

# 신경회로망을 이용한 불량 Data 처리에 관한 연구

°김 익 현\*      박 중 근\*  
\* 서울대학교 전기공학부

## A Study for Bad Data Processing by a Neural Network

°Ik-Hyeon Kim\*      Jong-Keun Park\*  
\* Dept. of Electrical Eng. Seoul National University

### ABSTRACT

A Study for Bad Data Processing in state estimation by a Neural Network is presented. State estimation is the process of assigning a value to an unknown system state variable based on measurement from that system according to some criteria. In this case, the ability to detect and identify bad measurements is extremely valuable, and much time in order to achieve the state estimation is needed.

This paper proposed new bad data processing using Neural Network in order to settle it. The concept of neural net is a parallel distributed processing. In this paper, EBP (Error Back Propagation) algorithm based on three layered feedforward network is used.

### 1. 서 론

최근에 각광을 받고 있는 신경 회로망 계산(Neural Network Computing)은 종래의 순차형 전자계산기를 보완하는 병렬분산 처리 시스템이다[1]. 이 시스템의 모델은 생체의 신경세포(Neuron)를 모의한 간단한 처리요소가 결합하여 다른 Neuron으로의 신호전달로써 정보처리를 수행하는 것으로 병렬 분산성을 특징으로 하고 있다.

현재 연구되고 있는 시스템의 구조는 Rumelhart형과 Hopfield형으로 대별되는데 특히 Rumelhart형은 Pattern을 분류, 인식하고 불량 Data를 검출하는데 유용하다[2] [3]. Rumelhart형의 대표적 모델로는 다계층 Feedforward Network으로 본 논문에서는 이 모델의 EBP(Error Back Propagation) Algorithm을 이용하여 전력계통의 상태 추정시 불량 Data 처리에의 적용 가능성을 제시하였다.

상태추정은 시스템에서 측정되는 측정치로부터 상태변수치를 추정하는 것으로 이 경우 측정치에 불량 Data가 따르므로 이를 제거함으로써 적정상태 추정치를 구하는 것이 필요하다[4].

상태추정의 일반적인 방법으로는 상태추정후 불량 Data를 처리하고 재 상태추정을 실시하는데, 상태추정에 비선형 역함수를 계산하는 어려움이 따르므로 불량 Data를 처리하고 재 상태추정을 실시하는데 많은 시간이 소요된다.

이를 해결하기 위해 많은 연구가 진행되고 있으나 본 논문에서는 접근방법을 달리하여 상태추정시 입력력을 대표 Pattern화하여 Neural Net에 교육(Learning)시킨 후 이를 이용하여 상태 추정전에 불량 Data를 제거하고 양호한 Data만을 상태추정에 입력시켜 상태추정을 고속화하는 가능성을 제시하였다.

본 논문에서는 제안된 Neural Net의 구조와 특성, 상태추정에의 적용 및 시뮬레이션 결과를 보인다.

### 2. 신경회로망 : 병렬 분산처리

전형적인 3계층 Feedforward Network는 다음 그림 1과 같이 표현된다[5].

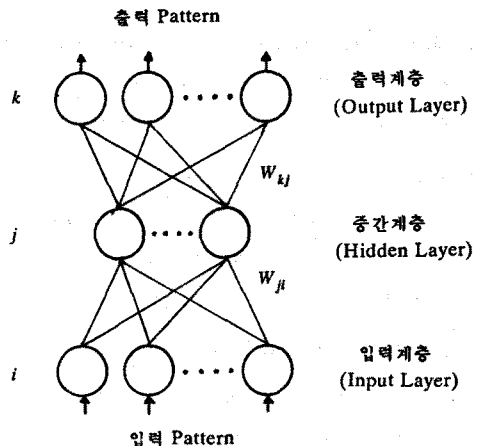


그림 1. 3계층 Feedforward Network

그림 1의 신경 회로망 모델에서 EBP(Error Back Propagation) Algorithm을 사용한 수식화는 다음과 같다.  $O_i$ 가 계층  $i$ 에서의 Unit 출력일 때 계층  $j$ 에서의 Unit의 총 입력의 합은

$$net_{pj} = \sum_i W_{ji} O_{pi} \quad (1)$$

이고 계층  $j$ 의 출력은

$$O_{pj} = f(net_{pj}) = 1 / (1 + \exp[-(net_{pj} - \theta_j) / \theta_0]) \quad (2)$$

$\theta_j$  : threshold

$\theta_0$  : shape

로 표현된다.  $f$ 는 전달함수로서 그림 2와 같이 미분 가능하고 단조증가하는 Sigmoid 함수 형태를 이룬다.




그림 2. Sigmoid 함수

신경 회로망에서 교육(Learning)은 주어진 입력 Pattern을 만족시키기 위한 Weight와 Threshold의 변화과정이다. Weight와 Threshold로 출력 Pattern을 만들고 이를 교사(Teacher) Pattern과 비교한다.

$$e_{pk} = t_{pk} - O_{pk} \quad (3)$$

총 Error의 합은 다음과 같다.

$$E = \frac{1}{2} \sum_p \sum_k (t_{pk} - O_{pk})^2 \quad (4)$$

Gradient Descent법으로  $E$ 가 최소가 되도록 한다. Weight의 변경은 다음 식 (5)와 같다.

$$\Delta W_{ji}(n+1) = \eta(\delta_{pj} O_{pi}) + \alpha \Delta W_{ji}(n) \quad (5)$$

$\eta$  : 가속정수

$\alpha$  : 관성정수

$\delta$  : error signal

$O$  : 출력

출력 Unit의 Error Signal은

$$\delta_{pk} = (t_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \quad (6)$$

이고 중간 Unit의 Error Signal은

$$\delta_{pj} = O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} W_{kj} \quad (7)$$

로 표현된다.

### 3. 상태추정 및 불량 Data 처리

#### 3.1 상태 추정기

상태추정은 다음의 측정 모델에서 측정치  $z$ 로부터 상태변수  $x$ 를 Noise의 영향을 최대한 제거하도록 구하는 것이 목적이다.

$$z = h(x) + w \quad (8)$$

$z$  :  $(m \times 1)$  측정 Vector

$x$  :  $(n \times 1)$  상태 Vector

$w$  :  $(m \times 1)$  측정 오차 Random Vector

$h(x)$  : 비선형 함수 Vector

$m > n$

상태 Vector  $x$ 의 추정치  $\hat{x}$ 는 Weighted Least Square Sense를 사용할 경우, 다음과 같이 구해진다.

$$\min J(\hat{x}) \quad (9)$$

$$J(\hat{x}) = [z - h(\hat{x})]^T W [z - h(\hat{x})]$$

$W$  :  $w$ 의 Covariance Matrix의 Inverse

위식의 해는 Stationary point에 존재하며, 따라서 다음의 비선형 연립 방정식 풀이를 통해  $\hat{x}$ 가 구해진다.

$$\frac{\partial J}{\partial \hat{x}} = -2 \left[ \frac{\partial h(\hat{x})}{\partial \hat{x}} \right]^T W [z - h(\hat{x})] = 0 \quad (10)$$

#### 3.2 불량 Data 처리

불량 Data의 검출(Detection)은 Hypothesis Testing[5]을 통해서 한다.

$$Prob(J(\hat{x}) > t_j) = \alpha \quad (11)$$

$\alpha$  : Probability for False Alarm

의 식을 바탕으로 하여

$$J(\hat{x}) > t_j \quad (12)$$

인 경우에, 현재의 Data들 중에 불량 Data가 있다고 판정한다.

불량 Data의 식별(Identification)은

$$y_i^{norm} = \frac{z_i - \hat{z}_i}{\sigma_{y_i}} \quad (13)$$

$$\hat{z}_i = h_i(\hat{x})$$

를 통해,  $y_i^{norm}$ 의 크기가 일정한 Error bound보다 크면  $z_i$ 가 불량 Data라고 판정한다.

4. 불량 Data 처리에 신경회로망을 이용한 방법

기존의 상태추정 방법은 상태추정 후 불량 Data를 처리하고 재 상태 추정을 실시하므로 많은 시간이 소요되었다. 본 논문에서는 신경 회로망의 내 Noise성, 고속성, 보간성능을 이용하여 신속하게 불량 Data를 처리할 수 있는 방법을 제안하였다.

신경 회로망에 측정치  $z$ 들을 입력 Pattern화하고 이에 대응되는 추정된 측정치  $\hat{z}$ 들을 계산하여 출력 Pattern화한다. 이 입력-출력 Pattern을 신경 회로망에 교육(Learning)시키면, 이 신경 회로망에 유사한 입력 Pattern이 들어올 때,  $\hat{z}$ 가 출력 Pattern으로서 나오게 된다. 이  $\hat{z}$ 로부터 식 (12)를 통해 불량 Data를 검출할 수 있으며, 식 (13)을 통해 불량 Data를 식별할 수 있다.

신경 회로망은 Learning이 완료된 후에는 Pattern을 빠르게 인식하여 처리하므로, 기존의 수치적 방법보다 고속으로 불량 Data를 검출, 식별하게 된다.

본 논문에서 제안한 불량 Data 처리 방법을 기존의 방법과 비교하면 그림 3과 같다.

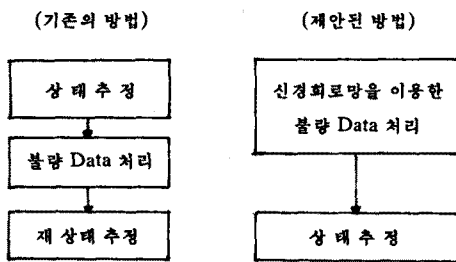


그림 3. 방법 비교

5. 시뮬레이션 결과

본 논문에서 신경회로망을 이용한 불량 data 검출여부를 시뮬레이션하기 위해 다음과 같은 선형 상태추정기를 이용하였다.

$$z = Hx + w \quad (14)$$

$z$  : 측정 Vector (18×1)

$x$  : 상태 Vector (12×1)

$H$  : 선형 Matrix (18×12)

$w$  : 측정 오차 Vector (18×1)

선형 상태 추정기를 이용하여 그림 4의 예와 같은 6개의 대표 Pattern을 구성하였다.




그림 4. Pattern 5의  $z$ 와  $\hat{z}$

신경 회로망은 EBP Algorithm을 이용하여 다음과 같은 조건하에서 Learning을 하였다.

- 출력계층 Unit : 18개
- 중간계층 Unit : 10개
- 입력계층 Unit : 18개
- $\eta$  : 0.8
- $\alpha$  : 0.5

Learning 결과 그림 5와 같이 Total Error가 수렴하였다.




그림 5. Error 수렴

Learning 후 입력 Pattern에 대한 출력 Pattern은 그림 6의 예와 같이 양호한 결과를 보였다.




그림 6. 신경회로망에서 Pattern 5의 입출력

불량 Data 처리 능력을 Test하기 위해 Node 4와 Node 16에 부호가 반전된 불량 Data를 포함한 Pattern 2와 유사한 입력 Pattern을 사용하였을 때 다음 그림 7과 표 1과 같이 불량 Data를 검출할 수 있었다.




그림 7. Pattern 2의 불량 Data 검출

표 1. 그림 7에 대한 Data

Node	입력	불량입력	출력	$y_i^{norm}$
1	0.57	0.57	0.636745	6.674562
2	-0.5	-0.48	-0.58786	10.78668
3	0.5	0.51	0.541629	3.162968
4	-0.2	0.22	-0.11610	33.61076
5	0.8	0.81	0.726451	8.354872
6	0.75	0.75	0.548399	20.16003
7	0.9	0.91	0.936483	2.648340
8	0.3	0.31	0.375883	6.588380
9	-0.07	-0.067	-0.06800	0.100921
10	0.95	0.95	0.917147	3.285267
11	0.61	0.62	0.601263	1.873687
12	0.24	0.25	0.135217	11.47821

13	1	1	0.961540	3.845962
14	0.32	0.34	0.246892	9.310777
15	0.65	0.66	0.643729	1.627008
16	0.28	-0.28	0.146574	42.65747
17	-0.045	-0.044	0.021921	6.592173
18	0.58	0.59	0.453204	13.67958

Pattern 6에서 node 5에 부호반전, node 10에 0으로 Setting된 불량 Data가 포함되었을 때도 양호한 결과를 내었다.

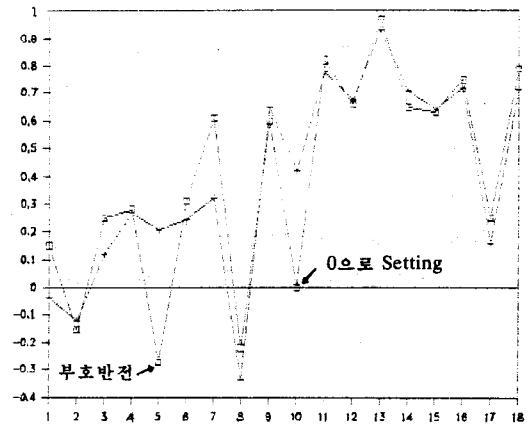


그림 8. Pattern 6의 불량 Data 검출

각 Pattern에 대해 다양한 Data를 사용하여 시뮬레이션한 결과 양호한 불량 Data 인식 능력을 보였다.

## 6. 결 론

본 논문에서는 신경 회로망을 이용하여 상태 추정시 불량 Data 처리 방법을 제안하였다. 시뮬레이션의 편의상 선형상태 추정기를 이용하였는데 이 경우 양호한 불량 Data 처리 결과를 얻을 수 있었다. 이 방법을 사용하였을 경우의 장점은 상태 추정시 불량 Data를 처리하고 재 상태추정을 실시하는데서 발생하는 시간지연을 Pattern화된 신경 회로망을 통해 불량 Data를 고속처리함으로써 상태추정 전 과정의 시간소요를 줄이는데 있다.

그러나 실제 전력계통에 응용하기 위해서는 많은 양의 대표 Pattern을 만들어야 하는 문제점이 있다. 따라서, 위 문제의 해결과 함께 전력계통의 비선형 상태 추정기를 시뮬레이션하여 연구를 더 추진해야 할 필요가 있다.

## 7. 참고문헌

- [1] Y.H. Pao, "Adaptive Pattern Recognition and Neural Network", 1989, Addison-Wesley Publishing Press.

- [2] D.E. Rumelhart and J.L. McClelland, "Parallel Distributed Processing", Vol. 1, Vol. 2, 1986, MIT Press.
- [3] 서촌, "Neural Nets의 전력계통에의 적용에 관한 고찰", 일본 전기학회 시스템제어 연구회, SC-88-20, 1988
- [4] A.J. Wood and B.F. Wollenberg, "Power Generation, Operation and Control", Chap 12, 1984, John Wiley & Sons Press.
- [5] D.J. Sobajic and Y.H. Pao, "Artificial Neural Net Based Dynamic Security Assessment for Electric Power System", IEEE Trans, on Power Systems, Vol. 4, No. 1, pp.220-228, Feb. 1989.
- [6] L. Mili and Th. Van Cutsem, "Hypothesis Testing Identification", IEEE Trans, on Power Apparatus and Systems, Vol. PAS-103, No. 11, November, 1984