

신경회로망을 이용한 고조파 부하의 식별

황창선^{*}, 김재식^{*}, 김동완^{*}, 김문수^{*}, 최중락^{**}
* 부산대학교 전기공학과 ** 국방과학 연구소

Identification of harmonic loads using neural network

C. S. HWANG^{*}, J. S. SHIM^{*}, D. W. KIM^{*}, M. S. KIM^{*}, J. L. CHOI^{**}
* Pusan National Univ. ** ADD

Abstract : Semiconductor devices generate harmonics which induced bad effects against power distribution systems. To suppress harmonics, the filter design and the identification of harmonic load sources are needed.

In this paper, artificial neural networks are used to identify the nonlinear relationship between harmonic loads and harmonic currents that vary at times. To find the best adequate network for solving this identification problem, we compared with recognition rates of neural networks by changing hidden layer neuron number

1. 서론

최근 전력전자 분야에 있어서 반도체 소자의 발달로 인해 비선형 부하가 증가하고 있다. 반도체 소자는 여러 종류의 산업용 기기 및 가전제품에 널리 이용되고 있어 정현파를 일그러지게 하여 고조파 발생의 원인이 되고 있다.^[1]

이러한 고조파는 배전계통을 통하여 인접하는 부하에도 영향을 줄 뿐만 아니라 전력계통의 특성에도 장해를 준다. 이와 같은 고조파 문제를 해결하려고 할 때 부하에 의해 발생된 고조파 성질로서 광범위하게 분포된 고조파 부하의 다양성, 고조파의 불규칙한 변동성 및 고조파신호의 비선형성등의 곤란한 점이 있고, 이와 같은 고조파 성질의 복잡성 때문에 고조파 억제책으로 필터설계와 같은 하드웨어적인 분야는 연구되고^[2] 있으나 고조파 식별문제에 관한 연구는 아직 초기연구 단계에 있다.

따라서, 본 논문에서는 부하에 의해 발생된 고조파 문제를 해결하기 위한 한 방법으로서 고조파 일그러짐의 원인이 되는 부하에 관한 정보를 얻기 위해 최근에 복잡하고 비선형성이 강한 대상에 대한 식별문제를 해결하는 수단으로 많은 연구가 이루어지고 있는 신경회로망을 이용하여 고조파 전류 스펙트럼으로부터 고조파 부하원을 식별하고자 한다. 그 방법으로서 BPN(Back-Propagation Network)과 CPN(Counter-Propagation Network)을 선택하여 중간층 뉴런(neuron)수에 따른 인식률과 수렴속도를 비교 분석하여 이 식별문제에 적용하기 위한 가장 최적의 신경회로망을 찾고자 한다.

2. 학습알고리즘

2.1 역전파(Back Propagation) 학습법에 의한 신경회로망

BPN의 학습법은 일반적으로 generalized delta rule로 알려져 있으며 지도학습의 한 방법으로써 주어진 모든 학습 패턴간의 실제출력과 목표출력간의 오차를 최대경사법(steepest descent method)을 이용하여 최소화하는 것이다.^[3] 그 오차식은 다음과 같다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - O_{pk})^2 \quad (1)$$

그리고 모멘텀을 고려한 가중치의 수정은 다음 식과 같다.

$$\Delta_p W_{kj}(n+1) = \eta \delta_{pk} O_{pj} + \alpha \Delta_p W_{kj}(n) \quad (2)$$

이때 출력층에서의 오차 δ_{pk} 는

$$\delta_{pk} = (t_{pk} - O_{pk}) f'_k (net_{pk}) \quad (3)$$

이고, 중간층에서의 오차 δ_{pj} 는

$$\delta_{pj} = f_j' (net_{pj}) \sum_k \delta_{pk} W_{kj} \quad (4)$$

와 같다.

2.2 Counter Propagation(CP) 학습법에 의한 신경회로망

CPN은 새로운 형태의 회로망이 아니라 경쟁(competitive) 회로망과 Grossberg의 outstar구조와의 결합으로 생성된 유형분류기이다. CPN의 학습법은 다음과 같다.^[3] 먼저 입력에서 경쟁층으로의 가중치는 경쟁층의 승자(win) 뉴런에 연결된 가중치만 다음 식으로 조정한다.

$$W_{ji}(t+1) = W_{ji}(t) + \alpha (X_i - W_{ji}) \quad (5)$$

또한, 승자 뉴런에서 출력층으로의 가중치만 Widrow-Hoff학습법인 다음 식과 같이 조정한다.

$$V_{ji}(t+1) = V_{ji}(t) + \beta (Y_j - Y_j') \quad (6)$$

3. 고조파 계측 장치구성 및 실험방법

3.1 고조파 계측 장치

고조파 전류는 그림 1과 같은 PC를 이용한 계측 시스템으로 측정된다.^[4]

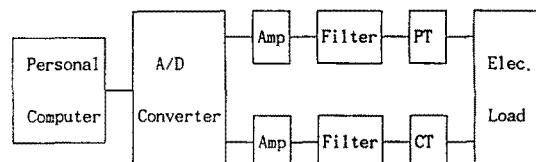


그림 1. 고조파 계측 장치 구성도

3.2 실험방법

- ① 부하선택 : TV, 전자렌지, PC, 냉장고, 형광등을 선택한다.
- ② 고조파 전류 측정 : 선택된 부하를 PC, CT (Current Transformer), PT (Potential Transformer), A/D Converter 등으로 구성된 시스템으로 고조파 전류를 측정한다.
- ③ data 분석 : FFT를 이용하여 전류의 스펙트럼을 분석한다.
- ④ 학습 data 구성 : 계산된 진폭을 몇 개의 집합으로 분류하여 학습 data로 사용하고 data도 고조파 차수에 따라 몇 가지 경우로 나눈다.

⑤ 신경회로망 적용 : 고조파 부하원을 식별하는데 알맞은 신경회로망을 찾기 위해 신경회로망 BPN, CPN의 중간층 뉴런수를 변화시키면서 중간층 뉴런수에 따른 인식률과 수렴속도를 비교 검토하여 최적의 신경회로망을 결정한다.

4. 시뮬레이션

4.1 학습 data

측정일이 다른 set A, B, C를 학습 data 및 test data로서 사용한다. 신경회로망에 적용되는 입력 data는 다음과 같다.

CASE 1 : h차 ($h = 1, 2, \dots, 31$)의 고조파 전류의 진폭

CASE 2 : CASE 1의 기수파 고조파 전류의 진폭

CASE 3 : 1, 3, 5, 7, 9, 11, 13, 15차의 고조파 전류의 진폭

그림 2는 TV에 대한 고조파 전류스펙트럼이다.

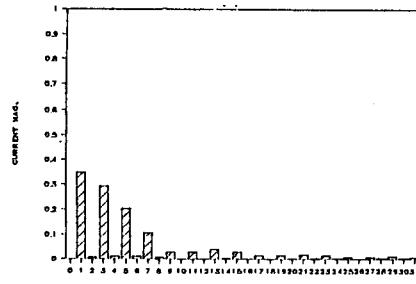


그림 2. TV의 고조파 전류스펙트럼

4.2 학습조건

① 입력 data에 대응하는 고조파 부하에 속하는 출력층의 뉴런의 출력을 1로 하고 그 외의 출력은 0으로 하는 방법으로 학습한다.

② 학습종료시점 : RMS오차가 1×10^{-3} 이하에 도달하거나 학습회수가 100,000회에 도달할 때 학습을 종료한다.

③ 학습한 신경회로망의 성능을 평가한 인식률 ξ 는 다음과 같이 정의한다.

$$\xi = \frac{n_c}{n_t} * 100(%) \quad (7)$$

단, n_c : 올바른 인식을 한 시행회수 n_t : 총 시행회수

④ 뉴런간의 weight초기값은 $-0.1 \sim +0.1$ 로 선택한다.

⑤ 학습률 η , β 와 모멘텀의 계수 α 는 다음과 같이 선택했다.

$$\eta = 0.3 \quad \alpha = 0.9 \text{ (BPN)} \quad \beta = 0.2 \text{ (CPN)}$$

4.3 인식률 및 수렴속도

BPN 및 CP학습알고리즘을 이용하여 신경회로망을 학습하고 학습완료된 신경회로망의 성능을 조사하기 위해 인식률을 검토한다. set A, B, C는 학습 data와 test data로 모두 사용된다. BPN인 경우 중간층 뉴런수를 $N = 2 \sim 20$, CPN인 경우 중간층 뉴런수를 $N = 5 \sim 20$ 까지 변화시키면서 인식률과 수렴속도를 검토했다. 그리고 학습 및 test data는 다음과 같다.

set A-BC : set A로 학습한 신경회로망을 이용해서 test data인 set B, C로 사용했을 때의 인식률

4.3.1 인식률 및 수렴속도

그림 3 ~ 그림 8 : 중간층 뉴런수에 따른 인식률

그림 9 ~ 그림 14 : 중간층 뉴런수에 따른 수렴속도

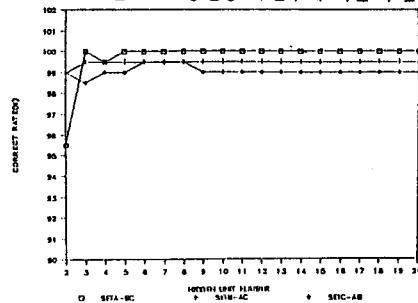


그림 3. CASE 1의 인식률 (BPN)

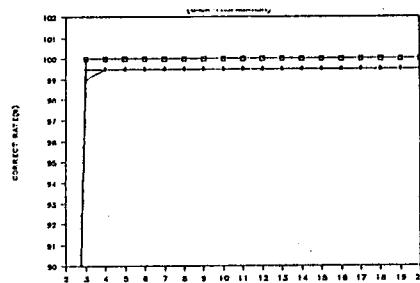


그림 4. CASE 2의 인식률 (BPN)

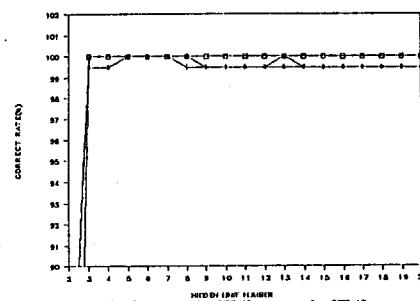


그림 5. CASE 3의 인식률 (BPN)

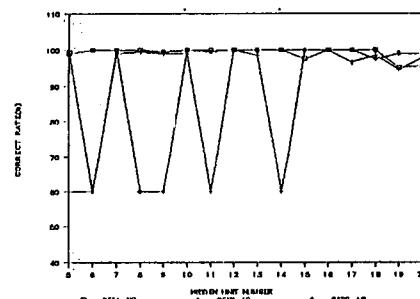


그림 6. CASE 1의 인식률 (CPN)

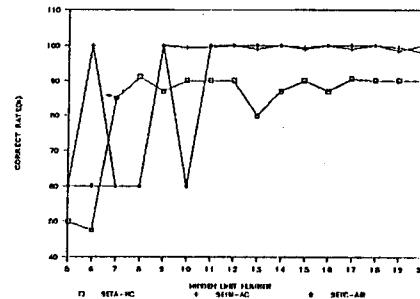


그림 7. CASE 2의 인식률 (CPN)

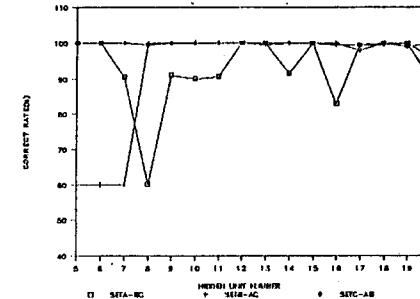


그림 8. CASE 3의 인식률 (CPN)

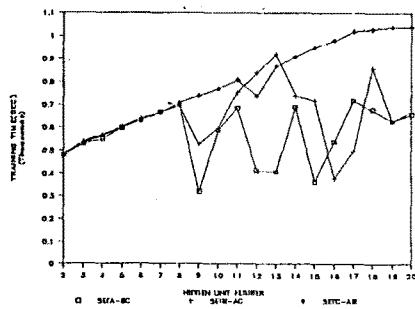


그림 9. CASE 1의 수렴속도 (BPN)

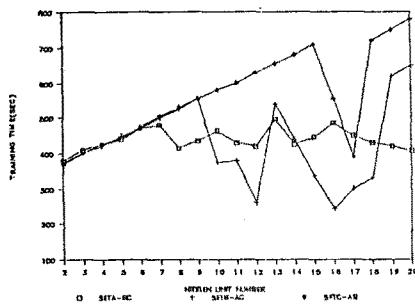


그림 10. CASE 2의 수렴속도 (BPN)

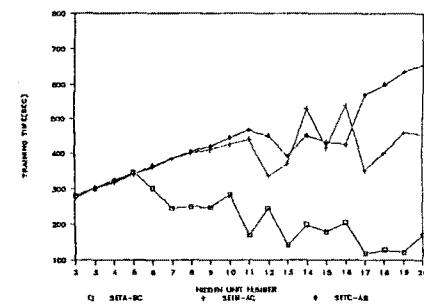


그림 11. CASE 3의 수렴속도 (BPN)

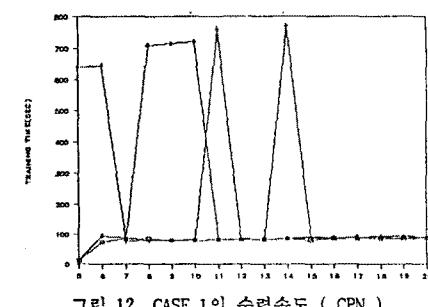


그림 12. CASE 1의 수렴속도 (CPN)

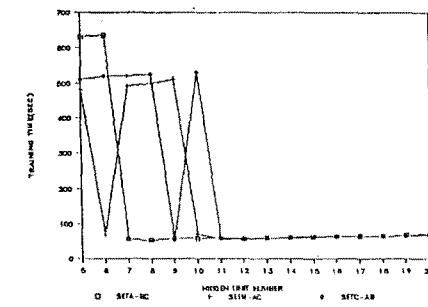


그림 13. CASE 2의 수렴속도 (CPN)

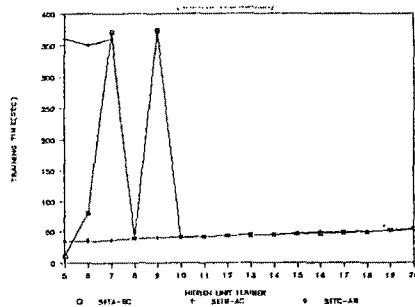


그림 14. CASE 3의 수렴속도 (CPN)

표1. BPN과 CPN의 인식률과 수렴속도의 비교

학습 - test data	100%의 인식률을 나타내는 중간층 뉴런수		인식률을 고려 한 수렴시간이 가장 빠른 중간 층 뉴런수		
	BPN	CPN	BPN	CPN	
CASE1	set A-BC 1,12,13,14,15,16 ,17,18,19,20	3,5,6,7,8,9,10,1 1,12,13,14,15,16 ,17,18,19,20	6,7,8,10,11,1 2,13,14,16,17 ,18	9	6
	set B-AC	최대 99.5%	12,15,16	16	12
	set C-AB	최대 99.5%	5,7,10,12,13, 14,15,16,20	3	5
CASE2	set A-BC 2,3,4,5,6,7,8,9, 10,11,12,13,14,1 5,16,17,18,19,20	2,3,4,5,6,7,8,9, 10,11,12,13,14,1 5,16,17,18,19,20	최대 90%	20	7
	set B-AC	최대 99.5%	6,9,12,14,16, 18	16	12
	set C-AB	최대 99.5%	9,11,12,13,14 ,16,17,18,20	17	9
CASE3	set A-BC 2,3,4,5,6,7,8,9, 10,11,12,13,14,1 5,16,17,18,19,20	2,3,4,5,6,7,8,9, 10,11,12,13,14,1 5,16,17,18,19,20	5,6,12,13,15, 18,19	17	5
	set B-AC	5,6,7,13	8,9,10,11,12, 14,15,19	5	8
	set C-AB	5,6,7,8	5,6,7,9,10,11 ,12,13,14,15, 16,18,20	5	5

5. 결론

본 연구에서는 신경회로망을 이용하여 비선형성이 강한 고조파 부하의 식별을 위한 최적의 신경회로망의 구성을 위하여 검토해 보았다. 최적의 신경회로망의 선택을 위해서 BPN과 CPN에 대해 중간층의 뉴런수를 변화시켜가면서 각각에 대한 인식률과 수렴속도를 비교하였다. 수렴속도는 CPN이 BPN보다 빨랐으나 인식률의 관점에서는 전체적으로 BPN이 CPN보다 양호하였다.

표1에서 보듯이 수렴속도와 인식률을 고려하여 각 CASE별로 가장 적절한 중간층 뉴런을 가진 신경회로망의 선택이 가능하였다. 이러한 적절한 신경회로망의 문제는 단일부하뿐만 아니라 복합부하로 확장함으로써 계통의 부하식별에 유용하리라 생각된다.

6. 참고문헌

- [1] IEEE Working Group on Power System Harmonics : "Power System Harmonics : An Overview", IEEE Trans. on PAS, vol. PAS-102, no. 8, pp 2455~2460, 1983.
- [2] 한전 기술 연구원 : "전력계통의 고조파 대책연구", 전력연구, 제5호, pp 304~313, 1989.
- [3] James A. Freeman, David M. Skapura : "Neural Networks Algorithms, Applications, & Programming Techniques", Addison-Wesley Publishing Company, 1991
- [4] J. A. Orr, D. Cyganski, A. E. Emanuel : "Design of System for Automated Measurement and Statistics Calculation of Volts and Current Harmonics", IEEE Trans. on Power Delivery, vol. PWRD-1, no. 4, pp. 23~30, 1986.