

효율적 특징벡터 추출기법과 신경회로망을 이용한 전력외란 자동 식별

반지훈^o, 김현수, 남상원
한양대학교 전기공학과

Automatic Classification of Power Quality Disturbances Using Efficient Feature Vector Extraction and Neural Networks

Ji-Hoon Ban, Hyun-Soo Kim and Sang-Won Nam
Dept. of Electrical Engineering, Hanyang Univ.

Abstract - In this paper, an efficient feature vector extraction method and MLP neural network are utilized to automatically detect and classify power quality disturbances, where the proposed classification procedure consists of the following three parts: i.e., (i) PQ disturbance detection using discrete wavelet transform, (ii) feature vector extraction from the detected disturbance, using several methods, such as FFT, DWT, Fisher's criterion, etc., and (iii) classification of the corresponding type of each PQ disturbance by recognizing the pattern of the extracted feature vector. To demonstrate the performance and applicability of the proposed classification algorithm, some test results obtained by analyzing 10-class PQ disturbances are also provided.

1. 서 론

최근 컴퓨터, 의료기기 등과 같은 전력외란에 민감한 전자장비의 사용이 늘어남에 따라 전력 품질 문제가 관심의 대상이 되고 있다. 이러한 전력 품질 문제를 해결하기 위하여 기존의 연구결과들이 제시한 절차는 다음과 같다: (i) 지속적인 전력 시스템 모니터링, (ii) 전력 파형의 외란 검출, (iii) 검출된 외란 종류에 따른 분류. 그러나 모니터링 과정에서 수집된 데이터의 양이 대단히 방대하여 각 외란의 식별을 위하여 많은 양의 계산이 요구되고 실시간에서의 해석이 어려운 문제점이 있다. 따라서 어떻게 외란을 자동으로 검출하고 적절히 분류하느냐는 문제가 제기되어 왔다.

본 논문의 목적은 Type A, Type B, Type C의 harmonic 외란을 포함한 voltage sag, phase controlled disturbances, notching, capacitor energizing transient, UPS, voltage swell, impulse, outage, flat-top 등의 전력 품질 외란의 효과적 검출기법, 식별에 용이한 특징벡터 추출기법, 그리고 신경회로망을 이용한 식별기법들을 적용한 전력품질 외란 자동식별 시스템을 제시하는데 있다. 구체적으로 본 논문에 제시된 자동식별 과정은 다음과 같다: (i) 푸리에 변환, 웨이블릿 변환 등의 신호처리 기법들을 적용하여 thresholding 방법을 이용한 외란 검출[2], (ii) 전력외란의 주파수 특성을 두드러지게 하기 위해 FFT를 이용하여 60Hz가 제거된 신호를 푸리에 변환, 웨이블릿 변환 등의 방법을 이용한 특징벡터 추출, (iii) 추출된 특징벡터로부터 신경회로망 MLP를 이용한 외란 종류 식별의 3단계로 구성된다. 끝으로, EMTP에 의해 발생시킨 전력 외란 데이터를 테스트하여 제안된 식별 알고리듬의 성능을 확인한다. 그림 1은 본 논문에서 제시한 전력외란 자동식별을 위한 알고리듬의 구성도이다.

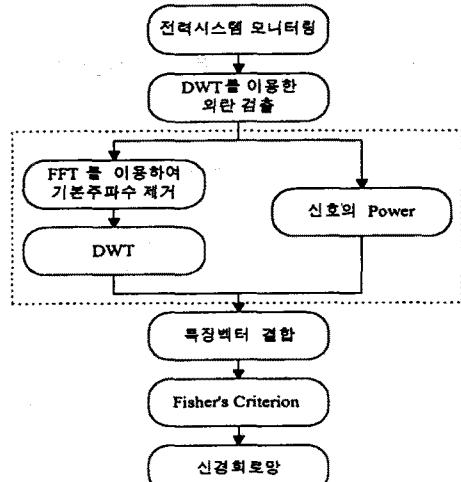
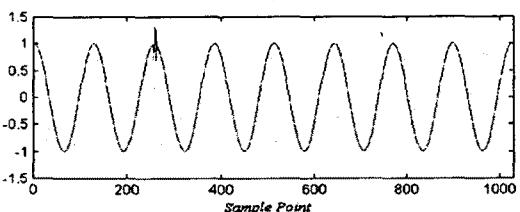


그림 1. 전력외란 자동식별 알고리듬 구성도

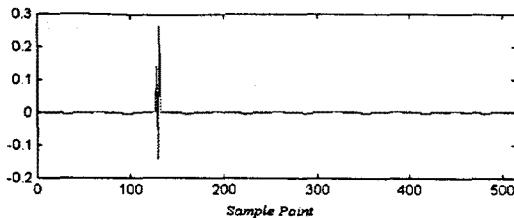
2. 본 론

2.1 외란 검출

전력외란 검출은 식별을 위한 기본 단계이며 필수적인 단계이다. 외란을 검출하는 기준의 방법으로는 '인접한 주기를 비교하는 방법과 문턱값(threshold) 이상일 때 외란이 발생했다고 판단하는 방법[2]' 등이 보고되어 있는데 전자는 주기적인 외란이 있을 때 검출하지 못할 수 있고, 후자의 경우는 문턱 값이 너무 높거나 낮은 경우 적용이 쉽지 않다는 단점이 있다. 따라서 본 논문에서는 외란 검출에 대한 연구 결과들 중 웨이블릿 변환을 이용한 thresholding 방법에 대하여 설명하고자 한다 [2,4]. 신호를 시간-주파수 영역에서 해석하는 웨이블릿 변환은 고주파에서 좋은 시간 분해능을 가진다. 이러한 특성으로 인해 impulse나 capacitor energizing transients와 같은 고주파의 전력외란을 검출하는데 효과적으로 사용될 수 있다. 그림 2는 웨이블릿 계수를 이용한 전력 외란 검출의 한 예이다.



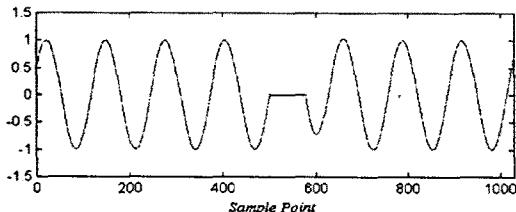
(a) Impulse의 정규화된 파형



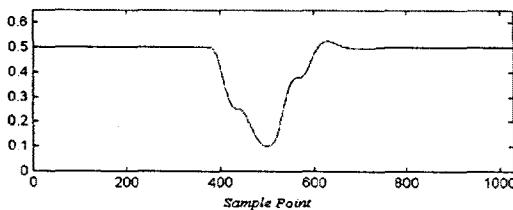
(b) Scale 1에서의 wavelet 계수

그림 2. Daub4을 이용한 Impulse의 검출

그러나 harmonic distortion, outage와 같은 저주파 외란의 경우에는 잡음의 영향으로 인해 웨이블릿을 이용한 외란이 잘 검출되지 않는다. 이러한 문제점을 해결하기 위하여 본 논문에서는 저주파 외란에 대해 신호의 한 주기 power를 이용한 검출법을 결합하여 적절히 사용하였다. 그림 3은 신호의 power를 이용하여 저주파 외란(outage)을 검출한 한 예이다. 이러한 결과로부터, 저·고주파의 외란을 검출하기 위해서는 DWT와 신호의 power를 이용한 검출법을 결합하여 적절히 사용하는 것이 효과적임을 알 수 있다.



(a) Outage의 정규화된 과정



(b) Outage의 주기당 Signal Power

그림 3. 신호의 Power를 이용한 Outage의 검출

2.2 특징벡터 추출

특징벡터 추출은 검출된 외란의 특징을 대표하는 적절한 정보를 추출하여 식별기의 식별능력을 향상시키는데 그 목적이 있다. 본 논문에서는 기존의 특징벡터 추출 방법의 단점을 보완하고 좀 더 향상된 식별성능을 얻기 위해 다음의 방법을 제시하고자 한다.

Step 1: 검출된 외란은 60Hz 기본파의 영향으로 인하여 상대적으로 작은 power를 가지게 되어 그 특징이 잘 나타나지 않으므로, 전력외란의 주파수 특성이 두드러지게 하기 위하여 FFT를 이용하여 60Hz 기본파를 제거한다. 그림 4는 검출된 capacitor energizing transient 외란 및 그 외란에서 기본파가 제거된 과정들을 나타낸다.

Step 2: 기본파가 제거된 신호를 높은 식별율과 적은 계산량을 나타내는 DWT를 사용하여 특징벡터를 추출하였다. 본 논문에서는 이산 웨이블릿 변환의 계산량을

고려하여 Daub 4의 웨이블릿 필터를 사용하였다[1,3].

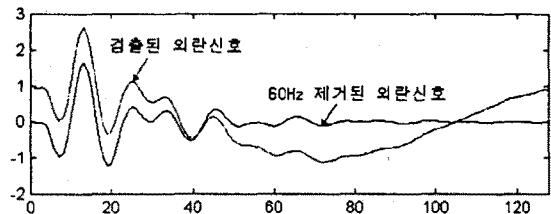
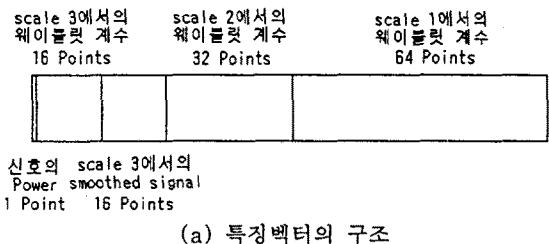
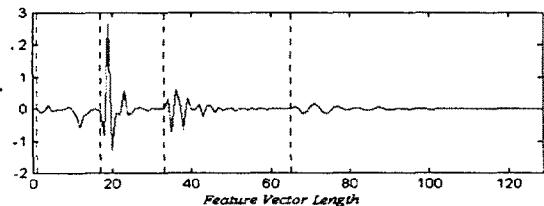


그림 4. 기본파가 제거된 capacitor energizing transient

Step 3: 저주파 외란의 식별 성능을 개선시키기 위하여 신호 power값을 위에 언급된 방법들을 이용해 얻은 특징 벡터에 결합한다. 이 때 특징벡터의 구조는 그림 5와 같이 구성된다.



(a) 특징벡터의 구조



(b) Capacitor energizing transient의 특징벡터

그림 5. Step 3의 특징벡터의 구조

Step 4: 주성분 해석법(Principal Component Analysis)의 하나인 Fisher's Criterion을 사용하여 데이터를 압축한다. 각 특징 벡터의 성분들은 나름의 정보를 가지고 있는데, 그 정보의 식별 능력은 Fisher의 공식에 의하여 다음과 같이 계산된다.

$$D = \frac{\bar{\mu}^2 - \mu^2}{\sigma^2} \quad (1)$$

여기서 μ^2 은 모든 종류의 특징벡터에 걸쳐 계산된 평균 값의 제곱이고, $\bar{\mu}^2$ 와 σ^2 은 각 종류의 특징벡터에 대해 구한 평균값의 제곱과 분산의 기대치를 의미한다. 본 논문에서는 특징벡터의 D 값을 계산하여 일정 값 이상의 D 값을 갖는 데이터만을 식별기의 입력으로 사용하였다. 그 결과 앞에서 얻어진 특징벡터 중에 단 20%의 데이터만을 가지고도 비슷한 식별성능을 보였다.

2.3 신경회로망을 이용한 외란 식별

본 논문에서 식별기로는 신경회로망을 사용하였다. 신경회로망은 패턴들에 대한 사전 정보 없이 입출력 관계로부터 필요한 정보를 학습을 통해서 얻을 수 있고 학습에 사용되지 않은 패턴에 대해서도 분류할 수 있는 능력

이 뛰어나다는 장점이 있다. 본 논문에서는 패턴 인식에 적합한 여러 신경회로망 중에서 MLP를 선택하여 식별해 보았다. MLP는 순방향 신경회로망으로서 에러 역전파법(error backpropagation)으로 가중치를 수정하며 은닉층의 개수에 따라 각기 다른 식별율과 수렴성을 보여준다. 본 논문에서는 여러 모의 실험을 통하여 적은 계산량으로 향상된 식별율을 보이는 은닉층이 하나인 MLP를 사용하였다.

2.4 모의 실험

본 논문에서 제안한 특징벡터를 가지고 MLP를 이용하여 식별한 결과는 표 2와 같다. 여기서 harmonic distortion의 세 가지 종류는 IEEE Standard 519에 의거한 비선형 부하에 따라 분류한 것으로서 크게 다음과 같다(5): (i) Type A : 전력전자 장비(컨버터, 인버터, SMPS), (ii) Type B : 아크 장비(아크로, 형광램프), (iii) Type C : 강자성체 장치(변압기). 또한 부하 유형에 따른 harmonic 전류 특성은 표 1과 같다. 본 논문의 모의 실험에서는 제시된 식별 알고리듬의 성능을 확인하기 위하여 harmonic의 위상은 고려하지 않았다.

표 1. 부하에 따른 harmonic 전류 특성

Harmonic order	Magnitude (%)		
	Type A	Type B	Type C
1	100	100	100
3	1-2	15-25	20-30
5	18-20	4-6	10-15
7	5-9	1-3	5-7
11	3-6	1-2	1-4
13	1-4	0.5-1	1-2
15	1-3	0.5-1	0-2

표 2. MLP를 이용한 여러 가지 특징벡터의 식별결과

특징벡터 Class	Step 3	Step 4
Class 1	100/100	100/100
Class 2	100/100	100/100
Class 3	93/100	91/100
Class 4	97/100	97/100
Class 5	100/100	99/100
Class 6	89/100	89/100
Class 7	98/100	98/100
Class 8	96/100	95/100
Class 9	100/100	100/100
Class 10	Type A	100/100
	Type B	88/100
	Type C	92/100
Total	1148/1200 (96.08%)	1138/1200 (95.75%)

Class 1 Voltage Sag

Class 2 Phase controlled disturbances

Class 3 Notching

- Class 4 Capacitor energizing transient
- Class 5 UPS
- Class 6 Voltage Swell
- Class 7 Waveshape fault - impulse
- Class 8 Outage
- Class 9 Flat - Top
- Class 10 Harmonic distortion

3. 결 론

본 논문에서는 웨이블릿 이론과 신경회로망을 이용하여 Type A, Type B, Type C의 harmonic 외란을 포함한 10종류의 전력품질 외란의 자동검출 및 식별을 위한 효율적 방법을 제안하였다. 특히, FFT와 DWT를 이용하여 전력외란의 특징벡터를 추출하였고, 특징벡터에 신호의 power값을 추가함으로써 저주파 외란에 대한 식별 성능을 향상시켰다. 그리고 Fisher's criterion을 이용하여 특징벡터의 개수를 줄임으로써 식별기의 계산량을 감소시킬 수 있었다. 본 논문에서 제시된 전력외란의 자동 검출 및 식별 알고리듬은 기존의 전력품질 연구와 관련 제품의 성능 향상에 많은 도움이 될 것으로 기대되어진다.

(참 고 문 헌)

- [1] S. Santos, E.J. Powers, W.M. Grady, and P. Hofmann, "Power quality assessment via wavelet transform analysis," paper no. 95 SM 371-5 PWRD.
- [2] 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.
- [3] C.H. Lee, J.S. Lee, J.O. Kim, and S.W. Nam, "Feature Vector Extraction for the Automatic Classification of Power Quality Disturbances," in 1997 IEEE International Symposium on Circuits and Systems, pp. 2681-2684, 1997.
- [4] S. Santos, 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.
- [5] S. Varadan and E.B. Makram, "Practical considerations in the application of neural networks to the identification of harmonic loads," Electric Power Systems Research 30, 103-106, 1994