

Wavelet Theory와 신경회로망을 이용한 전력 품질 외란의 검출 및 식별

김봉수^o, 김승조, 남상원, 김진오
한양 대학교 전기공학과

On the detection and Classification of Power Quality Disturbances using Wavelet Theory and Neural Networks

Bong-Soo Kim, Seung-Jo Kim, Sang-Won Nam and Jin-O Kim
Dept. Electrical Eng., Hanyang University

Abstract - The objective of this paper is to present a systematic approach to detect and classify automatically Power Quality Disturbances by applying the recent advances in digital signal processing techniques including wavelet theory and neural networks. To demonstrate the validity of the derived result, computer simulation results are included.

제 1 장 서 론

최근 전력의 품질(Power Quality)에 대한 개념이 전력 회사 혹은 수용가 입장 모두에게 점점 더 관심의 대상이 되고 있으며 이는 가정이나 사무실, 혹은 산업체에서 사용이 급증하고 있는 컴퓨터, 통신기기 등 전기의 외란(disturbance)에 민감한 전자 부품 또는 전력 전자(Power electronics)장비가 증가하고 있기 때문이다[1]. 따라서 상업 혹은 산업 수용가는 점점 더 이러한 전자 장비 성능에 의존적이 되고 전기의 품질에 대한 관심이 높아 가고 있어서 양질의 전력공급 요구는 앞으로 더욱더 늘어갈 것이다. 이러한 수요에 따라 외국의 몇몇 연구기관에서는 전력의 품질을 감시(monitor)하고 문제점을 찾는 연구를 진행하고 있다[2]. 그러나, 감시를 하기 위해 수집된 전력의 데이터량이 너무 방대하고, 전력 품질 외란(power quality disturbances)을 자동으로 검출하고 분류하는 방법이 없기 때문에 많은 데이터가 오랫동안 데이터베이스(database)에 축적되어 있어야 하는 문제점이 있다. 따라서, 외란을 자동으로 검출하여 분류하는 시스템의 필요성이 절실하다고 본다.

본 연구의 목적은 Batch processing 혹은 전문가 판단에 의존해 왔던 전력 품질 외란의 검출(detection) 및 분류(classification) 방법을 최근 급속히 발달된 디지털 신호처리 기법과 신경 회로망으로 구성된 분류기를 이용하여 완전 자동화함으로써 방대한 양의 데이터 처리를 신속 정확하게 하는데 있다.

본 연구는 크게 (1) 현재까지 발표된 여러 가지 디지털 신호처리 기법을 이용하여 전력 품질 외란을 자동으로 검출하는 방법과, (2) 분류기의 성능을 향상시키기 위한 최적 특징 벡터(feature vector)를 선정하는 방법, (3) 선정된 특징 벡터를 입력으로 하는 자동 식별기의 구현 등 세 분야로 나눌 수 있다.

제 2 장. 전력 품질 외란 검출

전력 품질 외란 검출은 외란이 일어난 시점과 끝점을 측정하는 것을 말한다. 전력 품질 외란을 검출하

는 연구 결과는 그리 많이 나와 있지 않다. 현재 나와 있는 결과로는 인접 사이클의 값을 비교하는 방법(point-to-point comparison of adjacent cycles) [3, 4], 전문가 시스템(expert system)을 이용하는 방법 [5], 신경 회로망을 이용하는 방법 [6], WT를 이용하는 방법 [2] 등이 있다.

본 연구에서는 Wavelet Transform(WT)을 이용하는 방법 [2]을 썼다. 외란을 검출하는 방법을 간략하게 설명하면 먼저 들어온 입력 신호에 대해 WT계수를 구한다. 외란의 검출은 WT계수 중 시간 축에서 resolution이 가장 좋은 스케일(scale 1)의 계수를 이용한다[2]. 이 계수 중에서 임계치를 넘는 지점을 측정한다. 그림1-그림5는 이 방법을 써서 외란을 검출한 결과이다. 그림에서 (a)는 외란이 섞인 신호의 파형이고, (b)는 scale 1(a=2¹)의 WT계수이다. 그리고 (c)는 섞인 외란을 검출한 결과이다. 예를 들면 그림2의 (a)는 약 0.005<t<0.045 기간 동안 외란이 섞인 파형이다. (b)의 WT계수를 보면 외란이 시작되는 지점과 끝나는 지점에서 상대적으로 큰 값을 나타낸다. (c)는 이 지점을 측정하여 검출한 외란이다.

2-1 Wavelet Theory

WT은 70년대 부터 수학과 물리학 분야의 연속 시간(continuous-time)영역에서 발전해 왔다[7]. 이 절에서는 WT이론에 대해 간략하게 설명한다.

2.1.1 연속 Wavelet Transform


주파수 영역에서 다른 resolution을 갖기 위해서는 시간 영역에서 주어진 신호 x(t)에 대해 팽창(expand), 압축(contract) 할 수 있는 창(window) 함수가 사용되어야 한다. 그런 창을 사용함으로써 시간과 주파수

영역의 resolution을 창 의 길이에 따라 바꿀 수 있다. 위에서 제시한 창 함수는 시간 축에서 하나의 원형 함수(mother wavelet)를 이동(translation), 팽창, 압축을 함으로써 얻을 수 있다.

원형 함수를 이동하고 팽창 하는 절차에 따라 WT은 연속 과 이산 형태로 분리된다[7]. 연속WT에서는 원형 함수가 시간 축에서 연속적으로 이동, 팽창 하는 반면에 이산WT에서는 원형 함수가 이산적으로 이동, 팽창한다. 연속 WT은 다음식과 같이 정의 된다.


$$CWT_{\psi}x(a,b) = W_x(a,b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}^*(t) dt \quad (2.1)$$

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (2.2)$$





(a) flat-top

(a) sag




(b) WT 계수 (scale 1)

(b) WT 계수 (scale 1)

(c) detection region
그림1. flat-top외란(c) detection region
그림2. voltage sag


(a) overvoltage

(a) capacitor energizing transient




(b) WT 계수 (scale 1)

(b) WT 계수 (scale 1)

(c) detection region
그림3. overvoltage 외란(c) detection region
그림4. capacitor energizing transient 외란


이다. 여기에서 $\psi(t)$ 는 원형 함수이고, $a \in \mathbb{R}$, $a \neq 0$ 는 팽창 변수, $b \in \mathbb{R}$ 는 이동 변수이다. 원형 함수로 쓰이기 위해서는 다음의 조건을 만족해야만 한다 [7].

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\psi(\Omega)|^2}{|\Omega|} d\Omega < \infty \quad (2.3)$$



(a) harmonic

(b) WT 계수 (scale 1)



(c) detection region

그림5. harmonic distortion 외란

여기서 $\psi(\Omega)$ 는 $\psi(t)$ 의 푸리에 변환이다.

2.1.2 이산 Wavelet Transform

연속 WT은 redundancy와 구현이 어려운 단점이 있다 [8]. 연속 WT의 이 문제점은 변수 a, b 를 샘플링 (sampling)해서 해결할 수 있다 [8]. 샘플링 격자를 $a = a_0^m, b = nb_0 a_0^m$, $m, n \in \mathbb{Z}$ 이라고 하면 이산 WT은

$$DWT_\psi x(m, n) = \int_{-\infty}^{\infty} x(t) \psi_{nm}^*(t) dt \quad (2.4)$$

와 같이 정의된다 [8]. 위식에서

$$\psi_{nm}(t) = a_0^{-m/2} \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (2.5)$$

이다.

이산 WT에서는 팽창, 이동 계수가 연속 WT에서와 달리 이산적으로 변하기 때문에 a 와 b 를 적절히 선택함으로써 정보의 중복을 없앨 수가 있다 [9].

제 3 장. 전력 품질 외란의 특징 벡터 추출

특징 벡터 (feature vector) 추출이란 각 신호로부터 그 신호의 특징에 해당되는 부분을 정의하고 추출하는 과정을 말한다. 다음은 본 논문에서 이용한 특징 벡터이다.

- 외란의 지속 기간
- 외란의 크기
- WT계수

본 논문에서 다루는 모든 데이터는 5.2kHz로 샘플되었다. 샘플링 주파수를 이렇게 잡은 이유는 Nyquist 주파수가 본 논문에서 다루는 외란 중에서 최대 주파수 (1.8kHz)를 포함할 수 있게 하기 위한 것이다.

위에 제시한 특징 벡터 중에서 지속 기간은 앞장에서 설명한 검출 방법을 이용하여 처음 검출된 지점과 마지막 검출된 지점의 차를 구했다. 외란의 크기는 검출된 부분의 최대값을 구했다. WT계수는 스케일 1에서 스케일 4 ($2^1 \leq a \leq 2^4$)까지 각 스케일마다 절대값의 최대값을 구했다.

제 4 장. 전력 품질 외란 식별

전력 품질 외란 문제에서 외란을 검출하는 것 외에도 더 중요한 과정은 외란을 식별하는 것이다. 현재 자동으로 여러 형태의 외란을 식별하는 방법은 그리 많지 않다. 이와 있지 않은 실정이다.

신경 회로망은 신호에 대한 수학적인 사전 지식을

필요치 않으며, 입, 출력 쌍을 통해서 입, 출력 관계를 배우는 non-parametric 분류기로서 요즘 많이 이용되고 있다. 또한 병렬 처리를 할 수 있기 때문에 하드웨어로 구현할 경우 빠른 처리속도를 가질 수 있다. 본 논문에서는 식별기로 신경 회로망 중 가장 일반적인 MLP를 사용하였다. MLP는 순 방향(feed forward) 지도 학습(supervised) 신경 회로망으로서 에러 역전파법(error backpropagation)으로 연결 강도(weight)를 수정한다. 중간층 노드가 충분하다면 3층의 MLP로 임의의 비선형 함수를 근사화 할 수 있다는 것이 증명되어 있으며 이것이 패턴간의 경계면을 근사화 할 수 있다는 이론적 배경이 되고 있다[10].

본 논문에서는 입력 층 노드 수는 6개(입력 벡터 차수) 중간층은 7개 출력 층은 5개(출력 패턴 수)의 구조를 이용하였다. 중간층 노드 수는 여러 번 노드 수를 바꿔서 혼란한 것 중 가장 빨리 수렴한 것을 정했다. 도표1은 앞장에서 구한 특징 벡터를 가지고 훈련(learning)시킨 MLP의 테스트 패턴에 대한 결과이다. 이 도표에서 지속 기간, WT계수, 외란 크기는 앞장에서 설명한 특징 벡터들이고, Epoch는 수렴 기간이다. 그리고, Error는 18개의 테스트 패턴 중 잘못 분류한 패턴 수 대 전체 패턴 수이다. 결과를 살펴보면 인식률에 있어서는 특징 벡터1(지속 기간+WT계수+외란 크기)과 특징 벡터2(지속 기간+WT계수)가 가장 높았고(0/18), 수렴 기간에 있어서는 특징 벡터1(지속 기간+WT계수+외란 크기)이 가장 짧았다(epoch=403).

지속 기간	WT계수	외란 크기	Epochs	Error
○	○	○	403	0/18
○	○		1322	0/18
○			1500	5/18
	○		1500	4/18
		○	1500	7/18
○		○	1500	2/18
	○	○	1377	4/18

도표1. 테스트 패턴에 대한 결과
○: 특징 벡터로 이용, Error/Total

제 5 장. 결론 및 연구과제


본 논문에서는 wavelet 이론 및 신경 회로망을 이용하여 전력 품질 외란을 식별하여 보았다. 도표2는 본 논문에서 이용한 특징 벡터이다. 특징 벡터는 외란 크기, 지속 기간과 3장에서 설명한 WT계수 4개를 합하여 전체 6개를 이용하였다. 모의 실험으로 본 논문에서 제시한 특징 벡터(WT계수+지속 기간+외란의 크기)를 사용하고, 식별기로 MLP를 이용하여 여러 전력 품질 외란이 연속으로 들어올 때 외란 들을 식별하는 실험을 해 보았다. 그림6은 이 실험의 검출 및

식별 결과이다. (a)는 연속으로 들어온 여러 외란 들이고, (b)는 외란이 존재하는 지속 기간 및 그 기간에서의 외란 신호를 나타내 준다. 그리고, (c)는 식별 결과이다. 결과는 (c)에서 보는 바와 같이 5가지 외란을 모두 식별 하였다(0/5). 여기서 C1, C2, C3, C4, C5는 입력된 외란 패턴 종류이고, OC1, OC2, OC3, OC4, OC5는 출력 노드에서의 식별된 값인데 이 중 최대값이 식별 결과를 나타낸다. 예를 들어 C1이 입력으로 들어갔을 때 OC1이 0.8719가 되어서 C1(pattern 1)으로 판별 된다.

결론은 본 논문에서 제시한 방법이 기존의 방법(지속 기간, 외란 크기로 특징 벡터를 잡음)에 비해 혼란기간에서는 약1/3로 단축되었고, 인식률에 있어서도 도표1과 같은 결과로서 기존의 방법에 비해 11%정도 향상 되었다.

지속 기간	크 기	W T 계수1	W T 계수2	W T 계수3	W T 계수4
-------	-----	---------	---------	---------	---------

도표2. 특징 벡터



ans =

	OC1	OC2	OC3	OC4	OC5
C1	0.8719	0.0037	0.0000	0.0000	0.0022
C2	0.0017	0.9997	0.0039	0.0001	0.0000
C3	0.0007	0.0000	0.9979	0.0000	0.0022
C4	0.0000	0.0000	0.0000	0.9979	0.0012
C5	0.0062	0.0000	0.0002	0.0027	0.9967

(c) 식별 결과

그림6. 연속된 외란의 검출 및 식별 결과

그러나 전력 품질 외란의 종류는 본 논문에서 식별한 5가지 이외에도 많이 있다. 따라서 더 많은 종류의 외란 데이터를 분석하여 최적의 특징 벡터를 추출하는 연구 및 본 논문에서 사용된 MLP이외의 많은 신경 회로망을 적용하여 최적 식별기를 선택 하고 설계하는데 대한 연구도 이루어져야 할 것이다.

참고 문헌

- [1] M.B.Hughes and J.S.Chan, 'Canadian national power quality survey,' in 12th International Conference on Electricity Distribution, IEE Conference Publication no.373, pp.2.19.1-5, 1993.
- [2] Surya Santoso, Jr., 'Application of wavelet transform analysis to the detection and localization of power quality disturbances,' Thesis, The Univ. of Texas at Austin, Aug. 1994.
- [3] D.S.Dorr, 'Power quality study-1990 to 1995: Initial results,' in IEEE seventh Annual Applied Power Electronics Conference and Exposition, pp.303-308, 1992.
- [4] A.McEachern, *Handbook of Power Signatures*, Basic Measuring Instruments, Foster City, CA, 1988.
- [5] P.Fauequembegue, O.Tache', J.M.Parant, J.Saint Pe' and D.Griffei, 'An expert system approach for auscultation of distribution systems,' in IEE Third International Conference on Power System Monitoring and Control, Conference Publication no. 336, pp. 216-218, 1991.
- [6] N.Kandil, V.K.Sood, K.Khorasani and R.V.Patel, 'Fault identification in an AC-DC transmission system using neural networks,' IEEE Trans. on Power Systems, vol.7, no.2, pp.812-819, May 1992.
- [7] I. Daubechies, *Ten Lectures on Wavelets*, SIAM, Philadelphia, Pennsylvania, 1992.
- [8] Ali N. Akansu, Richard and A. Haddad, *Multiresolution Signal Decomposition*, Academic Press, Inc., San Diego, CA, 1992.
- [9] Randy K.Young, *Wavelet Theory and Its Applications*, Kluwer Academic Publishers, Boston/Dordrecht/London, 1993.
- [10] K.Hornik, M.Stinchcombe, and H.White, 'Multilayer feedforward networks and universal approximations, Neural Networks(2), pp.359-366, 1989.