

웨이블릿 기반의 RBF 신경망을 이용한 전력품질 진단시스템

김홍균, 이진목, 최재호, 이상훈*, 김재식*
충북대학교 전기전자 컴퓨터공학부, (주)포스콘*

A Power Quality Monitoring system using wavelet based RBF network

Hong kyun Kim, Jinmok Lee, Jeaho Choi, Sanghoon Lee*, Jaesig Kim*

School of elcetrical and computer engineering, Chungbuk National Univresity, Poscon Ltd.*

ABSTRACT

This paper presents a wavelet-based neural network technology for the detection and classification of the various types of power quality disturbances. Power quality phenomena are short-time problems and of many varieties. Particularly, the 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 WN (PQ-DAS) and some case studies are described.

1. 서론

전력품질(PQ)은 전기설비와 전력품질에 민감한 부하들의 사용량이 급격히 증가되면서 생산자와 소비자들에게 중요한 문제가 되고 있다. 전력품질을 향상시키기 위해서는 지속인 감시와 진단하는 시스템이 중요시된다. 이러한 진단시스템에서는 모든 외란 파형들을 찾아내고 기록하여 데이터베이스화 하는 것이 문제를 해결하는 열쇠를 제공한다. 초창기에는 직접 측정을 통해 진단했으나 장시간 직접 진단하는데 한계가 있어 점차 자동 원격 진단시스템으로 바뀌었다. 그러나 지금의 시스템은 전문가 시스템이 대부분이어서 누구나 알아보기에는 어려움이 있다. 따라서 보다 이해가 쉽고 실시간으로 모든 전력품질 문제에 관해 원격 진단하는 시스템을 제작, 실험하였다. 본 전력품질 진단시스템은 넷

트웍상에서 웨이블릿 기반의 신경망을 이용한 실시간 전력품질 진단알고리즘을 내장하고 다음과 같은 특징을 갖는다.^{[1][2]}

- 웨이블릿 변환은 파형과 이미지 분석을 위해 사용하는 진보된 수학적 기술이다.
- 웨이블릿 변환은 고장 부분이나 불연속 등을 포함한 데이터의 모습을 감지하는 능력은 다른 연산 기술로는 불가능하다.
- 신경망의 전력 품질에 대한 감지와 분류는 훈련을 통해서 이루어진다.

전력품질문제는 지속시간에 따라 분류되며 과도상태는 수 ns부터 수 μ s의 매우 짧고 빠른 지속시간 동안 나타난다. 이러한 문제들을 진단하기 위해서는 웨이블릿 변환이 유용하다. 그러나 실시간 전력품질 진단시스템에서는 이러한 과도상태와 더불어 보다 긴 시간동안의 변화인 순시전압강하(Sag), 순시전압상승(Swell), 순시정전(Interruption)과 같은 품질문제를 진단하기에 웨이블릿 변환은 부족한 점이 있다. 본 논문에서는 웨이블릿 변환의 장점과 일반적으로 신호처리에 사용하는 특징벡터들을 이용하여 지속시간에 관계없이 모두 실시간으로 전력품질을 진단하는 시스템을 구성하여 그 분류율을 향상시켰다.

2. 본론

2.1 웨이블릿 변환

웨이브릿 변환은 모함수의 이동과 스케일 변화를 이용하여 비정형신호를 분석하기위한 수학적 이론이다. 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, $b = nb_0a_0^m$ 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 1에서와 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.^{[3][4]}

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

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




그림 1 다해상도 분해
Fig. 1 Diagram of MSD

2.2 RBF(Radial Basis Function) 신경망

방사기저함수(RBF) 신경망은 다층 퍼셉트론과 유사하지만 그림2와 같이 은닉층과 출력층의 2층 네트워크로 구조가 간결하기 때문에 수학적 표현이 명료하고 반복적인 학습알고리즘을 사용하지 않기 때문에 학습속도가 빠른 장점이 있다. 입력층에서 은닉층까지의 연결강도 값은 1이며 은닉층의 활성화함수는 RBF함수를 이용하고 연결강도 W_j 를 곱하여 선형적으로 합한 값을 최종적으로 출력하며 식5, 식6과 같다. c_i 는 은닉층 뉴런의 중심, σ_i 는 넓이, w_j 는 가중치를 나타낸다. 본 논문에서는 k-평균 클러스터링 알고리즘을 사용하여 은닉층의 중심 벡터를 최소자승법(LMS) 방법으로 중간층과 출력층 사이의 가중치를 구하였다.

$$f(y_i) = \sum_{j=1}^m w_j y_i \quad (5)$$

$$y_i = \left\{ \exp\left(-\frac{(x-c_i)^2}{\sigma_i^2}\right) \right\} \quad (6)$$




그림 2 RBF신경망의 구조
Fig. 2 Schematic of a RBF neural network

2.3 학습 데이터 선택

본 실험에 사용하기 위한 입력 데이터는 대형부하로 운전하는 기업들에서 측정된 것을 표1과 같은 분류기준으로 분류하여 학습에 사용하였다.^[5]

표 1 전력송전 시스템 상수의 P.U.값
Table 1 Per unit values of the system parameters

Categories	Typical spectral content	typical duration	Voltage mag.(pu)
Transient			
Impulsive			
Nano	5ns rise	<50ns	
Micro	1us rise	50ns-1ms	
Milli	0.1ms rise	>1ms	
Oscillatory			
Low fre.	<5kHz	0.3-50ms	
Medium fre.	5-500kHz	20us	0-4
High fre.	0.5-5MHz	5us	0-8
Interruption		>0.5cycle	0-4
Sag		>0.5cycle	<0.1
Swell		>0.5cycle	>1.1
Noise		Steady state	<0.01

과도상태 중에서 impulsive 과도상태는 대부분 번개에 의해서 일어나며, 전류나 전압 또는 모두에서 5ns ~ 0.1ms의 짧은 시간동안 일어나는 문제로 본 논문의 시스템이 65μs의 샘플링 주기를 감안할 때 nano-나 microsecond 과도상태는 진단하기 어렵다. 그러므로 실제 학습을 위해서는 millisecond 과도상태 데이터를 사용하였다.

공진이 원인인 Oscillatory 과도현상에 관해서는 본 시스템이 60Hz일때 256sampling/cycle 이므로 Nyquist sampling 주파수에 의해 7.66kHz이하의 영역에서 일어나는 진동 과도현상을 진단할 수 있으

므로 Low와 Medium 주파수 영역의 데이터를 학습에 사용하였다.

시스템의 고장이나 과부하의 갑작스런 동작이나 멈춤, 또는 큰 모터의 기동이나 멈춤에 의해서 발생하는 순시전압강하(Sag)나 순시전압상승(Swell)은 반주기 이상의 지속시간을 갖는다. 이러한 학습을 위해 적당한 데이터를 선별하였다.

정상상태에서 1%미만의 크기를 가지고 주파수가 200kHz 보다 작은 크기를 갖는 잡음(Noise)은 전력 전자 소자, 제어회로, 아크로, 정류기 또는 스위칭 전원공급장치에 의해 발생하며, 이 중에서 7kHz이하의 잡음을 선택하여 학습 데이터로 사용하였다.

2.4 시스템 구성

전력품질 진단시스템의 하드웨어(PQ-DAS)는 TI사의 TMS320VC33(150MHz)를 사용하였으며 RS232와 이더넷 1포트를 내장하고 있다. 부가장비 없이 3상 4선식의 7채널의 전압 -600~+600V, 전류 50A의 측정이 가능하며 실시간진단과 사고발생시 사고파형을 저장하고 데이터베이스 서버로 전송한다. 본 시스템의 진단프로그램은 마이크로소프트사의 비주얼 베이직으로 프로그래밍 하였다. 기본화면에서 역률, 실효값, FFT(50차), 사고 발생횟수와 사고파형을 볼 수 있다.^[6]

2.5 특징추출 및 학습방법

전력품질의 입력값은 시간에 따라 변화하는 전압과 전류 값으로 시간신호 자체에서 각각의 문제들에 대해 알 수 없기 때문에 신경망에 그대로 적용하기에는 어려움이 있다. 이러한 신호를 분석하기 위해서는 각 문제들이 갖는 고유한 특징 추출이 필

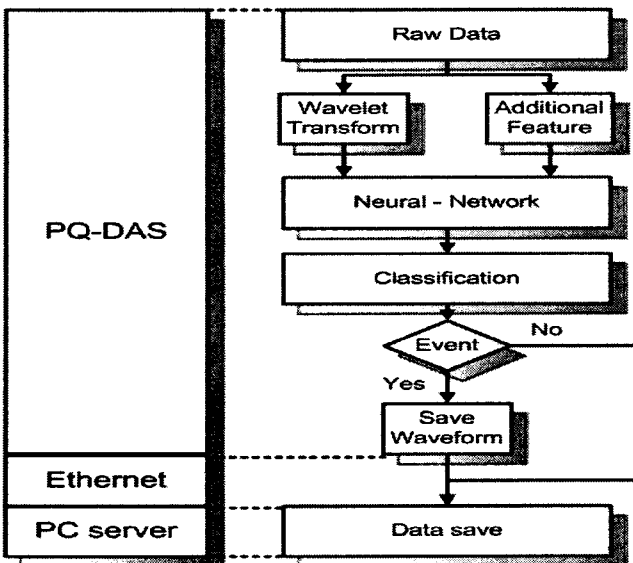


그림 3 전력품질 진단시스템의 흐름도
Fig. 3 Flow chart of power the quality monitoring system

표 2 Case 1에 대한 분류 결과

Table 2 Classification results of case 1

True Class	Classification Results					
	0	1	2	3	4	5
0	17	2	0	0	0	1
1	2	16	0	0	1	1
2	0	0	19	1	0	0
3	0	0	1	19	0	0
4	0	0	1	1	18	0
5	0	0	0	1	0	17

표 3 Case 2에 대한 분류 결과

Table 3 Classification results of case 2

True Class	Classification Results					
	0	1	2	3	4	5
0	19	0	0	0	0	1
1	0	19	0	0	0	1
2	0	0	18	2	0	0
3	0	0	1	18	1	0
4	1	1	1	0	17	0
5	0	0	0	0	0	20

표 4 Case 3에 대한 분류 결과

Table 4 Classification results of case 3

True Class	Classification Results					
	0	1	2	3	4	5
0	20	0	0	0	0	0
1	0	19	0	0	0	1
2	0	0	19	1	0	0
3	0	0	0	20	0	0
4	1	0	0	0	19	0
5	0	0	0	0	0	20

표 5 분류오차

Table 5 Classification error

True Class	% Error		
	Case 1	Case 2	Case 3
0	15	5	0
1	20	5	5
2	5	10	5
3	5	10	0
4	10	15	5
5	15	0	0
Total	11.666	7.5	2.5

요하다. 이 특징량은 시간에 따라 변화하지 않고 일정한 값을 가져야 하며 동일한 문제에 대해서는 특징량의 값이 서로 짧은 거리를 가져야 하고 서로 다른 문제에 대해서는 특징량의 거리가 멀어야 한다. 이러한 분석을 위해서는 일반적으로 사용되는 통계적인 분석방법인 평균, 표준편차, 왜도, 첨도,

FFT를 사용하는 것 이외에 파형률과 파고율을 고려 하여야한다. 그러나 이와 같은 특징량들은 과도상태 변화를 알아내기에는 한계가 있다. 이에 비해서 웨이블릿 변환은 빠른 변화에 민감한 특징을 가진다. 본 논문에서는 세 가지 시스템을 구성하고 학습 및 분류를 하여 결과를 비교 검토하였다.

Case 1. 일반적인 특징량 계산을 이용한 경우

Case 2. 웨이블릿 변환을 이용한 경우

Case 3. Case 1과 Case 2를 모두 이용한 경우

이와 같은 실험은 그림 3과 같이 데이터 분석 시스템(PQ-DAS)에서 데이터 수집과 특징량 계산 후 RBF신경망을 이용하여 문제 발생시 이상 파형 및 유형을 이더넷을 통해서 데이터베이스 서버에 전송하게 된다.

학습결과는 표2, 표3, 표4와 같으며 Class 0은 Impulsive 과도상태, Class 1은 Oscillatory 과도상태, Class 2는 순시정전, Class 3은 순시전압강하, Class 4는 순시전압상승, Class 5는 잡음을 나타낸다. 표2에서 보는 바와 같이 Case 1에서는 Impulsive 분류율이 저하되었고, 웨이블릿 변환을 이용한 Case 2에서는 표3에서 보는 바와 같이 순시전압강하와 순시전압상승에서 분류율이 저하되었다. 두 장점을 결합한 Case 3의 결과인 표4를 보면 전체적인 분류율이 개선된 것을 알 수 있다.

3. 결론

본 논문에서는 거의 모든 전력품질 문제를 보다 정확하게 감시와 진단을 하는 시스템을 제안한다. 이를 위하여 웨이블릿 변환의 장점을 이용 짧은 지속시간을 갖는 과도상태에 대해 고려하였다. 그리고 학습이 빠르고 지역 근사화가 뛰어난 RBF신경망을 이용하여 분류율을 향상시켰다. 웨이블릿 변환만을 이용한 경우와 일반적인 특징량 계산방법을 이용한 방법과 두 가지 방법 모두를 이용한 방법을 비교 실험한 결과 Case 1의 경우보다 9.1%, Case 2 보다는 5% 분류율이 향상된 결과를 얻을 수 있었다. 이것은 웨이블릿 기반의 RBF신경망의 우수성을 입증하는 결과이다. 본 논문에서 제안한 전력품질 진단시스템은 PQ-DAS 내에서 데이터의 수집, 연산, 특징량 계산과 분류가 이루어지고 전력품질 문제가 발생했을 때 이상 파형과 분류된 문제에 대한 정보를 이더넷을 통해 데이터베이스 서버로 전송 저장되어 원격으로 실시간 진단을 할 수 있도록 설계되었다.

참고 문헌

- [1] J. D. Hoyt and H. Wechsler, "RBF Models for Detection of Human Speech in Structured Noise", *IEEE Inter. Conf. on Neural Networks-IEEE World Congress on Computational Intelligence*, vol. 7, pp. 4493-4496, 1994.
- [2] 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.
- [3] J. Chen. W. Kinsner, and B. Huang, "Power System Transient Modeling and Classification", *Proc. of the 2002 IEEE Canadian Conf. on Electrical & Computer Engineering*, pp. 184-189, 2002
- [4] 이진목, 김홍균, 최재호, "이산 웨이블릿을 이용한 전력외란 측정시스템", *전력전자학회 논문지* 8권 6호, pp. 527-533, 2003.
- [5] IEEE Recommended Practice for Monitoring Electric Power Quality, IEEE Std. 1159-1995, June. 1995.
- [6] 김홍균, 이진목, 최재호, "파워진단을 위한 계측 시스템 설계", *전력전자학회 추계학술대회논문집*, pp. 109-194, 2002.