

신경회로망을 이용한 신호 자동식별기 구현 및 성능분석

*윤병수^o, *양성철, *남상원, **오원천
*한양대학교 전기공학과, **국방과학연구소

On the Performance Analysis of an Automatic Neural Network Signal Classifier

*Byung-Soo Yoon^o, *Seong-Chul Yang, *Sang-Won Nam, **Won-Tcheon Oh

*Dept. of Electrical Engineering, Hanyang Univ., **Agency for Defense Development

Abstract : In this paper a feature-based automatic neural network signal classifier is presented, where five neural network algorithms such as MLP, RBF, LVQ2, MLP-Tree and LVQ-Tree are combined in parallel to classify various signals from their features, based on the majority vote method. To demonstrate the performance and applicability of the proposed signal classifier, some test results for the classification of synthetic waveforms and power disturbances are provided.

1. 서 론

본 논문의 목적은 여러 측정된 실제 신호를 자동으로 식별해 낼 수 있는 식별기를 설계하는데 있다. 신호의 식별과정은 크게 다음의 두 단계로 이루어진다. 즉 각 신호의 특성을 가장 잘 나타낼 수 있는 적절한 특징벡터의 선정과 추출된 특징벡터를 입력으로하여 신호를 분류하는 식별알고리즘 개발로 나누어진다. 본 논문은 그 후자, 즉 특징벡터의 종류에 관계없이 주어진 특징벡터를 입력으로하여 신호를 분류할 수 있는 일반적인 식별기 설계에 중점을 두었다.

본 논문에서는 신호에 대한 수학적인 사전 지식을 요구하지 않고 일반화하는 능력이 뛰어난 신경회로망을 기본 식별알고리즘으로 선정하였다. 특히 MLP, RBF, LVQ2와 같은 기본적인 신경회로망과 MLP-Tree, LVQ-Tree와 같이 신경회로망과 결합트리를 결합한 알고리즘을 구현하고 이러한 5개의 식별알고리즘을 병렬로 연결하여 각 식별알고리즘의 출력을 다수결의 원칙을 사용하여 판단하도록 식별기를 구성함으로써 개별 알고리즘을 사용하였을 경우 보다 인식율을 향상시키고자 하였다. 끝으로 인식율이 이론적으로 규명이 되어있는 합성파형과 전력 외란 신호를 사용하여 각 식별알고리즘과 식별기를 학습 및 테스트해봄으로써 그 성능과 적용가능성을 평가하고자 하였다.

2. 식별알고리즘 구현 및 검증

다음은 본 논문에서 사용한 5개의 신경회로망에 대한 설명과 그 검증 결과이다.

2.1 기본 식별알고리즘

(A) Multilayer Perceptron (MLP)

MLP[1]는 순방향(feed-forward) 지도학습(supervised) 신경회로망으로서 에러 역전파법(error backpropagation)으로 가중치(weight)를 수정한다. 중간층 노드가 충분하다면 3층의 MLP로 임의의 비선형 함수를 근사화할 수 있다는 것이 증명되어 있으며 이것이 폐인간의 경계면을 근사화시킬 수 있다는 이론적 배경이 되고 있다[2]. MLP는 입력폐인과 그 상층의 대응하는 가중치를 곱한 후 그 값을 합한다. 그 합한 값을 비선형 함수(sigmoid function)를 통하여 같은 과정을 최종 출력층까지 반복함으로써 네트워크의 출력을 얻게 된다.

(B) Radial Basis Function (RBF)

RBF는 방사상으로 대칭인(radially symmetric) 함수를 중간층의 출력함수(activation function)로 사용한 single hidden-layer feedforward network이다[3]. 중간층 출력함수는 중심과 폭을 가지고 있는데 군집화(clustering) 알고리즘으로 중심을, 그리고 중심간의 거리로 폭을 미리 구해서 고정시켜놓은 후 학습시에는 출력층과 중간층 사이의 가중치만 엔터역전파법에 의해 수정하게 된다. RBF는 한 층의 가중치만 수정하기 때문에 학습속도가 MLP에 비해 빠를 수 있으나, 중심과 폭의 초기 설정에 따라 네트워크 성능이 크게 좌우될 수 있다는 단점이 있다.

(C) Learning Vector Quantization (LVQ)

LVQ는 몇몇의 codebook vector 또는 참조벡터(reference vector)들로 폐인공간을 분할하여 대표하게 되는 알고리즘이다[4]. 학습에 의하여 각 부류(class)를 대표하는 참조벡터를 구한 후, 미지의 폐인이 들어왔을 때 그 폐인과 각 참조벡터들과의 거리를 구해 가장 가까운 참조벡터를 선택하고, 그 선택된 참조벡터가 속한 부류를 입력폐인의 부류라고 할당함으로써 폐인을 분류하게 된다. LVQ는 클러스터링 알고리즘으로 초기 참조벡터를 구한 후 학습에 의해 에러가 최소가 되도록 그들의 위치를 조정한다. 본 논문에서는 LVQ1 학습 알고리즘을 개선하여 Bayes 결정 경계면을 좀더 근사화할 수 있도록 한 LVQ2 [4]를 식별 알고리즘으로 사용하였다.

(D) Decision Tree with MLP (MLP-Tree)

MLP-Tree [5]에서는 MLP가 임의의 비선형 함수를 근사화할 수 있다는 점을 고려하여, 결정트리[6]의 각 결정 단계, 즉 각 트리노드에 하나의 작은 MLP를 사용함으로써 비선형경계면을 형성할 수 있게 한 것이다. 각 결정단계에서 학습폐인들을 가능한 두 그룹으로 나누어 각각을 학습해본 후 가장 분류가 잘 되는 (Gini criterion[5]에 의해) 두 그룹을 그 결정단계의 좌, 우 그룹으로 정하고 그렇게 나누어진 폐인들을 각각 그 좌, 우 하위노드에 넘겨주어 다시 같은 과정을 반복한다. 트리는 중요조건이 만족되면 성장을 멈추게 된다.

(E) Decision Tree with LVQ (LVQ-Tree)

LVQ에서는 각 참조벡터가 폐인공간을 나누어 그 공간을 대표하며, 결정트리에서는 각 노드가 폐인 공간에 경계선을 그어 순차적으로 공간을 분할한다. LVQ-Tree [7]는 결정트리의 각 노드에 LVQ를 사용함으로써 두 개념을 결합하고 있다. 각 노드에서는 LVQ로 폐인공간을 나누며 이 나누어진 폐인공간을 그 참조벡터로 대표하고, 다시 하위 노드에서 분할된 공간 각각에 대해 위의 과정을 반복해감으로써 공간을 단일 LVQ보다 세밀하게 분할하여 대표한다. 트리의 성장과정은 CART(classification and regression tree) 방법[5,8]을 적용하였다.

2.2 기본 식별알고리즘 검증

알고리즘이 이론적인 인식율이 규정되어있는 합성파형을 인식하게 하여 각 식별알고리즘의 타당성을 평가해 보았다. 그럼 1의

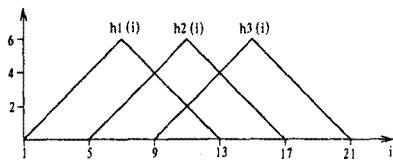


그림 1 : 실험용 합성파형

Class	Classification Algorithms				
	MLP	RBF	LVQ2	MLP-Tree	LVQ-Tree
C1	74.6 %	68.4 %	76.8 %	75.5 %	80.5 %
C2	86.5 %	92.6 %	83.4 %	86.5 %	82.1 %
C3	81.4 %	90.5 %	84.7 %	82.1 %	81.0 %
total	0.8 %	83.8 %	81.6 %	81.4 %	81.2 %

표 1 : 각 식별알고리즘의 합성파형 인식 결과

- class 1. $x_i = uh_1(i) + (1-u)h_2(i) + \epsilon_i, i = 1 \dots 21$ (1)
 class 2. $x_i = uh_1(i) + (1-u)h_3(i) + \epsilon_i, i = 1 \dots 21$ (2)
 class 3. $x_i = uh_2(i) + (1-u)h_3(i) + \epsilon_i, i = 1 \dots 21$ (3)

합성파형은 각 패턴부류 분포간에 어느 정도의 중복이 있고 이상적인 경우 14%의 최소 에러율을 갖는다[5,8]. 그림 1의 $h_1(i)$, $h_2(i)$, $h_3(i)$ 를 식(1), 식(2), 식(3)과 같이 합성하여 세 부류의 데이터로 만들었다. 여기서 u 는 [0,1]의 균일한 확률 분포를 갖는 랜덤 값이고 $\epsilon_1 \dots \epsilon_{21}$ 은 각각 평균이 0이고 분산이 1인 Gaussian 랜덤 값이다. 학습패턴으로는 각 클래스 당 100개씩 21차원의 300개의 패턴을 사용하였고, 클래스 당 1000개씩 3000개의 별도의 패턴으로 에러율을 측정하였다. 표 1에 각 알고리즘별 합성파형 인식결과를 나타내었다. 모든 알고리즘이 18% 안팎의 비교적 비슷한 에러율을 내었다. 그러나 각 부류별 에러율이 알고리즘별로 서로 다르고 한 신호에 대해 여러로 판단된 부류 또한 서로 다른 수가 있기 때문에 각 식별알고리즘을 결합하면 서로의 에러율 다른 식별알고리즘이 보상해줄 수 있을 것이 예상된다. 본 논문에서는 위의 5개 식별 알고리즘 모두를 식별시스템에 사용하기로 하였다.

3. 식별시스템 구성

3.1 식별시스템

최종적인 식별시스템은 그림2와 같이 구성된다. 신호가 식별기에 들어오면 각 식별알고리즘은 독립적으로 신호를 분류하게 되고 각 식별알고리즘으로부터 나온 결과를 다수결의 원칙에 따라 결합하여 최종적인 판단을 하여 신호를 분류하게 된다[11].

3.2 식별시스템 검증

그림 1의 기본 합성파형을 인식하게 한 2.2절의 5개 알고리즘들을 다수결 원칙에 의하여 결합하였다. 표 2의 결과를 보면 결합된 식별기는 어느 단일 식별기보다 우수한 인식율을 보였으며(표 1의 RBF: 83.8%, 표 2의 no T: 85.3%) 문턱값이 없을 경우에 거의 이상적인 에러율(14%)에 가까운 14.7%의 에러율을 보였다. 또한 문턱값이 3인 경우에도 분류되지 않은 신호까지 합한다. 하더라도 단일 식별기 보다 우수한 인식율(85.2%)을 보였다. 따라서 결합된 식별기가 단일 식별알고리즘들보다 우수한 성능을 보임을 알 수 있었으며 이것은 예상된 결과와도 일치한다.

Threshold (T)	Class			Total Classification Rate	Unclassified
	C1	C2	C3		
5	542/626	678/702	611/646	1831/1974 (92.8 %)	1026
4	682/836	825/886	797/863	2304/2585 (89.1 %)	415
3	773/999	893/997	890/999	2556/2995 (85.3 %)	5
2	226/1000	106/1000	110/1000	2558/3000 (85.3 %)	0
no T	226/1000	106/1000	110/1000	2558/3000 (85.3 %)	0

표 2 : 결합된 식별기의 합성파형 인식 결과

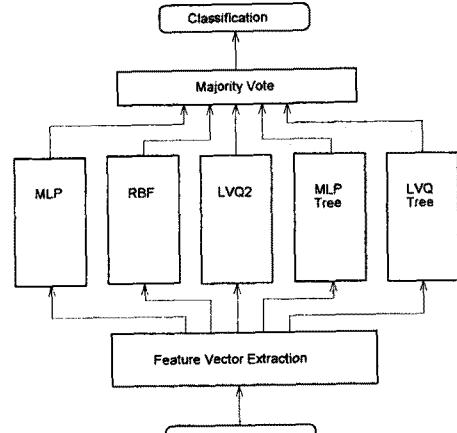
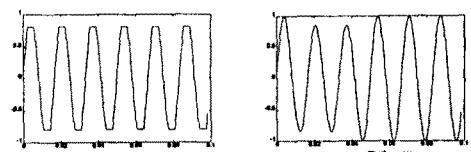


그림 2 : 결합된 식별기



(a) flat-top

(b) voltage sag

(c) overvoltage

(d) capacitor energizing

(e) harmonic

그림 3 : 전력외란신호

4. 전력외란신호 인식 실험

현재 정밀 전자제품이나 기기등의 사용이 늘어남에 따라 양질의 전력에 대한 수요가 증가하고 있다. 그러나 전력에 외란이 생겼을 때 이를 효율적으로 검출 또는 분류하고 있지는 못하는 실정이다[9]. 본 실험은 이러한 전력외란신호를 분류하게 함으로써 본 논문에서 구현한 각 식별알고리즘과 종합 식별기의 성능을 비교 분석하는데 목적이 있다.

4.1 실험데이터 및 특징베타

본 실험에는 실험실에서 만든 모의 전력외란신호를 사용하였다. 외란의 종류는 flat-top, voltage sag, overvoltage, capacitor energizing, transients, harmonics 이렇게 5가지이며 그림 3에 이들을 나타내었다[9]. 각 부류별로 50개의 신호가 있으며 이중에

Class	Algorithm				
	MLP	RBF	LVQ2	MLP-Tree	LVQ-Tree
C1	23/25(92.0%)	23/25(92.0%)	23/25(92.0%)	22/25(88.0%)	21/25(84.0%)
C2	23/25(92.0%)	20/25(80.0%)	21/25(84.0%)	23/25(92.0%)	25/25(100%)
C3	25/25(100%)	24/25(96.0%)	21/25(84.0%)	25/25(100%)	18/25(72.0%)
C4	23/25(92.0%)	23/25(92.0%)	25/25(100%)	25/25(100%)	24/25(96.0%)
C5	25/25(100%)	25/25(100%)	25/25(100%)	25/25(100%)	25/25(100%)
total	119/125 (95.2 %)	115/125 (92.0 %)	115/125 (92.0 %)	120/125 (96.0 %)	113/125 (90.4 %)

표 3 : 각 식별알고리즘의 전력외란신호 인식결과

Threshold (T)	Class					Classification Rate	Unclassified
	C1	C2	C3	C4	C5		
5	22/22	15/15	17/17	23/23	25/25	102/102 (100 %)	23
4	23/23	18/18	22/22	23/23	25/25	111/111 (100 %)	14
3	23/24	25/25	24/25	24/24	25/25	121/123 (98.4 %)	2
2	23/25	25/25	24/25	25/25	25/25	122/123 (97.6 %)	0
no T	24/25	25/25	24/25	25/25	25/25	122/123 (97.6 %)	0

표 4 : 식별기의 각 문턱값에 따른 전력외란신호 인식결과

Threshold (T)	Unclassified/Total		Total Error: Unclassified-Classification Error
	Unclassified	Total	
5	23 / 125 (18.4 %)	23 / 125	23 / 125 (18.4 %)
4	14 / 125 (11.2 %)	14 / 125	14 / 125 (11.2 %)
3	2 / 125 (1.6 %)	4 / 125	4 / 125 (3.2 %)
2	0 / 125 (0.0 %)	3 / 125	3 / 125 (2.4 %)
no T	0 / 125 (0.0 %)	3 / 125	3 / 125 (2.4 %)

표 5 : 각 문턱값에 따른 비 분류율 및 전체 에러율

각 부류별로 25개씩 모두 125개의 신호를 학습에 각 부류별로 25개씩 나머지 125개의 신호를 테스트에 사용하였다. 모든 신호는 5.2 KHz로 샘플링 되었고 의관은 Daubechies' wavelet을 사용하여 검출되었다 [9,10]. 신호의 특징벡터는 의관이 있을 때의 전력신호의 크기와 wavelet의 scale이 1, 2, 3, 4 일 때의 wavelet 변환된 계수중 각 scale에 하나씩 가장 큰 값을 취하였다. 따라서 한 신호의 특징벡터는 신호의 크기와 4개의 wavelet계수를 포함하여 5개로 구성된다.

4.2 전력외란신호 식별 결과

표 3에서 각 식별알고리즘의 성능을 비교해 보면 LVQ-Tree의 인식율이 90.4%로 다소 떨어지고 MLP와 MLP-Tree는 인식율이 각각 95.2%, 96.0%로 비교적 우수한 성능을 나타냈다. 그러나 모든 알고리즘과 각 신호 부류별로 비교적 비슷한 에러율을 내었다.

최종 식별기는 MLP, RBF, LVQ2, MLP-Tree, LVQ-Tree로 구성되어 있으며 이를 5개의 식별알고리즘의 출력을 다수결 원칙에 의해 결합하였다. 또한 문턱값(threshold)을 정해주어 최대 다수의 개수가 문턱값 이상이 될 때만 판단을 하도록 하였고 그 이하의 경우에는 경고신호를 하도록 하였다. 표 4를 보면 가장 우수한 개별 식별알고리즘 보다 결합한 후의 인식율이 1.6% 정도 향상되었다(표 3의 MLP-Tree: 96 %, 표 4의 no T: 97.6 %). 또한 문턱값이 높아 주면 분류되지 않은 신호를 제외한 신호들에 대해 식별기의 신뢰도가 높아짐을 알 수 있다. 표 5에 비분류율과 비분류된 신호와 분류된 신호를 합하여 에러율을 내었다. 문턱값이 3인 경우 까지는 비분류된 신호를 합해도 높은 인식율을 내었으나 문턱값이 4이상일 경우에는 비분류되는 신호의 수가 많아진다. 따라서 본 식별기는 문턱값을 조절함으로써 전체 인식율을 뿐만 아니라 분류된 신호에 대한 신뢰도 또한 높일 수 있는 장점이 있다.

5. 결론

본 논문은 신호의 특징벡터를 입력으로 받아 신호를 자동으로 식별할 수 있는 식별기를 설계하는 것을 목적으로 하고 있다. 식별 알고리즘으로는 MLP, RBF, LVQ2, MLP-Tree, LVQ-Tree와

같은 신경회로망을 구현하여 보았고 그들을 14%의 최소 에러율을 갖는 기본 합성파형 및 모의 전력외란신호로 테스트하여 보았다. 전력외란인식 실험에서 MLP, MLP-Tree가 비교적 우수한 인식율을 내었다. 최종 식별기는 각 식별알고리즘을 병렬로 연결하여 구성하였으며 각 알고리즘의 출력 결과를 다수결 원칙에 따라 결합하였다. 또한 식별시 문턱값을 설정하여 신뢰도를 높였으며 구현된 식별기는 기본 합성파형과 전력외란신호로 테스트해 볼으로써 구현된 식별기의 성능을 확인해 보았다. 기본 합성파형 테스트와 전력외란 테스트 모두 결합된 식별기가 각 개별 알고리즘보다 우수함이 입증 되었다.

성능이 좋은 식별기를 설계하기 위해서는 우수한 식별 알고리즘을 구현하는 것 못지 않게 좋은 특징벡터를 추출하는 것도 중요하다. 본 논문에서는 식별기를 모두 정적 신경회로망으로 구현하였다. 새로운 특징벡터의 선정 그리고 동적 신경회로망을 사용한 식별기 구성 등은 추후 연구의 대상이다.

* 본 연구는 전해 국방과학연구소 지원 위탁과제하에 이루어졌다.

6. 참고문헌

- [1] J.A. Freeman and D.M. Skupra, *Neural Networks: Algorithms, Applications, and Programming Techniques*. Addison Wesley, 1991
- [2] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks and universal approximations," *Neural Networks*(2), pp. 359-366, 1989.
- [3] P.D. Wasserman, *Advanced Methods in Neural Computing*. Van Nostrand Reinhold, New York, 1993.
- [4] T. Kohonen, "The self-organizing map," *Proc. IEEE*, vol. 78, no. 9, pp. 1464-1480, 1990.
- [5] H. Guo and S.B. Gelfand, "Classification trees with neural network feature extraction," *IEEE Trans. Neural Networks*, vol. 3, no. 6, pp. 923-933, Nov. 1992.
- [6] W.S. Meisel and D.A. Michalopoulos, "A partitioning algorithms with application in pattern classification and the optimization of decision trees," *IEEE Trans. Comput.*, vol. C-22, pp. 93-103, Jan. 1973.
- [7] 양성철, 남상원, 오원천, "LVQ와 결정 트리를 결합한 패턴분류 알고리즘," 대한전기학회 하계학술대회 논문집 B, pp. 1037-1039, 1994
- [8] L. Breiman, J.H. Friedman, R.A. Olshen, and C.J. Stone, *Classification and Regression Trees*. Belmont, CA: Wadsworth, 1984.
- [9] S. Santos, Jr., "Application of wavelet transform analysis to the detection and localization of power quality disturbances," M.S. Thesis, The Univ. of Texas at Austin, Aug. 1994.
- [10] M. Vetterli and C. Herly, "Wavelets and filter banks: theory and design," *IEEE Trans. on Signal Processing*, vol. 40, no. 9, pp. 2207-2232, Sept. 1992.
- [11] J. Ghosh, S. Beck, and C.C. Chu, "Evidence combination techniques for robust classification of short-duration oceanic signals," SPIE Conference on Adaptive and Learning Systems, Orlando, FL, April 1992.