

論文94-31B-8-23

신경 회로망에 의한 정현파 전류 추종 인버터의 제어 (Sinusoidal Current Tracking Inverter Control with Neural Networks)

裴相俊*, 李達海*, 金東熙*

(Sang-June Bae, Dal-Hae Lee and Dong-Hee Kim)

要約

정현파 전류 추종 인버터는 고성능 AC 구동 시스템에 많은 장점을 가지고 있고, 이 인버터를 제어하는 여러가지 방법을 많은 연구자들이 제안했다. 이 논문은 신경회로망으로 제어되는 정현파 전류 추종 인버터를 제안한다. 신경회로망의 접속 강도는 오차 역전파 알고리즘에 의해 기준 전류 파형을 추종하도록 훈련되고, 훈련된 신경회로망은 전류 제어에 적용된다. 필자는 기존의 전류 제어 방법(고정된 대역 히스테리시스 방법과 정현적인 대역 히스테리시스 방법)과 신경회로망 방법을 비교하고, 시뮬레이션 결과를 나타낸다.

Abstract

Sinusoidal current tracking inverters have substantial advantages in high performance ac drive systems and various control strategies for the inverter have been proposed by several researchers. This paper develops a sinusoidal current tracking inverter with neural networks. The neural network are trained to follow a set of reference current waveforms by erro back propagation algorithm and the trained neural networks are applied to the current control. We compare neural networks method with conventional current control methods (fixed band and sinusoidal band hystersis methods) and simulation results are presented.

1. 서론

최근에 자원 절약이나 에너지 절약의 관점에서 태

양전지나 연료전지 등과 같은 자연 에너지의 이용에 대한 연구가 활발히 진행되고 있는데, 이들 새로운 에너지에 의한 발전 계통은 직류 발전 이므로, 상용 전력으로 사용하기 위해서는 직-교류 변환장치 즉 인버터가 필요하다. 또, 다양한 부하에 대응하는 전원을 얻기 위해서는 고주파 성분이 적고, 가변전압 가변주파수 기능을 갖는 인버터 장치가 필수적이다. 이러한 기능을 갖는 정현파 인버터에 대한 여

*正會員, 嶺南大學校 工科大学 電氣工學科
(Dept. of Elec. Eng., College of Engineering
Yeungnam Univ.)

接受日字 : 1993年 12月 22日

러가지 방법들이 연구돼 왔고, 그들 중의 하나인 전류 제어 인버터도 다양한 방법들이 보고되고 있다. [1] ~ [3] 전류 제어 인버터는 순시 정현파 전류를 추종하는 것으로서 태양광 발전이나 또는 연료전지 발전용의 정현파 인버터에 적합하다. 기존의 전류 제어 방법 중에서 히스테리시스 전류 제어와 정현적인 대역 히스테리시스 전류 제어가 가장 간단하고 가장 광범위하게 사용되고 있는데, 리플이 커서 고조파를 많이 함유하게 된다. [1]

최근 수년 사이에 병렬 처리 능력을 가지고 전통적인 해석적 접근법으로 해결될 수 없는 많은 문제를 처리할 수 있는 신경 회로망이 제어계의 관심의 대상이 되고 있고, 비선형 계통의 동정(Identification)이나 제어, 그리고 로봇틱 등과 같은 분야에 많이 적용되고 있지만 [4] ~ [7] 전력변환 계통에 적용된 경우는 아직도 찾아보기 어려운 실정이다.

신경 회로망은 기본적으로 많은 뉴론과 특별한 구조를 갖는 상호 접속으로 구성된 것으로서 본질적으로 비선형이고, 주변 환경에 따라서 그들의 동작을 수정할 수 있는 유연성을 가지고 있고, 특히 비선형 사상을 통해서 계통 특성을 학습하는 능력을 가지기 때문에 비선형 스위칭 동작에 의해 특성이 결정되는 전력변환 계통에 잘 적용될 수 있다.

본 연구는 태양전지나 연료전지 계통용으로서 자기 소호형 소자를 사용한 정현파 인버터, 즉 순시 정현파 전류 추종 인버터의 제어 계통을 신경회로망을 적용해서 구성한 회로와 그의 동작 원리를 나타내고, 또 시뮬레이션을 통해서 동작을 확인하고자 한다.

II. 인버터의 출력 전류 제어 방법

그림 1은 전압 공급형 3상 PWM 인버터의 기본 회로를 나타낸다.




그림 1. 3상 PWM 인버터
Fig. 1. Three phase PWM inverter.

그림 1의 인버터의 출력 전류를 정현파에 가깝도록 제어하는 순시 정현파 전류 추종 인버터의 기본적인 개념은, 기준전류 발생회로로 기준 정현파를 발생시키고 부하에 유입 되는 전류를 검출하여 기준 정현파의 값과 비교해서 그를 추종하도록 스위칭 동작을 행하는 것이다. 이를 실행하는 방법은 1) 고정된 대역 히스테리시스 방법과, 2) 정현적인 대역 히스테리시스 방법 등이 광범위하게 사용되고 있고, 한 상(a 상)에 대한 제어 알고리즘을 간단히 요약하면 표 1과 같다.

표 1. 전류 제어 알고리즘
Table 1. Current control algorithm.

	1)	2)
기준전류 (i_r)	$I_{ar} \cdot \sin(\omega t)$	$I_{ar} \cdot \sin(\omega t)$
상한값 (i_u)	$i_r + \Delta$	$(I_{ar} + \Delta) \cdot \sin(\omega t)$
하한값 (i_l)	$i_r - \Delta$	$(I_{ar} - \Delta) \cdot \sin(\omega t)$
동작 상태	$i_r > i_u$ 일때 $v_a = -v_e$	a) $i_r > 0$ 일때 $i_r > i_u$ 인 경우 $v_a = -v_e$ $i_r < i_l$ 인 경우 $v_a = v_e$
비 고	b) $i_r < 0$ 일때 $i_r < i_l$ 인 경우 $v_a = v_e$ $i_r > i_l$ 인 경우 $v_a = -v_e$	
	1) 은 고정된 대역 히스테리시스 방법이고, 2) 는 정현적인 대역 히스테리시스 방법 이다. 2Δ 는 히스테리시스 대역이다.	

표 1과 같은 알고리즘으로 인버터의 출력 전류 파형이 정현파가 되도록 모드의 전환을 행하는 것이 가능하고, 이를 3단위 조합하면 3상 정현파 전류 추종 인버터가 구성된다. 그런데 이들 제어기의 입력 신호는 전압 오차나 전류 오차 같은 아날로그 신호이고 그의 출력은 스위칭 소자를 구동하기 위한 On-Off 패턴인 2진 신호이다. 따라서 이들 제어기는 아날로그 입력에서 2진 출력으로의 비선형 데이터의 사상을 수행하는 것으로 간주될 수 있고, 이러한 비선형 데이터의 사상을 실현하는 또다른 방법은, 학습 신호로 주어지는 입출력 데이터로 부터 자동적으로 비선형 데이터의 사상을 학습하는 능력을 갖는 신경

회로망을 적용하는 것이다.

Ⅲ. 신경 회로망에 의한 인버터의 제어

그림 2 는 신경 회로망으로 제어되는 3 상 전류 추종 인버터 계통을 나타낸 것이다.




그림 2. 신경 회로망에 의한 3 상 전류 추종 인버터 계통

Fig. 2. The system of sinusoidal current tracking 3 phase inverter with neural networks.

여기서 우리는 기준 전류를 추종하도록 인버터를 제어하는 방법을 알고 있으므로, 신경회로망을 직접적인 제어기로 사용할 수 있고, 직접적인 제어기로 사용되는 신경 회로망은 다층 Feedforward Neural Networks(이하 FNN 이라 칭한다)로서 그림 3 에 나타낸 바와 같이 입력층과 출력층, 그리고 하나의 히든(Hidden)층으로 구성된다. 그리고 각각의 층은 비선형 처리 요소인 다수의 뉴론으로 구성되고, 각 뉴론은 그의 입력 신호를 합해서 미리 정의된 어떤 함수에 따라 출력 신호를 발생하고, 이들 뉴론의 출력은 인접한 다음 층의 뉴론의 입력이 된다.




그림 3. 신경 회로망의 구조

Fig. 3. Structure of neural networks.

FNN 의 n 번째 층의 j 번째 뉴론에 대한 수학적 인 모델은 식(1) 과 (2) 로 나타내 진다.

$$I_j^{(n)} = \sum_i W_{ji}^{(n)} \cdot O_i^{(n-1)} + \theta_j^{(n)} \quad (1)$$

$$O_j^{(n)} = f(I_j^{(n)}) \quad (2)$$

여기서 $I_j^{(n)}$ 와 $O_j^{(n)}$ 는 각각 n 번째 층의 j 번째 뉴론의 입력과 출력을 나타내고,

$O_i^{(n)}$ 는 $(n-1)$ 번째 층의 i 번째 뉴론의 출력을,

$W_{ji}^{(n)}$ 는 $(n-1)$ 번째 층의 i 번째와 n 번째 층의 j 번째 뉴론 사이의 접속강도(weight)를,

$\theta_j^{(n)}$ 는 n 번째 층의 j 번째 뉴론의 바이어스(bias)를,

$f(\cdot)$ 는 Sigmoid 함수나 Logistic 함수, 또는 선형 함수 등이 사용될 수 있는데 본 연구에서는 Sigmoid 함수를 사용하였다.

각 뉴론 사이의 접속강도는 신경회로망을 훈련 시키는 오차 역전파(Error back Propagation) 알고리즘으로 알려진 일반화된 델타 룰(Delta rule)을 사용해서 출력 오차가 줄어드는 방향으로 수정된다. 계통에 입력이 가해져서 발생된 출력이 요구되는 출력(또는 목표값)과 비교해서 차이가 없으면 학습은 발생하지 않고, 차이가 있다면 접속강도는 식(3) 으로 주어지는 총 평균 자승 오차 E_t 를 최소화 하는 방향으로 변화된다.

$$E_t = \frac{1}{2p} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad (3)$$

여기서 T_{pk} 와 O_{pk} 는 각각 P 번째 입력 패턴(pattern)에 대한 출력층의 k 번째 목표값과 실제 출력값 이다. 이 오차를 최소화 하는 접속강도는 E_t 를 각 접속 강도에 대해 편미분 함으로서 얻을 수 있고, 접속강도의 변화는 식(4)와 (5)로 나타내 진다.

$$W_{ji}^{(n)}(t+1) = W_{ji}^{(n)}(t) + \Delta W_{ji}^{(n)}(t) \quad (4)$$

$$\Delta W_{ji}^{(n)}(t+1) = \eta \cdot \delta_j^{(n)}(t) \cdot O_i^{(n-1)}(t) + \alpha \cdot \Delta W_{ji}^{(n)}(t) \quad (5)$$

여기서 $\Delta W_{ji}^{(n)}$ 는 $(n-1)$ 번째 층의 i 번째 뉴론과 n 번째 층의 j 번째 뉴론 사이의 접속강도의 변화를 나타내고,

η 는 학습율을,

α 는 합성율을,

$\delta_j^{(n)}$ 는 n 번째 층의 j 번째 뉴론의 출력 오차를 나타낸다.

일반화된 델타 룰은 총 출력 오차가 정의해 둔 값보다 적어질 때까지 신경회로망의 접속강도를 새롭게 하는데 사용된다.

IV. 시뮬레이션 및 결과

신경 회로망을 사용한 제어부를 구성할때, 입력층과 출력층의 뉴런의 수는 제어 회로의 입력과 출력의 수에 따라 결정되지만 히든층의 뉴런의 수를 결정하는 확정된 알고리즘은 아직도 발견되지 않고 있어서, 10개인 경우로 부터 시작해서 2개인 경우까지 시험해 보았다. 히든층의 뉴런의 수가 적을수록 학습 회수와 시간이 더 많이 소요되었고, 학습이 가능한 최소수는 2개인 경우로 나타났다. 따라서 본 연구에서는 구성을 간단히 하기 위해서 히든층에 2개의 뉴런을 사용하였고, 입력층에 3개, 그리고 출력층에 3개의 뉴런으로 FNN 을 구성하였다.

식(4)와 (5)를 적용하여 뉴런 사이의 접속강도를 훈련시키는 방법에는 Pattern 학습법과 Batch 학습법이 있는데, Pattern 학습법의 효용성을 정확히 수학적인 감각으로 입증할 수는 없지만 실제적으로는 효과적이고, 학습율이 적은 경우의 Pattern 학습법은 Batch 학습법과 거의 동일하므로 본 연구에서는 pattern 학습법을 적용하였다. 그리고 학습에 사용된 각 값들은 학습율 $\eta = 0.15$, 합성율 $\alpha = 0.5$, 초기의 접속강도는 -1과 1사이의 임의의 값을 사용하였다.

검출기에서 검출된 3상 전류와 기준 전류사이의 오차를 제어부의 입력으로 사용해서 뉴런 사이의 접속강도를 새롭게 하는 학습 규칙은 다음과 같다.


$|i_{mr} - i_m| < \epsilon$ 인 경우, O_m 는 이전 상태와 동일한 상태를 유지한다.

$|i_{mr} - i_m| > \epsilon$ 인 경우, $O_m = 1$


$|i_{mr} - i_m| < -\epsilon$ 인 경우, $O_m = 0$

여기서 $m = a, b, c$ 로서 3 상을 나타내고, i_{mr} 은 각상의 기준 전류를, i_m 는 각 상의 전류를, ϵ 는 오차값을, 그리고 O_m 는 신경회로망의 출력을 나타내고 있다. 위의 각 상태에 따른 2³개의 학습 패턴으로 식(4)와 (5)에 따라서 FNN 을 충분히 학습시킨 후에 전류 제어 회로에 적용한다.


표 2는 8쌍의 학습 패턴을 나타낸 것으로서, (0, 0, 0) ~ (1, 1, 1)은 부하 상전압의 스위칭 신호로서 스위치 (S_1, \dots, S_6)의 On-off 상태를 나타낸다. 예를 들면, a 상의 전류오차 신호 ($i_{mr} - i_a$)가 0.1 이면 S_1 은 On, S_2 는 Off로 되고, -0.1이면 S_1 은 Off, S_2 는 On으로 된다. 이 학습 패턴에 의해서 학습이 끝



(a)



(b)



(c)

그림 4. 기준전류 변화에 대한 다이내믹 응답 (a) 고정된 대역 히스테리시스 방법 (b) 정현적인 대역 히스테리시스 방법 (c) 신경 회로망 방법


Fig. 4. Dynamic response to reference current changes (a) Fixed band hysteresis method (b) Sinusoidal band hysteresis method (c) Neural network method.

난 신경 회로망의 접속 강도는 전류제어 과정 중에는 학습되지 않고 고정된다.


표 2. 학습 신호

Table 2. Teaching signal.


	입력 신호			요구되는 출력		
1	0.1	0.1	0.1	1	1	1
2	-0.1	0.1	0.1	0	1	1
3	0.1	-0.1	0.1	1	0	1
4	0.1	0.1	-0.1	1	1	0
5	0.1	-0.1	-0.1	1	0	0
6	-0.1	0.1	-0.1	0	1	0
7	-0.1	-0.1	0.1	0	0	1
8	-0.1	-0.1	-0.1	0	0	0



(a)



(b)



(c)

그림 5. 상태 평면

- (a) 고정된 대역 히스테리시스 방법
- (b) 정현적인 대역 히스테리시스 방법
- (c) 신경 회로망 방법


Fig 5. Phase plane

- (a) Fixed band hysteresis method
- (b) Sinusoidal band hysteresis method
- (c) Neural network method.


그림 4는 그림 2의 계통에 대해 표 1에 나타난 2 가지 방법과 신경회로망 방법에 대해 기준전류 i_c 을 변화시킨 경우의 Dynamic 특성을 보여주고 있고, 그림 5는 3상중의 2상인 a, b 상의 전류 상태 평면을 나타낸 것이다. 그리고 그림 6은 기준 전류의 주파수 f 를 60Hz에서 30Hz로 그리고 다시 60Hz로 증감시킨 경우의 Dynamic 특성을 보여주고 있다. 이들의 시뮬레이션에 사용된 각 값은 직류 전원전압 $V_e = 110(v)$ 이었고, 부하는 3상 평형부하로서 한상에 대한 인덕턴스와 저항은 각각 $L = 45.5(mH)$, $R = 20(ohm)$ 이었다. 그림 4 - 그림 6에서 볼수 있듯이 신경 회로망 방법의 출력 전류 파형이 가장 정현파에 가깝고, 인버터의 parameter가 변화하더라도 잘 추종하여 동작하고 있다는 것을 알 수 있다.

기존의 2가지 제어방법과 신경회로망 제어방법의 출력 전류에 대한 평가를 하기 위해 실효치(I_{rms})와 왜형률 및 고주파 전류 성분을 시뮬레이션 한 결과를 그림 7(a), (b)에 나타내었다. 여기서 R.C는 기준 전류를 나타내고, N.N은 신경회로망 방법을, F.B는 고정된 대역 히스테리시스 방법을, S.B는 정현적인 대역 히스테리시스 방법을 나타내고 있으며, 그림 7(a)에서 빗금친 부분은 I_{rms} 를 나타내고 흑색 부분은 왜형률을 나타내고 있다.


신경회로망 방법의 경우에 기준전류에 대한 실효치의 오차는 1.1(%), 왜형률은 3.5(%)이었고, 고정된 대역 히스테리시스 방법의 경우는 각각 0.8 (%), 9.2(%)이었고, 정현적인 대역 히스테리시스 방법에서는 각각 0.7(%), 7.9(%)이었다. 신경회로망 방법은 실효치의 오차가 기존의 2가지 방법보다 약간 크지만 왜형률 및 고주파 전류 성분이 가장 적게 나타



(a)



(b)




(c)

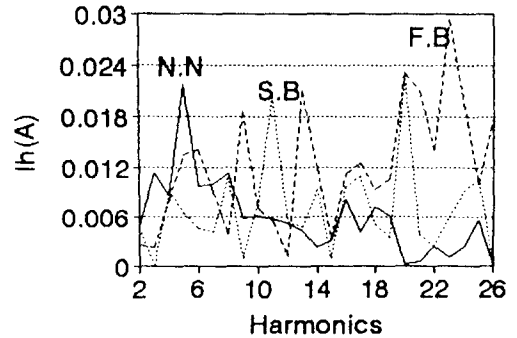
그림 6. 기준 전류의 주파수 변화에 대한 다이내믹 응답 (a) 고정된 대역 히스테리시스 방법 (b) 정현적인 대역 히스테리시스 방법 (c) 신경 회로망 방법

Fig. 6. Dynamic response to frequency changes of reference current

(a) Fixed band hysteresis method (b) Sinusoidal band hysteresis method (c) Neural network method.



(a)




(b)


그림 7. (a) 출력전류의 실효치와 왜형을 (b) 출력 전류의 고주파 성분

Fig. 7. (a) The rms value and distortion ratio of output current (b) The harmonics of output current.


나서 정현파에 가장 가깝다는 것을 알 수 있다. 그림 8 은 a 상의 전류 검출부가 고장이 발생한 경우에 대한 출력 전류로서 신경 회로망 방법으로 운전한 경우는 정상 상태와 거의 같은 파형을 나타내고 있어서 신경회로망 제어체통이 고장에 강하다는 것을 알 수 있다. 이는 기존의 2 방법에서는 전류 검출에서 부터 제어신호 발생까지 3 상이 각각 독립적으로 동작하는 반면에, 신경회로망 방법에서는 3 상의 오차신호가 회로망 내부에서 상호 접속되어 있어서 보상되기 때문 인 것으로 생각된다.



(a)



(b)



(c)

그림 8. 한상의 오차 입력이 없는 경우의 출력전류 파형
 (a) 고정된 대역 히스테리시스 방법
 (b) 정현적인 대역 히스테리시스 방법
 (c) 신경 회로망 방법

Fig. 8. Output current waveforms at the

lack of one-phase error input.

- (a) Fixed band hysteresis method
- (b) Sinusoidal band hysteresis method
- (c) Neural network method.

V. 결론


본 연구에서는 정현파 전류 추종 인버터를 신경 회로망에 의해 제어하는 방법을 제안하였고, 오차 역전과 알고리즘을 사용해서 뉴런 사이의 접속 강도를 훈련시키는 방법을 나타내었다. 인버터의 Dynamic 응답 특성, 실효치, 왜형을 및 고주파 전류 성분 등에 대해 시뮬레이션을 통해 검토한 결과, 신경 회로망 방법이 기존의 제어 방법보다 우수한 특성을 나타내었다. 더우기 한 상의 전류 검출이 불가능한 경우에도 신경 회로망 방법은 정상상태와 거의 동일한 출력 전류 파형을 발생시키고 있어서 고장에 강하다는 것을 알수 있었다.

參考文獻

- [1] Fumio Harashima, Yuzo Demizu, Seiji Kondo, Hideki Hashimoto, "Application of Neural Networks to Power Converter Control", Conf.Record of IEEE, IAS Annual Meeting, pp.1086~1091, 1989.
- [2] Bor-Ren Lin and Richard G.Hoft, "POWER ELECTRONICS INVERTER CONTROL WITH NEURAL NETWORKS", Applied Power Electronics Conference and Exposition, pp.128~134, 1993.
- [3] Michael R. Buhl and Robert D. Lorenz, "DESIGN AND IMPLEMENTATION OF NEURAL NETWORKS FOR DIGITAL CURRENT REGULATION OF INVERTERDRIVES", IEEE /IAS Annual Meeting, Vol.1, pp.415~421, 1991.
- [4] Si-Zhao Qin, Hong-Te Su, and Thomas J.McAvoy, "Comparison of Four Neural Net Learning Methods for Dynamic System Identification", IEEE Transactions on Neural Networks, Vol.3, pp.

- 122~130, 1992.
- [5] Shin-ichi Horikawa, Takeshi Furuhashi, and Yoshiki Uchikawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm", IEEE Transactions on Neural Networks, Vol.3, pp.801~806, 1992.
- [6] Jacek M. Zurada, *Introduction to Artificial Neural Systems*, West Publishing Company, pp.485~527, 1992.
- [7] E. Bernard, "Optimization for training Neural Networks", IEEE Trans. on Neural Networks, Vol.3, pp.232~240, 1992.
- [8] Si-Zhao Qin, Hong-Te Su and Thomas J. McAvoy, "Comparison of Four Neural Net Learning Methods for Dynamic System Identification", IEEE Transactions on Neural Networks, Vol.3, pp. 122-130, 1992.

 著 者 紹 介



李達海(正會員)

1935年 6月 20日生. 1959年 서울 대학교 졸업. 1987년 명지 대학교 공학 박사. 1994년 현재 영남 대학교 전기공학과 교수. 주관심 분야는 전력 변환장치 및 제어시스템 등임.



金東熙(正會員)

1950年 11月 20日生. 1973年 2月 영남 대학교 전기공학과 학사. 1975년 2월 영남 대학교 전기공학과 석사. 1987년 3월 (日) 神戸大學 공학박사. 1987년 4월 ~ 1989년 3월 한국 전기 연구소 전력전자 연구 부장. 1989년 4월 ~ 현재 영남 대학교 전기공학과 부교수. 주관심 분야는 신형 power device에 의한 고주파 인버터와 그의 응용 제어 기술 등임.



裴相俊(正會員)

1952年 10月 11日生. 1980년 2월 영남 대학교 전기공학과 학사. 1982년 2월 영남 대학교 전기공학과 석사. 1994년 2월 영남 대학교 전기공학과 박사과정 수료. 1994년 현재 경북산업대학교 강사. 주관심 분야는 Neural networks와 전력전자 등임.