

DSP320C6713기반의 인공지능형 단상전력품질 진단기 개발연구

곽선근*, 정교범*, 최재호**
홍익대학교*, 충북대학교**

Development of DSP Process-based Artificial-Intelligent Power Quality Equipment for Single-phase Power System

Sun-Geun Kwack*, Gyo-Bum Chung*, Jaeho Choi**
Hongik Univ.*, Chungbuk Univ.**

ABSTRACT

본 논문은, 전력계통 내의 순시 과형으로부터 전력품질 자동 진단을 위한 인공지능형 단상전력품질 진단기를 제안한다. 진단하는 전력품질은 전압강하(Sag), 전압상승(Swell), 과도현상(Transient) 및 전고조파함유율(THD)이다. 인공지능 구현을 위해서 인공신경망 이론을 이용하였으며, 시뮬레이션 및 TI DSP 320C6713 사용하여 하드웨어를 구현하였다.

인공신경망의 학습을 위하여, 00변전소에서 일년(2007년)동안 측정된 데이터 중에서 Sag, Swell, Transient 특성이 명확히 관측된 150주기의 과형과 정상상태의 50주기 과형으로 구성된 총 200주기의 데이터를 사용하였다. 측정된 과형을 1/60[sec.]마다 256번 샘플링하여, FFT 및 웨이블릿 변환을 시행하여 얻어진 값을 인공신경망 학습에 사용하였다. 상용프로그램 PSIM을 이용하여 인공신경망 학습을 시뮬레이션하였으며, DSP 프로세서를 이용하여 하드웨어로 구현하여 검증하였다.

1. 서론

산업사회가 발달하면서 전력계통내에 비선형 스위칭 부하가 증가하고 있다. 이로 인해 전압-전류의 고조파 성분, Surge 발생 빈도, 순간 전압변동 등과 같은 순시적 미소 외란이 전력 품질을 크게 위협하고 있다. 최근에 웨이블릿과 인공 신경망을 이용한 전력품질 진단에 관한 연구가 진행되고 있다.^[1] 이와 관련하여 전력품질 진단제품들이 지속적으로 개발되어 나오고 있으나 순시적 미소 외란은 크기가 작고 국지적인 현상으로 나타나기 때문에 그 정확한 측정과 평가진단이 어려우며 다양한 전원현상의 동시 측정을 필요로 한다. 따라서, 본 논문에서는 실효값 계산, 웨이블릿 변환 및 FFT의 병렬 처리 후에, 전압강하, 전압상승, 과도현상 및 고조파 왜곡 현상의 인공지능형 진단을 수행하였다. PSIM 프로그램을 이용하여 학습을 수행하고 완료된 인공신경망 회로의 가중치를 추출하였으며, 이를 C++언어를 사용하여 코드화하였고, DSP320C6713 프로세서를 채택한 지능형 전력품질 진단기기를 개발하였다.

2. 전력품질 분석을 위한 신호처리

IEEE std 1159-1995는 전압의 크기, 주파수, 지속시간에 따라 여러 가지 요소들로 정의하여 전력품질분류 기준으로 사용되고 있다.^[2] 전력계통의 과도상태신호를 분석하기 위해 일반적으로 푸리에 분석 방법을 사용한다. 푸리에 분석은 시간에 따

른 크기 성분을 주파수에 따른 크기 성분으로 변환하는 방법으로, 과도 상태에 따른 임의 주파수의 크기를 알 수 있는 유용한 신호 분석 방법이다.^{[3][4]} 그러나 푸리에 변환의 경우는 신호에 포함되어있는 주파수성분의 시간이 무한대라는 가정 하에 그 속에 포함된 주기 성분을 알아내는 방법이기 때문에 transient와 같은 짧고 단발적인 과도현상을 분석하기에는 부적절하다.^[4] 이를 보완하기 위하여 본 논문에서는 웨이블릿 변환과 실효값, FFT를 병렬처리하여 전력품질을 진단하였다.

2.1 실효값(RMS) 측정

실효값은 전력품질에 결정적인 영향을 미치는 여러가지 지수중의 하나이다. 전압강하 또는 전압상승의 판단기준으로 사용되며, 그 크기와 지속시간에 따라 여러 가지로 정의되어진다. 전력계통 내의 순시전압 또는 순시전류 신호 $f(t)$ 의 실효값은 식 (1)과 같다.

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

여기서 T는 주기이다.

2.2 Fourier Series Analysis

전력계통 내의 순시전압 또는 순시전류 신호 $f(t)$ 는 주기 T를 갖는다. 따라서 식 (2)와 같이 기본주파수 $1/T$ 의 정수배 주파수를 갖는 sin 및 cos 항들의 합인 푸리에 급수로 나타낼 수 있다.

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

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

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

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

C_1 은 주파수 $1/T$ 인 기본파의 크기이며, C_n 은 주파수 n/T 인 n 차 고조파 성분의 크기이다. 기본파성분(C_1)을 제외한 나머지 성분의 합은, 신호 왜곡(Distortion)의 정도를 나타내는 전 고조파(Total Harmonics) 지표로 쓰인다. 신호 $f(t)$ 에 대한 전 고조파 외형률은 식(4)와 같다.

$$\%THD = 100 \times \frac{c_{dis}}{c_1} = 100 \times \frac{\sqrt{f(t) - c_1}}{c_1} \quad (4)$$

2.2 Wavelet Transform

시간-주파수 변환인 푸리에 변환과 대비되는 시간-스케일 변환인 Wavelet Transformation(WLT)는, 신호의 주파수 특성 분석과 멀티스케일 특성 분석에 사용된다. 특히 시간에 따라 주파수 성분이 변화되는 비정형 신호의 분석에 효과적인 WLT는 전력계통 내의 과도현상 분석에 효율적이다.

입력의 전압 또는 전류 신호 $f(t)$ 의 연속 웨이블릿 변환식은 식 (5)와 같다.

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

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

식 (5)에서 $\psi_{b,a(t)}$ 는 모(mother)함수라 하고, a 는 scale(dilation)성분으로 모함수의 크기 즉 스케일의 변화를 의미하고, b 는 shift (translation)성분으로 모함수의 시간축으로의 이동을 의미한다. 식 (5)는 연속 웨이블릿변환으로 많은 연산이 필요하고 분석시간이 길어지는 단점이 있다. 그러나, 이분구간에서 모함수를 샘플링하여 직교 웨이블릿을 구성하면 이산웨이블릿 변환을 수행할 수 있으며, 다중해상도 해석을 제공한다.

3. 인공신경망(ANN)

전압강하 및 전압상승과 같이, 과도상태보다 지속시간이 긴 변화는 웨이블릿 변환이나 푸리에변환보다 실효치를 이용한 진단이 더 실용적이다. 이와 같은 과도상태보다 긴 시간동안의 전력품질을 효과적으로 분류하기 위하여 Back-Propagation 모델을 그림 1과 같이 설계였다.

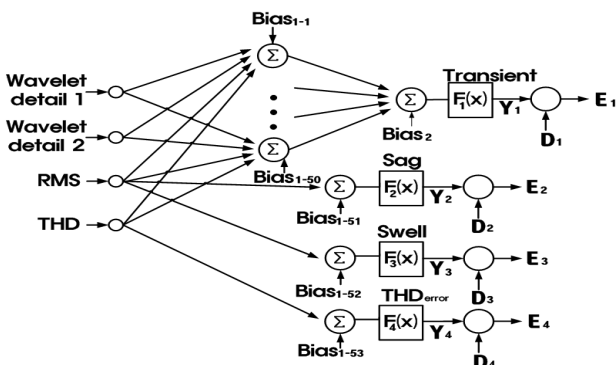


그림 1 전력품질 진단을 위한 인공신경망 구조

Fig. 1 Structure of ANN for PQ Diagnosis

그림 1의 출력단의 함수는 인간의 뉴론과 가장 유사한 비선

형 함수인 Sigmoid 함수를 사용하였다.^[5]

$$X_m = \sum_{n=1}^n x_n + bias_n \quad (6)$$

$$F_m(x) = \frac{1}{1 + e^{-\alpha x_m}} \quad (7)$$

학습의 진행에 따라 오차를 줄이기 위한 새로운 가중치는 식 (8)과 같이 기존의 가중치에 에러출력을 가중치로 미분한 양을 합산하여 학습이 진행된다.

$$W_n(k+1) = W_n(k) + \Delta W_n = W_n(k) - \eta \frac{\partial E_m^2}{\partial W_n(k)} \quad (8)$$

그러므로 갱신될 가중치의 변화량은 식 (9)와 같이 나타낼 수 있다. 여기서 η 는 학습율로서 가중치의 변화율을 나타낸다.

$$W_n(k+1) = W_n(k) - \eta 2\alpha (D_m - Y_m) Y_m (1 - Y_m) x_n \quad (9)$$

4. PSIM 프로그램을 이용한 인공신경망의 학습

본 논문에서는 학습신호를 한 주기당 256개의 데이터를 샘플링하여 RMS, FFT, WLT연산을 시행하였으며 기준 실효값을 1로 하여 학습하여 송전 계통이나 배전 계통에서 모두 판단이 가능한 학습을 하였다. PSIM 프로그램을 이용해서 학습 진행과 학습된 ANN이 전력품질을 진단하는 시뮬레이션을 수행하였고 이를 위해 그림 2와 같이 인공신경망을 설계하였다.

인공신경망 학습을 위해서 2007년 00번전소 측정데이터를 이용하였다. 측정데이터 중에서 Sag, Swell, Transient, THD 특성이 IEEE std 1159-1995 기준에 부합하는 과형을 추출하여 학습데이터를 구성하였으며, 그림 3과 같다. 학습데이터는 헤더 파일 형태로 프로그램에 추가되었고, ANN Block에서 이용하여 학습을 하였고, 각각의 퍼셉트론 학습에 사용된 학습율 ' η '은 전력품질 특성에 맞도록 Transient는 0.4, swell은 0.7, sag는 0.7, THDerror는 0.7이 적용되었다.

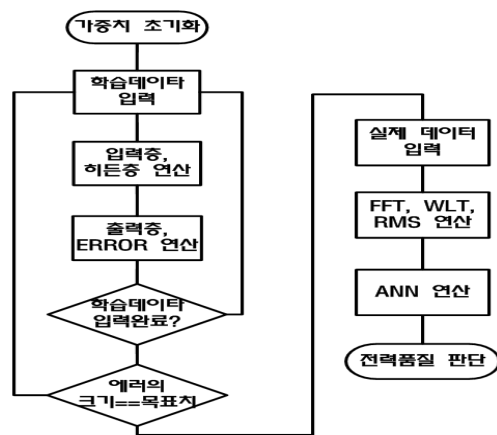


그림 2 전력품질 진단을 위한 PSIM 프로그램내의 순서도

Fig. 2 Flow chart in PSIM Program for PQ Diagnosis




그림 3 전력품질 진단용 인공신경망 학습데이터
Fig. 3 ANN Learning Data for Power Quality Diagnosis

Back-Propagation 알고리즘을 이용한 학습기능을 갖춘 인공 신경망은 Visual C++ DLL파일로 개발되어, 그림 4와 같이 PSIM 프로그램에서 Function Block으로 구현하였다.

신호처리 Block에서는 입력된 신호와 기준 전압을 단위범을 사용한 신호 처리하여 입력되어지는 실효값에 상관없이 신호 처리된 결과는 특성만이 '1' 내외의 값을 가짐으로서 학습의 빠른 수렴을 하도록 설계하였다.

인공신경망 Block에서는 학습데이터를 연산하여 출력되는 오차를 확인하여 목표 오차에 미치지 못할 경우 학습을 시행하고 학습된 퍼셉트론가중치의 오차가 목표 오차에 도달하였을 때부터는 학습을 끝내고 입력되어지는 신호를 FFT, Wavelet Block에서 신호 처리한 데이터를 입력받아 판단하도록 설계하였다.





그림 5 인공지능형 전력품질 측정기기
Fig. 5 Artificial Intelligent Power Quality Diagnosis Equipment

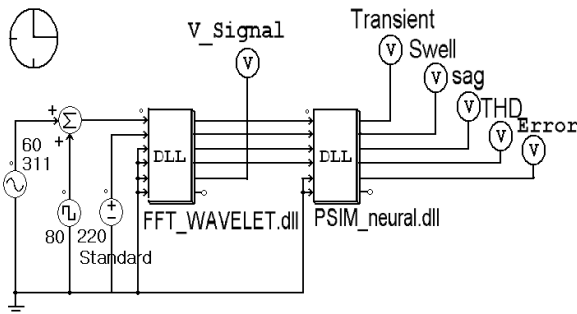


그림 4 인공신경망 학습을 위한 PSIM 프로그램
Fig. 4 PSIM Program for ANN Learning

5. 320C6713 DSP를 이용한 인공지능형 단상전력품질 측정기기 개발

본 논문에서 제안한 전력품질 진단기는, 고속 부동소수점 연산이 가능한 TI DSP320C6713 프로세서가 사용된 NDtech PM6713 모듈이 사용되었다. 본 모듈은 300MHz의 클럭 주파수를 사용하고 1M Byte의 Flash Memory가 내장되어있다. C 코드 컴파일러는 NDtech Code Builder 프로그램을 이용하였다. A/D 변환기는, 16Bit 분해능과 10µs의 샘플링 성능을 가진 Analog Devices AD976이 사용되었다. 전력품질을 진단한 결과를 보여주는 LCD 모듈은, 800 x 480 dots의 해상도와 RS232 Interface를 가진, 진영콘택 7" TFT LCD모듈을 채택하였다.

개발된 전력품질 측정기기와 이를 이용하여 진단한 신호의 특성을 그림 5에 나타내었다.

6. 결론

본 논문에서는 실효값, FFT 및 WLT의 병렬 처리를 이용하여 전압강하, 전압상승, 짧고 단발적인 과도현상 및 고조파왜곡의 4가지 전력품질을 인공지능을 이용하여 고속진단하는 전력품질 진단기기를 제안하였다. 4가지 전력품질 항목을 동시에 진단할 수 있는 성능을 가지고 있으며, 기존 제품과 비교해서 과도현상 진단은 월등히 높은 정확도를 보였다. 본 기기는, 더욱 강화되어갈 새로운 전력품질 기준의 ANN 학습을 통한 성능 개선으로, 향후 지속적인 사용이 가능할 것이다.

참고 문헌

- [1] Kanitpanyacharoean, W. Premrudeepreechacharn, S. "Power Quality Problem Classification using Wavelet Transformation and Artificial Neural Networks," Power Systems Conference and Exposition, IEEE PES, vol.3, pp.1496- 1501, Oct. 2004
- [2] "IEEE Recommended Practice for Monitoring Electric Power Quality," IEEE standards Coordinating Committee 22, June. 1995
- [3] Inigo Monedero, Carlos Leon, Jorge Roperro, Antonio Garcia, Jose Mabuel Elena Juan C.Montano "Classification of Electrical Disturbances in Real Time Using Neural Network," Power Delivery, IEEE Trans. on Vol.22, pp.1288-1296, July, 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] 정승 "신경회로망의 구조 및 사용법," 충남대학교 출판부, Aug. 2004