

신경망을 이용한 전력품질 문제 인식

김홍균, 이진목, 최재호
충북대학교 대학원 전기공학과

Recognition of Power Quality Problems using Neural Network

Hongkyun Kim, Jinmok Lee, Jaeho Choi
School of Electrical and Computer Engineering, Chungbuk National University

ABSTRACT

This paper presents about recognition power quality problems using neural network. Neural network is a very powerful way to detect and classify power quality problems. But the transient like as very fast problems is difficult event to recognize. Wavelet transform is appropriate method for detecting signal irregularities. So we make features from wavelet transform. Finally we get high efficiency for detecting and classifying almost all power quality problems.

1. 서 론

비선형 부하의 증가와 함께 외란에 민감한 시스템이 증가함으로 인해서 전력품질 문제에 대한 많은 연구가 진행되고 있다. 전력품질 문제의 연구 중심은 다양한 외란들을 얼마나 정확하게 인식하고 분류할 수 있는가이다. 최근, 전력품질 문제 인식 및 분류를 위해서 신경망, 퍼지 및 확률적인 접근이 진행되고 있다. 전력품질 문제에서 인식 및 분류하는 문제에서 확률적인 접근은 충분한 데이터를 얻기 어려워 적용하기 힘든 반면 신경망은 다양한 전력품질 문제를 학습에 의해서 정확한 결과를 얻을 수 있기 때문에 많은 연구들이 집중되고 있다^[1]. 그러나 신경망의 입력을 어떻게 주는가에 따라 결과는 상이하며 특히 시간영역에서 해석하기가 매우 어려운 과도상태 문제들은 더욱 어렵다. 그러나 변화를 감지하는데 탁월한 웨이블릿 변환은 과도상태 해석에 매우 강하므로 웨이블릿 변환을 기본으로 하여 여러 특징들을 추출하여 전력품질 문제의 인식률을 향상시켰다.

2. 웨이블릿 변환

웨이블릿 변환은 모웨이블릿 함수를 척도 와 이동을 통하여 비정체신호에 대한 분석에 사용하는 수학적 이론이다. 이산웨이블릿 변환 (DWT)는 식 (2)와 같다.

$$\phi_{m,n}(k) = a_0^{-\frac{m}{2}} \phi(a_0^{-m}k - nb_0) \quad (1)$$

$$DWTx(m, n) = \sum_k x(k) \phi\left(\frac{k - nb_0 a_0^m}{a_0^m}\right) \quad (2)$$

$$c_{l+1}[n] = \sum_k h[k-2n] c_l[k] \quad (3)$$

$$d_{l+1}[n] = \sum_k g[k-2n] c_l[k] \quad (4)$$

식 (1)에서의 함수 $\phi_{m,n}(k)$ 는 모함수로 $a = a_0^m$ 과 $b = nb_0 a_0^m$ 에 의해 크기조정과 이동을 한다. 이때 a_0 와 b_0 는, $a_0 > 1$, $b_0 > 0$ 를 만족하는 상수이며 m 과 n 은 양의 정수이다. 이산신호 $x[n]$ 이 $c_0[n] = x[n]$ 라 할 때, 다분해기법 (Multiresolution Signal Decomposition: MSD)은 크기 l 에서 신호 $c_1[n]$ 은 $c_{l+1}[n]$ 신호로 균사화 되고, $d_{l+1}[n]$ 신호로 세분화 되며 이때 $h[n]$ 은 고역통과필터 $g[n]$ 은 저역통과필터의 기능을 한다. 그림 1에서와 같이 다해상도 해석에서 균사화 된 신호를 다분해기법을 사용하여 여러 번 반복 될 수 있다^[2,3].

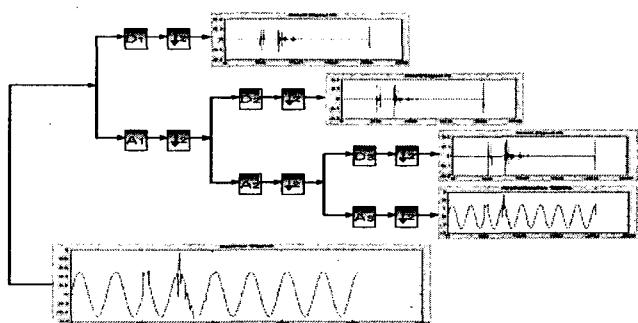


그림 1 이산웨이블릿 변환의 다해상도 해석
Fig. 1 MSD of discrete-time wavelet transform

3. 다층 신경망

방사기저함수 신경망은 식 (5)와 같은 가우시안 함수로 정의된다. 첫 번째 층은 입력층이며 입력 데이터로 구성된다. 이 분리된 $y(k)$ 벡터는 중간층에 연결되며 출력층은 중간층의 데이터에 가중치를 부여하여 나타난다. 함수 $h_j(y(k))$ 를 중간층 뉴런의 출력을 j , 뉴런의 중심을 c , 그리고 가중치를 w_j 라 한다. 신경망의 출력식은 식 (8)과 같다.

$$h(y) = \exp\left(-\frac{\|y - c\|^2}{\sigma^2}\right) \quad (5)$$

$$y(k) = [y(k), y(k-1), \dots, y(k-m+1)]^T \quad (6)$$

$$c = [c_1, c_2, \dots, c_N]^T \quad (7)$$

$$\begin{aligned} f(y(k)) &= \sum \omega_j \cdot \exp\left(-\frac{\|y - c_j\|^2}{\sigma^2}\right) \\ &= \sum_{j=1}^m \omega_j \cdot h_j(y(k)) \end{aligned} \quad (8)$$

일반적인 방사기저함수 신경망은 그림 2와 같이 입력층, 중간층, 출력층의 3층 구조를 가지고 있다.

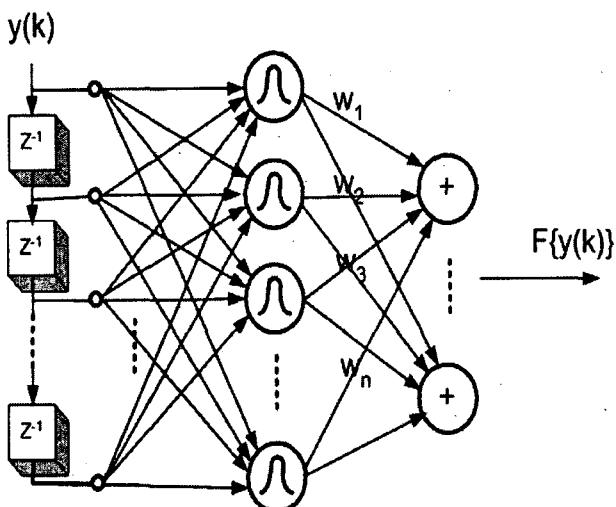


그림 2 방사기저함수 신경망의 구조

Fig. 2 Schematic of a radial basis function neural network

실험에서 방사기저함수 신경망은 다음의 3가지 변수값을 정해야한다.

중심 c_j

가중치 ω_j

반경 σ

방사기저함수의 중심을 최적화를 위해 외부교사의 도움이 필요 없는 k-평균 이론을 이용하였다. 비감독 학습은 학습을 외부에서 관리하는 외부교사가 없다는 것을 의미한다. 가중치 학습에서는 최소자승법(LMS) 이론을 사용하였다. 모든 RBF 중심 넓이의 평균을 반경으로 사용하였다^[4].

분류대상은 Normal (Class 1), Sag (Class 2), Swell (Class 3), Transient (Class 4), Harmonic (Class 5)의 5가지를 실험하였다. 100가지 유형을 학습에 사용하였고, 100가지 유형을 확인을 위해 사용하였다. 각각의 외란마다 20가지의 유형을 실험에 사용하였다.

가장 유용한 입력 특징은 외란을 효과적으로 인식하는 것이며 이러한 특징의 벡터수가 최소가 되는 것이 매우 중요하다. 본 논문에서는 식 (9) ~ 식 (15)으로 정의되는 평균 (μ), 분산 (σ^2), 왜도 (g_1), 침도 (g_2), 실효값(rms), 파형률(ff), 파고율(cf), FFT(X(k))의 8가지 특징들을 사용하였다.

$$\mu = Ex_t = \frac{1}{N} \sum_{t=1}^N x_t \quad (9)$$

$$\sigma^2 = E(x_t - Ex_t)^2 = \frac{1}{N} \sum_{t=1}^N (x_t - \mu)^2 \quad (10)$$

$$g_1 = \sqrt{\frac{1}{6N} \sum_{t=1}^N (\frac{x_t - \mu}{\sigma})^3} \quad (11)$$

$$g_2 = \sqrt{\frac{N}{24} \left\{ \frac{1}{N} \sum_{t=1}^N (\frac{x_t - \mu}{\sigma})^4 - 3 \right\}} \quad (12)$$

$$rms = \frac{1}{N} \sum_{t=1}^N x_t^2 \quad (13)$$

$$ff = \frac{\mu}{rms} \quad (14)$$

$$cf = \frac{peak}{rms} \quad (15)$$

$$X(k) = \sum_{n=1}^N (x(n) * \exp(\frac{-j\omega(k-1)(n-1)}{N})) \quad (16)$$

4. 시뮬레이션 결과

시뮬레이션의 전체 구성도는 그림 3과 같다. 샘플링된 전력 품질 데이터를 db4의 모함수를 이용하여 이산웨이블릿 변환을 하여 근사신호와 상세신호를 만든다. 이때 테이터의 축소를 위해서 다운샘플링을 한다. 이렇게 얻은 데이터를 8가지의 특징을 추출하고 이 결과를 신경망의 입력으로 사용하였다.

분류결과가 표 1에서 나타내고 있다. 정상상태와 순시전압상승은 모두 분류 한 반면 순시전압강하는 10%, 과도상태는 5%, 고조파 5%를 분류하지 못하였다.

표 1 인식 결과
Table 1 Classification results

True Class	Classification Results				
	1	2	3	4	5
1	20	0	0	0	0
2	1	18	1	0	0
3	0	0	20	0	0
4	0	0	0	19	1
5	0	0	0	1	19

표 2 인식률
Table 2 Percentage of recognition rate

PQ Event	Recognition Rate(%)
Normal	100
Sag	90
Swell	100
Transient	95
Harmonic	95
Total	96

5. 결 론

신경망을 이용한 전력품질 연구들은 보다 정확하고 높은 인식률을 갖는 것이 목적이이다. 본 논문에서 제안하는 전력품질 추정 방법은 구조가 간단하다. db4를 이용한 이산 웨이블릿 변

한 후 여러 가지 특징 추출하여 여러 가지 전력품질 문제의 인식에 높은 효율을 얻었다. 본 논문의 방사기저함수 신경망은 MLP 이론보다 빠르게 학습하여 근사화하기도 쉬운 특징이 있다.

전력품질 문제를 분류한 결과 정상상태와 순시전압상승은 모두 분류 한 반면 순시전압강하는 10%, 과도상태는 5%, 고조파 5%를 분류하지 못하였다.

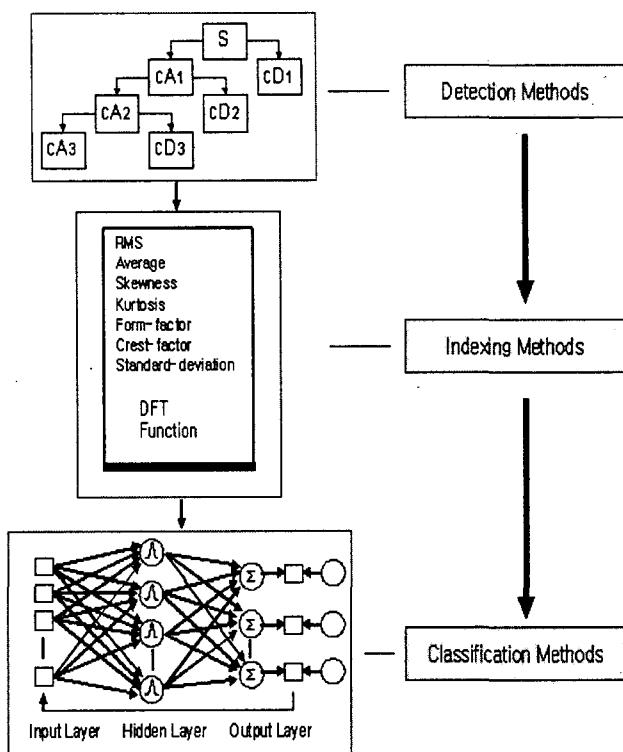


그림 3 전체 시뮬레이션 구성도
Fig. 3 Simulation flowchart

참 고 문 현

- [1] S. Santoso, E. D. Powers, W. M. Grady, and A. C. parsons, "Power Quality Disturbance Waveform Recognition using Wavelet-Based Neural Classifier-Part 1: Theoretical Foundation", Trans. on power delivery, Vol. 15, No. 1, 2000, January.
 - [2] J. Chen, W. Kinsner, and B. Huang, "Power System Transient Modeling and Classification", Proc. of the 2002 IEEE Canadian Conf. on Electrical & Computer Engineering, pp. 184-189, 2002.
 - [3] X. Xu and M. Kezunovic, "Automated Feature Extraction from Power System Transients using Wavelet Transform", Proc. of OWERCON'2002, Vol. 4, pp. 1994-1998, 2002.
 - [4] J. D. Hoyt and H. Wechsler, "RBF Models for Detection of Human Speech in Structured Noise", Conf. on Neural Networks-IEEE World Congress on Computational Intelligence, Vol. 7, pp. 4493-4496, 1994.