

전력 외란의 자동 식별 알고리즘

"최봉준", 김봉수", 김진오", 남상원", 오원천"

* 한양대학교 전기공학과, ** 국방과학연구소

On the Automatic Classification of Power Quality Disturbances

Bong-Joon Choi*, Bong-Soo Kim*, Jin-O Kim*, Sang-Won Nam*, Won-Tcheon Oh**

*Dept. of Electrical Engineering, Hanyang Univ., **Agency for Defense Development

Abstract - This paper proposes an effective algorithm for automatic classification of power quality disturbances(PQD), where wavelet theory is utilized for the detection of PQD, and three neural networks such as MLP, RBF, MLP-Class are combined in parallel to classify PQD. To demonstrate the performance of the proposed system, simulation results are provided.

1. 서론

상업 및 산업 시설에서 가전제품에 이르기까지 전력 외란에 민감한 전자 부품 및 장비가 많이 사용되고 있어서 전력 품질이 관심의 대상이 되고 있다. 따라서 전력의 품질을 감시하고 문제점을 찾는 연구가 활발히 진행되고 있다[1,2,3]. 현재 외란의 분류를 위해 주로 사용되고 있는 방법으로는 측정 장비를 이용하여 주기적으로 데이터를 저장한 후, 이를 관측창(observation window)을 통하여 시작과 끝점을, 그리고 외란의 크기를 측정하여 외란의 종류를 식별하는 방법이 제시되고 있다[2]. 그러나 이 방법을 사용하여 시작과 끝점을 측정하는 방법은 짧은 시간 동안 발생하는 외란을 검출하지 못하거나 부정확한 식별 결과를 가져올 수 있으며, 또한 많은 데이터를 저장하고 재생하여야 한다는 단점이 있었다. 따라서 이들을 효율적으로 자동 분류하는 체계적인 방법이 요구되고 있다.

본 논문의 목적은 이러한 전력품질외란의 검출 및 분류를 위한 자동 시스템의 설계에 있다. 즉 기존의 방법과 같이 측정된 데이터를 일정 기간 동안 저장하여 추후 분석하는 대신 현장에 연결된 측정 기구 및 PC를 이용하여 전력을 계속 감시하고, 외란의 발생 즉시 이를 자동으로 검출하고 분류하여 신속하게 외란의 원인을 진단, 해결책을 제시하는 것이다.

본 논문에서 제안한 자동 시스템은 그림 1과 같이 3 단계로 구성되어 있다. 첫째, 전력을 계속 감시하면서 외란을 검출하는 단계로 wavelet을 적용하였다(2절). 둘째, 외란이 검출되었을 경우 검출된 외란으로부터 특징벡터를 추출하는 단계로 AR 모델링을 사용하였다(3절). 마지막으로 검출된 외란을 추출된 특징벡터를 사용하여 식별하는 과정으로 MLP, RBF, MLP-Class 등 세개의 신경회로망을 entropy 방법으로 결합하여 성능이 향상된 식별기를 구성하였다(4절). 그리고 4 절에서 제안된 시스템을 그림 2에 보여진 5종류의 외란(flat-top waveshape disturbance, voltage sag, voltage swell, capacitor energizing transient, harmonic distortion)의 검출 및 식별 실험을 통해 검증해 보이며(5절) 끝으로 결론을 맺는다.

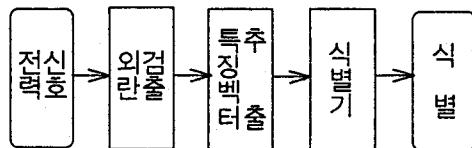


그림 1. 전체 자동 검출 및 식별 시스템

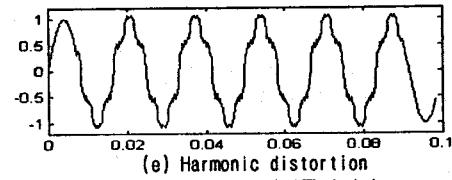
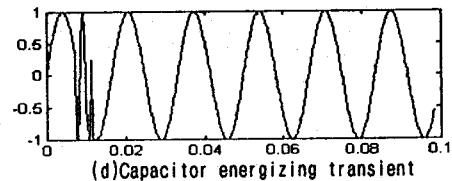
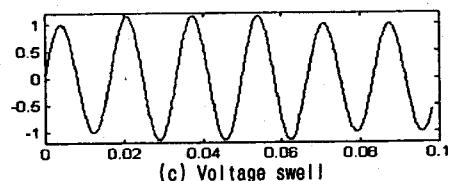
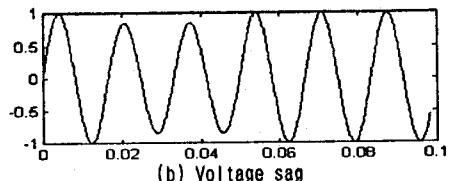
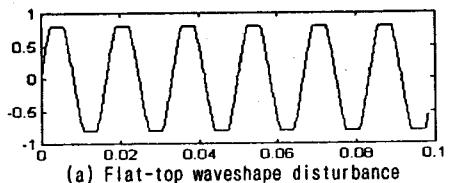


그림 2. 5가지 전력품질외란

2. 외란의 검출

전력품질외란의 검출이란 외란의 시작점과 끝점을 측정하여 외란의 존재 여부 및 구간을 결정하는 것을 말한다. 외란의 검출에 대한 연구 결과로는 인접 사이클의 값을 비교하는 방법, 전문가 시스템을 이용하는 방법, wavelet 변환을 이용하는 방법 등이 있다. 본 논문에서는 외란의 검출을 위하여 시간과 주파수에서 서로 다른 해상도를 갖는 wavelet 이론을 사용하였다[3].

Wavelet 변환은 신호를 시간-주파수 평면에 표현하는 한 방법으로 시간과 주파수에 대해 서로 다른 해상도를 갖는다. 즉 고주파에서는 시간 해상도가, 저주파에서는 주파수 해상도가 좋기 때문에 전력외란신호와 같이 짧은 고주파 신호와 긴 저주파 신호가 동시에 존재할 경우 이들의 에너지 분포를 적절하게 보여줄 수 있다는 장점이 있다. Wavelet 평면에서의 시간 - 주파수 해상도를 그림 3에 나타내었다.

이산 wavelet 변환에 대한 식은 다음과 같다.

$$DWT_{\phi}x(m, n) = \int_{-\infty}^{\infty} x(t) \psi_{mn}^*(t) dt \quad (1)$$

여기서

$$\psi_{mn}(t) = a_0^{-m/2} \psi\left(\frac{t-nb_0a_0^m}{a_0^m}\right) \quad (2)$$

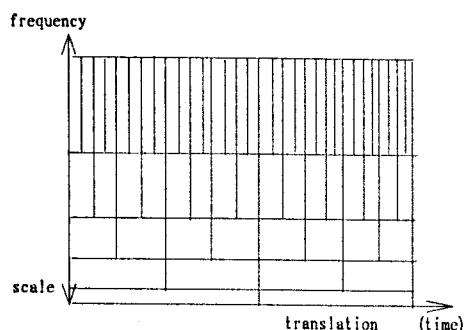


그림 3. Wavelet 평면에서의 시간-주파수 해상도

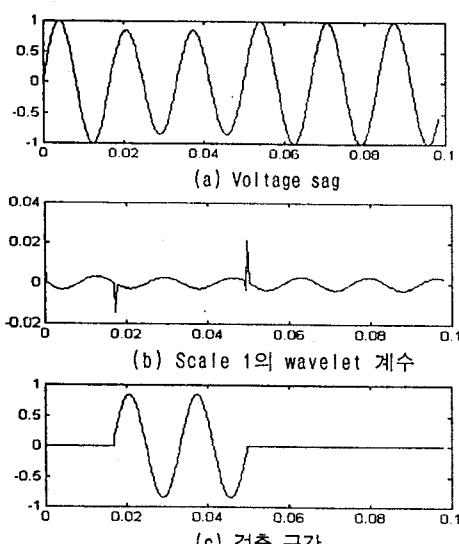


그림 4. Voltage sag의 검출 예

식 (1)에서 $\psi_{mn}(t)$ 는 원형 wavelet이다. Wavelet 변환에서 prototype wavelet은 용용 목적에 따라 다른 형태를 사용할 수 있으며, 본 논문에서는 Daubechies' wavelet을 사용하였다. Wavelet 계수는 multiresolution signal decomposition 방법에 의해 구하였다[4].

외란의 검출은 시간축에서 가장 좋은 해상도를 갖는 scale 1의 wavelet 계수를 이용한다. 이를 사용하여 변환된 신호의 과정을 보면 정상적인 신호가 들어올 때와는 그 특징이 다를 수 있고 외란을 검출하게 된다. 그럼 4는 본 논문에서 사용된 5 가지 외란 중 voltage sag의 검출 부분을 잘 보여주고 있다. 외란이 섞인 부분의 시작점과 끝점을 정확히 검출하고 있음을 알 수 있다.

3. 특징벡터 추출

외란이 검출되었으면 외란의 종류를 판단하기 위해 외란에 대한 적절한 정보를 식별기에 통과시켜야 한다. 식별기의 입력은 가급적 데이터의 수(또는 dimension)가 적고 각 신호의 특징을 잘 표현할 수 있어야 하는데 이를 특징벡터라 한다. 여기서 특징벡터를 사용하는 이유는 식별기의 식별 능력을 좀 더 향상시키는데 그 목적이 있다.

본 논문에서는 외란의 종류마다 다른 모양을 보이고 있는 wavelet 변환된 과정으로부터 특징벡터를 추출하기로 하였다. 검출된 외란신호의 wavelet 과정을 신호 근사화에 많이 사용되고 있는 AR(autoregressive) 모델로 근사화시켜 그 계수를 취한다[5].

그러나 voltage sag나 voltage swell과 같이 wavelet 과정만으로는 구분하기 힘든 외란도 있다. 따라서 본 논문에서는 AR 계수 이외에 외란의 최대 크기도 신호의 특징으로 사용하였다. AR계수를 6차, 8차, 11차로 바꾸어 가면서 실험을 해 본 결과 11차의 AR 계수가 인식율이 가장 좋았다. 따라서 11개의 AR계수와 외란의 크기를 합해 12개의 값으로 구성된 특징벡터를 선택하였다.

4. 식별기

본 논문에서는 주어진 특징벡터를 입력으로 하여 외란 신호를 식별해 내는 식별기를 패턴 분류 기법의 일종인 신경회로망(neural networks)으로 구현하였다. 신경회로망은 패턴들에 대한 사전 지식 없이 패턴으로부터 필요한 정보를 학습할 수 있으며, 학습하지 않은 패턴도 분류할 수 있는 일반화 능력이 뛰어나다는 장점을 가지고 있다. 본 논문에서는 MLP, RBF, MLP-Class와 같이 패턴 분류에 적합한 3개의 신경회로망을 구현하였고 이들을 다시 결합함으로써 신뢰성을 높이고자 하였다(그림 5 참조).

MLP[6,7]는 순방향(feed-forward) 지도학습(supervised) 신경회로망으로서 에러 역전파법(error backpropagation)으로 가중치(weight)를 수정하며 가장 일반적으로 사용되는 신경회로망이다. RBF[6]는 방사상으로 대칭인(radially symmetric) 함수를 중간층의 출력함수(activation function)로 사용한 single hidden-layer feedforward network이다. 중간층 출력함수는 중심과 폭을 가지고 있는데 군집화(clustering) 알고리즘으로 중심을, 그리고 중심간의 거리로 폭을 미리 구해서 고정시켜 놓은 후 학습시에는 출력층과 중간층 사이의 가중치만 에러역 전파법에 의해 수정하게 된다. MLP-Class[7]에서는 각 패턴 부류에 하나의 sub-MLP를 할당하여 해당 부류의 패턴만을 인식하도록 학습하는 신경회로망이다.

또한 위에서 설명한 세개의 신경회로망을 entropy 방법[8]에 의해 결합함으로써 전체 식별기를 구성하여 식별기의 성능을 높이도록 하였다[8].

Entropy 방법은 분류가 잘 된 식별기에는 큰 가중치를 주고 분류가 잘 안된 식별기에는 작은 가중치를 주어 각 부류별로 모든 식별기의 출력을 평균하여 신호를 분류하는 방법이며 다음과 같이 표현된다.

$$y_{c,i} = \frac{y_{c,i}}{\sum_c y_{c,i}} \quad (3)$$

$$H(c) = \frac{1}{n} \sum_{i=1}^n -\sum_c y_{c,i} \ln y_{c,i} \quad (4)$$

$$\text{assigned class label} = c : \max H(c) \quad (5)$$

여기서 c 는 페틴 부류를, i ($i=1, 2, 3$)는 각 식별기를, n 은 전체 식별기 갯수(여기서 $n=3$)를 나타내는 첨자이며, $y_{c,i}$ 는 각 식별기의 class별 출력값, 그리고 $y'_{c,i}$ 는 정규화된 출력값을 나타낸다. 식(4)는 식별기에 가중치를 주어 class별로 평균하는 식이며, 식(5)에서와 같이 최대의 값을 내는 class에 해당 페틴을 할당한다.

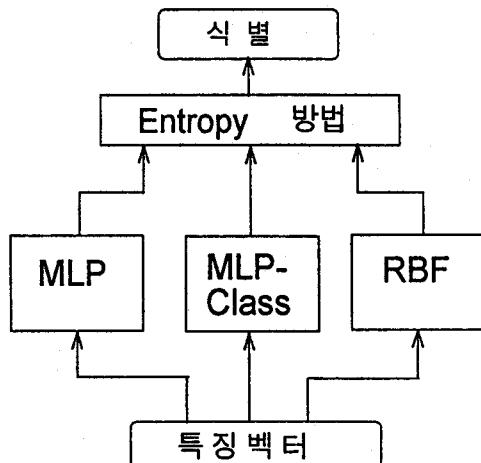


그림 5. 결합에 의한 식별 알고리즘

5. 실험 결과

제안된 시스템의 성능을 분석하기 위해 모의 전력외란신호를 사용하여 식별 실험을 하였다. 외란의 종류는 그림 3의 flat-top, voltage sag, voltage swell, capacitor energizing transients, harmonics 등 5가지이다. 각 종류별로 50개의 신호 중에서 25개의 외란 신호를 학습에, 나머지 125개의 외란신호를 테스트에 사용하였다.

표 1에 각각 알고리즘 및 entropy 결합 후의 전력외란신호 식별 결과를 나타내었다. 전체 125개의 테스트 페틴중 MLP, RBF, MLP-Class는 각각 123개(98.4%), 122개(97.6%), 122개(97.6%)의 신호를 분류하였으나 결합한 후에는 124개(99.2%)를 분류하였다.

또한 한 부류당 5개씩 모두 25개의 외란을 랜덤한 순서로 나열하여 4질에서 제안된 자동 식별을 위한 전체 시스템을 통과시켜 검출 및 식별하여 본 결과 25개의 외란 모두를 검출 및 식별해 내었다. 이렇게 높은 식별율을 내는 것은 외란의 종류가 5 가지로 한정되어 있고 외란 신호들이 비교적 상이한 특징들을 보여주기 때문이기도 하지만 본 논문에서 제시한 시스템의 우수한 성능에 기인한다고 할 수 있다.

Class	MLP	MLP-Class	RBF	Entropy combination
a	25/25 (100 %)	25/25 (100 %)	25/25 (100 %)	25/25 (100 %)
b	25/25 (100 %)	23/25 (92 %)	24/25 (96 %)	25/25 (100 %)
c	25/25 (100 %)	25/25 (100 %)	24/25 (96 %)	25/25 (100 %)
d	23/25 (92 %)	24/25 (96 %)	24/25 (96 %)	24/25 (96 %)
e	25/25 (100 %)	25/25 (100 %)	25/25 (100 %)	25/25 (100 %)
Total	123/125 (98.4%)	122/125 (97.6%)	122/125 (97.6%)	124/125 (99.2%)

표 1. 식별기의 전력외란신호 인식율

6. 결론

본 논문에서는 wavelet 이론과 신경회로망을 이용하여 전력품질외란을 자동으로 검출, 식별할 수 있는 시스템을 제안하였다. 본 시스템은 외란 검출, 특징벡터 추출, 식별기 구현의 3 단계로 구성하였다. Wavelet 변환을 이용하여 외란을 검출하였고 11개의 AR계수와 의관의 크기를 특징벡터로 사용하였으며 MLP, RBF, MLP-Class와 같은 3개의 신경회로망을 구현한 후 이들을 entropy 방법에 의하여 결합함으로써 식별기의 신뢰성을 높여 주었다. 구현된 외란식별 시스템을 전력외란 신호로 테스트해 본 결과, 외란 검출 및 식별에 제안된 시스템의 우수한 성능을 확인할 수 있었다. 그러나 더 많은 종류의 외란에 대한 검토와 이들에 대한 츠적의 특징벡터 선정 그리고 좀더 향상된 성능의 식별기 결합에 대한 연구가 요구된다.

참 고 문 현

- [1] A. McEachern, *Handbook of Power Signatures. Basic Measuring Instruments*, Foster City, CA, 1988.
- [2] R. Bergeron, "New method for assessing the disturbance level of a distribution system," 12th Int. Conf. on Electricity Distribution, Part I, pp. 17 - 22, 1993.
- [3] S. Santoso, Jr., "Application of wavelet transform analysis to the detection and localization of power quality disturbances," M.S. Thesis, The Univ. of Texas at Austin, Aug. 1994.
- [4] M. Vetterli and C. Herly, "Wavelets and filter banks: theory and design," IEEE Trans. on Signal Processing, vol. 40, no. 9, pp. 2207-2232, Sept. 1992.
- [5] B. Porat, *Digital Processing of Random Signals: Theory and Methods*, Prentice-Hall, 1994.
- [6] D. R. Hush, B. G. Horne, "Progress in supervised neural networks: What's new since Lipmann," IEEE Signal Processing Magazine, pp. 8 - 39, Jan. 1993.
- [7] S. Y. Kung, *Digital neural networks*, Prentice Hall, 1993.
- [8] J. Ghosh, S. Beck, and C.C. Chu, "Evidence combination techniques for robust classification of short-duration oceanic signals," SPIE Conf. on Adaptive and Learning Systems, Orlando, FL, Apr. 1992.