

웨이블릿 기반의 뉴럴네트웍을 이용한 전원의 왜란분류 시스템

김홍균, 이진목, 최재호
충북대학교 전기전자 컴퓨터공학부

A Power Disturbance Classification System using Wavelet-Based Neural Network

Hongkyun Kim, Jinmok Lee, Jeaho Choi
School of Electrical and Computer Engineering, Chungbuk National University

ABSTRACT

This paper presents a wavelet-based neural network technology for the detection and classification of the short durations type of power quality disturbances. Transients happen during very short durations to the nano- and microsecond. Thus, a method for detecting and classifying transient signals at the same time and in an automatic combines the properties of the wavelet transform and the advantages of neural networks. Especially, the additional feature extraction to improve the recognition rate is considered. The configuration of the hardware of TMS320C6711 DSP based with 16 channel 20Mhz sampling rate A/D(Analog to Digital) converter and some case studies are described.

1. 서 론

전력품질(PQ) 문제를 검출하는 방법으로는 신호의 크기와 반복주기 횟수를 이용하여 판단하는 RMS기법과 주파수로 분석하는 방법이 있다.

이중 주기가 긴 Sag, Swell, Interruption 등은 간단한 논리 비교로 판단이 용이하나 Harmonic 및 Noise, Transient 등 빠른 주기와 기본 주파수 성분을 왜해시키는 형태의 전원파형 검출 및 분류는 많은 문제를 안고 있다. 이러한 신호들은 크기와 주기만으로는 판단이 불가능하므로 주파수 분석법이 사용되는데, 이것을 효과적으로 검출하기 위하여 주로 FFT 및 웨이브릿(WAVELET)을 이용한다^[1]. 특히 웨이브릿은 과도상태 해석에 탁월한 효과로 말미암아 많은 곳에서 다양한 용도로 활용되고 있다. 또한 검출된 신호를 분류하는 것으로는 다양한 형태의 지식기반 전문가 시스템이 사용되고

있지만, 본 논문에서는 이산웨이블릿변환(DWT)과 뉴럴네트웍(Neural Network)을 이용하여 신호를 검출하고 분류하였다. Transient 신호는 수 ns 부터 수 μ s의 매우 빠르고 짧은 주기를 갖는다. 하지만 이러한 문제들을 진단 하기 위해서는 고속 Sampling Rate의 A/D를 내장한 왜란신호검출용 하드웨어가 필요하다. 본 논문에서는 최대 20MHz와 4MB의 버퍼를 각각 16 채널 내장한 시스템을 설계하여 실험에 응용하였다. 또한 분류를 위한 학습 자료로는 기존 논문들에 전원왜란 신호로 제시되었던 파형 및 현장에서 측정된 신호형태를 기반으로, 에질런트사의 임의 파형발생기(Arbitrary Waveform Generator)를 이용하여 그림 2 와 같은 형태의 왜란 파형을 생성하고 실험학습에 사용하였다^[2].

2. 본 론

2.1 웨이블릿 변환

웨이브릿 변환은 모함수의 이동과 스케일 변화를 이용하여 비정형신호를 분석하기 위한 수학적 이론으로 이산웨이블릿 변환은 다음과 같이 정의된다.

$$\psi_{m,n}(k) = a_0^{-\frac{m}{2}} \psi(a_0^{-m}k - nb_0) \quad (1)$$

$$DWTx(m,n) = \sum_k x(k) \psi\left(\frac{k - nb_0 a_0^m}{a_0^m}\right) \quad (2)$$

함수 $\psi_{m,n}(k)$ 는 모함수로 $a = a_0^m$ 에 의해 팽창 수축(scaling)을 하고, $b = nb_0 a_0^m$ 에 의해서 시간에 따른 이동(shifting)을 통해 신호를 해석하게 된다. 이때 a_0 와 b_0 는 0보다 큰 상수이다. 이산신호 $S[n]$ 을 $a_l[n] = S[n]$ 이라 하면 다해상도 분해는 저역통과필터인 $h[n]$ 와 고역통과필터인 $g[n]$ 에 그림 1에 서와 같이 근사신호(Approximation) $a_{l+1}[n]$ 과 세부신호(Detail) $d_{l+1}[n]$ 를 여러 번 반복연산을 통해

얻는 과정을 말한다. 이과정은 식 3, 4와 같으며 그림 1과 같이 나타낼 수 있다.

$$a_{l+1}[n] = \sum_k h[k-2n]a_l[k] \quad (3)$$

$$d_{l+1}[n] = \sum_k g[k-2n]a_l[k] \quad (4)$$

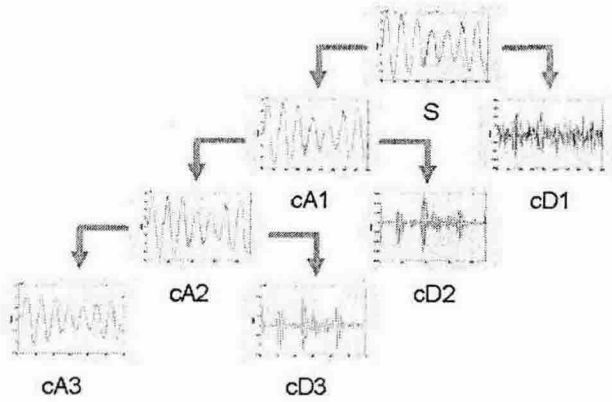


그림 1 다해상도 분해
Fig. 1 Multi-resolution signal decomposition




그림 2 뉴럴 학습을 위한 실험파형
Fig. 2 Experiment signal for NEURAL Network

2.2 왜란분류를 위한 알고리즘

다층 퍼셉트론(Multi-layer Perceptron)은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망으로 그림 3과같이 입력층, 은닉층, 출력층 3 방향으로 연결되어 있으며, 전방향(feed-forward)의 네트워크 구조를 갖는다. 학습알고리즘은 백프로퍼게이션을 사용하며 기본원리는 다음과 같다.

입력층의 각 유니트에 입력패턴을 주면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에서 역전파하여 하위층에 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 학습방법으로는 지도학습을 사용하는데 입력 및 원하는 목표출력이 네트워크에 제시된 후, 네트워크는 입력층에 주어진 패턴이 출력층에 전파되면

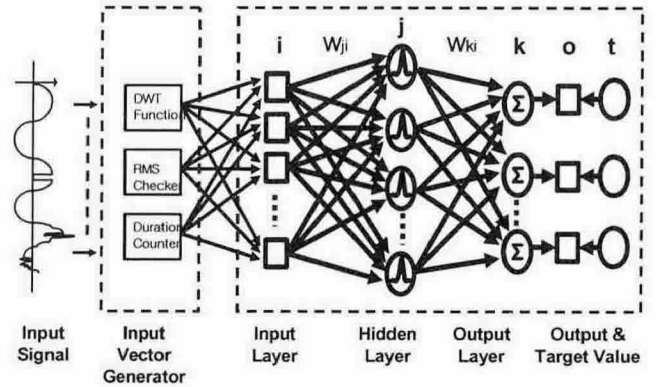


그림 3 분석알고리즘 네트워크
Fig. 3 Network diagram of signal analysis algorithm

서 변환된 출력을 목표패턴과 비교한다. 네트워크에서 출력된 패턴이 목표패턴과 일치 할 때까지 학습이 이루어진다. 그렇지 않은 경우는 얻어진 출력 패턴과 목표패턴의 차이를 감소시키는 방향으로 네트워크의 연결강도를 조절하여 학습한다. 즉 p 번째의 입력 목표출력 패턴이 제시되는 경우에 노드 i 에서 노드 j 로의 연결강도 변화는 식 5와 같이 표현된다.

$$\Delta_p W_{ji} = \eta(t_{pj} - o_{pj})i_{pi} = \eta\delta_{pj}i_{pi} \quad (5)$$

- t_{pj} : p 번째 목표출력 패턴의 j 성분
- o_{pj} : 네트워크에서 계산한 출력의 j 성분
- i_{pi} : p 번째 입력 패턴의 i 성분
- $\delta_{pj} = t_{pj} - o_{pj}$: 목표출력과 실제출력의 오차
- $\Delta_p W_{ji}$: i 와 j 유니트의 연결강도 변화량

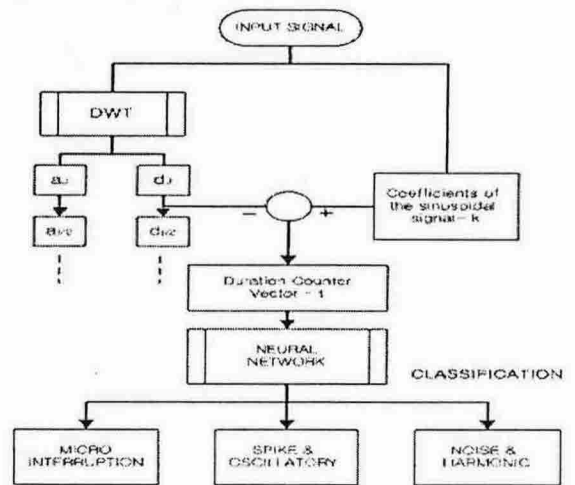


그림 4 신호분류 흐름도
Fig. 4 Flowchart of signal classification

분류학습을 위한 알고리즘의 흐름도는 그림 4와 같다. DWT에서 고역필터를 통과한 세부신호 c_n

검출된 신호의 크기를 갖고 있는 상관계수 k 와 합성된 후 신호왜란의 지속시간을 카운트하고 있는 k 의 검출벡터 연산에 의해 뉴럴학습에 이용된다.

2.4 시스템 구성

전력품질 진단시스템의 하드웨어는 그림 5와 같고 TMS320C6711(150MHz)를 사용하였으며 32MB의 보조메모리와 8MB의 메인 메모리를 내장하였고, RS232C와 USB-2 1포트를 지원한다. 또한 동시 16채널을 12비트, 20MHz 샘플링 간격으로 읽어서 독립된 4MB의 메모리에 저장한다. 이것을 위해서 DMA인터럽트를 사용한다. 내부구조는 그림 6과 같다. 아나로그부가 2채널씩 분리되어 각 1개의 FPGA를 거쳐 버퍼메모리에 쌓인다. 버퍼에 저장된 데이터는 메인 DSP부의 DMA 인터럽트 요청에 의해 메인부 메모리에 전송된 후 DWT와 뉴럴네트워크 알고리즘을 수행한다.




그림 5 전력품질 진단시스템 보드사진
Fig. 5 picture of power quality analysis system

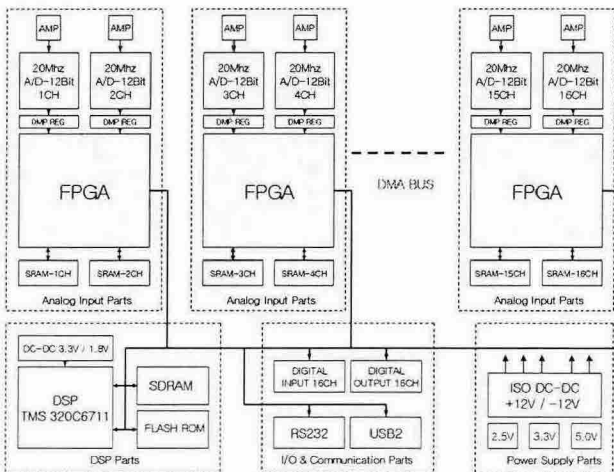


그림 6 전력품질 진단시스템 블록도
Fig. 6 Block diagram of power quality analysis system

2.5 전원왜란의 분류결과

시험과형은 각각 20종류로 세분화시켜 20,000번의 학습과정을 통해 네트워크의 상태를 결정하는 연결강도를 조정하였다. 표 1은 상기 시스템의 인식률을 나타낸다. Micro-Interruption에서는 94% Spake에서는 92% Oscillatory Transient에서는 89%로써 평균 92.7%의 인식률을 갖는다.

표 1 인식률
Table 1 Recognition rate

True Class	Recognition rate
Micro-Interruption	94%
Spake	92%
Oscillatory	89%
Total	92.7%

3. 결론

본 논문에서는 빠른 주기를 갖고 있는 Transient 신호를 검출하고 분류하는데 보다 정확하게 진단할 수 있는 알고리즘과 하드웨어를 제안하였다. 짧은 지속시간을 갖는 과도상태에서도 정확히 검출할 수 있도록 웨이블릿변환을 이용하였고, 진단을 위해서 다층퍼셉트론 알고리즘을 적용하였다. 학습벡터에 사용된 아이템은 가능한 그 종류를 줄여 전원왜란에 직접적인 영향을 주는 전압의 크기와 지속시간만을 입력패턴으로 사용하여 불필요한 연산시간과 여기에 따른 오류 판단을 줄여 줌으로써 보다 정확한 분류가 가능 하도록 하였다.

참고 문헌

- [1] Leopoldo Angrisani and Pasquale Daponte, "Wavelet Network-Based Detection and Classification of Transients", *IEEE Inter. Conf. Transactions on Instrumentation and measurement*, vol. 50, pp. 1425-1435, 2001.
- [2] Dolores Borrás, M.Castilla and Narciso Moreno and J.C Montano, "Wavelet and Neural Structure: A new Tool for Diagnostic of Power System Disturbances", *IEEE Inter. Conf. Transactions on Industry Applications*, vol. 37, pp. 184-190, 2001.
- [3] 김홍균, 이진목, 최재호, "인터넷을 이용한 전력품질 진단시스템", 대한전기학회 전력기술 부문회 추계학술대회논문집, pp. 23-26, 2002.