

직교 다항식 근사법과 고차 통계를 이용한 전력 외란의 자동식별

Automatic Classification of Power Quality Disturbances Using Orthogonal Polynomial Approximation and Higher-Order Spectra

°이재상, 이철호, 반지훈, 남상원

한양대학교 전기공학과(Tel: 02-290-0346; FAX: 02-297-1569; E-mail: swnam@email.hanyang.ac.kr)

Abstracts The objective of this paper is to present an efficient and practical approach to the automatic classification of power quality(PQ) disturbances, where an orthogonal polynomial approximation method is employed for the detection and localization of PQ disturbances, and a feature vector, newly extracted from the bispectra of the detected signal, is utilized for the automatic recognition of the various types of PQ disturbances. To demonstrate the performance and applicability of the proposed approach, some simulation results are provided.

Keywords power quality disturbances, feature vector extraction, orthogonal polynomial approximation, bispectrum, classification

1. 서론

최근의 전력 시스템에서 전력품질은 주요 관심사가 되고 있다 [4,6,12]. 양질의 전력에 대한 수요는 가정용 VCR이나 디지털 시계로부터 산업용 computer terminal, PLC, 최신 의료장비에 이르기까지 민감한 전자장비의 급증으로 인해 지속적으로 증가되어왔다. 이러한 장비들은 대부분 급변하는 수전 전압 파형에 대단히 민감하기 때문에 부하 장비의 효율적 사용을 보장하기 위해 양질의 전압 파형은 매우 중요하다. 이러한 전력 품질의 문제를 해결하기 위하여 요구되는 절차는 다음과 같다: (i) Power 시스템을 계속적으로 모니터하고[2], (ii) 전력 파형의 외란을 검출하며, (iii) 검출된 외란을 voltage sag, swell, impulse, interruption, harmonic distortion 등과 같은 외란의 범주로 분류한다[8]. 또한, (iv) 분류된 각각의 외란을 해결하기 위한 방안을 강구한다[5]. 그러나 모니터 과정에서 수집된 데이터는 대단히 방대하기 때문에 각 외란의 식별을 위해 많은 양의 계산이 요구되고 실시간에서의 해석이 어려운 문제점이 있다. 따라서 전력 품질 문제에서의 주된 관심사는 어떻게 외란을 자동으로 검출하고 적절히 분류하느냐에 있다.

본 논문의 목적은 전력 외란의 효과적 검출법과 식별에 용이한 특징 벡터 추출을 위한 실용적 접근법을 제시하는 데 있다. 제시된 방법은 직교 다항식 근사법의 이용과 고차 통계를 이용한 특징 벡터 추출 및 LVQ(learning vector quantization)에 의한 패턴 인식 등과 같은 최근의 결과에 근거하고 있다[9,10]. 본 논문에서는 사용된 식별 과정은 다음의 네 단계로 이루어져 있다: (i) 직교 다항식 근사법을 이용한 외란 검출 (2절) (ii) 검출된 외란의 고차통계를 이용한 특징 벡터 추출 (3절) (iii) 추출된 특징 벡터로부터 외란의 종류 식별 (4절). 그리고 끝으로 EMTP (Electromagnetic Transients Program)에 의해 발생시킨 7종류의 외란 데이터를 테스트함으로써 (5절) 제안된 식별 알고리듬의 성능을 확인한다.

2. 전력 외란의 검출

2.1 직교 다항식 근사법

근사화할 함수가 $f(x)$ 이고 샘플된 점들의 수열을 $\{x_i : i=0, \dots, n-1\}$ 라고 한다면 그 함수의 m 차 직교 다항식 근사식은 다음과 같다[10].

$$f^m(x) = \sum_{j=0}^m c_j p_j(x) \quad (1)$$

여기서 j 차 다항식의 집합 $\{p_j(x)\}$ 는 샘플된 점들에서 직교한다. 이것을 식으로 나타내면 다음과 같다.

$$\sum_{i=0}^{n-1} p_j(x_i) p_k(x_i) = 0, \quad \text{for } l \neq k \quad (2)$$

또한, 다항식들간의 생성 관계는 식 (3)과 같다.

$$p_{j+1}(x) = (x - a_{j+1}) p_j(x) - b_j p_{j-1}(x), \quad j \geq 0 \quad (3)$$

여기서 $p_0(x) = 1, p_{-1}(x) = 0$ 이고 a_{j+1} 과 b_j 는 아래와 같이 구할 수 있다.

$$a_{j+1} = \frac{\sum_{i=0}^{n-1} x_i [p_j(x_i)]^2}{\sum_{i=0}^{n-1} [p_j(x_i)]^2} \quad (4)$$

$$b_j = \frac{\sum_{i=0}^{n-1} x_i p_j(x_i) p_{j-1}(x)}{\sum_{i=0}^{n-1} [p_{j-1}(x_i)]^2} \quad (5)$$

식 (1)의 다항식 계수들은

$$c_j = \frac{\sum_{i=0}^{n-1} f_i p_j(x_i)}{\sum_{i=0}^{n-1} [p_j(x_i)]^2} \quad (6)$$

의 식으로 주어지며 \bar{f}_j 는 함수의 관찰 값이다.

직교 다항식은 임의의 간격을 지닌 점들로부터 생성되므로 근사하는 균일하지 않게 샘플된 데이터에 대해서도 적용이 가능하다[11].

2.2 직교 다항식 근사법을 이용한 전력 외란의 검출

$p_j(x)$ 가 j 개의 직교 다항식으로 신호를 근사화하는 연산자라고 한다면, $p_j(x)$ 는 이들 다항식에 의해 놓여지는 벡터 공간 W_j 의 선형 사영 연산자(linear projection operator)가 된다. 또한 $p_j f(x)$ 는 W_j 에 존재하는 모든 근사 함수들 중에서 $f(x)$ 에 가장 가깝다는 것도 쉽게 증명할 수 있다. 우리가 주목할 점은 (i) 신호 $f(x)$ 의 근사 $p_j f(x)$ 는 $j+1$ 개의 샘플로 특성화될 수 있으며 역으로, (ii) j 가 $n-1$ 으로 증가할수록, $p_j f(x)$ 는 n 개의 샘플을 가진 원 신호에 근사한다는 점이다. 그런데 다항식의 차수를 일정한 범위 안에 제한한다면 근사화된 신호는 원 신호의 전력 외란이나 잡음을 포함할 수 있는데 그 이유를 다음과 같이 설명할 수 있다[10]: (i) $n-1$ 차의 다항식으로 n 개의 샘플을 가지는 데이터 열을 근사화하려 한다면, 원 신호에서의 단 하나의 샘플의 변화도 근사화된 신호에 정확히 반영될 것이고 모든 점에서 정확한 값들이 재생산될 것이다; (ii) 다항식의 차수가 감소함에 따라, 곡선은 점점 완만해질 것이고 한 샘플에서의 변화는 인접한 샘플들로 전달될 것이다. 결과적으로, 그러한 전달로 인해 원 신호와 근사화된 신호 사이에 오차가 생기게 된다.

이러한 사실로부터 직교 다항식 근사를 이용한 전력 외란의 검출이 가능해짐을 알 수 있다. 예를 들어, 그림 1에서는 직교 다항식 근사를 통한 capacitor energizing transient의 검출을 보였다.

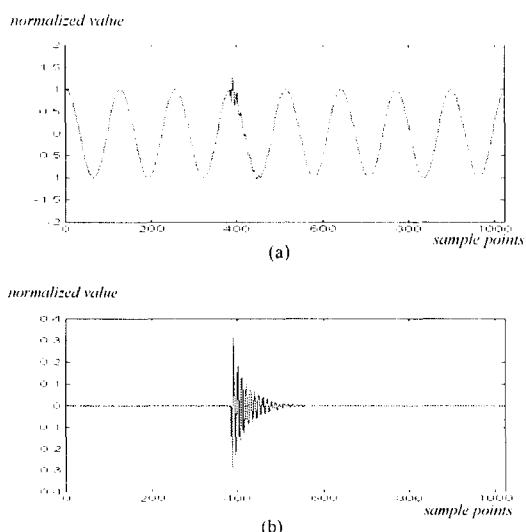


그림 1 직교 다항식 근사법을 이용한 capacitor energizing transient의 검출: (a) 원 신호; (b) 원 신호와 근사화된 신호의 차(차 수가 50일 때)

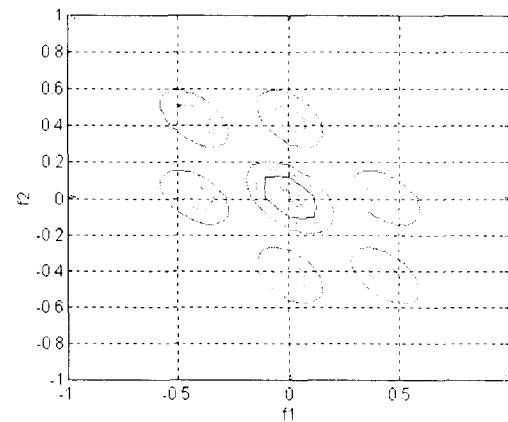
Fig. 1 Detection of a capacitor energizing transient using orthogonal polynomial approximation:
(a) the original signal; (b) the difference between original and approximated (order: 50) signals

3. 고차통계를 이용한 특징벡터 추출

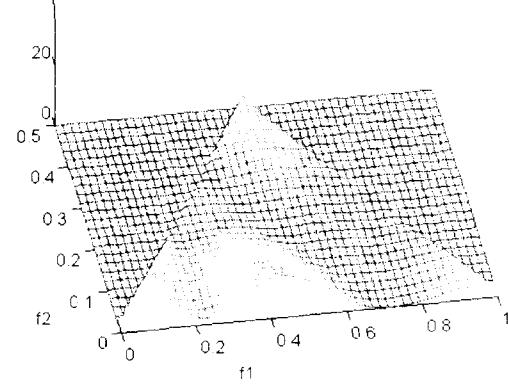
전력 외란의 효과적인 식별을 위해 본 논문에서는 원 신호와 근사화된 신호간의 오차의 이차 통계를 이용하여 특징 벡터를 추출하였다. 일차원이고 deterministic이며, 이산 시간 신호인 $x(n)$ 의 이차 통계는 다음과 같이 정의된다[3].

$$B(f_1, f_2) = X(f_1)X(f_2)X^*(f_1 + f_2) \quad (7)$$

여기서 $X(f)$ 는 $x(n)$ 의 이산 시간 푸리에 변환이며 f 는 정규화된 주파수이다. 실 신호의 이차 통계는 그 대칭성으로 인해 그림 2에서 나타낸 것과 같은 삼각형의 계산 영역 $0 \leq f_2 \leq f_1 \leq f_1 + f_2 \leq 1$ 에서 유일하게 정의된다.



(a)



(b)

그림 2 (a) 오차 신호의 이차 통계의 등고선 (waveshape fault-impulse) (b) 이차 통계의 삼각형 계산영역

Fig. 2 (a) Contour plot of the bispectrum of a difference signal (waveshape fault-impulse) (b) The triangular region of computation of the bispectrum

Translation, dc-level, amplification, scale invariant인 변수 $P(a)$ 는 $x(n)$ 의 이차 통계로부터 다음과 같이 정의된다:

$$P(a) = \arctan\left(\frac{I_r(a)}{I_i(a)}\right) \quad (8)$$

여기서

$$I(a) = I_r(a) + jI_i(a) = \int_{f_1=0}^{1/(1+a)} B(f_1, af_1) df_1 \quad (9)$$

이고 $0 < a \leq 1$, $j = \sqrt{-1}$ 이다.

이차 통계값들은 그림 3에서 보인 것처럼 이차 주파수 공간에서 원점을 지나는 기울기 a 의 직선을 따라 적분된다.

N -point의 실제 수열 $x(n)$ 이 주어졌을 때 $P(a)$ 를 구하는 계산 과정은 다음과 같다. 수열을 (FFT routine을 사용하여) 이산 푸리에 변환하여 $X(k)$ 를 얻는다. 이차 통계는 다음과 같이 계산된다.

$$\begin{aligned} B(k_1, k_2) &= X(k_1)X(k_2)X^*(k_1 + k_2) \\ \text{for } 0 \leq k_2 \leq k_1 \leq k_1 + k_2 \leq (N/2 - 1) \end{aligned} \quad (10)$$

식 (9)의 적분은 덧셈으로 근사화되어

$$I(a) = \sum_{k_1=1}^{(N/2-1)/(1+a)} B(k_1, ak_1) \quad \text{for } 0 < a \leq 1 \quad (11)$$

가 되고 이 덧셈에 대하여 이차 통계는 다음과 같이 interpolation 된다.

$$B(k_1, ak_1) = pB(k_1, \lfloor ak_1 \rfloor) + (1-p)B(k_1, \lfloor ak_1 \rfloor) \quad (12)$$

여기서 $p = ak_1 - \lfloor ak_1 \rfloor$ 이고, $\lfloor x \rfloor$ 와 $\lceil x \rceil$ 는 각각 x 에 포함되는 최대 정수와 x 를 포함하는 최소 정수를 의미한다.

본 논문에서는 $a = 0.05, 0.1, 0.15, \dots, 1$ 에 대하여 $P(a)$ 의 값을 구하였고 그렇게 얻어진 여러 값들은 하나의 특징 벡터를 구성하도록 하였다.

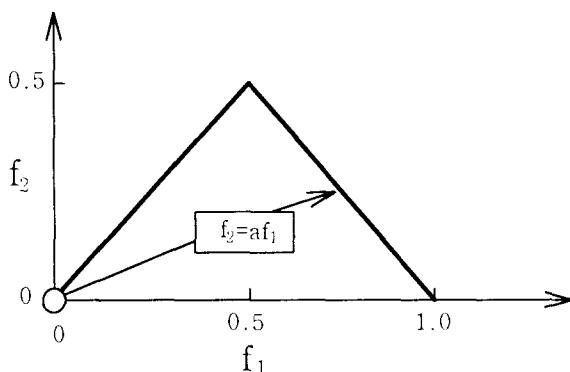


그림 3 이차 통계의 적분 경로(기울기 a 의 직선)

Fig. 3 The bispectrum is integrated along straight lines with slope a

4. 식별기 구성

다양한 종류의 전력 외란을 자동으로 식별하기 위해서 추출된 특징 벡터는 LVQ(Learning Vector Quantization)의 입력으로 사용된다[9]. 벡터 양자화(Vector quantization)은 입력 공간을 몇 개의 뚜렷한 구역으로 나누는 기술이며 각각의 구역에는 “template”이라는 것이 정의되어 있다. 유클리드 거리에 근거하

여 winning 노드를 결정하는 competitive learning rule은 m 개의 재건 벡터 $\mathbf{w}_i \in R^n$, $i = 1, 2, \dots, m$, n 차의 벡터 \mathbf{x} 로 이루어진 입력 공간에 할당하는데 사용된다. 우선 벡터 \mathbf{w}_i 의 초기값은 임의로 발생시킨 처음 m 개의 샘플 \mathbf{x} 로 설정한다. 나머지 샘플들은 학습을 위해 사용된다. Competitive learning 알고리듬은 unsupervised 방법으로 재건 벡터 \mathbf{w}_i 를 계산하는 유사한 알고리듬으로 생각할 수 있다. Kohonen은 적응 패턴 인식을 위해 벡터 양자화의 supervised version(이른바 learning vector quantization, 또는 LVQ)을 고안했다. 여기서 종류에 대한 정보는 식별기 결정 구역의 성능을 개선시키기 위해서 재건 벡터를 잘 조정하는데 사용된다. 학습 벡터 \mathbf{x}^k 가 종류 c_i 에 속한다고 가정하자. \mathbf{x}^k 에 가장 가까운 재건 벡터 \mathbf{w}_i 가 종류 c_i 에 의해 대표된다면 \mathbf{w}_i 는 다음과 같은 supervised rule(LVQ rule)에 의해 갱신된다:

$$\Delta \mathbf{w}_i = \begin{cases} +\rho^k(\mathbf{x}^k - \mathbf{w}_i) & \text{if } c_i = c_l \\ -\rho^k(\mathbf{x}^k - \mathbf{w}_i) & \text{if } c_i \neq c_l \end{cases} \quad (13)$$

여기서 ρ^k 는 반복수 k 에 대해 단조 감소 함수인 것으로 가정한다. LVQ의 수렴 속도는 각 벡터 \mathbf{w}_i 가 다음과 같이 주어지는 적응 학습률 ρ_i^k 에 의해 갱신된다면 더욱 개선될 수 있다.

$$\rho_i^k = \begin{cases} \frac{\rho_i^{k-1}}{1 + \rho_i^{k-1}} & \text{if } c_j = c_l \\ \frac{\rho_i^{k-1}}{1 - \rho_i^{k-1}} & \text{if } c_j \neq c_l \end{cases} \quad (14)$$

이 방법은 \mathbf{w}_i 가 \mathbf{x}^k 를 정확히 식별하면 ρ_i 를 감소시키고 그렇지 않으면 증가시킨다.

5. 테스트 결과

전력 외란의 자동식별을 위해 3 절에서 설명한 방법으로 추출된 특징 벡터를 LVQ의 입력으로 사용함으로써 제안된 방법의 식별 성능을 알아보았다. 테스트에 사용된 전력 외란은 EMTP를 통해 7 종류의 전력 외란 데이터를 발생시킴으로써 얻어질 수 있었고[1] 각 종류의 외란마다 10개의 데이터는 training에, 나머지 10개는 test에 사용되었다. 또한, 본 논문에서는 식별 성능의 개선을 위해 검출된 신호의 power값을 이용하였는데, 신호의 한 주기 power는 다음과 같이 정의된다.

$$P(n) = \frac{1}{2} \sum_{k=n}^{n+N-1} x^2(k) \quad (15)$$

여기서 N 은 한 주기당 sample 개수를 나타내며, $x(k)$ 는 신호 함수, $P(n)$ 은 한 주기 신호의 Power값을 나타낸다. 이렇게 구한 특징 벡터를 이용하였을 때 식별 성능의 개선 효과(8.57%)를 볼 수 있음을 표 1과 표 2를 통하여 알 수 있다. 이것은 outage, voltage swell, voltage sag와 같은 저주파 외란들의 특징 벡터가 서로 유사한 특성을 갖는 반면, 각 외란들의 power값들은 뚜렷이 구별된다는 사실에 기인한 것이다.

표 1 식별 결과 I: 7종류의 전력 외란에 대한 식별율.

Table 1 Test results I : Classification rate
for 7 class PQ disturbances

| Class | 20개의 성분에 대한 식별율 |
|---------------------------------------|-----------------|
| Voltage sag | 7/10 |
| Phase-controlled load waveshape fault | 3/10 |
| Harmonic distortion | 10/10 |
| Waveshape fault-impulse | 10/10 |
| Capacitor energizing transient | 10/10 |
| Voltage swell | 2/10 |
| Outage | 9/10 |
| Total | 51/70 (72.86%) |

식별 성능을 개선하기 위한 또 하나의 방법으로서, 본 논문에서는 주요 성분 해석법(Principal Component Analysis: PCA)을 제안하였다. 각 특징 벡터의 성분들은 나름의 정보를 가지고 있으며, 그 정보의 식별 능력은 Fisher의 공식에 의해 다음과 같이 계산된다[7].

$$D = \frac{\overline{\mu^2} - \overline{\mu^2}}{\sigma^2} \quad (16)$$

여기서 $\overline{\mu^2}$ 는 모든 종류의 특징 벡터에 걸쳐 계산된 평균값의 제곱이고, $\overline{\mu^2}$ 와 σ^2 는 각 종류의 특징 벡터에 대해 구한 평균값의 제곱과 분산의 기대치를 의미한다. 본 논문에서는 특징벡터마다 각 성분의 D 값을 계산하여 일정값 이상의 D 값을 갖는 성분만을 식별기의 입력으로 사용하였다. 표 1과 표 2의 비교를 통하여, 특징 벡터에 power 값은 결합하고 Fisher의 공식을 이용할 때 식별 성능의 상당한 개선 효과를 거둘 수 있음을 알 수 있다.

표 2 식별 결과 II: 7종류의 전력 외란에 대한 식별율.

Table 2 Test results II : Classification rate
for 7-class PQ disturbances

| Class | power 값 + 20 P(a)'s | power 값 + 6 P(a)'s (PCA 사용) |
|---------------------------------------|------------------------|-----------------------------------|
| Voltage sag | 9/10 | 10/10 |
| Phase-controlled load waveshape fault | 3/10 | 9/10 |
| Harmonic distortion | 10/10 | 10/10 |
| Waveshape fault-impulse | 10/10 | 10/10 |
| Capacitor energizing transient | 10/10 | 10/10 |
| Voltage swell | 6/10 | 10/10 |
| Outage | 9/10 | 9/10 |
| Total | 57/70 (81.43%) | 68/70 (97.14%) |

6. 결론

본 논문에서는 전력 외란의 자동식별을 위한 실용적이고 체계적인 접근법을 제시하였다. 외란을 감출하기 위해 직교 다항식 근사법을 사용하였고 특징 벡터를 구하기 위해서는 고차 통계를 이용한 특징 벡터 추출법을 제안하였다. 또한, 전체 식별 알고리듬의 성능을 향상시키기 위해 power값의 결합과 Fisher의 공식을 이용하여 특징 벡터를 재구성하였다. 제인된 방법에 의해 얻어진 특징 벡터를 LVQ를 이용하여 테스트하였을 때 주어진 외란의 97.14%가 정확히 식별되었고, 이것은 제시된 접근법의 성능과 실제 응용 가능성을 보여준다.

Acknowledgment : This work was supported by Electrical Engineering and Science Research Institute(EESRI) grant 96-059, which was funded by Korea Electric Power Corporation(KEPCO).

참고 문헌

- [1] Alternative Transients Program(ATP) Rule Book, by Canadian/American EMTP user group, 1992.
- [2] P.P. Barker, et al., "Power quality monitoring of a distribution system," *IEEE Trans. on Power Delivery*, vol. 9, No. 2, pp. 1136-1142, Apr. 1994.
- [3] V. Chandran and S.L. Elgar, "Pattern recognition using invariants defined from higher order spectra-one dimensional inputs," *IEEE Trans. on Signal Processing*, vol. 41, No. 1, pp. 205-212, Jan. 1993.
- [4] A. Domijan, G.T. Heydt, A.P.S. Meliopoulos, S.S. Venkata, and S. West, "Directions of research on electric power quality," *IEEE Trans. on Power Delivery*, vol. 8, No. 1, pp. 429-436, Jan. 1993.
- [5] J. Douglas, "Power quality solutions," *IEEE Power Engineering Review*, pp. 3-7, Mar. 1994.
- [6] Roger C. Dugan, Mark F. McGranaghan, H. Wayne Beaty, *Electrical Power Systems Quality*, McGraw-Hill, New York, 1996.
- [7] K. Fukunaga, *Introduction to statistical pattern recognition*, Academic Press, London, 1990.
- [8] A.K. Ghosh and D.L. Lubkeman, "The classification of power system disturbance waveforms using a neural network approach," *IEEE Trans. Power Delivery*, vol. 10, No.1, pp. 109-115, Jan. 1995.
- [9] M.H. Hassoun, *Fundamentals of Artificial Neural Networks*, The MIT Press, Cambridge, Massachusetts, 1995.
- [10] R. Kumar and P. Sircar, "Multiresolution analysis using orthogonal polynomial approximation," Proc. of EUSIPCO-96, vol. 1, pp. 45-48, Trieste, Italy, Sep. 10-13, 1996.
- [11] P. Sircar and A.C. Ranade, "Nonuniform sampling and study of transient system response," Proc. IEE, Part F, 139(1), pp. 49-55, Feb. 1992.
- [12] J.C. Smith, "Power quality: end user impacts," *Energy Engineering*, vol. 88, no. 5, pp. 35-54, 1991.