

퍼지-뉴럴 네트워크 구조의 최적 동정

Optimal Identification of Fuzzy-Neural Networks Structure

윤기찬, 박춘성, 안태천, 오성권

원광대학교 제어계측공학과, 전라북도 익산시 신용동 344-2 ☎570-749

kichan yoon, Chun-sung Park, Taecheon Ahn, Sungkwun Oh

Dept. of Control & Instrumentation Engineering, Wonkwang Univ., Iksan, KOREA

Abstract

본 논문에서는 복잡하고 비선형적인 시스템의 최적 모델링을 위해서 지능형 퍼지-뉴럴네트워크의 최적 모델 구축을 위한 방법을 제안한다. 기본 모델은 퍼지 추론 시스템의 언어적인 규칙 생성의 장점과 뉴럴 네트워크의 학습기능을 결합한 FNNs 모델을 사용한다. FNNs 모델의 퍼지 추론부는 간략추론이 사용되고, 학습은 오류 역전파 알고리즘을 사용하여 다른 모델들에 비해 학습속도가 빠르고 수렴능력이 우수하다. 그러나 기본 모델은 주어진 시스템에 대하여 퍼지 공간을 균등하게 분할하여 퍼지 소속을 정의한다. 이것은 비선형 시스템의 모델링에 있어서 성능을 저하시켜 최적의 모델을 얻기가 어렵다. 논문에서는 주어진 데이터의 특성을 부여한 공간을 설정하기 위하여 클러스터링 알고리즘을 사용한다. 클러스터링 알고리즘은 주어진 시스템에 대하여 상호 연관성이 있는 데이터들끼리 특성을 나누어 몇 개의 클래스를 이룬다. 클러스터링 알고리즘을 사용하여 초기 FNNs 모델의 퍼지 공간을 나누고 소속함수를 정의한다. 또한, 최적화 기법중의 하나로 자연선택과 자연계의 유전자 메카니즘에 바탕을 둔 탐색 알고리즘인 유전자 알고리즘을 사용하여 주어진 모델에 대하여 최적화를 수행한다. 또한 본 연구에서는 학습 및 테스트 데이터의 성능 결과의 상호 균형을 얻기 위한 하중값을 가진 성능지수가 제시된다.

1. 서 론


비선형 공정의 복잡성과 불확실성을 제어할 수 있는 것으로는 지능형 모델을 들 수 있다. 이러한 지능모델링에는 사람의 자연적인 언어 체계를 표현하는 데에 효과적인 퍼지 이론과 생물학적 신경 계통을 모방한 인공 신경망을 들 수 있다. 본 논문에서는 퍼지 이론과 신경망이 갖는 독특한 특성들을 살리면서 지능 모델의 효율과 성능향상을 시킬 수 있는 방법으로 퍼지 이론과 신경망을 하나의 모델로 결합한 퍼지-뉴럴 네트워크(Fuzzy-Neural Network)

을 통하여 보다 나은 모델을 구축한다. 퍼지추론은 퍼지 논리의 언어적논리를 규칙의 형태로 표현할 수 있는 능력과 신경망은 학습기능을 이용함으로써 가능하다는 점이 있다. 본 논문의 기본 모델은 Yamakawa에 의해 제안된 모델로 다른 모델에 비해서 학습속도가 빠르고, 수렴특성이 매우 우수하다는 장점을 가진다. 그러나 이 모델은 주어진 시스템에 대하여 퍼지 공간을 균등하게 분할하여 퍼지 소속을 정의한다. 이것은 비선형 시스템의 모델링에 있어서 성능을 저하시켜 최적의 모델을 얻기가 어렵다. 그러므로 복잡하고 비선형적인 시스템에 대해서는 퍼지 공간을 분할하는데 있어서 주어진 데이터의 특성에 맞게 소속함수를 정의하는

것이 중요하다. 클러스터링 알고리즘을 사용하여 초기 FNNs 모델의 퍼지 공간을 나누고 소속 함수를 정의한다. 그리고 최적화 문제에서 탁월한 성능을 발휘하는 유전자 알고리즘을 통하여 최적화를 수행한다. 또한, 제안된 개선방안은 가스로공정, 하수처리공정에서 얻어진 데이터를 이용하여 성능을 평가하여 원래 방법에 비해 우수한 모델을 구축할 수 있음을 보인다. 그리고 학습 및 테스트 데이터의 성능 결과의 상호 균형을 얻기 위한 하중값을 가진 성능지수가 제시된다.

2. 기본모델구조

Yamakawa에 의해 제안된 퍼지-뉴럴 네트워크 모델의 구조는 그림1과 같으며, 퍼지추론부에 규칙의 형태는 보수적 소속함수를 가지는 간략 추론법이 사용되고, 신경망의 학습은 오류역전파알고리즘(Error Backpropagation Algorithm)을 사용한다.



$$\hat{y} = f_1(x_1) + f_2(x_2) + \dots + f_m(x_m)$$

$$= \sum_{i=1}^m f_i(x_i) \quad (1)$$

그림1. Yamakawa의 FNN구조

3. 클러스터링 알고리즘을 이용한 소속함수 정의

Yamakawa에 의해 제안된 FNNs 모델의 구조는 주어진 데이터에 대하여 최소값과 최대값을 임의의 개수로 균등하게 분할하여 일률적으로 소속 함수를 정의하게 한다. 그러므로 주어진 데이터의 특성을 살리지 못한다는 점에서 모델의 성능에 좋은 영향을 끼치지 못한다. 그러므로 이 특성에 맞는 소속 함수를 정의하는 것이 보다 효율적이다. 본 논문에서는 데이터들간의

거리를 기준으로 하여 근접한 정도를 측정하고, 이를 바탕으로 데이터를 분류하는 HCM(Hard C-mean) 방법을 이용하여 입력데이터의 특성을 분류하여 클러스터들의 중심을 그림3과 같이 각 소속 함수의 중심값으로 사용한다. 그림3에서 x_{min} 은 데이터의 최소값, x_{max} 은 데이터의 최대값이고 C_n 은 각 클러스터의 중심이다.




그림2. Yamakawa FNN 모델의 소속 함수의 정의




그림3. HCM을 이용한 소속 함수의 정의

4. 유전자 알고리즘을 이용한 최적화

최적화 문제에서 탁월한 성능을 발휘하는 유전자 알고리즘은 자연 세계의 진화 과정(유전자적 특성, 적자생존)을 이용한 탐색 알고리즘이다. 기존의 방법들과는 달리 미분에 대한 제약이 없고, 지역극소가 존재하더라도 문제없이 적용이 가능하므로 최적화 해결에 많이 응용되고 있다. 제안된 모델의 최적화를 위하여 사용된 유전자 알고리즘은 변수를 2진 코딩하여 코딩된 문자열을 하나의 개체로 그리고 개개의 비트를 유전자처럼 취급하고, 개개의 점을 탐색하는 것이 아닌 동시에 여러 지점을 탐색하고, 미분과 같은 수학적 연산이 아닌 결과의 적합도를 목적함수로 수행한다. 그리고 결정적인 방법이 아닌 확률적인 방법을 사용한다. 유전자 알고리즘의 연산자는 각각의 유전자를 적합도에 근거하여 다음 세대에 영향을 미칠 수 있는 기회를 차등적으로 부여한 재생산(reproduction)과 한 쌍의 유전자들이 교차하

여 새로운 값을 만들어내는 교차(crossover), 그리고 잠재적 능력을 가진 유전자의 도태를 막기 위해 사용하는 돌연변이(mutation)이다. 논문에서는 제안된 모델의 최적화를 위하여 클러스터링 알고리즘에 의해 얻어진 중심값 c_n , 신경망의 학습률 및 모멘텀계수를 유전자 알고리즘을 통하여 자동동조를 한다.




그림4. HCM을 이용한 수처리 데이터의 소속함수의 정의

5. 하중값을 가진 목적함수

본 논문에서는 학습 및 테스트 데이터의 성능 결과의 대하여 위한 하중값을 가진 목적함수가 제시된다.

$$f = \theta \times pi + (1 - \theta) \times E_pi \quad (2)$$

pi 는 학습데이터, E_pi 는 테스트데이터, 그리고 θ 는 pi 와 E_pi 에 대한 하중값을 나타낸다. 목적함수는 데이터의 성능향상이 최대가 되도록 하기 위해 전반부 소속함수 즉 삼각형 소속함수의 모든 파라미터들은 변화한다. 하중값 설정에 따라 다음과 같은 특징을 가진다.

1. $\theta=1$ 이면 모델은 학습을 바탕으로 최적화 된다. 테스트는 영향을 주지 않는다.
2. $\theta=0$ 이면 모델은 테스트를 바탕으로 최적화 된다. 학습은 영향을 주지 않는다.
3. $\theta=0.5$ 이면 학습과 테스트는 모두 같은 비중을 가지고 평가한다.
4. $\alpha \in [0, 1]$ 에 대해서 $\theta = \alpha$ 이면 학습과 테스트 모두를 포함하고, α 의 선택은 퍼지모델의 근사화 일반화 사이에서 최적화에 대한 방향을 설정한다.
5. 일반적으로 θ 는 독립적으로 조절하고, 선택할 수 있다.

6. 시뮬레이션

6.1 가스로공정 모델링

가스로 공정은 많은 연구자들이 제안하는 모델링 기법을 성능 평가하는데 널리 사용되는 데이터이다. 가스로 공정 데이터는 1개의 입력과 1개의 출력으로 구성된 296쌍의 입출력 데이터집합이다. 본 논문에서는 제안된 모델의 입력으로 $u(t-3)$ 과 $y(t-1)$ 을, 출력으로 $y(t)$ 으로 2입력 1출력을 사용한다.

표1. 하중값을 가진 목적함수에 의한 성능지수

기존모델	Weight	FNNs(유전자)		FNNs(유전자+HCM)	
		pi	E_pi	pi	E_pi
0.023	0	0.116	0.251	0.101	0.264
	0.4	0.045	0.266	0.068	0.259
	0.6	0.030	0.287	0.055	0.273
	0.75	0.028	0.294	0.046	0.276
	1	0.022	0.339	0.042	0.325




그림5. 최적화 모델의 학습성능 ($\theta=0.75$)




그림6. 최적화 모델의 테스트성능 ($\theta=0.75$)

6.2 하수처리 공정 모델링

하수처리를 위한 다양한 방법중 가장 많이 사용되는 것이 활성오니를 이용한 방법으로, 침사지, 최초침전지, 폭기조 및 최종침전지로 구성된다. 본 논문에서는 제안된 방법을 통해 수도권 하수처리장 중의 하나를 모델로 선정하여 1년분 수질 데이터로부터 모델링하였다. 혼

합액 부유물(MLSS), 잉여오니흐름율(WSR), 반송율 설정치(RRSP), 용존산소 설정치(DOSP)을 입력으로하고, 부유물의 농도(ESS)를 출력으로 하는 2입력 1출력 구조를 가진다.




그림7. HCM을 이용한 수처리 데이터의 소속함수의 정의

표2. 하중값을 가진 목적함수에 의한 성능지수

기존모델	Weight	FNNs(유전자)	FNNs(유전자+HCM)	
			pi	E_pi
23.462 20.997	0	14.599	11.507	20.471
	0.4	13.634	11.683	15.125
	0.6	13.443	11.834	11.813
	0.75	12.670	13.769	11.234
	1	11.964	25.252	9.534

(입력: MLSS, WSR 출력: ESS)




그림8. 유전자 알고리즘에 의한 모델의 최적화 과정($\theta=0.6$)

7. 결 론

체계적이고 효율적인 모델링을 얻기 위하여 HCM방법과 유전자 알고리즘을 사용하였다. 비선형성이 상대적으로 약한 가스로서는 주어진 데이터가 비교적 균일하게 분포되어 있으므로 클러스터 중심값 측정의 효율면에서 다소 떨어진다. 그러므로 주어진 데이터의 특징에 따라 소속함수를 균일하게 설정하여 유전자 알

고리즘을 사용하면 기존의 모델보다 성능 향상을 보인다. 그러나 수처리 공정에서는 주어진 데이터가 비선형성이 강한 특징이 있으므로 클러스터링 알고리즘을 사용하여 소속함수를 정의하면 기존 모델보다 강인한 모델을 설계할 수 있다. 그리고 하중값을 가진 목적함수에서는 하중값의 설정은 근사화·일반화에 따라 학습과 테스트 사이에 상호 연계를 통한 최적화 향상을 위한 방향을 제시하였다.

8. 참고문헌

- [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 Effective 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.
- [4] Zbigniew Michalewicz, "Genetic Algorithms + Data Structure = Evolution Programs", Springer-Verlag.
- [5] 오성권, 노석범, 남궁문, "퍼지-뉴럴 네트워크 구조에 의한 비선형 공정시스템의 지능형 모델링", 한국퍼지 및 지능시스템학회 논문집 제5권 제4호, pp.41-55, 1995.
- [6] 최재호, 오성권, 안태천, 황형수, "유전자 알고리즘을 사용한 퍼지-뉴럴네트워크 구조의 최적모델과 비선형공정시스템으로의 응용", 한국퍼지 및 지능 시스템학회 '96 추계 학술대회 논문집 Vol.6, No.2, pp302-305, 1996.
- [7] 최재호, 박춘성, 오성권, 안태천, "FNN 성능 개선을 위한 클러스터링기법의 적용", 한국 퍼지 및 지능 시스템학회 '97 추계 학술대회 학술발표논문집 Vol. 7, No. 2, pp135-138, 1997