

시간-주파수 해석 기법을 이용한 특징벡터 추출 및 전력 외란 신호 식별에의 응용

이주영, 김기표, 남상원
한양대학교 공과대학 전자전기컴퓨터공학부

Feature Vector Extraction using Time-Frequency Analysis and its Application to Power Quality Disturbance Classification

Ju-Young Lee, Ki-Pyo Kim, and Sang-Won Nam

Division of Electrical and Computer Eng. Hanyang Univ., E-mail : swnam@hanyang.ac.kr

Abstract

In this paper, an efficient approach to classification of transient and harmonic disturbances in power systems is proposed. First, the Stop-and-Go CA CFAR Detector is utilized to detect a disturbance from the power signals which are mixed with other disturbances and noise. Then, (i) Wigner Distribution, SVD(Singular Value Decomposition) and Fisher's Criterion (ii) DWT and Fisher's Criterion, are applied to extract an efficient feature vector. For the classification procedure, a combined neural network classifier is proposed to classify each corresponding disturbance class. Finally, the 10 class data simulated by Matlab power system blockset are used to demonstrate the performance of the proposed classification system.

1. 서론

최근 사용하고 있는 많은 장비들은 전압이나 전류의 변화에 상당히 민감하여 보다 좋은 품질 전력의 공급을 요구하고 있다. 실제 전력 시스템에서 capacitor energizing, notching, outage 등 여러 가지 원인에 의해 정격 전압이나 전류, 또는 주파수를 유지하지 못할 경우 그 현상을 전력 외란(disturbance)이라고 한다[1]. 이러한 전력 외란이 발생된 경우 사전에 검출하고 발생 원인을 미리 파악하여 조치를 하게 되면 외란에 의해 발생할 수 있는 피해의 정도를 최소화 할 수 있다. 실제 전력 시스템에서는 DFR(Digital Fault Recorder)과 같은 모니터링 시스템으로 전력 신호들 중 외란 데이터들만을 기록하고 통신선로를 통해 중앙 서버에 전송하게 된다. 이렇게 모니터링 되어 저장된 데이터들은 식별 시스템을 이용하여 분석, 식별하게 된다.

기존에 사용하던 외란 검출 방법은 DWT의 wavelet 계수를 이용한 방법이 사용되어 왔으나, 신호대 잡음비(SNR)

가 높은 환경에서 모니터링 되는 전력 신호의 경우 DWT를 이용한 검출 방법은 신뢰성이 떨어진다는[4]. 본 논문에서는 SNR이 높은 외란 신호에서도 검출 성능이 뛰어난 Stop-and-Go CA CFAR 검출기를 응용하였다[2,4]. DWT에 의한 외란 신호의 특징벡터 추출 방법은 시간 정보를 포함하지 않아 분석에 한계가 있다. 이를 보완하기 위해 시간-주파수 해석 기법 중 WD(Wigner Distribution)을 이용한 특징 벡터 추출을 동시에 사용하여 각 추출 방법의 장점들을 이용하였다[3,5-6]. 또한 신경망 식별기를 서로 상보적으로 결합하여 식별 성능을 향상시키는 방법을 제시하였다[7]. 끝으로 Matlab의 Power system blockset으로 발췌된 10가지 종류의 전력 외란 신호를 제안된 시스템에 사용하여 분석 식별하여 기존에 사용하던 식별 알고리즘과 비교하여 성능을 검증하였다.

2. 외란 검출 시스템

기존에 사용하던 검출 시스템은 DWT를 이용하였으나 잡음 성분이 포함된 전력 신호의 경우 검출 성능이 현저히 저하된다[4]. 이를 해결하기 위해 통계적 기법을 사용한 CA CFAR(Cell Average Constant False Alarm Rate) 검출기를 전력 외란 신호의 검출에 사용되기도 한다[2]. 그러나 일반적으로 CA CFAR 검출기는 레이더 시스템에서 사용하는 것으로 전력 외란 신호 검출에 적합하지 않기 때문에, 본 논문에서는 짧은 시간 동안의 평균은 일정하다는 전제하에 구조를 변형한 Stop-and-Go CA CFAR 검출기가 사용되며 그 구조는 그림 1과 같다[2]. 여기서 $q(n)$ 은 인가된 신호, $M1$ 은 q_1, \dots, q_N 의 Local mean, THR 은 상수 T 와 $M1$ 의 곱으로 구해지는 임계치이다. Test Cell $q(0)$ 가 임계치 이상이 되면 외란이 발생된 것으로 판단하고 Test Cell은 $M1$ 계산에 사용하지 않는다. 반대로 임계치 이하인 경우 외란이 없는 것으로 판단하고 Test cell을 $M1$ 계산에 사용한다.

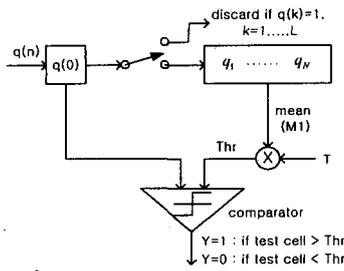


그림 1. CA CFAR Detector

외부 잡음 신호가 포함된 신호에서 외란 검출의 false alarm rate P_{FA} 및 최대 검출 확률 P_D 는 다음과 같다.

$$P_{FA} = \int_0^{\infty} e^{-qT} p_M(q) dq \quad (1)$$

$$P_D = \int_0^{\infty} e^{-qT/(1+SNR)} p_M(q) dq \quad (2)$$

이때, $p_M(q)$ 는 Local mean이 $M1$ 인 신호의 확률밀도함수(pdf)이고, SNR은 신호의 크기와 잡음의 크기의 비율이다. 주어진 P_{FA} 에 대해 최대 검출 확률을 갖기 위한 상수 T 는 다음과 같다.

$$T = N(P_{FA}^{-1/N} - 1) \quad (3)$$

외란 신호의 검출을 위해서는 검출기를 통과하여 출력되는 Y 신호의 값을 모니터링하여 1의 값이 출력될 때, 외란 신호가 발생된 것으로 판단하고 그 때의 한 주기 성분만을 추출하여 외란 데이터로 사용하게 된다. 그림 2는 제안된 검출기를 사용하여 전력 외란 신호를 검출한 것이다.

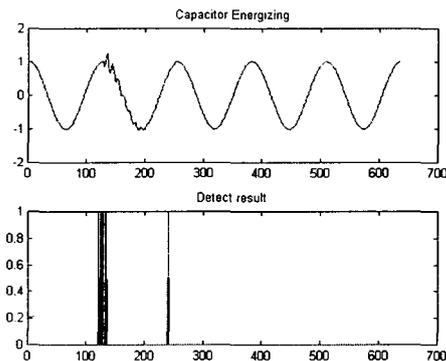


그림 2. Capacitor Energizing의 검출

3. 특징벡터 추출 알고리즘

전력 외란 신호의 데이터를 중앙 서버에 전송하기 위해서는 데이터를 효과적으로 압축하여 전송할 필요가 있다.

또한 외란 종류의 식별을 위해 사용하는 신경망 식별기의 일반화 능력을 향상시키기 위하여 신경망의 입력을 저차원의 벡터로 이용하는 것이 보다 효율적이다. 검출된 외란 신호는 시간 축으로 표현된 데이터로 외란 식별에 필요한 정보들을 많이 포함하고 있다. 본 논문에서는 검출된 신호들 가운데 외란 신호를 가장 적절하게 표현할 수 있는 특징벡터만을 추출하는 알고리즘을 개발하여 식별 과정에 이용하였다.

3.1 시간-주파수 해석 기법을 이용한 특징 추출

신호의 다양한 특성을 표현하는 방법 중 FFT나 DWT와 같은 해석 기법은 신호의 주파수 특징 분석에는 효과적이거나, 신호의 시간 특성을 간과하는 단점을 가지고 있다. 이를 보완하기 위해 시간-주파수 해석 기법을 사용하여 신호의 시간 특성까지 함께 고려한 특징 분석을 사용하였다. Cohen의 일반화한 시간-주파수 분포함수는 다음과 같다[5,6].

$$C_x(t, \omega, \phi) = \frac{1}{4\pi^2} \iint \int x^*(u - \frac{\tau}{2}) x(u + \frac{\tau}{2}) \phi(\theta, \tau) e^{-j\theta t - j\omega u + j\theta\tau} d\theta d\tau du \quad (4)$$

여기서 $\phi(\theta, \tau)$ 는 커널, $x(t)$ 는 분석하고자 하는 신호, θ 와 τ 는 각각 주파수, 시간 변수이다.

본 논문에서는 커널이 1인 WD(Wigner Distribution)을 사용하여 주어진 외란 신호를 분석하였다. 즉 WD는 다음과 같다[3].

$$W_x(t, f) = \int x(t + \tau/2) x^*(t - \tau/2) e^{-j2\pi f\tau} d\tau \quad (5)$$

시간-주파수 해석 기법은 1차원 신호를 2차원으로 표현하기 때문에 redundancy가 생기게 된다. 특히 잡음 성분이 포함된 신호의 WD는 잡음 신호와 외란 신호가 섞이게 되어 특징 벡터를 추출하는 데에 어려움이 발생하게 된다. 이 문제를 해결하기 위해 WD한 신호는 SVD(Singular Value Decomposition)을 이용하여 외란 신호의 특징 벡터만을 추출하는 알고리즘을 사용한다[3].

$$W_N = \sum_{i=1}^N \alpha_i u_i v_i^T \quad (6)$$

랭크 K ($K < N$)까지의 근사치를 W_K 이라고 하면, 오차가 최소가 되기 위한 W_K 는,

$$W_K = \sum_{i=1}^K \sigma_i u_i v_i^T \quad (7)$$

이다. $\{\sigma_i\}$ 는 신호의 에너지 스펙트럼을 나타내는 것이며 SVD로 분해된 외란 신호의 특징은 대부분이 몇몇 $\sigma_i u_i v_i^T$ ($i=1, 2, \dots, K$)에 분포하게 된다. 따라서 가장 적절한 랭크 K 를 선택하여 WD를 표현하게 되면 잡음의 영향을 최소로 줄이며 외란 신호의 특징만을 쉽게 선택하

여 사용할 수 있다.

랭크 선정을 통해 표현된 외란 신호는 효율적으로 특징 벡터를 찾기 위해 주성분 분석법(Principal Component Analysis)인 Fisher's Criterion을 적용한다. Fisher's Criterion은 다음과 같다[8].

$$D = \frac{\frac{1}{m} \sum_{i=1}^m (\mu_i - \mu)^2}{\frac{1}{m} \sum_{i=1}^m \sigma_i^2} = \frac{E[\mu_i^2] - E^2[\mu]}{E[\sigma_i^2]} \quad (8)$$

이때, m 은 Class의 개수, μ_i 는 Class i 의 평균값, μ 는 전체 Class의 평균값, 그리고 σ_i^2 은 Class i 의 분산이다. D 는 특징 성분의 분별력을 갖는 척도로써 각 특징벡터의 D 값을 계산하고 일정치 이상의 값들만을 신경망 식별기의 입력 벡터로 사용하였다. 마지막으로 전압의 크기가 변하는 외란들을 식별하기 위해 전압의 에너지를 특징 벡터에 추가하여 사용하였다.

3.2 DWT을 사용한 특징벡터 추출

일반적으로 전력 외란의 식별에는 DWT를 사용한 방법이 사용되었다. DWT는 원형 함수(mother wavelet)의 이동 및 팽창에 의해 다중분해능 해석이 가능하다. scaling 함수를 $\phi(t)$, wavelet 함수를 $\psi(t)$ 라고 하면, 이들은 다음과 같다.

$$\phi(t) = \sqrt{2} \sum_n h(n) \phi(2t-n) \quad (9)$$

$$\psi(t) = \sqrt{2} \sum_n g(n) \psi(2t-n) \quad (10)$$

분해할 신호를 $c_0(n)$ 이라고 하면, wavelet 함수와 scaling 함수의 직교성을 이용하여 다음과 같이 분해할 수 있다.

$$c_0(n) = \sum_n c_1(n) \phi_1(t) + \sum_n d_1(n) \psi_1(t) \quad (11)$$

이때, $c_1(n)$ 과 $d_1(n)$ 은 다음과 같이 구할 수 있다.

$$c_1(n) = \sum_k h(k-2n) c_0(k) \quad (12)$$

$$d_1(n) = \sum_k g(k-2n) c_0(k) \quad (13)$$

scale 2에서의 분해는 위의 과정을 통해 구해진 $c_1(n)$ 으로부터 위의 과정을 반복하여 분해할 수 있다. 그림 3은 scale 2로 분해하는 과정을 나타낸 것이다[9-10].

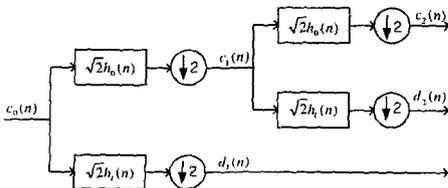


그림 3. Multiresolution decomposition for scale 2

DWT를 통해 구한 데이터는 보다 효율적인 특징 벡터 추출을 위해 Fisher's Criterion을 적용하여 가장 적절한 특징 벡터를 찾아 사용하였다.

4. 결정 결합 방법

전력 외란 신호의 식별을 위해 사전 통계 지식이 필요한 신경망 식별기 중 MLP(Multi-Layer Perceptron) 식별기를 사용하였다. MLP는 교사 학습(supervised learning)의 일종으로 일반화 능력이 뛰어나지만 학습 속도가 느린 단점을 가지고 있다[7]. 따라서 입력 데이터의 개수를 최소로 줄여 계산속도를 향상시키는 것이 중요하다. MLP는 식별 결과와 목표치 사이에 오차가 발생한 경우 역전파법에 의해 가중치(weight)를 변화시키며 오차를 줄여나가는 알고리즘(back-propagation)을 사용한다. 본 논문에서는 WD와 DWT를 통하여 추출된 특징 벡터들을 각각 MLP 식별기로 식별하고, 그 결과들을 상보적으로 결합하여 새로운 MLP로 식별함으로써 식별 능력을 높였다. 즉, 각각의 식별 결과가 같은 경우 식별 결과가 타당한 것으로 판단하고 최종 식별로 결정하지만, 다른 경우 각각의 식별 결과를 다른 MLP의 식별기의 입력 벡터로 사용하여 다시 학습과정을 거치게 된다[11]. 이러한 과정을 이용하여 다양하고 신뢰성 높은 전력 외란 식별 시스템을 설계하고자 한다. 결정 결합 시스템의 전체 구조는 그림 4와 같다.

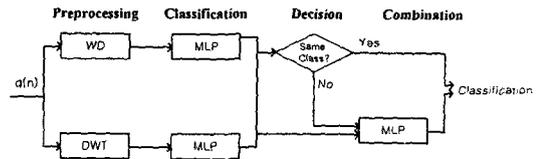


그림 4. 결정결합 방법의 식별 시스템

5. 시뮬레이션 및 결과

본 논문에서 제시된 외란식별 시스템의 성능을 확인하기 위해 다음과 같은 과정으로 시뮬레이션을 하였다.

- (1) 외란 신호는 Matlab의 Power System Blockset으로 모의 실험을 통해 1주기를 256 point로 샘플링한 10 종류의 신호를 발생시키고, SNR이 각각 80dB, 40dB인 잡음 신호를 섞은 전력 외란 데이터를 사용하였다.
- (2) Stop-and-Go CA CFAR 검출기의 수렴구간 N 을 24 point로 사용하였으며, 외란 신호의 false alarm rate P_{FA} 을 10^{-3} 으로 정하였을 때, 계산상의 T 는 7.71이지만 실험적으로 8.51을 사용하였다.
- (3) 특징벡터 추출 과정에서는 외란 신호의 특징을 보다 잘 나타내기 위해 기본 주파수 성분을 제거하

였다.

- (4) SVD에 의해 분해된 데이터는 외란의 에너지가 랭크 2까지 약 90%이상 분포되어 있기 때문에 랭크를 2로하여 특징벡터를 추출하였다.
- (5) DWT를 이용한 추출 과정에는 Daubechies 4를 사용하였다.
- (6) 신경망 식별기의 학습에 사용된 데이터는 종류 당 30개로 모두 300개의 데이터를 사용하였으며, 식별 결과를 확인하기 위한 테스트 데이터는 종류 당 70개로 모두 700개의 데이터를 사용하였다.
- (7) 결정 결합을 이용한 식별기의 학습은 이전 식별기의 식별 결과가 틀린 데이터들만을 사용하여 이루어졌으며, 테스트 역시 테스트 결과가 다른 데이터들만을 이용하여 테스트하였다. 시뮬레이션 결과는 표 1과 같이 95.86%의 높은 식별율을 보였다.

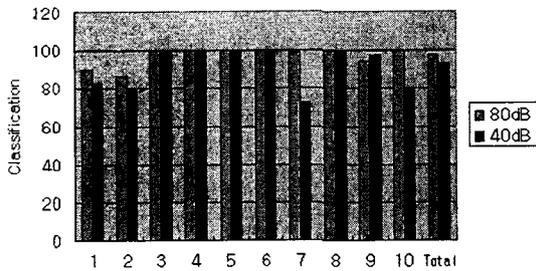


그림 5 SNR에 따른 DWT의 식별 결과 비교(%)

표 1. DWT와 WD의 식별 결과 비교(SNR=40dB)

	DWT	WD	Same Class	Second Classify	Combine
Class 1	58/70	70/70	56/70	10/14	66/70
Class 2	55/70	64/70	55/70	14/15	69/70
Class 3	70/70	70/70	70/70	-	70/70
Class 4	70/70	70/70	70/70	-	70/70
Class 5	70/70	70/70	70/70	-	70/70
Class 6	70/70	70/70	70/70	-	70/70
Class 7	51/70	60/70	51/70	9/19	60/70
Class 8	69/70	45/70	41/70	28/29	69/70
Class 9	68/70	52/70	50/70	14/20	64/70
Class 10	56/70	70/70	56/70	7/14	63/70
Total(%)	91.00	91.57	84.14	59.78	95.86

표 2. 외란 데이터의 종류

Class1	Capacitor Energizing	Class 6	Outage
Class2	Impulse Waveshape fault	Class 7	Phase Controlled Waveshape
Class3	Flat-Top	Class 8	Voltage Sag
Class4	Harmonic distortion	Class 9	Voltage Swell
Class5	Notching	Class10	UPS

6. 결론

본 논문에서는 전력 외란의 자동 식별을 위한 효율적인 식별 시스템을 제시하였다. 모의 시뮬레이션으로 제안된 시스템의 성능을 시험해 본 결과, WD의 경우 voltage sag나 swell과 같이 전압 크기 변화를 갖는 외란 신호의 식별률이 상당히 낮았으며 DWT는 outage나 harmonic distortion과 같은 외란의 식별률이 낮게 나타났다. 두 방법을 상보적으로 결합하여 사용함으로써 각각 식별에 어려움이 있던 외란 신호의 식별에 보다 효과적인 것을 확인할 수 있다. 제안된 기법을 확장하여 사용하게 되면 전력 외란 신호의 식별 뿐만 아니라 변압기의 고장 진단에도 적용이 가능하며 데이터 저장시 효율성을 기할 수 있을 것으로 기대된다.

참고문헌

- [1] R.C. Dugan, M. F. McGranaghan, and H. W. Beatty, *Electrical Power System Quality*, McGraw-Hill, New York, 1996.
- [2] J.H. Chung, *Applications of Digital Signal Processing to Electric Power Quality and Wireless Communications*, Ph.D. Dissertation, The Univ. of Texas at Austin, May, 2000.
- [3] W. Mecklenbrauker and F. Hlawatsch, *The Wigner Distribution*, Elsevier, Netherlands, 1997.
- [4] S. Santoso, "Power quality disturbance waveform recognition using wavelet-based neural classifier-part 1: Theoretical foundation", *IEEE Trans. Power Delivery*, Vol. 15, No. 1, pp.222-228, Jan. 2000.
- [5] Leon Cohen, *Time-Frequency Analysis*, Prentice Hall Inc., N.J., 1995.
- [6] Shie Qian, *Joint Time-Frequency Analysis*, Prentice Hall Inc., Saddle River, 1996.
- [7] S. Hykin, *Neural Networks*, Prentice Hall Inc., N.J. 1999.
- [8] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Academic Press, London, 1990.
- [9] A.N. Akansu, *Multiresolution Signal Decompositon*, AP. Press, Inc., N.J., 1992.
- [10] 58+55+7C. Sidney Burrus, Ramesh A. Gopinath, Haitao Guo, "Wavelet and Wavelet Transforms", Prentice-Hall, 1998.
- [11] T.K. Ho, J. J. Hull and S. N. Srihari, "Decision Combination in Multiple Classifier System", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 16, No. 1, pp. 66-75, Jan, 1994.