

방사형 기저 함수 기반 다항식 뉴럴네트워크 설계 및 최적화

김기상*, 진용하**, 오성권***
수원대학교 전기공학과

Design of RBF-based Polynomial Neural Network And Optimization

Ki-Sang Kim*, Yong-Ha Jin**, Sung-Kwon Oh***
The University of Suwon

Abstract - 본 연구에서는 복잡한 비선형 모델링 방법인 RBF 뉴럴 네트워크(Radial Basis Function Neural Network)와 PNN(Polynomial Neural Network)을 접목한 새로운 형태의 Radial Basis Function Polynomial Neural Network(RPNN)를 제안한다. RBF 뉴럴 네트워크는 빠른 학습 시간, 일반화 그리고 단순화의 특징으로 비선형 시스템 모델링 등에 적용되고 있으며, PNN은 생성된 노드들 중에서 우수한 결과값을 가진 노드들을 선택함으로써 모델의 근사화 및 일반화에 탁월한 효과를 가진 비선형 모델링 방법이다. 제안된 RPNN모델의 기본적인 구조는 PNN의 형태를 이루고 있으며, 각각의 노드는 RBF 뉴럴 네트워크로 구성하였다. 사용된 RBF 뉴럴 네트워크에서의 커널 함수로는 FCM 클러스터링을 사용하였으며, 각 노드의 후반부는 다항식 구조로 표현하였다. 또한 입력개수, 입력변수, 클러스터의 개수를 PSO알고리즘(Particle Swarm Optimization)을 사용하여 최적화 시켰다. 제안한 모델의 적용 및 유용성을 비교 평가하기 위하여 비선형 데이터를 이용하여 그 우수성을 보인다.

제의 해가된다. 각 particle은 m차원 실수 벡터로 구성된다. 여기서 m은 파라미터의 수가된다. 따라서 각 파라미터는 주어진 문제의 차원을 나타낸다. PSO알고리즘에서 swarm은 n개의 particle을 가지며 이들은 주어진 문제의 해가된다. 각 particle은 m차원 실수 벡터로 구성된다. 여기서 m은 파라미터의 수가된다. 따라서 각 파라미터는 주어진 문제의 차원을 나타낸다.

2.2 Fuzzy c-means를 이용한 RPNN의 설계

본 논문에서 제안한 다항식 RPNN모델은 3층의 PNN모델[1]을 기초로 한다. PNN의 각 노드에 RBF 뉴럴 네트워크[6]를 사용한다. 사용된 RBF 뉴럴 네트워크에서의 커널 함수로는 FCM 클러스터링을 사용하였으며, 각 노드의 후반부 다항식은 표 1과 같은 형태를 가진 다항식 구조로 표현하였다. 그림 1은 RPNN의 일반적인 구조를 도식적으로 나타내었다.

네트워크에서 표현된 각 노드의 개수 k는 식 (2)와 같이 표현된다.

$$k = \frac{m!}{(n-r)!r!} \tag{2}$$

여기서, n : 총 입력변수의 수
r : 한 노드의 입력변수의 수

각 노드의 입력 및 클러스터의 개수는 2~5개로 설정하여 각각의 노드를 최소자승법에 의해 파라미터를 구하고, 여기서 추정된 계수 a_0, a_1, \dots, a_n 을 각각의 부분표현식에 대입한다. 평가용 데이터를 사용하여 성능지수를 구하고, 하중값을 가진 목적함수로 최적의 입력변수들의 조합을 선정한다. 이 성능지수는 실제 출력 데이터와 모델 출력 데이터의 MSE (Mean Square Error)로 정밀도를 평가하였다. 성능지수를 평가하여 다음 층으로 넘겨줌으로써, 출력이 곧 입력의 형태로 바뀌어 적용된다. 종료 판정 후 가장 좋은 성능지수를 가지는 노드가 최종 출력이 된다.[2][3]

<표 1>. 회귀 다항식의 구조

Type	Polynomial equation
Linear	$y = a_0 + a_1x_i + a_2x_i$
Quadratic	$y = a_0 + a_1x_i + a_2x_i + a_3x_i^2 + a_4x_i^2 + a_5x_i^2$
Modified quadratic	$y = a_0 + a_1x_i + a_2x_i + a_3x_i^2$

1. 서 론

자연현상을 분석하고 원하는 정보를 이용하는 것은 물론 생산자동화와 컴퓨터에 의한 생산체제에서의 적절한 작업관리를 위하여 안정된 시스템 모델링은 필요가 아닌 필수인 상황이 도래했다. 그러나 대부분의 현상들은 비선형성을 바탕으로 하고 있으므로 과거의 방법들을 이용해서 상황을 해석하기에는 많은 어려움에 부딪히게 된다. 따라서 시스템의 복잡성과 결과의 불확실성에 대한 분석을 위해 많은 연구가 지속되고 있으며 인간의 언어체계를 표현하는데 효과적인 지능형 모델이 출현하면서, 점진적으로 개선하는 추세이다. 본 연구에서는 입력변수가 증가하면 시스템이 복잡해지고 함수식으로 표현하는데 한계를 드러내는 모델의 설계를 위하여 PNN(Polynomial neural network)[1][2]을 바탕으로 RBF (Radial Basis Function) 뉴럴 네트워크를 적용시킨 RPNN모델을 제안한다. RBF 뉴럴 네트워크는 하나의 은닉층(hidden layer)만을 가지는 네트워크의 구조로 빠른 학습시간, 일반화, 단순화특징을 가지고 있다. 또한 데이터의 특성을 충분히 반영하기 위하여 Fuzzy c-means(FCM)클러스터링[4][5]을 이용하여 구조 동정하여 적용시켰으며, 모델의 최적화를 위하여 PSO알고리즘을 적용하여 모델의 입력 및 다항식 차수, 클러스터의 개수를 동정하였다. 본 논문에서는 RPNN의 구조와 PSO알고리즘을 설명하고, FCM에 의하여 분류되어진 데이터를 사용하여 각 알고리즘의 장점을 최대한 활용한 최적모델을 연구하였다.

2. 본 론

2.1 입자군집 최적화 알고리즘(PSO)

PSO는 한 개의 연산자를 가지므로 알고리즘이 단순하고, 계산시간이 짧다는 장점이 있다. PSO에서 각 Particle은 각각 지금까지의 탐색 중 목적함수의 값을 기억하고 있고, 각 세대에서는 이제까지의 탐색과정에서 발견한 해 중에 최량의 해를 공유한다. 각 Particle은 현재 위치 벡터와 속도 벡터, 그리고 pbest, gbest를 이용해서 PSO 성능의 효과적인 개선을 위해서 v_{max} 만으로 불충분하여, 이전 속도 값과 하중계수를 결합한 방법을 사용한다. 따라서 particle velocity는 다음 식(1)에 의해 계산된다.[7]

$$v_{j_k}(t+1) = u(t) \cdot v_{j_k}(t) + c_1 \cdot r_1 \cdot (pbest_{j_k}(t) - x_{j_k}(t)) + c_2 \cdot r_2 \cdot (gbest_k(t) - x_{j_k}(t)) \tag{1}$$

PSO알고리즘에서 swarm은 n개의 particle을 가지며 이들은 주어진 문


2.3 시뮬레이션 및 결과 고찰

제안된 모델을 평가하기 위하여 Automobile Miles Per Gallon(MPG) 데이터를 적용한다. MPG데이터는 7입력 1출력의 형태로 차량의 고유한 정보에 대한 기준 용량(1 Gallon)의 연료로 차량이 주행한 거리(Miles)의 관계를 갖는다. 평가를 위해 학습데이터와 테스트데이터를 랜덤하게 6:4의 비율로 나누었다.

본 연구에서는 FCM의 weight(지수의 가중)를 1.8부터 3까지, 0.2의 차를 두어 접근하였다. 표2는 성능이 가장 우수한 weight 2.8인 경우의 층별 성능지수를 나타낸다.

<표 2>. weight 2.8의 층별 성능지수


Layer	1	2	3	4	5
PI	1.61	1.60	1.61	1.59	1.55
E_PI	5.75	5.74	5.73	5.53	5.36




〈그림 1〉 RPNN의 네트워크 구조 (weight 2.8)

〈표 2〉. PSO와 RPNN의 파라미터

PSO	Generation	100
	Swarm size	150
	Selected Swarm size	30
	v_{max}	탐색공간의 20%
	$[w_{min} \ w_{max}]$	[0.4 0.9]
	C_1, C_2	2.0
RPNN	No. of input to be selected	2~6
	No. of layer	5
	No. of cluster	2~5
	Type	Linear, Quadratic, Modified quadratic
	Weighting factor(θ)	0~1




(a) Training




(b) Testing

〈그림 2〉 RPNN의 출력 데이터와 모델 출력 데이터 비교



(a) Training



(b) Testing

〈그림 3〉 RPNN의 출력 데이터와 모델 출력의 오차

〈표 3〉. 제안된 모델의 성능지수

weight	PI	E_PI	Type	Cluster
2.0	2.23	4.88	1	5
2.2	1.85	5.46	3	5
2.4	1.74	6.02	1	4
2.6	1.64	5.79	1	5
2.8	1.55	5.36	3	4
3.0	1.61	6.64	3	2

3. 결 론

본 연구에서는 비선형 시스템의 수학적 모델을 얻기 위해 RBF를 기반으로 하여 FCM알고리즘을 적용한 다항식 뉴럴 네트워크 구조를 설계하였다. 기존의 PNN 알고리즘은 선형 모델에 비해 우수한 시스템 묘사력을 가지고 있었다. 본 논문의 RPNN모델은 PSO알고리즘을 적용하여 클러스터의 수를 동조하였다. 또한 입력개수, 입력변수 그리고 다항식 차수를 선택하게 함으로써 데이터의 특성을 최대한 반영할 수 있었다. PSO알고리즘의 접목은 설계자의 주관적 경험에서 비롯된 것이 아닌 객관적인 구조동정의 결과를 얻는 기반이 되었다. 층마다 노드의 선택과 제거를 통하여 최량의 성능지수를 얻을 수 있도록 설계하여 최적의 모델을 얻을 수 있었고, 비선형 공정에 대해 매우 정밀한 예측 성능을 가지고 있음을 보였다.

또한 Automobile Miles Per Gallon(MPG) 데이터를 사용함으로써 비선형의 제한된 데이터 수 일지라도 데이터의 특성을 최대한 반영한 구조 및 파라미터 동정의 의한 최적화된 다항식 뉴럴 네트워크를 설계할 수 있음을 알 수 있었다.

감사의 글

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음 [GRRC 수원2009-B2, U-city 보안감시 기술협력센터].

[참 고 문 헌]

- [1] Oh, S. and Pedrycz, W., 2002, "The Design of Self-Organizing Polynomial Neural Networks", Information Sciences.
- [2] S. K. Oh and Pedfycz, W and B. J. Park, "Polynomial Neural Networks Architecture : Analsis and Design", Computers and Electrical Engineering, 2002
- [3] A. G. Ivahnenko, "Polynomial theory of complex systems", IEEE Trans. On Systems, Man and Cybernetics, Vol, SMC-1, pp. 364-378, 1971.
- [4] W. Pedrycz, "Conditional fuzzy C-means", Pattern Recognition Letters. Vol.17 No.6, 1996. pp.625-632
- [5] 이상경, 장동식, "Genetic 알고리즘과 퍼지 c-Means을 이용한 역전파신경망의 패턴인식 성능 개선", 대한군사운영분석학회지, 제 21권, 제 1호, 1995. 6. 30.
- [6] 박호성, 오성권, "Granular Computing에 의한 RBFNN의 구조동정", 한국인터넷정보학회 2008 정기총회 및 추계학술발표대회 제9권 제2호, 2008. 11
- [7] 박병준, 오성권, 김용수, 안태천 "PSO의 특징과 차원성에 관한 비교 연구", 제어·자동화·시스템공학 논문지 제 12권, 제 4호, pp. 328-338, 2006. 4.