

## DSP를 이용한 인공지능형 전력품질 진단기법 연구

(Development of Artificial-Intelligent Power Quality Diagnosis Algorithm using DSP)

정교범\* · 박선근

(Gyo-Bum Chung · Sun-Geun Kwack)

### 요 약

본 논문은 이산웨이블렛 변환, 푸리에 변환 및 실효값의 연산 결과를 이용하여 전력품질을 진단하는 인공지능형 진단기법을 제안한다. 제안된 진단기법을 채택한 인공지능형 전력품질 진단기는 과도현상, 순간전압강하, 순간전압상승, 순간정전 및 전고조파 외형률의 진단 및 분류가 가능하다. 신호처리를 위한 데이터 샘플링주파수는 15.36[kHz]가 사용되었으며 샘플링된 이산데이터는 이산웨이블렛변환, 고속푸리에변환, 실효값의 연산에 사용되어진다. 효율적인 인공지능형 전력품질 진단을 위해서, 진단하고자 하는 전력품질 요소에 맞추어 간단한 다층구조의 인공신경망을 설계하였다. 제안된 인공신경망은 C++ 언어로 프로그램되어 PSIM 시뮬레이션 연구에 사용되었으며, TI DSP 320C6713 마이크로프로세서를 사용한 MP PQ+256 하드웨어에서 검증하였다.

### Abstract

This paper proposes a new Artificial-Intelligent(AI) Power Quality(PQ) diagnosis algorithm using Discrete Wavelet Transform(DWT), Fast Fourier Transform(FFT), Root-Mean-Square(RMS) value. The developed algorithm is able to detect and classify the PQ problems such as the transient, the voltage sag, the voltage swell, the voltage interruption and the total harmonics distortion. The 15.36[kHz] sampling frequency is used to measure the voltages in a power system. The measured signals are used for DWT, FFT, RMS calculation. For AI diagnosis of the PQ problems, a simple multi-layered Artificial Neural Network(ANN) with the back-propagation algorithm is adopted, programmed in C++ and tested in PSIM simulation studies. Finally, the algorithm, which is installed in MP PQ+256 with TI DSP320C6713, is proved to diagnose the PQ problems efficiently.

Key Words : Power quality(PQ), Discrete Wavelet Transform(DWT), Fast Fourier transform(FFT), Artificial Neural Network(ANN)

### 1. 서 론

\* 주저자 : 홍익대학교 전기공학과 교수

Tel : 041-860-2595, Fax : 041-863-7605

E-mail : gbchung@wow.hongik.ac.kr

접수일자 : 2008년 10월 14일

1차심사 : 2008년 10월 16일

심사완료 : 2008년 11월 20일

산업사회의 발달로 계통 내에 많은 비선형 스위칭 부하들이 증가하였고 이러한 부하들은 전력품질을 저해시키는 요인으로 동작한다. 전력품질은 전력시

스템에 발생하는 전자기 외란현상으로 전력계통에 공급되는 전압 및 주파수의 특성을 나타낸다[1].

계통내의 비선형 스위칭 부하들은 전압, 전류의 고조파, 써지, 순간전압변동등의 순시적 미소 외란들을 발생시키며 이러한 전력품질 외란들은 전기기기의 오동작이나 반복적으로 발생하게 되면 기기를 열화시키며 강한 써지의 경우 충분한 대비책이 없다면 일거에 사용불능의 상태로 파괴시키기도 한다. 이러한 전력품질 문제를 해결하기 위해 국내에서는 전력전자학회, 전기학회, 한국조명설비학회를 중심으로 많은 연구가 수행되었지만 정확한 전력품질 계측과 진단이 선행되지 않는다면 충분한 대비책 마련이 어려울 수밖에 없다.

인공지능은 전력품질 분석 및 진단에 유용한 도구로 관심을 받으며 이를 이용한 전력품질진단이 연구되어왔으나 일부 전력품질진단에는 다소 오류가 발생하기도 하였다[2-4]. 인공지능은 복합적인 문제를 학습을 통해 각각의 입력벡터들 간의 연결강도를 조절하여 일련의 의미 있는 출력을 도출하는 강력한 도구이다[5]. 인공지능의 구현은 학습을 통해서 구현되지만, 이를 위해서 많은 반복 연산의 수행이 필요하다. 이 연산의 필요성으로 인해서 일반적인 하드웨어에서는 인공지능의 실시간 구현은 짧은 시간동안 많은 연산이 가능한 프로세서를 필요로 해왔다.

전력품질의 주요한 지표로 쓰이는 순간과도현상 분석에는 아직까지 명확한 진단법이 없으며 푸리에 변환과 웨이블렛변환을 사용한 진단법이 많이 연구되어지고 있고 주로 이산 데이터 형식의 고속푸리에 변환과 이산웨이블렛변환을 이용하는 연구가 많이 제안되어져왔다[6-8]. 그러나, 순시적 미소 외란은 크기가 작고 국지적인 현상으로 나타나기 때문에 그 정확한 측정과 진단이 어려우며 다양한 전원현상의 동시측정과 진단을 필요로 한다.

본 논문은 IEEE 1159에서 규정한 과도현상, 크기와 지속시간에 따른 순간전압변동 및 웨이블렛 등 13 가지의 전력품질의 이상요소를 진단하는 인공지능형 전력품질 진단기를 위한 알고리즘 개발 연구를 수행한다. 이를 위하여 13가지 전력품질 문제의 특징이 명확한 실측데이터를 이용하여 실효값연산, 이산웨이블렛변환 및 고속푸리에변환을 시행하여 4가

지 종류의 인공신경망 입력벡터를 추출한다. 이 입력벡터를 사용하여 순간전압변동, 전압과도현상 및 고조파 웨이블렛을 확률적으로 판단할 수 있는 간결한 인공신경망을 설계하였다. 진단 알고리즘의 효용성을 검증하기 위해서, 제안된 인공지능신경망을 Visual C++ DLL파일로 구현하여 PSIM프로그램을 사용한 시뮬레이션 연구를 수행하였다. PSIM 시뮬레이션연구를 통해 검증된 인공신경망의 하드웨어 구현을 위해, NDtech의 C컴파일러를 사용하여 신호 처리 및 인공지능을 구현하였으며, DSP320C6713프로세서를 내장한 MP사의 PQ+256장비를 이용하여 제안된 진단 알고리즘을 실험을 통해 그 성능을 입증하였다.

## 2. 전력품질 분석을 위한 신호처리

순간전압강하, 순간전압상승 및 순간정전과 같은 순간전압변동은 한 주기의 실효값만을 지속적으로 계산함으로 검출이 가능하지만 고조파웨이블렛, 과도현상과 같은 기본주파수에 포함된 신호의 검출은 푸리에변환, 웨이블렛변환과 같은 신호 처리 기술을 필요로 한다. 60[Hz]의 원 신호  $f(t)$ 에 포함된 고조파 신호를 분석하기 위해 일반적으로 푸리에변환 방법을 사용한다. 푸리에변환은 시간에 따른 크기 성분을 주파수에 따른 크기 성분으로 변환하는 방법으로, 원 신호  $f(t)$ 에 포함된 정수배 주파수의 크기를 알 수 있는 유용한 신호 분석 방법이다. 그러나 푸리에변환은 원 신호에 포함되어 있는 주파수성분의 분포시간이 무한대라는 가정 하에 그 속에 포함된 주기 성분을 알아내는 방법이기 때문에 과도현상과 같은 짧고 단발적인 현상을 분석하기에는 부적절하다. 즉, 푸리에 분석방법은 과도현상 같은 순간적인 신호변화는 잘 나타나지 않는 단점이 있다. 그러나 웨이블렛변환은 모 함수(Mother function)의 크기변화와 이동을 통한 분석으로 짧은 과도신호 해석에 용이하게 사용된다.

### 2.1 실효값(RMS) 측정

실효값은 전력품질에 결정적인 영향을 미치는 전

력품질지수중의 하나이다. 순간전압강하, 순간전압상승 및 순간정전의 판단기준으로 사용되며, 그 크기와 지속시간에 따라 여러 가지로 정의되어 있다[9].

전력계통 내의 순시전압 또는 순시전류 신호  $f(t)$ 의 한 주기 동안의 실효값은 식 (1)과 같이 표현된다.

$$S = \sqrt{\frac{1}{T} \int_0^T f(t)^2 dt} \quad (1)$$

여기서 'T'는 주기이다.

## 2.2 푸리에 시리즈 분석

전력계통 내의 순시전압 또는 순시전류는 기본주파수  $f(t)$ 를 갖는다. 계통내의 전압주파수  $f(t)$ 는 인버터나 변압기와 같은 전력변환기기에 의해 기본주파수의 정수배에 해당하는 고조파가 발생하게 된다.

푸리에 시리즈 분석은 식 (2)와 같이 전압에 포함되어있는 기본주파수의 정수배에 해당하는 고조파를  $\sin$  및  $\cos$  항들의 합인 푸리에 급수로 나타낼 수 있다.

$$f(t) = a_0 + \sum_{n=1}^{\infty} a_n \cos(nwt) + \sum_{n=1}^{\infty} b_n \sin(nwt) \quad (2)$$

식 (2)를 오일러(Euler) 방정식을 적용하여 복소푸리에 변환식으로 표현하면 식 (3)과 같이 표현된다.

$$f(t) = \sum_{n=-\infty}^{\infty} C_n e^{jnwt} dt \quad (3)$$

$$\text{여기서, } C_n = \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} f(t) e^{-jnw t} dt \quad n = 0, 1, 2, \dots$$

$C_1$ 은 주파수 기본파의 크기이며,  $C_n$ 은 기본파주파수의  $n$ 배인  $n$ 차 고조파 성분의 크기이다. 기본파성분을 제외한 나머지 성분의 합과 기본파성분의 비는, 신호 왜곡의 정도를 나타내는 전고조파왜형을 나타내는 지표로 쓰인다. 신호  $f(t)$ 에 대한 전고조파왜형율은 식 (4)와 같이 표현된다.

$$\%THD(nT) = 100 \times \sqrt{\frac{|rms(nT)^2 - |c_1(nT)|^2|}{|c_1(nT)|^2}} \quad (4)$$

## 2.3 웨이블렛 변환

시간-주파수 변환인 푸리에 변환과 대비되는 시간-스케일 변환인 웨이블렛변환은 신호  $f(t)$ 의 주파수 성분이 변화되는 비정형 과도신호 분석에 유용하게 사용된다. 푸리에변환은 신호의 주파수에 상관없이 원도우가 동일한 반면, 웨이블렛변환은 원도우의 크기가 변화하는 멀티 스케일 유연성을 갖는다. 따라서 다양한 입력 신호에 대해 시간과 주파수 정보를 모두 보여준다[10]. 임의의 전압 또는 전류 신호  $f(t)$ 의 연속 웨이블렛변환식은 식 (5)와 같다.

$$W_f(b, c) = \int_{-\infty}^{+\infty} f(t) \overline{\psi_{b,a}(t)} dt \quad (5)$$

$$\text{여기서, } \overline{\psi_{b,a}(t)} = \frac{1}{\sqrt{a}} \psi_{b,a}\left(\frac{t-b}{a}\right)$$

식 (5)에서  $\psi_{b,a(t)}$ 는 모(mother)함수라 하고,  $a$ 는 크기성분으로 모함수의 크기 변화를 의미하고,  $b$ 는 이동성분으로 모함수의 시간 축으로의 이동을 의미한다. 연속 웨이블렛변환은 많은 연산이 필요하고 분석시간이 길어지는 단점이 있기 때문에 Mallet에 의해서 제안된 이산 웨이블릿변환을 사용하면 효율적이다.

이산 웨이블렛 변환은 식 (6)과 같이 표현된다.

$$DWTx(m, n) = \sum_k x(k) \psi\left(\frac{k-nb_0 a_0^m}{a_0^m}\right) \quad (6)$$

$$\text{여기서, } \psi_{mn}(k) = a_0^{-\frac{m}{2}} \psi(a_0^{-m} k - nb_0)$$

이산 웨이브렛 변환에 있어서 DWTx( $m, n$ )의 계수는 식 (7)과 같은 근사계수  $c[n]$ 과 식 (8)과 같은 세부계수  $d[n]$ 으로 구성된다. 근사계수는 모함수의 압축 팽창 정도가 크고 신호의 낮은 주파수 성분을 갖게 되고 세부계수는 압축 팽창 정도가 낮고 고주파성분을 갖게 된다. 이는 신호처리 관점에서 보면

필터 뱅크를 기반으로 한 대역별 신호의 재구성과 아주 밀접한 관계가 있다. 이러한 과정은 고역필터와 저역필터를 사용하는 2가지 필터링의 개념으로 확장될 수 있다.

$$c_{l+1}[n] = \sum_k h[k-2n] c_l[k] \quad (7)$$

$$d_{l+1}[n] = \sum_k g[k-2n] c_l[k] \quad (8)$$

모 함수는 Daubechies 웨이블렛을 사용하였으며 식 (9)와 같은 4개의 웨이블렛 계수와 4개의 스케일 계수를 사용하였다.

Scaling function coefficients

$$h_1 = \frac{1 + \sqrt{3}}{4\sqrt{2}}, h_2 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, h_3 = \frac{3 - \sqrt{3}}{4\sqrt{2}}, h_4 = \frac{1 - \sqrt{3}}{4\sqrt{2}}$$

Wavelet function coefficients (9)

$$g_1 = \frac{1 - \sqrt{3}}{4\sqrt{2}}, g_2 = -\frac{3 - \sqrt{3}}{4\sqrt{2}}, g_3 = \frac{3 + \sqrt{3}}{4\sqrt{2}}, g_4 = -\frac{1 + \sqrt{3}}{4\sqrt{2}}$$

이산 웨이블렛변환은 신호에 대한 다중해상도 분석을 제공하며, 다중해상도 웨이블렛 기법은 각 레벨의 근사계수를 다음레벨의 근사계수와 세부계수로 나누어 순차적으로 처리하므로 식 (10)과 같이 각 레벨의 계수를 순차적으로 합하여 원 신호의 복구도 가능하며 샘플링개수에 따라 분해 가능한 레벨이 식 (11)과 같이 정하여진다.

$$S(t) = D_1(t) + D_2(t) + D_3(t) + D_4(t) \quad (10)$$

$$+ D_5(t) + D_6(t) + D_7(t) + D_8(t) + C_8(t)$$

$$\text{분해가능 Level 수} = \log_2 \text{Sampling 수} \quad (11)$$

그림 1은 입력된 256개의 이산데이터를 기준전압 크기와 비교한 단위법을 사용하여 '1'을 기준으로 연산을 시행하며 각 레벨의 연산이 이루어질 때마다 상위 주파수의 절반의 주파수로 경계가 나뉘는 것이 반복되어지며 샘플링은 1/2로 다운샘플링하여 한 주기에서 각 레벨별로 최대의 절대값만을 추출하여 인

공신경망의 입력벡터로 사용하였다.

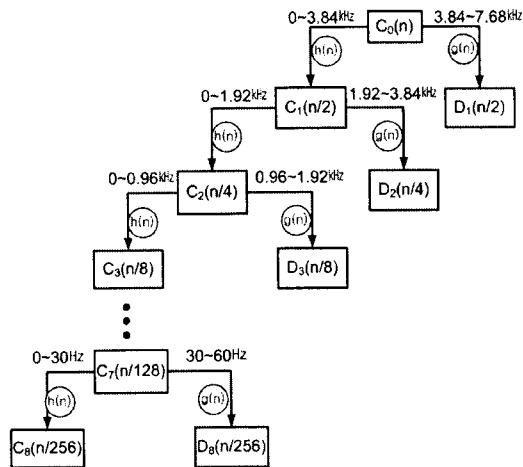


그림 1. 이산 웨이블렛의 다운 샘플링 원리  
Fig. 1. Down sampling algorithm in discrete wavelet transform

### 3. 인공신경망(ANN)

본 논문에 사용된 인공 신경망은 지도학습계열의 다층 퍼셉트론 이론을 사용하였다. 퍼셉트론은 입력 벡터와 가중치를 연산한 값의 합이 전달함수를 통하여 출력하는 형태로 되어있으며 선형분리 가능한 패턴만이 학습가능하다는 단점이 있다. 다층 퍼셉트론은 이러한 퍼셉트론을 하나이상의 층으로 연결되어 있는 형태로 되어있으며 단층 퍼셉트론의 문제점을 해결하여 현재 많은 분야에 응용되어 사용되고 있다 [11-12]. 인공신경망은 복합적인 문제를 학습을 통해 각각의 입력벡터들 사이의 연결강도를 조절하여 일련의 출력을 도출하므로 입력벡터로 사용될 요소를 선정하는 것은 매우 중요한 관건이다[13]. 웨이블렛과 전고조파왜형율, 실효값을 기반으로한 인공신경망은, 각 전력품질 이상요소가 명확한 학습데이타의 학습을 통해서 입력벡터의 가중치를 갱신함으로서 신경망의 전력품질 감지와 분류가 이루어지며 다른 연산기술로는 불가능한 고장부분이나 불연속성을 포함한 데이터의 모습을 감지하는 능력을 가진다 [14]. 인공신경망의 출력은 식 (12)와 같이 각각의 입력벡터와 가중치를 연산한 값의 합이며 그림 2

## DSP를 이용한 인공지능형 전력품질 진단기법 연구

의 출력단의 함수는 식 (13)과 같이 인간의 뉴론과 가장 유사한 비선형 함수인 Sigmoid(Logistic)함수를 사용하였다[15].

$$X_m = \sum_{n=1}^N x_n w_n + bias_n \quad (12)$$

$$F_m(x) = \frac{1}{1 + e^{-\alpha X_m}} \quad (13)$$

학습의 진행에 따라 오차를 줄이기 위해 텔타률의 연쇄법칙인 역전파이론을 사용하여 학습하였으며 새로운 가중치는 식 (14)와 같이 기존의 가중치에 에러출력을 가중치로 미분한 양을 합산하여 학습이 진행된다.

$$\begin{aligned} W_n(k+1) &= W_n(k) + \Delta W_n \\ &= W_n(k) - \eta \frac{\partial E_m^2}{\partial W_n(k)} \end{aligned} \quad (14)$$

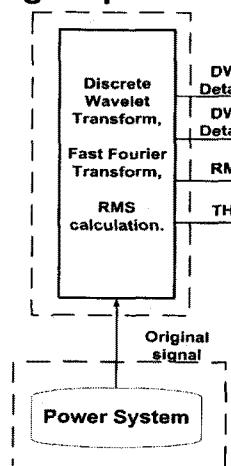
식 (15)는 식 (14)의 가중치 미분양을 Sigmoid 함

수를 사용하였을 때 미분하여 나타낸 식이며 여기서 ' $\eta$ '는 학습율로서 가중치의 변화율을 나타낸다.

$$W_n(k+1) = W_n(k) - \eta 2\alpha(D_m - Y_m) Y_m (1 - Y_m) x_n \quad (15)$$

순간전압변동과 같이 실효값의 변화가 과도상태보다 지속시간이 긴 변화는 웨이블렛 변환이나 푸리에변환보다 실효치만을 이용한 진단이 실용적이며 전고조파왜형율도 푸리에시리즈를 이용한 전고조파왜형율만을 이용한 진단이 실용적이다. 웨이블렛의 결과는 같은 크기의 과도현상 파형이라도 실효값의 크기와 고조파왜형율에 따라 차이를 보이므로 전체 입력벡터를 이용한 진단이 이루어져야 한다. 본 논문에서 제안한 전력품질 진단알고리즘은 순간전압변동은 실효값만을 학습하고 고조파왜형율은 전고조파왜형율을 학습하고, 과도현상은 복합적인 데이터로 학습하도록 인공신경망 모델을 그림 2와 같이 설계하여 학습속도와 인공신경망의 오류 가능성을 줄였으며 출력층에는 Fuzzy-Count를 제안하여 순간전압변동의 지속시간에 따라 순간전압변동, 짧은

## Data acquisition and Signal process



## ANN-structure

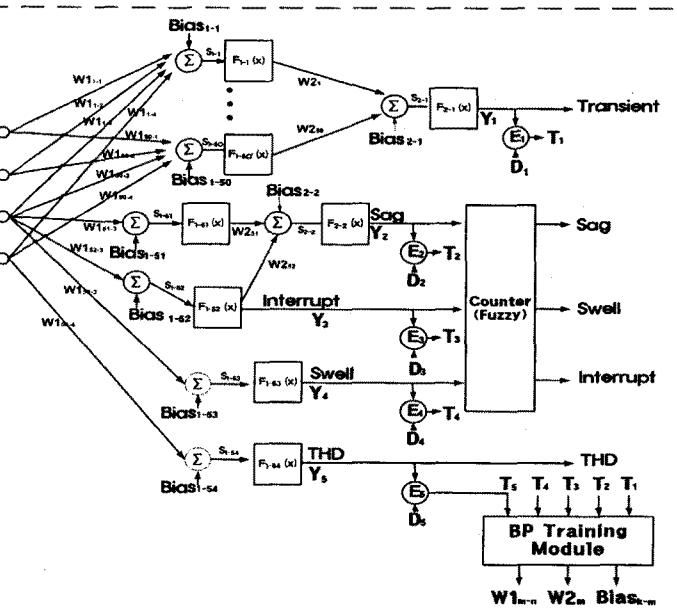


그림 2. 인공 신경망을 포함한 진단시스템의 구성도  
Fig. 2. PQ diagnosis diagram including ANN

전압변동 및 일시전압변동으로 나뉘어 진단이 가능하도록 설계하였다. 이와 같은 구조는 과도현상현상과 실효치의 변화, 고조파왜곡현상과 같은 전력품질 현상을 효과적이고 정확하게 분류가 가능하다. 각각의 학습에 사용된 학습률 'η'은 인공신경망 특성에 맞도록 과도현상은 0.4, 그 외의 학습률은 0.7이 적용되었다. 인공신경망의 학습에 사용된 학습데이터는 전력품질 이상요소 특징이 명확히 관측된 실측 데이터와 시뮬레이션 데이터가 사용되었으며 전체 학습 데이터 230[patterns]의 구성은 그림 3과 같은 특징의 데이터로 구성되었다.

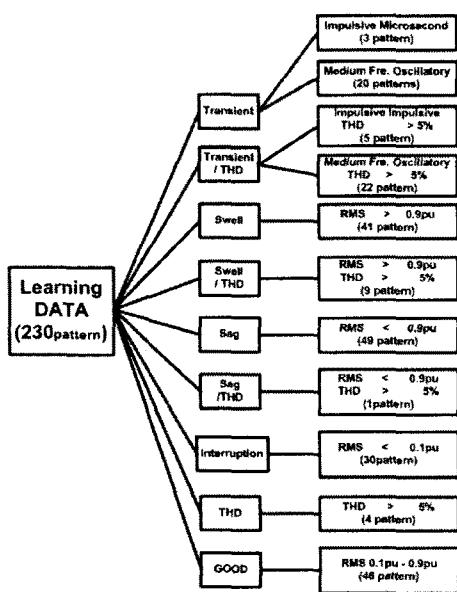


그림 3. 학습 데이터 분류  
Fig. 3. Learning data classification

#### 4. PSIM 프로그램을 이용한 인공신경망의 학습

본 논문에서 제안한 인공지능형 전력품질 진단이론은 Visual C++과 PSIM 프로그램을 이용하여 학습 및 시뮬레이션을 진행하였다. 학습에 사용된 데이터는 총 230[patterns]의 데이터가 사용되었으며 한 주기당 256개의 데이터를 기준전압과의 비율로

단위법을 사용하여 실효값, 고조파함유율, 웨이블렛 연산을 시행하여 헤더파일로 첨부되었다. 그림 4는 PSIM 시뮬레이션을 위한 회로구조이며 DLL function block은 Visual C++의 Dynamic-Link Library Project를 사용하여 프로그래밍 하였다. 'Measured\_Signal'에서는 사전에 저장되어진 데이터 또는 회로 상에 입력된 파형을 'Select\_Int' 단자를 사용해 선택가능하며 'Select\_Num' 단자를 사용하여 저장되어있는 파형신호의 번호 선택이 가능하고

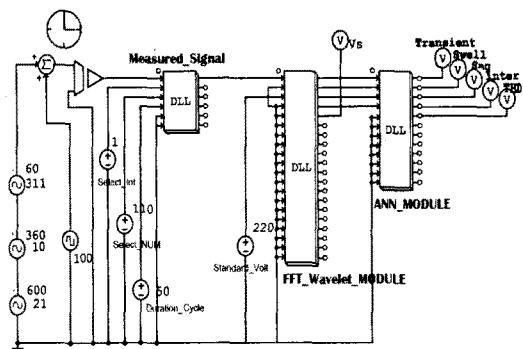


그림 4. 인공신경망 학습 시뮬레이션  
Fig. 4. PSIM simulation for ANN learning

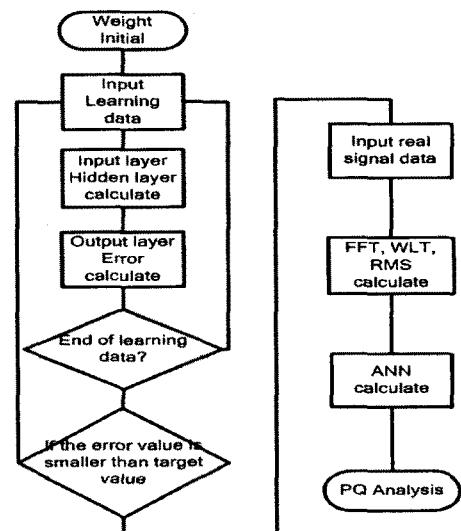


그림 5. 인공신경망 순서도  
Fig. 5. ANN flowchart

## DSP를 이용한 인공지능형 전력품질 진단기법 연구

'Duration\_cycle'를 사용하여 지속시간 선택이 가능하도록 설계하였다. 'FFT\_Wavelet\_MODULE'에서는 신호 발생 단에서 입력되어진 신호를 기준신호대비 단위법을 사용하여 15.36[kHz]로 샘플링 하여 고속 푸리에변환을 사용한 전고조파함유율, 웨이블렛변환 및 실효값을 연산하여 인공신경망으로 출력한다. 'ANN\_MODULE'에서는 헤더파일 형태로 추가된 학습데이터를 학습하여 전체 오차가 목표한 값에 도달하였을 경우 학습을 끝내고 신호처리 단에서 입력되어진 데이터의 전력품질을 판단하게 된다.

'ANN\_MODULE'의 내에서 수행된 학습 및 진단 알고리즘을 그림 5에 나타내었다.

### 5. 320C6713 DSP를 이용한 인공지능형 단상전력품질 진단기기 개발

본 논문에서 제안한 전력품질 진단기법은 MP PQ+256 모델을 사용하여 구현하였다. 신호의 고속 부동소수점 연산이 가능한 TI DSP320C6713 프로세서가 내장되어있는 NDtech PM6713 모듈이 내장되어있으며, 300[MHz]의 명령처리 주파수를 사용하고 1[M Byte]의 플래쉬메모리가 내장되어 있다. C코드 컴파일러는 NDtech Code Builder프로그램을 이용하여 에뮬레이터 및 ROM 다운로드를 실행하였다. A/D변환기는, 16[Bit] 분해능과 10[ $\mu$ s]의 샘플링 성능을 가진 Analog Devices AD976이 사용되었다. 전력품질을 진단한 결과를 보여주는 LCD 모듈은, 800×480[dots]의 해상도와 RS232 Interface를 가진, 진영콘택 7" TFT LCD모듈을 채택하여 휴대가 가능한 진단 장치로 개발하였다. PSIM 프로그램에서 시뮬레이션하여 학습 완료한 가중치를 헤더파일로 첨부하여 장비 사용 시에 학습시간을 대폭 축소하여 장비의 초기 부팅 속도를 향상하였다. 실시간 연산 처리에 따른 하드웨어의 부담을 줄여주기 위하여 4주기 동안 샘플링 하여 다음 4주기 동안 신호처리와 인공신경망연산을 시행하여 2초에 한 번씩 TFT LCD를 생성하여 전력품질 진단 결과를 출력한다.

그림 6은 아날로그보드, 디지털보드 및 LCD의 신호 처리 흐름도를 도식하여 나타내었다.

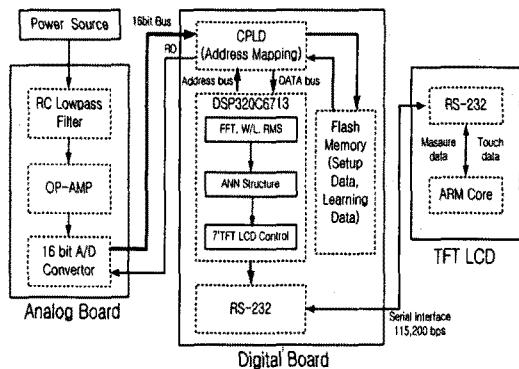


그림 6. 하드웨어 신호처리 구조  
Fig. 6. Hardware structure of signal process

그림 7 (a)는 AD976이 내장되어 있는 아날로그보드이며, (b)는 PM6713모듈과 플래쉬메모리가 사용되어진 디지털보드를 나타내었다. (c)는 TFT LCD의 전력품질 진단결과를 출력하는 화면의 디자인을 나타내며, (d)는 LCD에 터치키패드에 구성되어진 기준전압 설정 화면의 디자인이다. (e), (f)는 각각 1-25th의 고조파와 26-50th의 고조파 크기가 비교 가능하도록 설계되어진 화면 디자인이다.

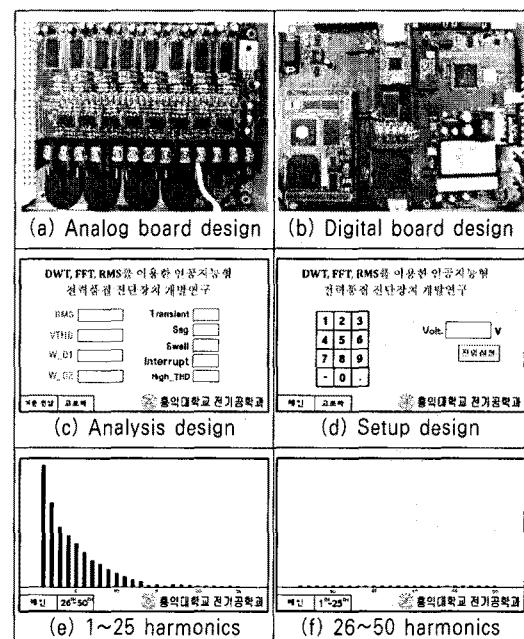


그림 7. 전체 하드웨어 구성 및 화면구성  
Fig. 7. Hardware & display structure

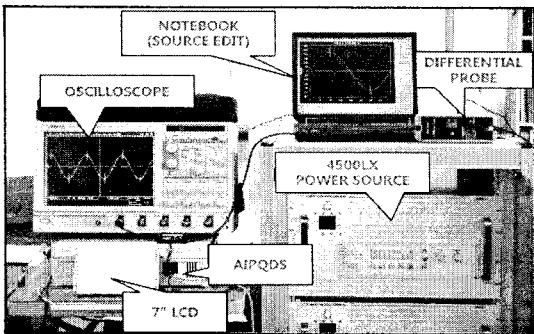


그림 8. 전력품질 측정기와 4,500[lx] AC발생기 시험구성  
Fig. 8. Construction of PQD with 4,500[lx] AC power source for power quality test

그림 8은 California instrument 4,500[lx] AC Power Source를 사용하여 개발된 전력품질 측정기를 시험하기 위한 장비구성을 나타내었다.

시험 입력파형은 순간 전압변동, 과도현상, 고조파 왜곡 및 2가지 이상의 복합적인 전력품질 문제파형을 시험하였으며 순간전압변동 시험은 전압변동 지속 시간을 변동하여 시험하였다. 표 2는 순간전압변동의 실험결과를 나타내었다. 20번의 실험결과 순간전압강하와 고조파함유율은 정확한 진단결과를 보였으나 순간전압상승은 정상상태에서 순간전압상승상태로 변화하는 과도시점에서 과도현상으로 진단하기도 하였다. 표 3 (a)는 과도현상과 10[%]의 순간전압강하의 복합적인 전력품질이상 현상이다. 진단 결과는 과도현상 99.9[%], 순간전압강하(Instantaneous) 99.9[%]의 정상적인 진단결과를 보여주었다. (b)와 같은 진동형 과도현상은 과도현상 99.9[%], 고조파 97.9[%]의 진단결과를 보였다. 이는 신호 전체적으로 분포하는 진동형 과도현상이 고조파 왜곡현상과 비슷한 형상이기 때문이다. (c)와 같은 단펄스형 과도현상의 경우 진단결과과도현상 99.9[%]의 정확한 진단결과를 보였다.

표 2. 실효값변동에 대한 전력품질 분석 결과  
Table 2. PQ diagnosis result of RMS variation

전력품질 분류	실험 결과
순간전압상승	95[%]
순간전압강하	100[%]
순간정전	100[%]

### 표 3. 전력 품질 분석 결과

- (a) 과도현상과 순간전압강하의 복합전력품질 문제 진단결과
- (b) 진동형 과도현상 진단결과
- (c) 임펄스형 과도현상 진단결과.

Table 3. Power quality analysis result

- (a) result of transient with sag
- (b) result of Oscillatory transient
- (c) result of impulsive transient

Waveform	Analysis result			
	RMS	Transient	99.9	
	79.92	Sag	99.9 I	
	W_D1	0.21	Swell	0.0 N
	W_D2	0.32	Interruption	0.0 N
			High THD	0.0
(a)				
	RMS	100.5	Transient	99.9
	THD	7.20	Sag	0.0 N
	W_D1	0.27	Swell	0.0 N
	W_D2	0.28	Interruption	0.0 N
			High THD	97.9
(b)				
	RMS	100.5	Transient	99.9
	THD	4.19	Sag	0.0 N
	W_D1	0.62	Swell	0.0 N
	W_D2	0.06	Interruption	0.0 N
			High THD	0.0
(c)				

## 6. 결 론

본 논문에서는 DSP를 이용한 인공신경망기반의 전력품질 진단기법을 제안하였다. 인공신경망의 입력벡터로는 이산웨이블렛변환, 이산푸리에변환을 이용한 전고조파왜형율 및 실효값을 사용하여 측정하고자하는 전력품질특성에 맞도록 인공신경망의 구조를 설계하였다. 일반적인 인공신경망 구조에 비해 본 논문에서 제안한 구조는 원하는 전력품질 요소에 맞추어 입력층의 구조를 최소화 하여 설계하였으며 출력층에 Fuzzy-Count를 제안하여 지속시간에 따른 전력품질 분류를 시행하였고 PSIM 시뮬레이션과 DSP를 사용한 전력품질진단기를 이용하여 실험을 통해 증명하였다. 2개 이상의 복합적인 전력

## DSP를 이용한 인공지능형 전력품질 진단기법 연구

품질 문제에 대하여도 분석이 가능하다는 장점이 있으며 더욱 세분화된 학습데이터의 추가로 전력품질 진단의 정확도는 향상될 것으로 보인다.

이 논문은 2008학년도 홍익대학교 학술연구진흥비에 의하여 지원되었음.

## References

- [1] G.B. Chung, "중앙 집중형 전력계통에서의 전력품질 규제" 전력전자학회, 전력전자학회지 제10권 제6호, pp. 26 ~ 32 Dec. 2005.
- [2] Wei-Ming Tong<sup>1</sup>, Xue-Lei Song<sup>1</sup>, Dong-Zhong Zhang<sup>2</sup> "Recognition and Classification of Power Quality Disturbances Based on Self-adaptive Wavelet Neural Network" Advances in Neural Networks - ISNN 2006, pg 1386- 1394, May 2006.
- [3] Liu Hu'a, Wang Yuguo, Zhao Wei, "Power Quality Disturbances Detection and Classification Using Complex Wavelet Transformation and Artificial Neural Network" Control Conference, 2007. CCC 2007. Chinese, pg 208-212, June 2007.
- [4] J.H. Choi, H.K. Kim, J.M. Lee, G.B. Chung "Power Disturbance Classifier Using Wavelet-Based Neural Network," KIPE, Journal of Power Electronic(JPE), Vol.6, No.4, pp.307-314, Oct. 2006.
- [5] Anis Ibrahim, W.R. Morscos, MM. "artificial intelligence and advanced mathematical tools for power quality applications : A Survey" Power Delivery, IEEE Transactions on, Vol 17, pg 668-673, Apr 2002.
- [6] A. Serdar Yilmaz, Abdulhamit Subasi, Mehmet Bayrak, Vedat M. Karsli, Ergun Ercelebi "Application of lifting based wavelet transforms to characterize power quality events" Energy Conversion and Management 48, pg 112-123 2007.
- [7] Gaouda, A.M. Salama, MMA. Sultan, MR. Chikhani, A.Y. "Power Quality Detection and Classification Using Wavelet-Multiresolution Signal Decomposition" Power Delivery, IEEE Transactions on, Vol 14, pg 1469-1476, Oct 1999.
- [8] Godoy, R.B. Pinto, J.O.P. Galotto, L. "Multiple signal processing techniques based power quality disturbance detection, classification, and diagnostic software" Electrical Power Quality and Utilisation, 2007. EPQU 2007. 9th International Conference on, pg 1-6, Oct 2007.
- [9] "IEEE Recommended Practice for Monitoring Electric Power Quality," IEEE standards Coordinating Committee 22, June. 1995.
- [10] Gaouda, A.M. Salama, MMA. Sultan, MR. Chikhani, A.Y. "Power Quality Detection and Classification Using Wavelet-Multiresolution Signal Decomposition" Power Delivery, IEEE Transactions on, Vol 14, pg 1469-1476, Oct 1999.
- [11] Monedero, I, Leon, C, Ropero, J, Garcia, A, Elena, J.M, Montano, J.C. "Classification of Electrical Disturbances in Real Time Using Neural Networks" Power Delivery, IEEE Transactions on, Vol 22, pg 1288-1296, July 2007.
- [12] Kasula, V.D.K. "Classification of Power Quality Disturbance Signals Using FFT, STFT, Wavelet Transforms and Neural Networks - A Comparative Analysis" Conference on Computational Intelligence and Multimedia Applications, 2007. International Conference on, Vol 1, pg 335-340, Dec 2007.
- [13] Santoso, S. Powers, E.J.Grady, W.M. Parsons, A.C. "power quality disturbance waveform recognition using wavelet-based neural classifier -part 1: theoretical foundation" Power Delivery, IEEE Transactions on, Vol 15, pg 222-228, Jan 2000.
- [14] P. L. Mao and R. K. Aggarwa, "A Novel Approach to the Classification of the Transient Phenomena in Power Transformers Using Combined Wavelet Transform and Neural Network", IEEE Trans.Power Delivery, Issue: 4, Vol. 16, pp. 654 660, 2001, Oct.
- [15] 정율 "신경회로망의 구조 및 사용법," 충남대학교 출판부, Aug. 2004-.

## ◇ 저자소개 ◇

### 정교범 (鄭教範)

1983년 서울대 공대 전기공학과 졸업. 1985년 동 대학원 전기공학과 졸업(석사). 1992년 Univ. of Florida(박사). 1992~1993년 Virginia Tech (Post Doc.). 1993~1995년 한국전기연구소 선임연구원. 1995년~현재 홍익대 전자전기공학과 교수.

### 곽선근 (郭善根)

2002년 대림대 전자공학과 졸업. 2002~2005년 PSD tech. 근무. 2005~2007년 Micropower 근무. 2005년 교육진흥원 학사학위 취득. 2007년~현재 홍익대학교 대학원 전기공학과 석사과정 재학.