학교 제어계측공학과

** 원광대학교 전기전자 및 정보공학부

요 약

본 논문에서는 복잡하고 비선형적인 시스템을 위하여 최적 면역 알고리즘의 개선된 클론선택에 기반을 둔 최적FNN 설계 방법을 제안한다. FNN은 퍼지추론의 간략추론과 학습방법으로는 오류역전과 알고리즘을 하였고 멤버쉽함수의 파라미터, 학습률 및 모멘텀 계수들을 선정하기 위하여 개선된 클론 선택을 사용하는 방법을 도입하였다. 제안한 알고리즘은 생체의 면역반응에 기초를 둔 면역알고리즘의 클론선택을 기본으로 분화율을 조절하여 성능을 개선하였다. 그 과정을 통하여 다양한 항체들을 생성하고 목적함수나 제한조건과 같은 항원들에 대하여 가장 높은 친화도를 가지는 항체를 최적 항체로 선택하였다. 제안된 알고리즘의 성능을 평가하기 위하여 가스공정 과 교통경로선택 공정을 사용한다.

Abstract

In this paper, an optimal design method of clonal selection based Fuzzy-Neural Networks (FNN) model for complex and nonlinear systems is presented. The FNNs use the simplified inference as fuzzy inference method and Error Back Propagation Algorithm as learning rule. Also Advanced Clonal Selection (ACS) is proposed to find the parameters such as parameters of membership functions, learning rates and momentum coefficients. The proposed method is based on an Immune Algorithm (IA) using biological Immune System and The performance is improved by control of differentiation rate. Through that procedure, the antibodies are produced variously and the parameter of FNN are optimized by selecting method of antibody with the best affinity against antigens such as object function and limitation condition. To evaluate the performance of the proposed method, we use the time series data for gas furnace and traffic route choice process.

Key words : FNN, 오류역전과, 클론선택, 면역알고리즘, 가스공정, 교통경로선택

1. 서 론

비선형 공정의 복잡성과 불확실성을 제어하기 위해 많은 연구가 계속되고 있으며, 이 중 지능형 모델은 수학적 모델로 해결하지 못했던 문제들과 어려움들을 극복하였고 만족스러운 결과를 가져왔다. 이러한 지능형 모델에는 사람의 자연적인 언어 체계를 표현하는데 효과적인 퍼지모델과 생물학적 신경 계통을 공학에 응용한 신경회로망을 들 수 있다. 퍼지 모델은 1965년 Zadeh에 의해 창안된 "퍼지집합"이론을 이용하여 비선형적이고 복잡한 실 시스템의 특성을 해석하는데 적용함으로써 수학적 모델보다 좋은 결과를 가져왔다. 신경 체계의 구조를 응용한 신경회로망은 단순한 기능을 수행할

수 있는 신경소자들의 병렬연결로 이루어져 있다. 기능면에 있어서도 생물학적 신경망과 마찬가지로 병렬 분산처리를 함으로써 계산처리 능력을 증가시켰고, 학습이나 훈련을 통해 연결강도를 조절하여 정보를 추가하거나 변형할 수 있는 적응 학습능력을 가지고 있다.

최근에는 이러한 퍼지모델과 신경회로망이 가지고 있는 독특한 특성들을 살리면서 지능 모델의 효율과 성능향상을 위해 두 모델의 융합에 관한 연구가 활발히 진행되고 있다. 이는 퍼지추론에 의한 시스템과 신경회로망 시스템이 가지는 장점을 결합함으로써 보다 나은 시스템 성능 특성을 얻기 위한 퍼지-뉴런 융합화 연구로써 양 이론의 유사성과 상호 보완관계를 이용한다. 이들 융합에 관한 연구는 여러 가지 각도에서 다양하게 제시되고 있는데 Takagi, Hayashi[1]등은 신경회로망으로 구동되는 퍼지추론을 제안하였으나 전반부가 신경회로망으로 특성화된 함수로 구성되어 기존의 퍼지추론보다 정성적으로 이해하기가 힘들다는 단점을 가지고 있다. Horikawa[2]는 퍼지-뉴럴네트워크에 의한 합성방법과 동정에 관한 연구를 하였는데, 멤버쉽함수 초기치 선정이 어

접수일자 : 2004년 5월 27일

완료일자 : 2004년 6월 24일

감사의 글 : 본 연구는 산업자원부의 지원에 의하여 기초전력연구원(R-2003-0-285) 주관으로 수행된 과제임

롭고, 최적성능으로의 수렴특성이 나쁘다. Yamakawa[3,4]에 의해 제안된 FNN은 보수적(complementary) 멤버쉽함수를 가지는 퍼지규칙과 오류 역전파 알고리즘을 사용한 신경회로망의 학습을 결합한 형태이다. 이 모델은 다른 구조에 비해 학습속도가 빠르고, 안정성이 높으며, 수렴특성이 매우 우수하다는 장점을 가졌으나, 멤버쉽함수의 퍼지입력 공간 선택 및 파라미터 선택의 어려움이 있고 초기 파라미터의 선택에 따라 성능의 큰 차이를 보이는 단점이 있다. 이런 단점들을 해결하기 위하여 여러 최적화 알고리즘들을 이용한 방법들이 제안되어졌다[5].

본 논문에서는 면역알고리즘의 개선된 클론선택 알고리즘(Advanced Clonal Selection:ACS)을 제안하고 클론 분화율을 조정하여 최적 FNN 구조가 되도록 하였다.

면역 알고리즘은 생체의 면역체계를 모방한 최적화 알고리즘이다. 척추동물의 면역체계는 기본적인 생체방어 기능으로 생체 내에 이물질이 침입한 경우 항원 하나하나를 식별하여 배제하고 기억하는 특성이 있다. 이러한 특성들은 같은 항원의 2차 침입에 대해서 1차 침입 때 보다 빠른 항원 식별 능력과 면역반응을 할 수 있도록 한다. 이런 효과적인 반응들은 면역체계가 기억기능이 있는 메모리 셀(Memory cell)과 클론선택이라는 분화 과정을 가지고 있기 때문에 나타나게 된다. 클론 선택은 분화를 통하여 항체의 수를 항원의 수에 비례되도록 조속히 생성하고 분화율을 조절하여 항체들의 수를 적당히 유지한다. 이 과정을 메모리 셀(Memory cell)의 생성에 적용하고 재선택 과정을 통하여 복잡하고 비선형적인 시스템에 대한 최적FNN의 파라미터 값들을 찾을 수 있도록 한다. 제안된 알고리즘을 가스로공정 및 교통 경로선택공정에 적용하여 성능을 평가하였고 기존 방법에 비해 우수한 모델을 구축할 수 있음을 보인다

2. 퍼지-뉴럴 네트워크 모델

FNN은 그림 1에서 보여지는 것처럼, 각각의 입력변수들에 대해 정의된 퍼지집합을 기반으로 개개의 변수만을 고려한 공간분할에 의해 설계되어진다. 이것은 각 입력변수들에 대해 독립적으로 이루어지며, 분할된 공간을 통해 형성된 퍼지언어 정보로 퍼지규칙을 형성함으로써 구성된다.




그림 1. 입력변수에 대한 퍼지집합 기반 퍼지공간 분할
Fig. 1. Division of fuzzy space for the input variables

간략 퍼지추론에 의해 구현되는 FNN의 구조는 그림 2와 같으며, 다른 모델에 비해 학습속도가 빠르고 수렴특성이 우수하다는 장점을 가진다. 그림에서 '원'은 FNN의 뉴런 유닛을 나타내고, 'N'은 정규화를, 'Σ'은 대수적 합을 의미한다.

x_k 의 각 입력신호는 퍼지집합에 의해 정의된 각 멤버쉽함수를 거쳐 적합도가 구해지고, 정규화된 적합도는 연결 가중

치 w_{ki} 와 곱해지며 이들이 Σ 뉴런에 의해 대수적으로 합쳐져 k 번째 출력 $f_k(x_k)$ 를 생성한다. 생성된 출력 값은 식 (1)과 같이 모두 합쳐져 \hat{y} 를 출력하게 된다.

$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_k(x_k) = \sum_k f_k(x_k) \quad (1)$$

여기서, k 은 입력변수 수이다. 입력 x_k 에 대한 $f_k(x_k)$ 는 퍼지규칙을 이루고 있으며 그 규칙은 식 (2)와 같다.

식 (2)에서 R_i 는 i 번째 퍼지규칙을 나타내며, A_{ki} 는 전반부 멤버쉽함수로 보수적(complementary)인 관계를 가진 삼각형 형태이다.

$$R^1 : \text{If } x_k \text{ is } A_{k1} \text{ then } Cy_{k1} = w_{k1} \quad (2)$$

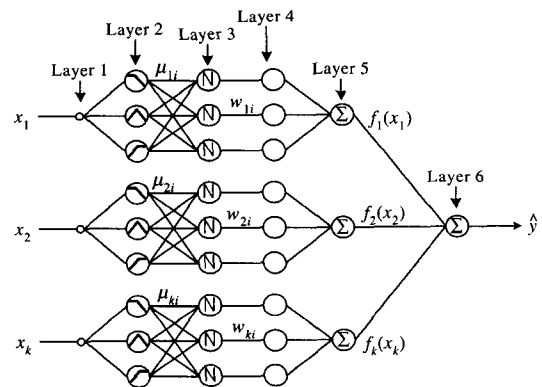


그림 2. 간략 퍼지추론 구조를 가지는 FNN
Fig. 2. Fuzzy-neural network architecture

후반부의 w_{ki} 는 상수이며, 그림 2의 연결 가중치를 나타낸다. 식 (2)의 최종 추론결과는 식 (3)과 같이 표현된다.

$$f_k(x_k) = \sum_{i=1}^n \mu_{ki} \cdot Cy_{ki} = \sum_{i=1}^n \mu_{ki} \cdot w_{ki} \quad (3)$$

여기서 μ_{ki} 는 입력 x_k 에 대한 전반부 적합도이다.

입력변수 x_k 는 보수적인 특성의 멤버쉽함수에 의해 동시에 두 개의 멤버쉽함수에만 영향을 받기 때문에 식 (3)은 식 (4)가 된다. 이러한 구조로부터 FNN은 추론속도가 빠른 특징을 가지게 된다.

$$f_k(x_k) = \mu_{ki} \cdot w_{ki} + \mu_{ki+1} \cdot w_{ki+1} \quad (4)$$

간략 퍼지추론 FNN의 학습은 그림 2에서 멤버쉽함수 뒷부분에 위치한 연결가중치 w_{ki} 를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 신경회로망의 학습에 가장 일반적으로 사용되는 BP 알고리즘이 사용되며, 이는 최종출력과 원 데이터간의 차, 즉 오차를 바탕으로 이루어진다. 모멘텀을 포함하는 연결가중치 변화량 Δw_{ki} 은 식 (5)와 같다.

$$\Delta w_{ki} = 2 \cdot \eta \cdot (y - \hat{y}) \cdot \mu_{ki} + \alpha (w_{ki}(t) - w_{ki}(t-1)) \quad (5)$$

여기서 y 는 주어진 데이터, \hat{y} 는 모델의 출력, η 는 학습율, α 는 모멘텀계수이며 η 와 α 는 0과 1 사이의 값을 갖는다. $w_{ki}(t)$ 는 현재 연결가중치, $w_{ki}(t-1)$ 은 이전 연결가중치이다. [3,4]

[Layer 1] 입력층 : 각 입력신호를 다음 층으로 보낸다.
[Layer 2] 멤버쉽함수에 대한 적합도(활성값) 계산 : 각 뉴런은 입력변수에 대해 정의된 퍼지집합, 즉 각 입력변수의 언어변수(small, large 등)에 대응하며, 1층의 입력신호에 의해 멤버쉽함수(언어변수)의 적합도가 결정된다. 멤버쉽함수는 보수적 관계를 갖는 삼각형 함수를 이용한다.
[Layer 3] 정규화된 적합도 계산 : 2층에서 멤버쉽함수의 적합도가 구해지면, 각 규칙에 대한 정규화된 적합도 $\bar{\mu}_{ki}$ 를 계산한다.

$$\bar{\mu}_{ki} = \frac{\mu_{ki}}{\sum_{i=1}^n \mu_{ki}} \quad (6)$$

여기서 n 은 각 입력에 대한 멤버쉽함수의 수, 즉 퍼지규칙 수이다. 입력변수 x_k 는 앞 절에서 언급했듯이 두 개의 멤버쉽함수에만 영향을 받기 때문에 식 (6)은 식(7)과 같이 다시 쓸 수 있다.

$$\bar{\mu}_{ki} = \frac{\mu_{ki}}{\mu_{ki} + \mu_{ki+1}} = \mu_{ki} \quad (7)$$

즉, $\bar{\mu}_{ki} = \mu_{ki}$ 이다. 이와 같은 특징 때문에 빠른 추론속도의 효과를 얻을 수 있다.

[Layer 4] 연결 가중치와의 곱 : 3층에서 구해진 적합도는 연결가중치에 의한 후반부 출력과 곱해져 각 규칙의 출력을 생성하고 다음 층의 입력이 된다.

$$a_{ki} = \bar{\mu}_{ki} \times Cy_{ki} = \mu_{ki} \times Cy_{ki} = \mu_{ki} \times w_{ki} \quad (8)$$

[Layer 5] 각 입력의 퍼지규칙에 대한 퍼지추론 : FNN의 5층에서 각 뉴런 출력은 무게중심법(무게평균법)에 의한 퍼지추론에 의해 구해지며 식 (9)과 같다.

$$\begin{aligned} f_k(x_k) &= \sum_{i=1}^n a_{ki} = \sum_{i=1}^n \bar{\mu}_{ki} \cdot Cy_{ki} \\ &= \sum_{i=1}^n \frac{\mu_{ki} \cdot Cy_{ki}}{\sum_{i=1}^n \mu_{ki}} = \sum_{i=1}^n \mu_{ki} \cdot Cy_{ki} \end{aligned} \quad (9)$$

식 (9)은 보수적인 멤버쉽함수의 연산특징에 의해 식(10)과 같이 정리된다.

$$\begin{aligned} f_k(x_k) &= \frac{\mu_{ki} \cdot Cy_{ki} + \mu_{ki+1} \cdot Cy_{ki+1}}{\mu_{ki} + \mu_{ki+1}} \\ &= \mu_{ki} \cdot Cy_{ki} + \mu_{ki+1} \cdot Cy_{ki+1} = a_{ki} + a_{ki+1} \end{aligned} \quad (10)$$

[Layer 6] FNN의 출력 : 5층에서 출력된 값들은 식 (11)과 같이 모두 대수적으로 합해져 FNN의 출력 \hat{y} 를 최종적으로 계산하게 된다. FNN의 6층에서 계산된 최종출력은 원 출력과의 오차를 구하고, 구하여진 오차를 역방향으로 전달시켜 식 (5)에 의해 연결가중치를 학습을 통해 조절한다.

$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_k(x_k) = \sum_k f_k(x_k) \quad (11)$$

3. 면역알고리즘

생체 면역계는 생체 내부로 침투한 외부 물질(바이러스, 기생균, 박테리아 등)을 제거하여 생체의 방어 및 유지를 수

행하는 시스템이다. 이러한 방어 기능을 효율적으로 수행하기 위하여 면역 체계는 자기 자신의 세포와 외부의 세포를 구별하기 위한 패턴 인식(Pattern Recognition)

작업을 수행하며, 이 과정을 통해 항원을 인식하여 배제하고 한번 배제한 항원에 대해서는 그 항원을 기억하여 같은 항원의 2차 침입에 대하여 항체를 조속히 생성하는 기억 학습 능력을 갖고 있다. 면역 알고리즘은 다른 일반적인 최적화 알고리즘들과 비교하여 다음과 같은 특징을 갖는다.

- 1) 면역 알고리즘은 하나의 가능해를 가지고 최적화 과정을 수행하는 것이 아니라, 동시에 여러 개의 가능해로써 최적화를 진행하는 병렬 분산 처리를 한다.
- 2) 면역 알고리즘은 해의 값 자체를 그대로 사용하는 것이 아니라, 코드화(Encoding)된 수의 배열을 사용한다.
- 3) 기억 학습 기구와 다양성이 있는 항체의 유지 기구로 인해 과거에 배제한 항원에 대응하는 항체를 재빨리 생성하기 때문에 시스템의 초기 상태와 비교해서 최적해가 고속으로 구해진다.
- 4) 실제 면역계의 다양성을 구현하기 위한 진화도 계산 과정이 있다.
- 5) 항원에 대한 '기대치'의 계산에 의해 면역계의 자기 조절 기능을 수행한다.

3.1 생체 면역계 요소

생체 면역계에는 복잡한 면역 반응을 구현하는 많은 면역 세포들이 유기적으로 결합하여 하나의 시스템을 형성하고 있다. 이렇게 복잡하게 형성된 면역계를 구성하는 기본 면역세포는 각각 B세포와 T세포이다. B세포는 항원을 죽이는 항체를 생산, 분비하는 체액성 반응(Humora Response)을 하며, T세포는 면역에 관련된 세포를 자극 또는 억제하거나 항원에 의해 감염된 자기세포를 죽이는 세포성 반응(Cell-mediated Response)을 주로 담당한다. 그 밖의 다른 면역 세포들도 직간접적으로 면역반응에 영향을 준다. 다음은 면역반응에 관여하는 요소들이다.

- (1) 항원 : 항원 혹은 면역원(Immunogen)은 단백질, 핵산, 탄수화물 등이며 생체에 침입하여 세포나 장기에 피해를 주어 병을 형성한다.
- (2) 항체 : 항체 혹은 면역글로블린(Immunoglobulin)이라 불리는 물질은 B세포에서 생산되는 특수한 단백질로서 외부에서 들어온 항원으로 인식되는 이물질에 대한 반응으로 생성된다.
- (3) T세포 : 특성방어에서 중요한 역할을 수행하는 면역 세포로서 다른 면역세포의 자극 및 억제와 감염된 자기세포의 제거 등 세포성 반응을 주로 한다.
- (4) B세포 : 특성방어에서 T세포와 더불어 중요한 역할을 수행하는 면역 세포이다. 보조 T세포로부터 전달받은 항원의 특성에 맞는 항체를 생산하는 역할을 한다.

3.2 클론선택(clonal selection)

클론선택이론은 생체 면역계에서 항원자극에 적합한 면역 반응들을 설명하기 위한 이론이다. 클론선택은 T세포와 B세포에서 모두 작용한다. 그러나 T세포에서는 돌연변이의 영향을 받지 않고 B세포에서는 돌연변이의 영향을 받는 차이점을 가지고 있어 면역반응에서 세포성반응을 하는 T세포와 항체를 생산하는 B세포의 항원에 대한 적응 성능에 영향을 미친다. B세포가 인식된 항원에 대하여 클론들을 재생산하는 동안에 더 우수한 진화도를 가질 수 있도록 돌연변이 과정을 거쳐게 되고 이것은 클론들이 항원에 대하여 더 좋은 면역반

응을 보일 수 있게 한다. 높은 친화도를 갖는 활성화된 B 세포는 항원에 대하여 면역반응을 하고 같은 항원에 2차 침입을 위해 오랜 생존 기간을 갖는 메모리 세포로 남게 된다. 이 메모리 세포는 같은 항원 패턴, 또는 유사한 항원의 2차 침입에 대하여 빠른 응답을 할 수 있어 1차 반응보다 더 우수한 면역 반응을 보일 수 있다. 이러한 반응들을 할 때 항체들은 클론 선택의 분화율에 따라서 그 수들을 조절하여 필요이상의 항체들이 생성되는 것을 억제한다.




그림 3. 클론 선택 이론.
Fig. 3. The Clonal Selection Principle

그림 3에서는 클론선택의 확장(증식)과 분열과정을 나타내었다. 여러 항체들 중 A항체가 항원에 대한 최적항체로 선택되면 1단계에서 클론 분화를 시작한다. 분화된 클론들의 일부는 항원에 대하여 반응을 시작하고 일부는 메모리 셀 M으로 된다. 메모리 셀 M은 같은 항체의 2차 침입에 대하여 1단계와 2단계를 거쳐 2차 침입 항원에 대하여 면역반응을 한다.

3.3 개선된 클론선택

본 논문에서는 메모리 셀에 저장된 항체들 중 우수한 항체들에 대하여 클론선택을 하고 전체 메모리 셀에 대해서 일반적인 돌연변이와 교배를 적용하고 성능을 평가하여 친화도가 높은 순으로 메모리 셀에 재선택하는 방법을 제안한다. 제안된 방법은 다양한 항체생성을 가능하게 하고 친화도가 우수한 항체들을 클론선택과 일반적 유전연산자에서 동시에 사용함으로써 최적친화도를 가지는 항체 생성의 확률을 증가시켰다. 클론선택을 위해 선택된 우수한 항체들은 정해진 분화율에 따라 클론 항체들을 생성 한다. 생성된 항체들은 항원에 대하여 더 좋은 반응을 위해 돌연변이를 일으키게 된다. 돌연변이를 일으킨 후 생성된 항체들의 친화도를 계산하여 우수한 항체를 재선택하게 되고 일반적인 유전연산자에서 생성된 항체와 비교하여 친화도가 높은 항체들만을 다시 메모리 셀에 저장하게 된다.

제안한 ACS알고리즘의 과정과 순서도는 다음과 같다.

[step1] 항원의 정의 및 인식한다. FNN의 목적함수 및 제한 조건을 정의한다. 목적함수는 근사화 및 일반화 성능을 동시에 만족할 수 있도록 Oh[9]가 제안한 목적함수에서 θ 를 0.5로 선정하였다.

$$f(PI, E_PI) = \theta \times PI + (1 - \theta) \times E_PI \quad (12)$$

위 식에서 PI는 근사화 능력에 대한 성능지수이고 E_PI는 일반화 능력에 대한 성능지수이다.

[step2] 초기 항체를 생성한다. 멤버쉽함수의 초기 파라미터, 학습률, 모멘텀을 포함하는 항체를 생성한다. 그림 4는 항원에 대한 항체의 구조를 보여준다.




그림 4. 항체의 구조.
Fig. 4. Structure of Antibody

[step3] 초기항체의 목적함수 값들을 계산하여 친화도를 계산한다. 정의된 FNN의 목적함수와 초기항체로 선정된 파라미터를 이용하여 각각의 친화도를 계산한다.(여러 값들을 계산한다)

[step4] 계산된 적합도가 우수한 항체 순으로 정렬하고 메모리 셀에 저장한다.

[substep1] 메모리 셀에서 정의된 클론 수만큼을 분화한다. 메모리 셀에서 FNN의 성능이 가장 우수한 항체를 클론분화율에 따라 클론들을 생산한다. 클론 분화율을 조정하여 항체생산에서의 다양성과 우수한 항체들을 얻을 수 있다.

[substep2] 돌연변이를 일으킨다. 분화된 클론들에 대하여 FNN의 성능 개선을 위하여 돌연변이를 일으킨다.

[step5] Rulet wheel 방법을 이용하여 Memorycell로부터 우수한 항체를 선택한다.

[step6] 교배를 일으킨다.

[step7] 돌연변이를 일으킨다.

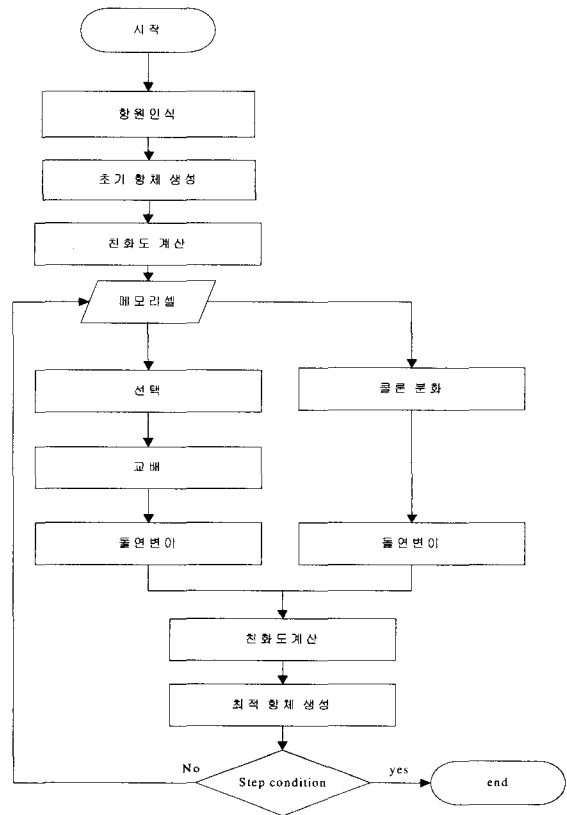


그림 5. Advanced Clonal Selection 의 순서도
Fig. 5. Flow Chat of Advanced Clonal Selection

[step8] 새롭게 형성된 항체들에 대하여 목적함수 값을 계산하여 친화도 계산 후 메모리 셀에 저장한다. 재생산된 항체들에 대하여 각각의 친화도를 계산하고 친화도가 좋은 순서로 메모리 셀에 저장된다.

[step9] Stop Condition에 만족을 하면 전체 계산과정을 종료하며, 그렇지 못하면 4단계로 가서 반복 수행을 한다.

4. 실험 및 결과 고찰

본 논문에서는 모델의 성능을 확인하기 위하여 2종류의 데이터를 이용해 시뮬레이션을 행한다. 첫 번째는, 많은 연구자들에 의해 모델의 성능을 판단하기 위해 사용되는 가스공정 데이터이고, 두 번째는 교통 경로선택 공정을 이용한다. 이들 데이터는 입력과 출력의 관계를 나타내는 다수의 집합으로 나타내어진다. 모델의 우수성을 평가하기 위한 성능평가 지수(Performance Index; PI)는 가스공정에 대해 식 (13)을, 교통 경로선택에 대해서는 식 (14)를 사용하여 계산한다.

$$PI = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (13)$$

$$PI = \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

여기에서, \hat{y} 는 실 모델의 출력, y_i 는 주어진 출력 데이터, n 은 데이터 개수를 나타낸다.

4.1 가스공정

제안된 FNN모델링을 Box와 Jenkins[7]가 사용한 가스공정 시계열 데이터를 이용하여, 입출력 데이터인 가스 흐름율과 연소된 이산화탄소 농도의 가스공정을 모델링한다. 입력이 가스 흐름율이고 출력이 이산화탄소 농도인 1입력 1출력의 가스공정 시계열 입출력 데이터 296쌍을 시뮬레이션을 위해 입력으로 $u(t-3)$ 과 $y(t-1)$ 을, 출력으로 $y(t)$ 를 사용하는 2입력 1출력으로 설정하여 사용한다[10,11].

그림 6는 가스공정 입력데이터의 최대 최소값에 의한 멤버쉽함수를 정의하였고 또한 ACS 알고리즘에 의한 멤버쉽함수 정의를 상호 비교하였다. 가스공정 데이터는 입출력 데이터의 분포가 균일하여 비선형성이 상대적으로 약한편이기 때문에, 성능지수가 우수하게 나타난다. 표1은 가스공정을 동정하기 위하여 ACS(Advanced Clonal Selection)에서 이용한 각각의 파라미터들이다.





그림 6. ACS를 이용한 가스공정의 멤버쉽함수 정의.
Fig. 6. The definition of membership functions of gas furnace process by ACS

표 1. ACS의 초기 파라미터
Table 1. Initial Parameter of ACS

Parameter	Value
Antibody Number	60
Memory cell size	30
Crossover	0.75
Mutation	0.065
Differentiation	0.2~0.5

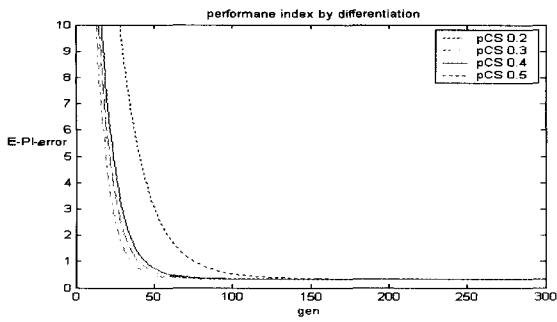
표 2. 분화율에 따른 Advanced clonal selection의 성능
Table 2. Performance of Advanced clonal selection by pCS

pCS	PI	E_PI	MF
0.2	0.0354	0.2857	4
	0.0354	0.2857	6
0.3	0.0408	0.2729	4
	0.0356	0.2855	6
0.4	0.0409	0.2726	4
	0.0359	0.2852	6
0.5	0.0409	0.2726	4
	0.0359	0.2852	6

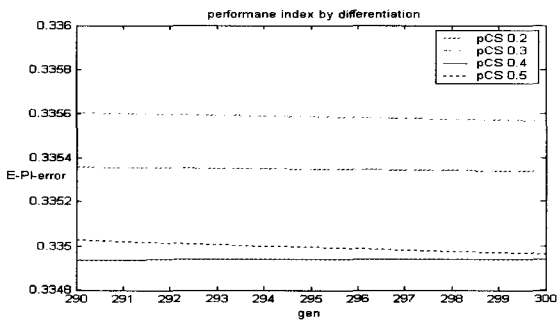
표2에서 PI와 E_PI는 각각 학습데이터와 테스트 데이터에 대한 성능지수이다. pCS는 클론선택의 분화율 나타내고 있다. 멤버쉽 함수의 개수에 대하여 각각 다른 분화율을 적용하고 그에 따른 성능들을 나타내었다.

그림7은 Clone의 분화율에 따른 FNN모델 성능을 나타낸 것으로 분화율이 높아질수록 계산 시간은 길어지지만 최적값을 찾는 성능은 더 우수함을 알 수 있다. 다시 말해 근사화 능력에 있어서는 분화율이 높을수록 최적해를 찾는 성능이 우수하다.

그림8-11까지는 각각의 입력변수에 대해서 2개의 멤버쉽 함수를 가지는 FNN모델에 대하여 분화율 변화에 따른 적합도, 목적함수, 멤버쉽함수들의 최대 최소 정점, 학습률, 모멘텀 계수들의 최적화 과정을 보였다.




(a) 전체 세대에 대한 성능지수




(b) 확장 부분

그림 7. 분화율에 따른 테스트 데이터에 대한 성능지수 변화
Fig.7. Performance index for the testing dataset by differentiation rate




(a) X1에 대한 멤버십 함수값의 최적화 과정




(b) X2에 대한 멤버십 함수값의 최적화 과정

그림9. ACS를 이용한 FNN모델의 최적 파라미터 탐색과정(멤버십함수 개수=[2,2],분화율=0.3)
Fig. 9. Search process of optimal parameters for FNN model by ACS




(a) X1에 대한 멤버십 함수값의 최적화 과정




(b) X2에 대한 멤버십 함수값의 최적화 과정

그림 8. ACS를 이용한 FNN모델의 최적 파라미터 탐색과정(멤버십함수 개수=[2,2],분화율=0.2)
Fig. 8. Search process of optimal parameters for FNN model by ACS




a) X1에 대한 멤버십 함수값의 최적화 과정




b) X2에 대한 멤버십 함수값의 최적화 과정

그림10. ACS를 이용한 FNN모델의 최적 파라미터 탐색과정(멤버십함수 개수=[2,2],분화율=0.4)
Fig. 10. Search process of optimal parameters for FNN model by ACS

표 3에서는 제안된 방법과 다른 방법들에 대한 성능을 비교하였다. 제안된 알고리즘의 성능이 PI 성능지수에 대하여 다른 알고리즘에 비해 좋지 못한 성능을 보이고 있으나 E_PI 성능지수와 합산 오차에서 해석해 보면 만족할만한 결과를 보이고 있다.



a) X1에 대한 멤버십 함수값의 최적화 과정



b) X2에 대한 멤버십 함수값의 최적화 과정
 그림 11. ACS를 이용한 FNN모델의 최적 파라미터 탐색과정 (멤버십함수 개수=[2,2],분화율=0.5)

Fig. 11. Search process of optimal parameters for FNN model by ACS

표 3. 다른 모델링의 방법의 성능
 Table 3. Performance of other modeling methods

Type		PI	E_PI	Total No. Of MF
Fuzzy model (Complex)[1]	Simplified	0.024	0.328	4
	Linear	0.022	0.326	4
Fuzzy model (HCM-GA) [12]	Simplified	0.035	0.289	4
	Linear	0.022	0.333	6
FNN (GA)[5]		0.027	0.298	4
		0.026	0.304	6
FNN (HCM+GA)[5]		0.027	0.294	4
		0.032	0.304	6
Proposed method		0.0409	0.2726	4
		0.0359	0.2852	6

4.2 교통 경로선택

도로망에 대한 교통량배분은 종래부터 교통계획 및 공학에 있어서 실무자 및 연구자의 관심을 불러일으키고 있는 분야중의 하나이다. 이에 대한 연구는 1950년대부터 산업경제의 발전에 따른 미국, 유럽, 일본 등 선진국을 중심으로 사람 및물동량 수송을 위해 수많은 고속도로가 계획 설계되게 되어, 경쟁관계에 있는 도로간 즉 2개 경로 또는 다수 경로간에 어떻게 적절하게 교통량을 배분하여 원활한 수송시스템을 구축할 것인가가 교통계획에 있어 큰 문제로 대두되어 일반도로에서 고속도로로, 또는 고속도로에서 일반도로로의 교통 전환 모델에 대한 연구가 진행되게 되었다. 이것에 대한 기본 개념은 전부 아니면 전무(all or nothing)법이 이용되고 있는데 이것은 임의의 기종점(OD) 교통량은 가장 짧은 경로로 흐른다는 것을 배경으로 하고 있다 [10]. 그림 12은 본 논문에서 실행대상으로 한 경쟁관계에 있는 2개의 경로를 나타낸 것이다. 경로선택의 모델화는 교통수단 및 교통로의 상이, 그리고 경쟁 경로수 등에 의해 다양하게 전개되어지지만 논문에서는 목적함수의 주요요소로 시간비용과 교통비용만을 생각한다. 성능지수는 식 (14)에 의해 정의된다.

그림 13은 교통경로선택 문제에서 FNN의 각 파라미터들의 최적화 되는 과정을 보였다. 표4는 다른 모델링 방법들과 제안된 알고리즘들의 성능을 비교하였다.







그림 12. 경로선택의 간단한 예
 Fig. 12. Simple example of Route Choice



(a) X1에 대한 멤버십 함수값의 최적화 과정



(b) X2에 대한 멤버십 함수값의 최적화 과정



(c) 학습율과 모멘텀계수의 최적화 과정

그림 13. ACS를 이용한 FNN모델의 최적 파라미터 탐색과정(멤버쉽함수 개수=[2,2],분화율=0.2)

Fig. 13. Search process of optimal parameters for FNN model by ACS.(mem=[2,2],pCS=0.2)

교통경로 선택 문제는 2개의 경로 중 능률적인 1개의 경로를 설정하는 문제이므로 제안된 알고리즘 결과에서의 PI 와 E_PI의 값들은 멤버쉽 함수의 총 수가 4개일 때 모든 입력에 대한 잘못된 경로선택이 한 번씩 있었음을 나타내고 있다.

표 4. 다른 모델링의 방법의 성능
Table. 4. Performance of other modeling methods

Type		PI	E_PI	Total No. Of MF
Fuzzy model (Complex)[1]	Simplified	1.397	1.246	4
		1.444	1.596	6
	Linear	2.073	2.281	4
		0.001	1.273	6
FNN (GA)[5]		1.001	1.002	4
		-1.005	1.007	6
FNN (HCM+GA)[5]		1.000	1.001	4
		0.858	1.001	6
Proposed method		1.000	1.000	4

5. 결 론

본 논문에서는 여러 가지 비선형 특징을 갖는 시스템의 학습에 유효한 퍼지추론과 신경망이 결합된 퍼지-뉴럴 네트워크(FNN)의 파라미터를 클론선택에 의한 최적 튜닝할 수 있는 방법을 제안하였다.

퍼지-뉴럴 네트워크는 멤버쉽함수의 퍼지입력 공간 선택 및 파라미터 선택의 어려움이 있고 초기 파라미터의선택에 따라 성능의 큰 차이를 보이는 단점이 있다.

이러한 단점들을 극복하기 위해서 본 논문에서는 면역알고리즘에서의 개선된 클론선택을 제안하였다. 즉, 면역알고리즘은 생체의 면역계통의 반응들을 기반으로 하는 최적화 알고리즘이고 클론선택은 면역알고리즘에서의 우수한 항체들을 빠른 시간에 생성하여 항원에 대하여 효과적인 대응을 할 수 있도록 하는 반응을 말한다. 면역알고리즘과 클론선택을 이용하여 메모리셀에 저장된 우수한 항체에 대하여 분화율을 조정하고 목적함수의 해범위에 대하여 더 융통성 있는 성능을 가지도록 유도하였다. 클론선택을 하는 동안 돌연변이를 이용하여 다양한 해를 생성할 수 있도록 하였고, 목적

함수는 FNN의 근사화 성능과 일반화 성능의 양쪽 모두를 같은 비율로 반영함으로써 두 가지 성능에 대한 최적FNN의 구조를 구축하였다.

제안된 알고리즘의 성능을 평가하기 위한 가스로 공정 과 교통경로 선택 실험에서 클론선택의 분화율이 증가하면서 FNN의 성능이 더 좋아짐을 알 수 있었고 FNN의 근사화 성능과 일반화 성능을 동시에 만족할 수 있는 방향을 제시하였다.

참 고 문 헌

- [1] H. Takagi and I. Hayashi, "NN-driven fuzzy reasoning," Int J. of Approximate Reasoning, vol.5, no. 3, pp. 191-212, 1991.
- [2] S. I. Horikawa, T. Furuhashi, and Y. Uchigawa, "On fuzzy neural networks with the back propagation algorithm," IEEE trans. Neural Networks, vol. 3, no. 5, pp. 801-806, 1992.
- [3] T. Yamakawa, "A neo fuzzy neuron and its applications to system identification and prediction of the system behavior," Proceedings of the 2nd International Conf. on Fuzzy logic & Neural Networks. pp. 477-483, 1992.
- [4] T. Yamakawa, "A new effective learning algorithm for a neo fuzzy neuron model," 5th IFS World Conf. pp. 1017-1020,1993.
- [5] 오성권, 윤기찬, 김현기, "유전자 알고리즘과 합성 성능지수에 의한 최적 퍼지-뉴럴 네트워크 구조의 설계," Journal of Control, Automation and Systems Engineering, Vol.6, No. 3, pp 273-283, 2000.
- [6] Zbigniew Michalewicz, Genetic Algorithms + Data Structure = Evolution Programs, Springer-Verlag.
- [7] Box and Jenkins. Time series Analysis, Forecasting and Control, Holden Day, SanFrancisco, CA.
- [8] 오성권, 우광방, "퍼지추론 방법에 의한 퍼지동정과 하수처리공정시스템 응용," 대한전자공학회 논문집 제31권 B편 제6호, pp. 43-52, 1994.
- [9] 오성권, 노석범, 남궁문, "퍼지-뉴럴 네트워크 구조에 의한 비선형 공정시스템의 지능형 모델링," 한국퍼지 및 지능시스템학회 논문집 제5권 제4호. pp. 41-56, 1995.
- [10] S. K. Oh and W. Pedrycz, "Identification of fuzzy systems by means of an auto-tuning algorithm and its application to nonlinear systems," Fuzzy sets and Syst., 1999(To appear).
- [11] 박병준, 오성권, 안태천, 김현기, "유전자 알고리즘과 하중값을 이용한 퍼지 시스템의 최적화," 대한전기학회 논문집 제48권 A편 제6호, pp. 789-799, 1999.
- [12] 오성권, "C 프로그래밍에 의한 퍼지모델 및 제어시스템", 내하 출판사, 2002.
- [13] L. N. castro, and F. J. Zuben, "TheClonal Selection Algorithm with Engineering Applications.", Proceedings of The 2000 Genetic and Evolutionary Computation Conference(GECCO.2000) Workshop Program, pp. 36-37, 2000
- [14] Dong Hwa Kim, "Intelligent Tuning of the 2-DOF PID Controller On the DCS for Steam Temperature Control of Thermal Power Plant,"

IEEE Industrial Application Society. I&CPS 2002, May 5 - 8, 2002, Savannah, GA, USA.

[15] 오성권, "C 프로그래밍에 의한 컴퓨터지능(퍼지, 신경회로망, 진화알고리즘을 중심으로)", 내하 출판사, 2002.

저 자 소 개




조재훈(Jae Hoon Cho)

2002년 : 국립한밭대학교 제어계측공학과 졸업.
2004년 : 동 대학원 석사 졸업.

관심분야 : 지능형 알고리즘, 번역 알고리즘, 유전알고리즘.

Phone : 042-821-1712
Fax : 042-821-1713
E-mail : jhcho@hanbat.ac.kr



김동화(Dong-Hwa Kim)

1991년 : 아주대 전자공학과졸(공학박)
1976~1993 : 한국원자력 연구소
1993~현재 : 국립한밭대학교 제어계측공학과 교수
1985~1985 : 캐나다 원자력 연구소 초빙 연구원(computer aided multivariable control system design)

1998.8~11 : 미국 ANL (Algonne National Laboratory)에서 nuclear electronic Senior visiting engineer
2000~2001 : 캐나다 University of Albertaqkdans 연구

관심분야 : 번역알고리즘, 유전자 알고리즘, 지능제어 등.
Phone : 042-821-1170
Fax : 042-821-1164
E-mail : kimdh@hanbat.ac.kr



오성권(Sung-Kwun Oh)

1981년 : 연세대 전기공학과 졸업.
1983년 : 동 대학원 졸업(공학석).
1993년 : 동 대학원 졸업(공학박)
1993년~현재 : 원광대 전기전자및정보공학부 부교수
2002년~현재 : 대한전기학회 및 제어자동화시스템공학회 편집위원

관심분야 : CI, 뉴로퍼지컴퓨팅, 퍼지이론, 하이브리드 시스템, 유전알고리즘, 지능형 모델링 및 제어 등.

Phone : 063-850-6342
Fax : 063-853-2196
E-mail : ohsk@wonkwang.ac.kr