

유전자 알고리즘 기반 최적 다항식 뉴럴네트워크 모델

김 완 수, 김 현 기, 오 성 권
 수원대학교 전기공학과

Genetic Algorithms based Optimal Polynomial Neural Network Model

Wan-Su Kim, Hyun-Ki Kim, Sung-Kwun Oh
 Department of Electrical Engineering, The University of Suwon

Abstract - In this paper, we propose Genetic Algorithms(GAs)-based Optimal Polynomial Neural Networks(PNN). The proposed algorithm is based on Group Method of Data Handling(GMDH) method and its structure is similar to feedforward Neural Networks. But the structure of PNN is not fixed like in conventional Neural Networks and can be generated. The each node of PNN structure uses several types of high-order polynomial such as linear, quadratic and modified quadratic, and is connected as various kinds of multi-variable inputs. The conventional PNN depends on experience of a designer that select No. of input variable, input variable and polynomial type. Therefore it is very difficult a organizing of optimized network. The proposed algorithm identified and selected No. of input variable, input variable and polynomial type by using Genetic Algorithms(GAs). In the sequel the proposed model shows not only superior results to the existing models, but also pliability in organizing of optimal network. The study is illustrated with the ACI Distance Relay Data for application to power systems.

1. 서 론

인간의 문명이 발달함에 따라 시스템이 복잡해지고 대규모 구조로 변하여 연구인들이 시스템을 모델링 하는데 많은 어려움을 겪고 있다. 시스템이 복잡하고 대규모 구조인 경우에는 함수식으로 모델의 표현이 한정되지 않기 때문에 회기분석을 적용할 수 없는 경우도 있다. 따라서 일반적인 수학적 방법보다는 퍼지, 신경망 등과 같은 진보된 지능 기반 연산기술에 많은 관심이 집중되고 있다. 하지만 두 이론은 추정방법의 계수가 많으면 추정에 필요한 데이터의 양이 방대해지는 문제점을 지니고 있다. 그러므로 시스템에 대하여 파악하기 힘든 변수들에 대해서는 이에 대한 경험적 지식을 갖춘 모델설계자를 필요로 한다. 그러나 모델설계자가 이런 변수들을 추측하고 경험에 의존하여 시스템을 설계한다면, 좋은 예측 신뢰도를 가진 모델을 만들거란 거의 불가능하게 된다. 이러한 단점을 극복하기 위하여, 모델 설계시 설계자의 선입견을 첨가하지 않는 순수한 객관적 모델구축이 필요하게 되었다. 이런 문제를 해결하기 위한 한 가지 방법으로 A. G. Ivakhnenko는 Group Method of Data Handling (GMDH) 알고리즘을 제안하였다[1-3]. GMDH는 2변수 2차식에 의한 부분표현식을 계층적으로 조합하여 비선형 모델 추정식을 얻을 수 있다. 그러나 자연계의 다양한 시스템을 예측하는데 있어 2변수로 국한을 하여 다양한 입력변수들끼리의 상호의존적인 면을 약하게 하였으며, 2차식으로는 다소 복잡한 시스템을 표현하기에는 역부족이다.

이를 개선하기 위해 S. K. OH는 Self-Organizing Polynomial Neural Networks(SOPNN 또는 PNN)을 설계하였다[4, 5]. SOPNN 모델은 입력변수의 선택과 입력력 데이터의 분할, 부분표현식을 정의하여 시스템 방정식을 예측한다. 즉 입력변수를 2로 한정짓지 않고 설계자가 원하는 수만큼 선택할 수 있게 설계하였다. 하지만 이 모델 또한 선호된 모델을 구하기 위해서는 노드의 입력변수의 수, 입력변수 그리고 다항식 차수를 설계자의 시행착오에 의존하여 결정해야만 한다. 따라서 최적의 성능을 얻기 위하여 각 노드의 부분표현식을 구성하는 입력변수의 수, 입력변수 그리고 다항식 차수를 결정하는 객관적이고 신뢰성 높은 새로운 자동 선택방법이 필요하다.

이에 본 논문에서는 최적탐색 방법인 유전자 알고리즘 [6, 7]을 이용하여 입력변수의 수와 그에 따른 입력변수 그리고 다항식의 차수를 탐색하는 Genetic Algorithms-based Polynomial Neural Networks(GAs-based PNN)를 제안한다. 이 모델은 설계자의 경험에 의존하지 않고 유전자 알고리즘을 이용하여 입력변수의 수, 입력변수 그리고 다항식 차수를 선택한다.

본 논문은 GAs-based PNN 구조로 최적의 모델을 구축하고, 전력시스템에 적용하기 위하여 지중선로 시스템의 ACI 거리계전 데이터를 사용하여 제안된 모델의 타당성, 정확성 및 예측 성능 등을 보인다.

2. 유전자 알고리즘 기반 다항식 뉴럴 네트워크 (GAs-based PNN)

2.1 다항식 뉴런 (PN)

PN은 가장 기본이 되는 유닛으로 선택되어진 입력이 들어오면 하나의 다항식을 이루게 되는 연산소이다.




그림 1. 다항식 뉴런(PN) 구조

그림 1은 2입력일 때의 2차 다항식 뉴런(PN)의 구조를 보여주고 있다.

2.2 다항식 뉴럴 네트워크(PNN)

GMDH 알고리즘을 기반으로 PNN 설계 알고리즘은 다음과 같이 단계별로 설명된다.

[단계 1] 출력변수 y에 관계하는 n개의 시스템 입력변수를 결정한다.

[단계 2] 전체 입력력 데이터를 학습용 데이터와 테스트 용 데이터로 분할한다.

[단계 3] PNN의 다양한 구조 선택을 통하여 주어진 시스템 환경의 변화에 적응할 수 있는 유연성을 가진 모델을 구축한다.

[단계 4] 선택한 모델에 따라 각 노드의 입력변수 수와 다항식 차수를 결정한다.

표 1. 회귀다항식의 차수 형태

입력수 차수(Type)	1	2	3
1(Type 1)	Linear	Bilinear	Trilinear
2(Type 2)	Quadratic	Biquadratic	Triquadratic
2(Type 3)		Modified Biquadratic	Modified Triquadratic

[단계 5] 선형 회귀분석에는 학습 데이터를 사용하고, 성능지수 즉 동정오차는 다음의 식 (1)을 이용한다.

$$E = \frac{1}{N_i} \sum_{m=1}^{N_i} |y_m - \hat{y}_m| \quad (1)$$

여기서, N_i 는 학습데이터 총 수이다.

추정된 후반부 다항식에 테스트 데이터를 사용하여 식 (1)의 테스트 데이터에 대한 동정오차 에러를 계산한다.

[단계 6] 단계 5의 현재 층에서 얻어진 최소 동정오차 E_i 이 다음의 부등식을 만족하는 경우에 알고리즘을 종료한다.

$$E_i \geq E_s \quad (2)$$

단, E_s 는 이전 층의 최소 동정오차 이다.

[단계 7] 현재 층에서 보존된 노드의 출력들에서 다음의 새로운 입력들이 구성되고, [단계 4]부터 [단계 7] 까지 반복한다.

본 논문에서는 복잡한 구조를 피하기 위해 식(2)의 종료판정을 사용하지 않고, 5층으로 제한하도록 한다.

2.3 유전자 알고리즘

유전자 알고리즘(GAs)은 1975년 John Holland에 의해서 개발되었으며, 이것은 이진수의 형태로 표현된 유전자와 적합도들로 이루어진 개체들의 집합을 이용해서 최적화 과정을 수행하는 알고리즘이다[6]. 기존의 최적화 알고리즘은 최적화 하고자 하는 목적함수를 미분해서 탐색을 수행하는 반면, GAs는 선택연산자, 교배연산자, 돌연변이연산자와 적합도를 이용해서 탐색을 수행한다[7].

본 논문에서는 재생산(Reproduction)연산으로 엘리트 전략(Elitist strategy)과 함께 roulette-wheel 방식, 돌연변이(mutation)연산으로 invert 방식, 교차(crossover)연산으로 one-crossover 방식을 사용하였다. 위에서 언급한 PNN 구조에서의 각 노드의 입력변수 수와 이에 해당하는 입력변수 그리고 다항식 차수의 선택을 최적화 알고리즘인 유전자 알고리즘을 통해 탐색하여 경험자의 경험에 의존한 구조의 최적화를 객관적이고 효율적으로 구축하게 된다.




그림 2. 유전자 최적화를 이용한 PN 설계

2.4 하중계수를 가진 목적함수

본 논문에서는 근사화 및 일반화의 상호 균형과 의존 능력을 가진 합성 목적함수(성능지수)를 이용하여 상호 연계된 최적 모델 구조를 생성한다[8].

$$f(PI, EPI) = \theta \times PI + (1 - \theta) \times EPI \quad (3)$$

본 논문에서는 식(3)의 하중계수 값이 $\theta=0$ 인 경우와 $\theta=0.5$ 인 경우를 고찰 하도록 한다.

3. 시뮬레이션 및 결과 고찰

전력시스템에 적용하기 위하여 ACI 거리계전 데이터를 사용하였다. 성능지수 식은 식(1)을 이용한다. ACI 거리계전 데이터는 고장거리(500, 900, 1500, 2000, 2500, 3000, 3400, 4000, 4400, 5000m)와 접지저항(1, 2, 3, 4, 5, 6, 7, 8, 9, 10 Ω) 변화에 따른 저항(R)값 100개와 리액턴스(X)값 100개, 그리고 목표치 저항(R)값 10개와 리액턴스(X)값 10개로 이루어진 데이터이다.

전체 220개 데이터 중에서 고장거리에 따른 변화를 기준으로 다음과 같이 학습 데이터와 테스트 데이터를 분류한다.

[학습 데이터]-고장거리 500, 1500, 2500, 3400, 4400m의 각 접지저항에 따른 R 값 50개와 X 값 50개 총 100개의 데이터를 입력으로 하고, 목표치의 R 값 5개와 X 값 5개의 데이터를 각각 출력으로 한다.

[테스트 데이터]-고장거리 900, 2000, 3000, 4000, 5000m의 각 접지저항에 따른 R 값 50개와 X 값 50개 총 100개의 데이터를 입력으로 하고, 목표치의 R 값 5개와 X 값 5개의 데이터를 각각 출력으로 한다.

그림 3과 4는 하중 계수 값 $\theta=0.5$ 일 때 출력 \hat{R} 과 \hat{X} 의 성능지수를 나타내고, 그림 5와 6은 하중 계수 값 $\theta=0$ 일 때 출력 \hat{R} 과 \hat{X} 의 성능지수를 나타낸 것이다. 그림에서 $\Delta 2(A)$ 는 2입력이고, $\square 3(B)$ 는 3입력을 나타낸다. 그리고 각각의 입력에 대하여 A(최적노드 ; 다항식 차수), B(최적노드 ; 다항식 차수)를 나타낸다.




그림 3. $\theta=0.5$ 일때 출력 \hat{R} 의 성능지수






그림 4. $\theta=0.5$ 일때 출력 \hat{X} 의 성능지수

그림 3과 4에서 알 수 있듯이 층이 증가할수록 모델의 근사화와 일반화 능력이 뚜렷하게 향상되는 것을 알 수 있다. 제안한 방법으로 모델을 구축하였을 경우, 하중계수 값이 $\theta=0.5$ 일 때 $PI=0.0014684$, $EPI=0.0056267$ 의 좋은 결과를 얻을 수 있었다.




(a) Training data (b) Testing data
그림 5. $\theta=0$ 일때 출력 \hat{R} 의 성능지수



(a) Training data (b) Testing data
그림 6. $\theta=0$ 일때 출력 \hat{X} 의 성능지수


그림 5와 6은 하중계수 값이 $\theta=0$ 인 경우로 테스트 데이터를 기조로 동정한다.

그림 7은 하중계수 값이 $\theta=0.5$ 이고 입력이 3입력인 경우에 3층에서 네트워크를 나타낸 것이다.



(a) \hat{R} 의 최적 구조 (b) \hat{X} 의 최적 구조
그림 7. 최적의 GAs-based PNN 구조 ($\theta=0.5$)

그림 8은 하중계수 값이 $\theta=0.5$ 이고 입력이 3입력인 경우에 5층일 때의 주어진 데이터의 출력값과 모델의 출력값을 비교한 그림이다.



(a) 출력 \hat{R} (b) 출력 \hat{X}
그림 8. 실제 출력과 모델 출력 곡선

표 2는 2입력 2출력의 ACI 거리계전 데이터를 사용하여 얻어진 기존 PNN 모델과 본 논문에서 제안된 GAs-based PNN 모델의 동정오차비교이다. 성능지수는 식(1)에 의해서 계산되며 모델 출력 \hat{R} 과 \hat{X} 에 대하여 각각 비교한 것이다. 표에서도 알 수 있듯이 제안한 알고리즘의 성능이 우수함을 알 수 있다.

표 2. ACI 거리계전 데이터의 동정오차비교

Model	Model Output	Input Max	Node	T	Performance Index	
					PI	EPI
PNN	\hat{R}	2	1 2	2	0.0030989	0.0088285
	\hat{X}	2	1 2	2	0.0052908	0.0150730
Our Model	\hat{R}	2	21 30	2	0.0016426	0.0059677
		3	11 4 18	3	0.0014684	0.0056267
	\hat{X}	2	25 29	2	0.0028045	0.0101890
		3	24 26 0	2	0.0024480	0.0098476

4. 결 론

본 논문에서는 유전자 알고리즘을 이용하여 다항식 뉴럴 네트워크의 최적 구조를 설계하였다. 기존의 PNN 알고리즘은 층을 구성하는 노드의 입력변수의 수와 다항식 차수 그리고 고정된 입력변수 선택을 설계자의 경험에 의해서 결정함으로써 객관적이고 주어진 데이터의 특성에 맞는 최적의 모델을 구축하지 못하였고, 또한 최적의 모델을 구축하기 위해서 많은 시행착오를 필요로 하였다. 이러한 기존의 PNN 모델의 구조의 한계를 극복하기 위하여 최적화 방법인 유전자 알고리즘을 이용하여 노드의 입력변수의 수와 그에 해당하는 입력변수 그리고 다항식 차수 등의 파라미터를 최적 선택하여 모델 구축에 있어서 유연성과 정확성을 가지며 더욱 정확한 예측 능력을 가진 최적화된 PNN 모델구조를 구축하였다. 이러한 최적화된 GAs-based PNN 구조를 통하여 ACI 거리계전 데이터의 성능을 확인하였다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력연구원 (R-2003-B-274) 주관으로 수행된 과제임.

[참 고 문 헌]

- A. G. Ivahnenko, "The group method of data handling: a rival of method of stochastic approximation", Soviet Automatic Control, 1-3, pp. 43-55, 1968
- A. G. Ivakhnenko, "Polynomial theory of complex systems", IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-1, pp. 364-378, 1971
- A. G. Ivakhnenko and H. R. Madala, Inductive Learning Algorithms for Complex Systems Modeling, CRC Press, London, 1994
- S. K. Oh and W. Pedrycz, "The design of self-organizing Polynomial Neural Networks", Information Science, Vol. 141, pp. 237-258, 2002
- S. K. Oh and W. Pedrycz and B. J. Park, "Polynomial Neural Networks Architecture: Analysis and Design", Computers and Electrical Engineering, 2002(in press)
- Holland, J. H., Adaptation in Natural and Artificial Systems. The University of Michigan Press, Ann Arbor, 1975
- D. E. Goldberg, Genetic Algorithm in search, Optimization & Machine Learning, Addison Wesley, 1989
- 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 Systems, Vol. 115, No. z, pp. 205-230, 2000