

선형 퍼지추론을 이용한 뉴로퍼지 네트워크의 설계와 소프트웨어 공학으로의 응용

박병준, 박호성, 오성권
원광대학교 전기전자 및 정보 공학부

Design of Neurofuzzy Networks by Means of Linear Fuzzy Inference and Its Application to Software Engineering

Byoung-Jun Park, Ho-Sung Park and Sung-Kwun Oh
School of Electrical Electronic and Information Engineering, Wonkwang University.

Abstract - In this paper, we design neurofuzzy networks architecture by means of linear fuzzy inference. The proposed neurofuzzy networks are equivalent to linear fuzzy rules, and the structure of these networks is composed of two main substructures, namely premise part and consequence part. The premise part of neurofuzzy networks use fuzzy space partitioning in terms of all variables for considering correlation between input variables. The consequence part is networks constituted as first-order linear form. The consequence part of neurofuzzy networks in general structure(for instance ANFIS networks) consists of nodes with a function that is a linear combination of input variables. But that of the proposed neurofuzzy networks consists of not nodes but networks that are constructed by connection weight and itself correspond to a linear combination of input variables functionally. The connection weights in consequence part are learned by back-propagation algorithm. For the evaluation of proposed neurofuzzy networks, The experimental results include a well-known NASA dataset concerning software cost estimation.

Imasaki[3]는 퍼지규칙이 전반부 네트워크, 추론 네트워크, 후반부 네트워크로 구조화된 신경회로망을 제안하였으며, 이는 추론 네트워크의 추가로 인한 오랜 학습 시간과 동조의 난점을 가지고 있다. 또한 입출력 증가에 따른 네트워크 구성시 경험적인 방법을 많이 요구한다. Nomura[4]는 델타규칙에 의한 퍼지 추론의 자동 동조 방법을 제안하였다. 그러나 이것은 학습에 의한 동조로 각 규칙마다 멤버십함수가 변형됨에 따라 퍼지규칙 수가 증가하며, 입출력의 증가는 더 많은 퍼지규칙 수를 요구한다. 최근의 경향은 퍼지 모델링, 뉴로 컴퓨팅, 유전자 알고리즘을 포함하는 CI(computational intelligence) 기술을 이용하는 것이다.

본 논문에서는 퍼지추론 방법 중 선형추론 방법을 이용한 뉴로퍼지 네트워크를 설계하며 이 구조는 유전자 알고리즘에 의해 최적화된다. 제안된 뉴로퍼지 네트워크 구조는 퍼지규칙과 유사한 형태를 가지며 전반부와 후반부로 나뉘어 설계된다. 뉴로퍼지 네트워크의 전반부는 입력변수들 간의 상호관계를 고려하여 공간을 분할한 퍼지공간을 이용하며, 후반부는 1차 선형식의 형태를 가지는 네트워크 구조이다. 일반적인 뉴로퍼지 네트워크의 경우(예를 들어 ANFIS[7]의 경우) 후반부 구조는 1차 선형식으로 표현된 함수형태의 노드로 구성되지만 제안된 뉴로퍼지 네트워크의 후반부 구조는 네트워크 자체가 선형식을 형성하며 연결가중치는 오류역전과 알고리즘에 의해 학습된다. 제안된 뉴로퍼지 네트워크의 성능평가를 위해 소프트웨어 비용 추정과 관련된 NASA 데이터 집합을 이용한다.

1. 서 론

소프트웨어 기술에서 실험 연구는 소프트웨어 개발과정을 이해하고 그것의 특징을 평가하기 위해 실험에 의한 데이터를 이용한다. 소프트웨어 생산물과 공정에 관계된 데이터는 그것에 대해 좀더 이해하고 나중에는 좋은 특징을 가지는 소프트웨어를 생성하는 효과적인 방법을 개발하는 것이 중요하다. 소프트웨어 데이터의 해석은 많은 다른 분야에서 연구되고 있다. 그러나 아직 소프트웨어 개발과정을 표현하는 메카니즘을 충분히 이해되지 못했거나, 너무 복잡해서 이론으로부터 요구되는 정확한 모델을 만들지 못한다. 따라서 소프트웨어 공정을 효과적으로 다루는 능력을 지닌 강한 비선형 적응 모델의 개발에 관심이 집중되고 있다. 이러한 관심은 퍼지 집합과 신경회로망의 연구 영역까지 확대되었으며 더 나아가 이들 두 기술의 합성인 뉴로퍼지 시스템으로 확장되고 있다. Takagi, Hayashi[1]는 신경회로망으로 구동되는 퍼지추론을 제안하였으나 입력력 수가 적은 경우는 그 효과가 미미하고, 전반부가 신경회로망이라는 특성화된 함수로 구성되어 기존의 퍼지추론보다 시스템 표현에 있어서 정성적으로 이해하기가 힘들다는 단점을 가지고 있다. Horikawa[2]는 퍼지-뉴럴네트워크에 의한 합성방법과 동정에 관한 연구를 하였다. 그러나 퍼지규칙의 전반부인 시그모이드 형태의 멤버십함수 초기치 선정이 어렵고, 최적 성능으로의 수렴특성이 나쁘다.

2. 본 론

2.1 뉴로퍼지 네트워크

뉴로퍼지 네트워크 구조는 퍼지와 신경회로망의 독자적인 연구과정에서 이 두 구조가 유사성과 상호보완적인 특성을 가짐을 인식하고 이들의 결합이 시도되었다. 이렇게 얻어진 구조는 특히 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경회로망의 오류역전과 알고리즘을 사용한 학습기능 및 높은 응용성을 가지게 되었다.

본 논문에서 제안된 뉴로퍼지 네트워크는 전반부와 후반부로 나뉘어 설계된다. 뉴로퍼지 네트워크의 전반부는 입력변수들 간의 상호관계를 고려하여 공간을 분할한 퍼지공간 분할을 이용하여 설계된다. 그림 1에서 (a)는 각 입력변수에서 정의된 퍼지집합을 이용하여 공간을 분할한 형태로 Yamakawa가 제안한 뉴로퍼지 구조[5,6]에 이용되었다. 그러나 이 퍼지공간은 입력변수들 사이의 상호관계를 고려하지 못한다. 따라서 본 논문에서는 (b)에 보여지는 퍼지공간을 이용한다. (b)는 입력변수 공간에서 Cartesian product로 정의된 퍼지공간을 이용한 퍼지공간 분할을 포함한다.

제안된 뉴로퍼지 네트워크의 후반부는 1차 선형식의 구조를 가진다. 일반적인 뉴로퍼지 네트워크의 후반부 구조, 예를 들어 ANFIS[7]모델의 후반부 구조를 살펴

보면 전체 네트워크 구조상에 하나의 뉴론으로 구성되어 이 뉴론은 입력변수에 대한 함수형태를 가지게 된다. 그러나 제안된 뉴로퍼지 네트워크는 네트워크 자체가 1차 선형식을 표현하게 된다. 즉 연결가중치에 의한 네트워크의 출력이 1차 선형식이 된다.




그림 1. 뉴로퍼지 네트워크의 전반부 퍼지공간 분할: (a) 퍼지집합에 의한 각 입력변수의 공간분할 (b) 퍼지관계에 의한 입력변수의 공간 분할

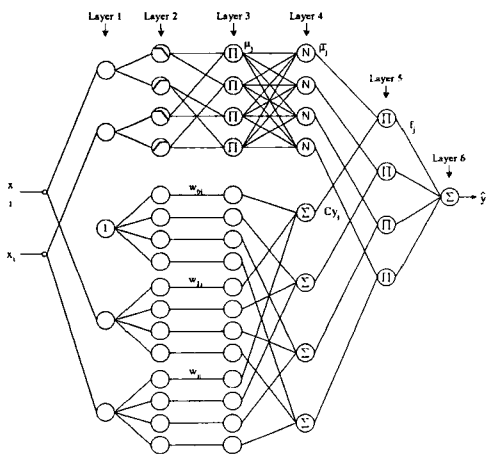


그림 2. 제안된 뉴로퍼지 네트워크의 구조

입력변수들의 퍼지관계에 의해 분할된 퍼지공간을 네트워크 구조로 확장하여 생각하자. 모든 변수들에 대한 퍼지분할의 네트워크 형태는 그림 2에 보여진다. 그림 2에서 원은 뉴로퍼지 네트워크의 뉴론을 나타내며, Π 는 Cartesian product, 즉 모든 입력신호의 곱을 나타내며, N 은 정규화, Σ 은 선형 합을 나타낸다. 제안된 뉴로퍼지 네트워크 구조는 비선형적인 데이터들간의 상호 연관성을 찾아 상호 결합된 입력공간의 분할로부터 각 입력변수들의 상호관계를 나타내는 퍼지규칙의 적합도를 구하고 입력신호와 연결가중치의 곱으로 표현되는 1차 선형식을 구성함으로써 각 규칙을 생성한다. 따라서 그림 2의 뉴로퍼지 네트워크는 식 (1)의 퍼지규칙으로 나타낼 수 있다.

R^1 : If x_1 is A_1 and x_2 is B_1 Then $Cy_1 = w_{01} + w_{11}x_1 + w_{21}x_2$ (1)
 여기서 R_j 는 j번째 퍼지규칙, i 는 i번째 입력변수, Cy_j 는 규칙의 후반부 출력, w_{ij} 는 퍼지규칙의 후반부를 구성하는 연결가중치이다. 제안된 뉴로퍼지 네트워크의 추론과정은 각 규칙의 적합도를 구하고 모든 규칙의 적합도 합을 비례를 계산한다. 즉 정규화된 μ_i 는 후반부 출력 Cy_j 와 곱하며, 출력층의 입력이 된다. 각 뉴론의 출력 \hat{y} 는 식 (2)와 같이 모두 대수적으로 합쳐져 \hat{y} 를 최종적으로 출력하게 된다.

$$\hat{y} = \sum_{j=1}^n \mu_j \cdot \sum_{i=1}^m \mu_i \cdot Cy_j = \sum_{j=1}^n \frac{\mu_j \cdot \sum_{i=1}^m \mu_i \cdot Cy_j}{\sum_{i=1}^m \mu_i} \quad (2)$$

$$= \sum_{j=1}^n \frac{\mu_j \cdot (w_{0j} + w_{1j}x_1 + w_{2j}x_2)}{\sum_{i=1}^m \mu_i}$$

뉴로퍼지 네트워크의 학습은 Back-Propagation 알고리즘이 사용되며, 본 논문에서는 식 (3)와 같은 형태의 출력오차를 이용한다.

$$E_p = \frac{|y_p - \hat{y}_p|}{y_p} \quad (3)$$

연결 가중치의 조절은 식 (4)과 같으며 모멘텀을 포함한 연결 가중치 변화량 Δw 는 식 (5)와 (6)과 같다.

$$w(\text{new}) = w(\text{old}) + \Delta w \quad (4)$$

$$\begin{cases} \Delta w_{0j} = \eta \cdot \frac{\mu_j}{y_p} + \alpha(w_{0j}(t) - w_{0j}(t-1)) & \text{for } y_p \geq \hat{y}_p \\ \Delta w_{0j} = -\eta \cdot \frac{\mu_j}{y_p} + \alpha(w_{0j}(t) - w_{0j}(t-1)) & \text{for } y_p < \hat{y}_p \end{cases} \quad (5)$$

$$\begin{cases} \Delta w_{ij} = \eta \cdot \frac{\mu_j}{y_p} \cdot x_i + \alpha(w_{ij}(t) - w_{ij}(t-1)) & \text{for } y_p \geq \hat{y}_p \\ \Delta w_{ij} = -\eta \cdot \frac{\mu_j}{y_p} \cdot x_i + \alpha(w_{ij}(t) - w_{ij}(t-1)) & \text{for } y_p < \hat{y}_p \end{cases} \quad (6)$$

2.2 유전자 알고리즘

유전자 알고리즘[8,9]은 최적화 문제에 있어서 향상된 성능을 가진 새로운 해들을 얻기 위해 사실적 정보를 효과적으로 이용하는 능력을 가지고 있기 때문에 매우 유용하며, 또한 복잡한 탐색 공간에서 강한 탐색 능력을 제공한다. 이것이 이론상 그리고 경험적으로 증명되었다. 뿐만 아니라, 그들은 경사 하강법(gradient descent method)과는 달리 지역 극소에 빠질 가능성을 제거하기 위해 임의의 지점을 검사함으로써, 해 공간 전체를 탐색할 수 있는 능력을 가진다. 유전자 알고리즘의 특징은 주어진 값을 2진 코딩하여 코딩된 문자열을 하나의 개체로 그리고 개체의 비트를 유전자처럼 취급하며, 미분과 같은 수학적 연산이 아닌 결과의 적합도를 기준(목적함수)으로 수행된다. 유전자 알고리즘은 3개의 기본 연산자로 생산, 교배, 돌연변이를 가지고 있으며, 평가, 선택, 재생산을 통해 반복 수행된다.

본 논문에서는 뉴로퍼지 네트워크의 최적화를 위해 유전자 알고리즘을 이용하여 전반부 파라미터, 학습율, 및 모멘텀 계수를 동정한다.

2.3 NASA 소프트웨어 데이터의 모델링

실험 예제는 잘 알려진 NASA[10] 데이터 집합을 이용한다. 이 데이터 집합은 두 개의 독립변수, 즉, 코드의 개발 라인(Developed Lines: DL)과 방법론(Methodology: ME) 그리고 하나의 종속변수, 즉 성과(Effort: Y)로 구성된다. 여기서 두 가지의 경우로 나누어 뉴로퍼지 네트워크의 모델을 구현한다. 첫 번째는 1입력(DL) 1출력 모델, 두 번째는 2입력(DL, ME) 1출력 모델이다.

2.2.1 1입력(DL)을 가지는 경우

1입력 1출력에 대한 제안된 뉴로퍼지 네트워크의 동정예러를 표 1에 보여주고 있다. 여기서 PI는 학습데이터에 대한 모델의 성능지수를, E_{PI} 는 LOOCV[10]를 이용한 모델의 테스트 성능지수이다.

표 1. 뉴로퍼지 네트워크의 성능지수

규칙 수	PI	E_{PI}
2	0.209	0.246
3	0.240	0.283

두 개의 규칙을 가지는 뉴로퍼지 네트워크의 퍼지 규칙은 식 (7)과 같으며 네트워크 구조는 그림 3에 보였다.

$$\begin{aligned} R^1: & \text{ If DL is } A_1 \text{ Then } Cy_1 = w_{01} + w_{11}DL \\ R^2: & \text{ If DL is } A_2 \text{ Then } Cy_2 = w_{02} + w_{12}DL \end{aligned} \quad (7)$$




그림 3. 1입력 1출력을 가지는 뉴로퍼지 네트워크

2.2.2 2입력(DL,ME)을 가지는 경우

표 2는 NASA 데이터집합에 대해 2입력 1출력을 가지는 뉴로퍼지 네트워크의 결과를 보여주고 있다.

표 2. 뉴로퍼지 네트워크의 성능지수

규칙 수 (멤버쉽함수 수)	PI	E_PI
4 (2×2)	0.154	0.196
6 (3×2)	0.197	0.233

- R^1 : If DL is A_1 and ME is B_1 Then $y_1 = w_{01} + w_{11}DL + w_{21}ME$
 R^2 : If DL is A_1 and ME is B_2 Then $y_2 = w_{02} + w_{12}DL + w_{22}ME$
 R^3 : If DL is A_2 and ME is B_1 Then $y_3 = w_{03} + w_{13}DL + w_{23}ME$
 R^4 : If DL is A_2 and ME is B_2 Then $y_4 = w_{04} + w_{14}DL + w_{24}ME$




그림 4. 2입력 1출력을 가지는 뉴로퍼지 네트워크

식 (8)은 규칙 4개를 가지는 퍼지규칙을 나타내며 이 규칙에 대한 뉴로퍼지 구조를 그림 4에 보였다. 여기서 뉴로퍼지 네트워크 구조는 유전자 알고리즘에 의해 최적화되었으며 동정된 파라미터를 그림 5와 표 3에 보였다.




그림 5. 유전자 알고리즘에 의해 최적화된 전반부 멤버쉽함수

표 3. 유전자 알고리즘에 의해 최적화된 뉴로퍼지 네트워크의 학습 파라미터

파라미터	파라미터 값
학습회수	500
학습율	0.996
모멘텀 계수	0.182

표 4는 간략추론 구조를 가지는 뉴로퍼지 네트워크와 본 논문에서 제안된 뉴로퍼지 네트워크의 동정오차를 비교하고 있다. 이 표에서 알 수 있듯이 제안된 뉴로퍼지 구조에서 좀 더 나은 결과를 얻을 수 있다.

표 4. 뉴로퍼지 네트워크의 동정오차 비교

뉴로퍼지 구조	시스템 입력	규칙 수	PI	E PI
간략추론구조	1입력	2	0.287	0.299
		3	0.291	0.32
	2입력	4	0.211	0.241
		6	0.310	0.350
제안된 구조 (선형추론구조)	1입력	2	0.209	0.246
		3	0.240	0.283
	2입력	4	0.154	0.196
		6	0.197	0.233

3. 결 론

본 논문에서는 비선형 시스템에 대한 뉴로퍼지 네트워크를 제안하였다. 제안된 뉴로퍼지 네트워크는 퍼지규칙과 신경회로망의 학습기능을 융합한 구조이며 선형추론의 형태를 가진다. 또한 규칙의 후반부를 구성하는 선형식은 기존 뉴로퍼지 구조와 달리 연결가중치에 의해 네트워크로 표현되며 이 연결가중치는 오류역전과 알고리즘에 의해 학습된다. 제안된 뉴로퍼지 네트워크의 성능 향상을 위해 유전자 알고리즘을 이용하여 전반부 멤버쉽함수의 파라미터 및 후반부를 구성하는 연결가중치를 학습하기 위한 학습율과 모멘텀 계수를 동정하였다. 제안된 뉴로퍼지 네트워크의 성능평가를 위해 소프트웨어로 모델링을 시도하였으며 실험 예에서 보여지는 것처럼 제안된 구조는 좋은 특성을 나타내고 있다.

감사의 글

본 연구는 한국과학재단 목적기초연구(과제번호: R02-2000-00284) 지원으로 수행되었음.

[참 고 문 헌]

- H. Takagi and I. Hayashi, "NN-driven Fuzzy Reasoning," Int. J. of Approximate Reasoning, Vol. 5, No. 3, pp. 191-212, 1991.
- S. Horikawa, T. Furuhashi, and Y. Uchigawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back Propagation Algorithm," IEEE Trans. Neural Networks, Vol. 3, No. 5, pp. 801-806, 1992.
- 今崎直樹, 木沼潤一, "ファジィ룰構造化ニューラルネットワーク," 日本ファジィ學會誌 Vol.4, No.5, pp. 985-995, 1992.
- H. Nomura and Wakami, "A Self-Tuning Method of Fuzzy Control by Descent Methods," 4th IFSA World Conference, pp. 155-159, 1991.
- T. Yamakawa, "A New Effective Learning Algorithm for a Neo Fuzzy Neuron Model," 5th IFSA World Conference, pp. 1017-1020, 1993.
- 오성권, 윤기찬, "유전자 알고리즘과 합성 성능지수에 의한 최적 퍼지-뉴럴 네트워크 구조의 설계," 제어자동화시스템공학논문지, 6권, 3호, pp. 273-283, 2000.
- J. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," IEEE Trans. on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.
- D. E. Goldberg, Genetic Algorithms in search, Optimization & Machine Learning, Addison-wesley.
- Z. Michalewicz, Genetic Algorithms + Data Structure=Evolution Programs, Springer-Verlag.
- M. Shin and A. L. Goel, Empirical Data Modeling in Software Engineering Using Radial Basis Functions, IEEE Trans on Software Engineering, Vol. 26, No. 6, June, 2000.
- 오성권, "C 프로그래밍에 의한 퍼지모델 및 제어시스템," 내하출판사, 2002.