

최적 알고리즘과 합성 성능지수에 의한 퍼지-뉴럴네트워크구조의 설계

윤기찬*, 오성권*, 박종진**

원광대학교 전기전자공학부, 청운대학교 인공지능과

Design of Fuzzy-Neural Networks Structure using Optimization Algorithm and an Aggregate Weighted Performance Index

Kichan Yoon*, Sungkwon Oh*, Jongjin Park**

*Div. of Electrical & Engineering, of Wonkwang Univ., **Dept. of Artificial Intelligence, of chungwoon Univ.

Abstract - This paper suggest an optimal identification method to complex and nonlinear system modeling that is based on Fuzzy-Neural Network(FNN). The FNN modeling implements parameter identification using HCM algorithm and optimal identification algorithm structure combined with two types of optimization theories for nonlinear systems. we use a HCM Clustering Algorithm to find initial parameters of membership function. The parameters such as parameters of membership functions, learning rates and momentum coefficients are adjusted using optimal identification algorithm. The proposed optimal identification algorithm is carried out using both a genetic algorithm and the improved complex method. Also, an aggregate objective function(performance index) with weighted value is proposed to achieve a sound balance between approximation and generalization abilities of the model. To evaluate the performance of the proposed model, we use the time series data for gas furnace, the data of sewage treatment process and traffic route choice process.

1. 서 론

퍼지이론과 신경망의 특성을 적절히 융합한 상호보완적인 구조를 가지는 퍼지-뉴럴네트워크모델은 복잡성과 불확실성을 나타내는 비선형 공정에서는 기존 지능형 모델에 비해 보다 나은 성능을 가지고 있다. 그러나 퍼지 추론부의 멤버쉽함수나 신경망 부분의 학습률, 모멘텀 계수 등의 초기값들의 결정에 체계적인 방법이 제시되어 있지 않아 이를 조정하기 위해서 시행착오 및 전문가의 경험으로 결정해야하는 단점이 있다. 따라서, 이들의 선택시 좀 더 객관적인 방법을 이용한다면 모델의 신뢰성을 높일 수 있다.

유전자 알고리즘은 탐색영역이 넓어 광범위한 영역에서 방대한 지역 극소를 제거하고 모델의 성능지수가 최소가 되는 전역 극소 영역을 찾는다. 그러나 최저값을 가지는 최적점 선택에 어려움을 가지고 있다. 그리고 캠플렉스 알고리즘은 전역 극소 영역에서 최적점 추출이 용이하나 초기값의 영향을 따라 지역 극소에 빠지는 단점을 가지고 있다. 그러므로 유전자 알고리즘과 개선된 캠플렉스 알고리즘을 결합한 최적 알고리즘을 이용하면 좀 더 나은 최적해 탐색성능을 획득할 수 있다.

본 논문은 Yamakawa[1,2]가 제안한 퍼지-뉴럴네트워크 모델을 이용하여 최적 모델을 얻고자 한다. 이 모델은 다른 구조에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가졌으나, 주어진 시스템에 대해 퍼지입력 공간을 균등하게 분할하여 멤버쉽함수를 정의함으로써 그 계통의 특성을 반영하지 못했다. 따-

라서 이러한 문제를 해결하기 위해 HCM 클러스터링 알고리즘을 사용하여 시스템의 특성에 맞게 퍼지입력 공간 분할을 통하여 초기멤버쉽함수의 파라미터를 얻는다. 그리고 유전자 알고리즘과 캠플렉스 알고리즘을 결합한 최적 알고리즘을 이용하여 모델을 최적화한다. 또한 학습 데이터 및 테스트 데이터를 고려한 퍼지-뉴럴네트워크 모델 성능 즉 근사화 및 일반화 능력 모두를 고려한 성능결과를 위해 하중 계수를 가진 합성 목적함수를 제안한다. 제안된 모델은 가스로공정, 하수처리공정과 교통 경로선택공정에서 얻어진 데이터를 이용하여 성능을 평가하며 기존 방법에 비해 우수한 모델을 구축할 수 있음을 보인다.

2. 본 론

2.1 개선된 퍼지-뉴럴 네트워크

본 논문에서 사용되는 Yamakawa에 의해 제안된 퍼지-뉴럴 네트워크모델은 퍼지추론과 뉴럴 네트워크의 오류역전파 알고리즘을 합성한 형태이다.

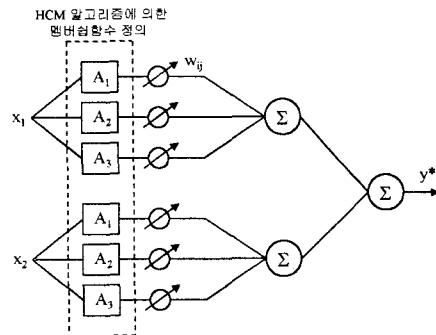


그림 1. 개선된 퍼지-뉴럴 네트워크

Fig 1. Improved Fuzzy-Neural Network

기존 퍼지-뉴럴네트워크 모델의 구조는 주어진 데이터에 대하여 최소값과 최대값을 임의의 개수로 균등하게 분할하여 일률적으로 멤버쉽함수를 정의했다. 따라서 주어진 데이터의 특성을 살리지 못하고 모델의 성능에 좋은 영향을 끼치지 못했다. 그러므로 계통의 특성에 맞은 멤버쉽함수를 정의하는 것이 보다 성능을 향상시키는 방법이다. 본 논문에서는 데이터들간의 거리를 기준으로하여 근접한 정도를 측정하고, 이를 통해 데이터를 분류하는 HCM 클러스터링 알고리즘을 사용하여 입력데이터의 거리에 따른 특성을 분류하고 그 클러스터들의 중심을 그림 2과 같이 각 멤버쉽함수의 정점으로 사용한다. 그림 2에서 \$X_{min}\$은 데이터의 최소값, \$X_{max}\$은 데이터의 최대값이고 \$C_n\$은 각 클러스터의 중심이다.

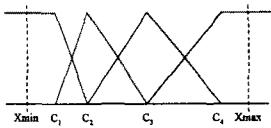


그림 2. HCM을 이용한 멤버십함수 정의
Fig 2. Membership function definition using HCM

2.2 최적 알고리즘

본 논문에서는 유전자 알고리즘과 캠플렉스 알고리즘의 장점을 이용하여 상호 결합된 최적 알고리즘의 단점 및 한계성을 극복하여 보다 최적화된 모델 구조의 생성 효과를 얻을 수 있다. 즉, 캠플렉스 알고리즘에서 사용되는 초기값을 유전자 알고리즘으로 구하여 캠플렉스 알고리즘의 초기값 문제에 따른 어려움과 유전자 알고리즘의 탐색 능력의 한계성을 극복한다. 따라서, 유전자 및 캠플렉스 알고리즘의 합성에 의한 최적 알고리즘에 의한 HCM 클러스터링 알고리즘에 의해 얻어진 멤버십함수의 정점 c_i 와 학습률 및 모멘텀계수를 자동 튜닝으로 최적 퍼지-뉴럴네트워크모델을 구축할 수 있다.

2.2.1 유전자 알고리즘

최적화 문제에서 탁월한 성능을 발휘하는 유전자 알고리즘은 자연 세계의 진화 과정(유전자적 특성, 적자생존)을 이용한 탐색 알고리즘이다. 기존의 방법들과는 달리 미분에 대한 제약도 없고, 지역극소가 존재하더라도 문제없이 적용이 가능하므로 최적화 해결에 많이 응용되고 있다. 제안된 모델의 최적화를 위하여 사용된 유전자 알고리즘은 변수를 2진코딩하여 코딩된 문자열을 하나의 개체로 그리고 개개의 비트를 유전자처럼 취급하고, 개개의 점을 탐색하는 것이 아닌 동시에 여러지점을 탐색하고, 미분과 같은 수학적 연산이 아닌 결과의 적합도를 목적함수으로 수행한다. 그리고 결정적인 방법이 아닌 확률적인 방법을 사용한다.

2.2.2 개선된 캠플렉스 알고리즘

개선된 캠플렉스 알고리즘은 기존의 최적화 이론인 캠플렉스 개념을 확장, 융합함으로써 목적함수를 최소화시키는 방법인 캠플렉스법에 제약조건이 주어지는 경우로 식(1)의 형태의 수식을 풀기 위한 방법이다.

Minimize $f(x)$

Subject to $g_j(x) \leq 0, j = 1, 2, \dots, m$ (1)

$$x_i^l \leq x_i \leq x_i^u, \quad i = 1, 2, \dots, n$$

여기서, l 은 하한, u 는 상한을 나타낸다.

캠플렉스의 개념에서 투영, 확장, 축소의 기본 개념을 이용하여, α, β, γ 의 초기값을 설정한다.

I) 투영(reflection) : $x_r = x_0 + \alpha(x_0 - x_h)$

II) 확장(expansion) : $x_e = x_0 + \gamma(x_r - x_0)$

III) 축소(contraction) : $x_c = x_0 + \beta(x_h - x_0)$

개선된 캠플렉스의 수렴조건은 X_1, \dots, X_k 사이의 임의의 두 정점사이의 거리가 지정된 미소값 이하로 된 경우와 목적함수(평가치)의 표준편차가 지정된 미소값보다 작은 경우이다. 이 경우의 표준편차는 식 (2)과 같다.

$$Q = \frac{\sum_{i=1}^n ((f(x_i) - f(x_0))^2)}{n+1} \leq \epsilon \quad (2)$$

2.2.3 하중값을 가진 목적함수

본 논문에서는 주어진 학습 데이터를 이용하여 퍼지-뉴珥네트워크 모델을 구축하고 테스트 데이터를 사용하여 모델을 평가하기 위한 근사화 및 일반화의 상호 균형

과 의존 능력을 가진 합성 목적 함수(성능지수)를 이용하여 상호 연계된 최적 모델 구조 생성에 의한 성능지수의 향상을 꾀하였다. 이를 위해 학습 및 테스트 데이터의 성능 결과에 대한 하중값을 가진 목적함수를 다음과 같이 정의한다.

$$f(\text{PI}, \text{E_PI}) = \theta \times \text{PI} + (1 - \theta) \times \text{E_PI} \quad (3)$$

PI는 학습데이터, E_PI는 테스트데이터에 대한 성능지수, 그리고 θ 는 PI와 E_PI에 대한 하중값을 나타내고, 목적함수는 모델의 성능향상이 최적이 되도록 하기 위해 전반부 멤버십함수의 모든 파라미터들과 학습률, 모멘텀 계수들은 최적 알고리즘에 의해 조절된다.

식 (3)은 하중값 설정에 따라 다음과 같은 특징을 가진다.

- $\theta = 1$ 이면 목적함수는 $f(\text{PI}, \text{E_PI}) = \text{PI}$ 와 같으므로 학습 데이터를 기초로 최적화 된다.
- $\theta = 0.5$ 이면 목적함수는 $f(\text{PI}, \text{E_PI}) = 0.5\text{PI} + 0.5\text{E_PI}$ 와 같으므로 학습과 테스트 모두 같은 비중을 가지고 평가한다.
- $\theta = 0$ 이면 목적함수는 $f(\text{PI}, \text{E_PI}) = \text{E_PI}$ 와 같으므로 테스트 데이터를 기초로 최적화 된다.
- $\alpha \in [0, 1]$ 에 대해서 $\theta = \alpha$ 이면 학습과 테스트 모두를 포함하고, α 의 선택은 퍼지모델의 근사화 일반화 사이에서 상호 균형에 의한 최적화를 시도한다.

2.3 실험 예

본 논문에서는 모델의 성능을 확인하기 위하여 3종류의 데이터를 이용해 시뮬레이션을 행한다. 제안된 방법과 기존 방법을 비교하기 위해서 다음 표 1, 2, 3에서 Model 1은 최소, 최대값에 의해 멤버십함수를 정의하고 유전자 알고리즘으로 최적화 한다. Model 2은 HCM 알고리즘에 의해 멤버십함수를 정의하고 유전자 알고리즘으로 최적화 한다. 그리고, Model 3은 제안된 방법으로 HCM 알고리즘에 의해 멤버십함수를 정의하고 최적 알고리즘으로 최적화 한다.

2.3.1 가스로 공정

가스로공정은 많은 연구자들이 제안하는 모델링 기법을 성능 평가하는데 널리 사용되는 데이터이다. 가스로공정 데이터는 1개의 입력과 1개의 출력으로 구성된 296쌍의 입출력 데이터집합이다. 입력은 가스흐름률이고, 출력은 CO_2 농도이다. 본 논문에서는 제안된 모델의 입력은 $u(t-3)$ 과 $y(t-1)$ 으로 하고 출력은 $y(t)$ 으로 2 입력 1출력을 사용한다.

표 1. 하중값을 가진 합성 성능지수

Table 1. The aggregate performance index with weighting factor

Weight t (θ)	Model 1		Model 2		Model 3 (제안된 모델)	
	PI	E_PI	PI	E_PI	PI	E_PI
0	0.062	0.275	0.112	0.251	0.099	0.247
0.2	0.077	0.272	0.054	0.254	0.063	0.249
0.4	0.036	0.286	0.056	0.257	0.050	0.254
0.5	0.032	0.288	0.033	0.276	0.043	0.261
0.6	0.029	0.292	0.032	0.277	0.036	0.266
0.8	0.026	0.304	0.032	0.276	0.027	0.289
1	0.022	0.338	0.024	0.336	0.022	0.337

2.3.2 하수처리 공정

하수처리를 위한 다양한 방법 중 가장 많이 사용되는 것이 활성오니를 이용한 방법으로, 침사지, 최초침전지, 폭기조 및 최종침전지로 구성된다. 본 논문에서는 제안

된 방법을 통해 수도권 하수처리장 중의 하나를 모델로 선정하여 1년분 수질 데이터로부터 모델링하였다. 혼합 액 부유물(MLSS), 잉여오니호름율(WSR), 반송율 설정치(RRSP), 용존산소 설정치(DOSP)을 입력으로 하고, 부유물의 농도(ESS)를 출력으로 하는 2입력 1출력 구조를 가진다.

표 2. 하중값을 가진 합성 성능지수

Table 2. The aggregate performance index with weighting factor

Weight (θ)	Model 1		Model 2		Model 3 (제안된 모델)	
	PI	E_PI	PI	E_PI	PI	E_PI
0	14.448	9.8430	17.234	5.902	19.589	5.550
0.2	14.301	9.444	15.589	6.434	14.407	5.539
0.4	13.725	10.652	13.021	7.436	13.267	6.024
0.5	12.632	11.322	13.034	7.280	11.313	8.707
0.6	11.133	12.575	9.955	11.155	9.971	9.428
0.8	10.163	14.698	9.920	10.129	9.059	11.283
1	10.249	27.977	8.791	15.582	8.277	22.472

(입력 변수 : WSR, DOSP)

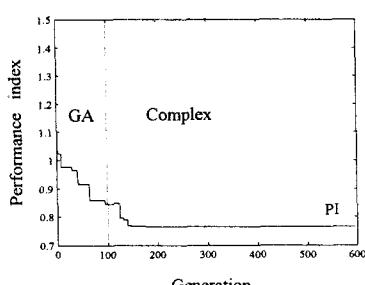
2.3.3 교통 경로 선택

일반적으로 어느 한 지점에서 출발하여 목적지까지는 매우 다양한 경로가 존재한다. 우리는 여러 가지 가능한 모든 경로에 대해서 장점과 단점을 비교하여 최적의 경로를 선택하게 한다. 이러한 선택에 영향을 미치는 인자들은 거리, 시간, 노면의 쾌적성, 경로 주변의 경치, 안전성 등 매우 다양하다. 위의 인자들은 교통 비용이라는 궁극적인 인자로 통일될 수 있다.

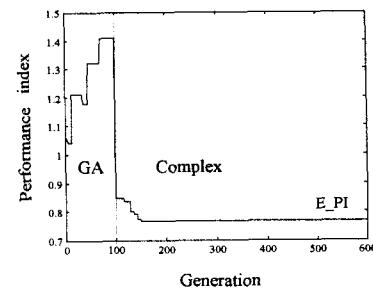
표 3. 하중값을 가진 합성 성능지수

Table 3. The aggregate performance index with weighting factor

Weight (θ)	Model 1		Model 2		Model 3 (제안된 모델)	
	PI	E_PI	PI	E_PI	PI	E_PI
0	1.006	1.005	1.034	1.015	0.780	0.777
0.2	1.007	1.005	1.007	1.008	0.791	0.785
0.4	1.000	1.001	1.013	1.015	0.829	0.829
0.5	1.004	1.003	1.007	1.009	0.759	0.759
0.6	1.006	1.005	1.013	1.012	0.819	0.820
0.8	1.005	1.007	0.858	1.409	0.765	0.768
1	1.004	1.004	0.773	1.556	0.652	0.655



(a) 학습 성능 지수



(b) 테스트 성능 지수

그림 3. 성능지수의 최적화 과정 ($\theta = 0.8$)
Fig 3. The optimization process of performance index

3. 결 론

본 논문에서는 퍼지-뉴럴네트워크를 이용하여 체계적이고 효율적인 최적화 모델을 구축하기 위하여 HCM 클러스터링 알고리즘과 유전자 및 컴플렉스 알고리즘이 가진 각 단점과 한계성을 극복한 최적 알고리즘을 제안하였다.

제안된 방법은 여러 가지 특성을 가지고 있는 데이터를 이용하여 성능을 평가하였다. 앞 결과에서 알 수 있듯이 비선형성이 상대적으로 약하고 비교적 균일하게 분포된 가스로 데이터에서는 뚜렷한 성능향상을 나타내지 못하지만, 비선형성이 강하며 균일하지 않고 분산된 구조를 가지는 수처리 데이터와 출력력 데이터 수가 적은 교통 선택 데이터에서는 좀 더 우수한 특히 예측성능이 향상된 모델을 구축할 수 있었다. 그리고 합성 목적함수에서 하중값의 설정으로부터 FNN모델의 근사화 및 일반화사이에서 최적 성능결과에 대한 해석을 시도함으로써 FNN모델의 근사화와 일반화 사이의 상호 연계를 통한 최적화 향상을 제시하였다.

감사의 글

이 논문은 1998년도 한국학술진흥재단의
공모과제연구비에 의하여 연구되었습니다.

(참 고 문 헌)

- [1] Takeshi Yamakawa, "A Neo Fuzzy Neuron and Its Applications to System Identification and Prediction of the System Behavior", *Proceedings of the 2nd International Conference on Fuzzy logic & Neural Networks*, pp.477-483, 1992.
- [2] Takeshi Yamakawa, "A New Effectie Learning Algorithm for a Neo Fuzzy Neuron Model", *5th IFS World Conference*, pp.1017-1020, 1993.
- [3] David E. Goldberg, "Genetic Algorithms in search, Optimization & Machine Learning", Addison-wesley, 1989
- [4] 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)
- [5] 오성권, "퍼지모델 및 제어이론과 프로그램", 기다리출판사, 1999