

Optimal Heating Load Identification using a DRNN

鄭基澈* · 梁海元**

(Kee-chull Chung · Hai-won Yang)

Abstract - This paper presents an approach for the optimal heating load Identification using Diagonal Recurrent Neural Networks(DRNN). In this paper, the DRNN captures the dynamic nature of a system and since it is not fully connected, training is much faster than a fully connected recurrent neural network. The architecture of DRNN is a modified model of the fully connected recurrent neural network with one hidden layer. The hidden layer is comprised of self-recurrent neurons, each feeding its output only into itself. In this study, A dynamic backpropagation (DBP) with delta-bar-delta learning method is used to train an optimal heating load identifier. Delta-bar-delta learning method is an empirical method to adapt the learning rate gradually during the training period in order to improve accuracy in a short time. The simulation results based on experimental data show that the proposed model is superior to the other methods in most cases, in regard of not only learning speed but also identification accuracy.

Key Words : Diagonal Recurrent Neural Networks, Identifier, Heating load, Delta-bar-delta learning method

1. 서 론

최근 날로 심각해지고 있는 경제위기로 인하여 전력시스템을 경제적이고 안정적으로 운영하기 위한 방안의 하나로 심야전력을 이용하는 분야가 활발히 연구되고 있다[1][2]. 특히 심야전력을 이용하는 축열식 난방기기는 고밀도 철화합물이나 산화 마그네슘(MgO)등을 포함한 세라믹 소재를 이용하여 만든 축열벽돌을 심야전력을 사용하여 600 ~ 800℃까지가 열, 축열하였다가 실내의 온도에 따라 방열하는 방식으로 현재 널리 활용되고 있다.

축열식 난방기기를 설치, 운용하는 데는 건축물의 익일 난방부하를 정확히 계산하여 전일의 심야전력시간(오후10시~오전8시)동안 축열벽돌에 필요한 열량을 축열해야 한다. 그러려나 건축물 구조체의 난방부하는 특성상 다른 시스템에 비하여 시정수가 대단히 클 뿐만 아니라 외기온도, 실내온도, 인접된 공간의 난방유무, 외벽 또는 유리창, 지붕의 재질 및 면적에 따라 열전달률에 의해 발생하는 손실, 외부공기 취입량에 따른 손실, 실내온도 설정 등 여러 가지 요인에 기인하고 있어 정확한 난방부하를 식별하는데 어려움이 있다.

기존의 축열식 난방기기는 전일의 심야전력시간(10시간) 동안 축열벽돌을 최고 온도까지 축열하도록 하여 익일의 난방에 사용하는 방식을 사용하기 때문에 불필요한 전력의 손

실을 가져와 경제적인 운전이 불가능하다. 따라서 축열식 난방기기 설치장소에 따른 건축물 구조체의 손실열량, 사용자 운전패턴 및 외부공기 유입량에 의한 손실열량 등에 기인하는 난방부하를 빠르고 정확하게 식별(Identification)할 수 있는 식별기설계에 대한 필요성이 제기되고 있다. 이에 따라 본 논문에서는 적응식 학습률 조정 알고리즘(delta - bar - delta)을 이용하여 빠른 학습을 할 수 있는 신경망 난방부하 식별기를 제안하였다.

본 논문에서는 비선형 mapping 능력과 식별기능이 뛰어난 DRNN(Diagonal Recurrent Neural Networks)을 사용하여 신경회로망 식별기를 구성하였다[3][4]. DRNN은 내부에 제한성을 지니고 있기 때문에 시스템의 외부제한을 사용하는 것보다 구성이 간단하다. 또한 적응식 학습률 조정 알고리즘(delta - bar - delta)을 이용하여 DRNN의 학습속도 및 성능을 높여 시정수가 큰 건축물 난방부하의 식별기 구현이 용이하도록 하였다. 제안된 난방부하 식별기의 건축물 구조체와 외기온도 및 사용자 운전 패턴의 변화에 따른 성능을 검증하기 위하여 시험용 건축물 구조체에서 난방부하 측정에 관한 실험을 하였고, 이 실험에서 측정된 데이터를 토대로 모의실험을 하여 식별기 성능을 입증하였다.

본 논문의 구성은 2장에서는 시험용 건축물 구조체의 식별기 모델과 학습방법에 대하여 살펴본다. 그리고 3장에서는 제안된 식별기의 설계 및 구현방법에 대하여 제시하고 4장에서는 난방부하 측정을 위한 실험조건 및 결과에 대해 알아보고 5장에서는 제안된 식별기의 성능을 알아보기 위한 모의실험의 결과에 대하여 제시하고 마지막으로 6장에서는 결론을 맺는다.

* 正 會 員 : 漢陽大 電氣工學科 博士課程

** 正 會 員 : 漢陽大 電氣工學科 教授 · 工博

ERC-ACI 참여교수

接受日字 : 1999年 4月 27日

最終完了 : 1999年 9月 13日

2. 식별기 모델

건축물 구조체나 시험용 구조물의 냉난방 시스템에 대한 모델링 기법으로는 AR(auto-regressive)모델을 기본으로 하고 최소자승법(least-squares method)을 이용하는 기법이 널리 사용되고 있다[5]. 이러한 모델링 기법은 시험용 구조물의 연속적인 냉난방 부하 및 습도등을 시험을 하는 경우에도 자주 사용되는 구조이다. 따라서 이 장에서는 AR 모델과 본 연구에서 제안한 신경망 모델에 대하여 알아보기로 한다.

2.1 AR 모델

최소자승법(Recursive least squares)을 이용하여 파라미터를 추정하기 위한 시험용 구조체를 다음과 같이 가정한다.

$$A(q)y(k) = B(q)u(k) \quad (1)$$

여기서 $u(k)$ 는 시험용 구조체의 외기온도, $y(k)$ 는 난방 부하이다. 그리고 q 는 단위시간 지연 연산자이며, $A(q)$ 와 $B(q)$ 는 각각 다음과 같다.

$$A(q) = q^n + a_1q^{n-1} + \dots + a_n \quad (2)$$

$$B(q) = b_1q^{m-1} + b_2q^{m-2} + \dots + b_m \quad (3)$$

식(2)와 (3)을 이용하면 식(1)은 다음과 같이 쓸 수 있다.

$$y(k) + a_1y(k-1) + \dots + a_ny(k-n) = b_1u(k+m-n-1) + \dots + b_mu(k-n) \quad (4)$$

이 식에서 외기온도 $u(k)$ 와 난방부하 $y(k)$ 는 각각 측정할 수 있는 값이다. 추정해야하는 미지 파라미터 벡터와 regression 벡터는 각각 다음과 같다.

$$\theta^T = (a_1 \dots a_n \ b_1 \dots b_m) \quad (5)$$

$$\phi^T(k-1) = (-y(k-1) \dots -y(k-n) , u(k+m-n-1) \dots u(k-n)) \quad (6)$$

따라서 식 (1)은 식(4), (5), (6)으로부터 다음과 같은 AR 모델로 표현된다.

$$y(k) = \phi^T(k-1)\theta(k) \quad (7)$$

윗 식에서 미지의 매개변수 $\theta(k)$ 에 대한 추정치를 $\hat{\theta}(k)$ 라고 하면 식별된 시스템은 다음과 같이 쓸 수 있다.

$$\hat{y}(k) = \phi^T(k-1)\hat{\theta}(k) \quad (8)$$

여기서 매개변수 $\hat{\theta}(k)$ 는 최소자승법을 이용하여 다음과 같은 형태로 추정된다.

$$\hat{\theta}(k) = \hat{\theta}(k-1) + P(k)\phi(k-1)\epsilon(k) \quad (9)$$

$$P(k) = \frac{1}{\lambda} \left(P(k-1) - \frac{P(k-1)\phi(k-1)\phi^T(k-1)P(k-1)}{\lambda + \phi^T(k-1)P(k-1)\phi(k-1)} \right)$$

여기서

$$\epsilon(k) = y(k) - \phi^T(k-1)\hat{\theta}(k-1) \quad (10)$$

이다.

2.2 신경망(Diagonal Recurrent Neural Networks) 모델[4]

본 논문에서 사용한 신경망 난방부하 식별기의 구조는 그림 1과 같이 입력층, 은닉층, 출력층으로 구성되어 있다.




그림 1 Diagonal Recurrent Neural Network의 구조
Fig. 1 Architecture of Diagonal Recurrent Neural Network

주어진 DRNN의 입출력 관계는 다음과 같이 표현된다.

$$O(k) = \sum_j W_j^0 X_j(k) \quad (11)$$

$$X_j(k) = f(S_j(k)),$$

$$S_j(k) = W_j^D X_j(k-1) + \sum_i W_{ij}^I I_i(k) \quad (12)$$

여기서 $I_i(k)$ 는 i 번째 뉴런의 입력, $S_j(k)$ 는 j 번째 recurrent 뉴런에 들어가는 입력의 합, $X_j(k)$ 는 j 번째 recurrent 뉴런의 출력, $O(k)$ 는 DRNN의 출력이고 $W^I \in R^{N_i}$, $W^O \in R^{N_o}$, $W^D \in R^{N_o}$ 는 각각 입력, 출력, recurrent 뉴런의 연결강도이다. $y(k)$ 를 교사신호, $y_f(k)$ 를

DRNN의 출력이라고 하면 성능지수 E_I 를 다음과 같이 정의할 수 있다.

$$E_I = \frac{1}{2} (y(k) - y_f(k))^2 \quad (13)$$

여기서 $y_f(k) = O(k)$ 이다. 위 식에 경사감소법(gradient descent rule)을 적용하면 연결강도를 다음 식과 같이 학습시킬 수 있다.

$$W(k+1) = W(k) + H(k) \left(-\frac{\partial E_I}{\partial W} \right) + \alpha (W(k) - W(k-1)) \quad (14)$$

여기서 $H(k)$ 는 적응 학습률(Adaptive learning rate)이고 α 는 모멘텀 계수이다.

$$\frac{\partial E_I}{\partial W} = -e_f(k) \frac{\partial y_f(k)}{\partial W} = -e_f(k) \frac{\partial O(k)}{\partial W} \quad (15)$$

$$e_f(k) = y(k) - y_f(k) \quad (16)$$

이므로 식(14)에 의하여 연결강도를 학습시키려면 DRNN의 출력 $O(k)$ 를 각 입력, 출력, recurrent 뉴런의 연결강도로 편미분한 값을 알아야 하며, 그것들은 다음과 같이 나타내어질 수 있다.

$$\frac{\partial O(k)}{\partial W_j^0} = X_j(k) \quad (17)$$

$$\frac{\partial O(k)}{\partial W_j^D} = W_j^D P_j(k) \quad (18)$$

$$\frac{\partial O(k)}{\partial W_{ij}^I} = W_{ij}^I Q_{ij}(k) \quad (19)$$

여기서 $P_j(k) \equiv \partial X_j(k) / \partial W_j^D$ 이고 $Q_{ij} \equiv \partial X_j(k) / \partial W_{ij}^I$ 이다.

위 식의 유도과정은 다음과 같다. 식(11)로부터 DRNN의 출력 $O(k)$ 를 출력층 연결강도로 미분하면

$$\frac{\partial O(k)}{\partial W_j^0} = X_j(k) \quad (20)$$

또한, 식(11)의 DRNN의 출력 $O(k)$ 를 recurrent 뉴런의 연결강도로 미분하면

$$\frac{\partial O(k)}{\partial W_j^D} = W_j^D \frac{\partial X_j(k)}{\partial W_j^D} \equiv W_j^D P_j(k) \quad (21)$$

으로 나타내면, 식(11)과 식(12)로부터

$$\frac{\partial X_j(k)}{\partial W_j^D} = \frac{\partial X_j(k)}{\partial S_j(k)} \frac{\partial S_j(k)}{\partial W_j^D} = f'(S_j(k)) \frac{\partial S_j(k)}{\partial W_j^D} \quad (22)$$

$$\frac{\partial S_j(k)}{\partial W_j^D} = X_j(k-1) + W_j^D \frac{\partial X_j(k-1)}{\partial W_j^D} \quad (23)$$

와 같이 되므로 다음 식을 만족하게 된다.

$$P_j(k) = f'(S_j) (X_j(k-1) + W_j^D P_j(k-1)) \quad (24)$$

$$Q_{ij}(k) = f'(S_j) (I_i(k) + W_{ij}^D Q_{ij}(k-1)) \quad (25)$$

3. 신경망 식별기 학습 방법

본 연구에서는 심야전력을 이용한 축열식 전기온풍기를 난방원으로 하는 건축물 구조체의 난방부하를 신경망을 이용하여 식별하였다. 심야전력은 1일 10시간(22:00 ~ 08:00) 통전되므로 심야전력을 이용하는 축열식 난방기기의 경우 심야시간(10시간)동안 축열하였다가 비심야시간(14시간)동안 축열된 열량을 발열하여 건축물의 난방에 이용한다. 그러나 외기온도가 일정한 상태에서도 난방기기의 설치장소, 사용자 운전패턴과 외부공기 유입량에 따라서 난방에 필요한 열량이 가변될 수 있다.

축열식 난방기기의 최적인전을 위해서는 외기온도에 따른 건축물 구조체의 1일간의 총 난방부하를 알고 있어야 한다. 그러나 기존의 부하 모델 입출력 추정방법[5]이나 신경망을 이용한 난방부하 식별기의 경우 학습신호가 1일간의 총 난방부하가 되기 때문에, 1일 1회 학습하게 된다. 그러나 1일 1회의 학습으로는 학습속도가 느려서 우리나라의 계절적인 특성상 실제 난방기기에 적용하기에는 어려움이 있다. 본 연구에서는 이러한 문제점을 해결하기 위하여 적응식 학습률 조정 알고리즘[6](delta - bar - delta)을 이용한 난방부하 식별기를 제안하여 난방부하 식별기의 학습시간을 감소시켰을 뿐 아니라 식별기 성능을 향상시켰다. 본 연구에서 제안한 난방부하 식별기의 구성은 그림 2와 같다. 그림에서 알 수 있는 바와 같이 난방부하 식별기의 입력은 건축물 구조체의 외기온도와 출력된 난방부하의 궤환으로 이루어지고 있다.

식별기 입력으로 사용되는 외기온도 $u(k)$ 와 난방부하 $y(k)$ 는 다음 식과 같이 정규화하여 사용하였다.

$$Nu(k) = \frac{u(k) - T_{\min}}{T_{\max} - T_{\min}} \quad (26)$$

$$Ny(k) = \frac{y(k) - B_{\min}}{B_{\max} - B_{\min}} \quad (27)$$

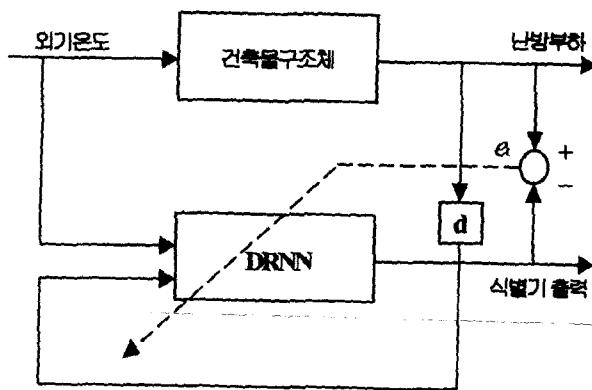


그림 2 제안된 식별기의 블록선도
Fig. 2 Block diagram of proposed identifier

여기서 $Nu(k)$, $Ny(k)$ 는 정규화된 외기온도와 난방부하이다. 또한 T_{max} , T_{min} , B_{max} , B_{min} 은 외기온도와 난방부하의 상한치와 하한치를 나타내고 있다.

3.1 적응식 학습률 조정 알고리즘

본 논문에서는 적응식 학습률 조정 알고리즘으로 delta-bar-delta ($\Delta - \bar{\Delta}$) 방법을 사용하였다[6]. delta-bar-delta 알고리즘은 각각의 연결강도마다 독립적인 학습률을 사용할 수 있을 뿐만 아니라 학습 단계에서 학습률을 적응식으로 변화시킬 수 있어 기존의 오차 역전파 알고리즘에 비해 학습속도가 빠르므로 난방부하와 같이 시정수가 큰 시스템에 적합하다. delta-bar-delta ($\Delta - \bar{\Delta}$) 알고리즘에서는 k 학습 단계에서의 Δ 와 $\bar{\Delta}$ 를 다음과 같이 정의할 수 있다.

$$\Delta_j^o(k) = \frac{\partial E_I}{\partial W_j^o} \quad (28)$$

$$\Delta_j^p(k) = \frac{\partial E_I}{\partial W_j^p} \quad (29)$$

$$\Delta_{ij}(k) = \frac{\partial E_I}{\partial W_{ij}} \quad (30)$$

여기서 E_I 는 식별기 오차이며

$$\bar{\Delta}(k) = (1 - \beta)\Delta(k) + \beta\bar{\Delta}(k - 1) \quad (31)$$

이다. 이와 같은 Δ 와 $\bar{\Delta}$ 를 이용하여 $(k+1)$ 단계에서 새로운 학습률 $H(k+1)$ 을 다음 식과 같이 구할 수 있다.

$$H(k+1) = \begin{cases} H(k) + \alpha & \text{if } \bar{\Delta}(k-1) \cdot \Delta(k) > \zeta, \\ (1-\gamma)H(k) & \text{if } \bar{\Delta}(k-1) \cdot \Delta(k) < -\zeta, \\ H(k) & \text{otherwise.} \end{cases} \quad (32)$$

여기서 β , α , γ , ζ 는 임의의 상수이다.

4. 난방부하 측정실험

본 연구에서는 시험용 건축물 구조체의 난방부하를 측정하기 위해 실내온도와 외기온도의 변화에 따른 축열기의 발열량을 측정하고 이에 따라 시험용 건축물 구조체의 난방부하를 환산하였다. 본 실험에서 사용한 난방원은 (주)서울전기에서 제조한 축열식전기온풍기(3.2Kwh)로 축열제는 내부 온도 1℃ 하강시 38.17[kcal]의 열량을 배출하도록 제조되었고 최대 배출열량은 21,375[kcal]이다. 그림 3은 본 측정실험에서 사용된 축열식 전기온풍기의 내부 온도검출 위치를 나타내고 있다. 본 논문에서 사용된 시험용 건축물 구조체의 난방부하를 측정하기 위해 시험용 건축물 구조체의 외기온도 환경을 기상청에서 제시한 서울지역 96년 12월의 외기온도 중 온도변화폭이 가장 큰 날짜의(1월 29일 08:00 ~ 2월 5일 08:00) 외기온도와 같도록 만들어주어(오차범위 ±0.5℃) 시험한 결과 그림 6과 같은 난방부하 데이터를 취득하였다. 또한 축열식 전기온풍기의 축열전원은 한전에서 제공하는




그림 3 축열식 난방기 온도검출 포인트
Fig. 3 Temperature detect point for thermal storage material

심야전력을 사용하여 10시간(22:00 ~ 08:00)축열후 비심야시간(14시간)동안 발열하도록 하였고 시스템을 보호하기 위하여 축열재 표면에 과승방지기를 부착하여 축열기 내부 온도가 700℃를 넘지 않도록 하였다.

본 연구에서 사용된 시험용 건축물 구조체는 2중구조로 되어있어 건축물 구조체 외부에서 실내온도와 외기온도를 설정하게 되어있다. 외기온도의 측정은 2중구조 건축물의 중간층 4곳에 온도계를 설치하여 측정된 값을 평균하여 사용하였고, 실내온도는 건축물 구조체 내부 중심부 바닥에서 1.5m 되는 부분에 설치 측정하였다.

온도측정은 YOKOGAWA 자동온도 타점 기록계로 각 측정위치의 온도 데이터를 60초 단위로 자동 측정하였다. 또한 실험에 들어가기 전 10시간 동안 난방기를 가동시켜 내부구조물을 완전히 건조시킨후 실내온도 4℃, 외기온도 0℃로 설정한 상태에서 실험을 시작하였다. 실험중 환기는 1시간 단위로 20초간 출입구와 창문을 개방후 닫는 방식으로 하였다. 그림 4는 실험에 사용된 건축물 구조체이다.




그림 4 난방부하 측정실험을 위한 건축물 구조체
Fig. 4 Building construction for real experiment for heating load

난방부하 측정실험에 사용된 건축물 구조체의 사양은 표 1과 같다.

표 1 건축물구조체의 사양
Table 1 Specification of building construction

구조체 외부사양		구조체 내부사양	
규격	4700x6700x 2700[mm]	규격	4500x3500x 2300[mm]
		창문 규격	1030x760[mm], (2 개)
체적	85.023 [m ³]	체적	36.225 [m ³]

시험용 건축물 구조체의 벽체, 천정 부분은 열관류율 $K = 0.36$ [kcal/m²h℃]인 75t 샌드위치 판넬을 사용하였고 구조체의 바닥은 $K = 1.927$ [kcal/m²h℃]의 슬라브를 사용하였으며, 창문은 단층유리를 사용였다. 그림 5는 난방부하 측정실험에 사용된 외기온도와 실내온도를 나타내고 있다. 그림 6은 시험용 건축물 구조체의 외기온도와 실내온도를 변화시켜 취득한 난방부하 특성을 나타내고 있다.




그림 5 난방부하 측정실험에 사용된 외기온도 및 실내온도
Fig. 5 Outdoor and indoor temperature using experiment




그림 6 건축물 구조체의 난방부하
Fig. 6 Heating load of the building construction


5. 모의실험

본 연구에서는 건축물 구조체를 미지의 플랜트로 가정하고 그림 2와 같은 난방부하 식별기를 제안하였다.


제안된 난방부하 식별기의 입력층은 갑작스런 외기온도 및 건축물 구조체의 사용환경 변화에 적절히 대응하기 위해 정규화된 외기온도 및 난방부하 $Nu(k)$, $Ny(k)$ 의 조합 ($Nu(k)$, $Nu(k-1)$, $Nu(k-2)$, $Nu(k-3)$, $Ny(k-1)$, $Ny(k-2)$, $Ny(k-3)$)을 사용하였으며 은닉층은 11개 출력층은 1개의 뉴런을 사용하였고 활성화 함수로는 양극성 시그모이드 함수를 사용하여 난방부하 식별기를 구성하였다. 또한, 식별기 학습은 1일간의 건축물 총 난방부하를 교차신호로 사용하여 1일 1회 학습하도록 하였다. 본 논문에서는 제안한 식별기 구성시 $\rho = 10000$ kcal, 초기 학습률은 $H(0) = 0.01$, $\alpha = 0.0035$, $\gamma = 0.0333$, $\beta = 0.7$, $\zeta = 0.001$ 로 하였다. 또한 시험용 건축물 구조체의 외기온도는 기상청에서 제시한 서울지역의 1996년도 1,2월의 외기온도를 사용하였고 구조체 내부 실내온도는 21℃로 설정하여 모의실험을 수행하였다. 그림 7은 최소자승법(Recursive least squares)을 이용하여 AR 모델 계수를 1일 1회 추정하여 얻은 결과이다. 그림 8은 고정된 학습률을 가진 BPN(입력층 7, 은닉층 11, 출력층 1)을 이용하여, 그림 9는 고정된 학습률의 DRNN을 이용하여 1일간의 총 난방부하를 1일 1회 학습하여 얻은 결과를 나타내고 있다.

그림 10은 본 논문에서 제안된 적응식 학습률을 가진 DRNN을 이용하여 1일간의 총 난방부하를 1일 1회 학습한 결과를 보여주고 있다. 그림에서 알 수 있듯이 제안된 식별

기의 경우 갑작스러운 운전조건의 변화에도 빠른 학습을 보여주고 있다.




(a) 식별기 출력

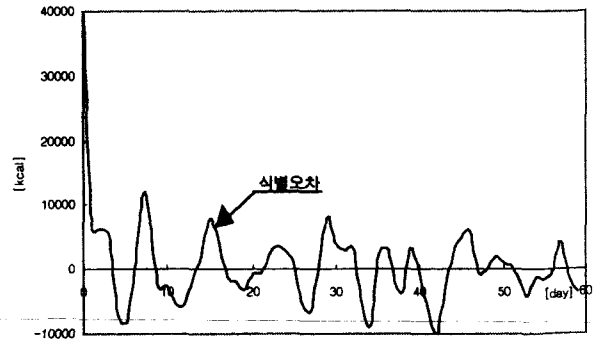


(b) 식별오차

그림 7 RLS를 이용하여 식별한 경우
Fig. 7 case of identification using RLS




(a) 식별기 출력




(b) 식별오차

그림 8 고정된 학습률을 가진 BPN을 이용하여 난방부하를 학습한 경우 ($H(0) = 0.5$)

Fig. 8 The case of learning for heating load using BPN with fixed learning rate ($H(0) = 0.5$)




(a) 식별기 출력




(b) 식별오차

그림 9 고정된 학습률을 가진 DRNN을 이용하여 난방부하를 학습한 경우 ($H(0) = 0.01$)

Fig. 9 The case of learning for heating load using DRNN with fixed learning rate ($H(0) = 0.01$)



(a) 식별기 출력



(b) 식별오차

그림 10 적응식 학습률을 가진 DRNN을 이용하여 난방부하를 학습한 경우 ($H(0) = 0.01$)

Fig. 10 The case of learning for heating load with adaptive learning rate ($H(0) = 0.01$)

위 그림에서 나타나 있는 바와 같이 본 논문에서 제안한 적응식 학습률 조정 알고리즘(delta - bar - delta)을 이용한 난방부하 식별기가 기존의 방법에 비해 초기 학습속도 및 운전조건 변화 등에서 식별능력이 뛰어나 난방부하와 같이 시정수가 큰 시스템에 적합하다는 것을 알 수 있다.

6. 결 론

본 논문에서는 DRNN으로 구성된 건축물 구조체의 최적난방부하 식별기에 대하여 제안하였고 제안된 식별기의 학습에 적응식 학습률 조정 알고리즘(delta - bar - delta)을 사용하였다. 또한 시험용 건축물 구조체에서 난방부하 측정 실험을 시행하여 측정된 데이터를 토대로 모의실험을 수행하여, 제안된 식별기의 성능을 입증하였다. 제안된 난방부하 식별기는 축열식 난방기 설치장소에 따른 건축물 구조체의 손실, 사용자 운전패턴 및 외부공기 유입량에 의한 손실을 정확히 학습, 식별하여 익일 난방에 필요한 최적의 열량만을 심야전력을 사용하여 축열할 수 있도록 하여 기존의 난방부하 식별 기능이 없는 심야난방기기에 비해 전력손실을 최소화할 수 있도록 하여 축열식 심야전력기기의 효율을 향상시

킬 수 있었다. 앞으로는 난방부하 식별기능을 포함한 예측 시스템에 대한 연구가 계속되어야 할 것으로 사료된다.

감사의 글

이 논문은 1999년 한양대학교 교내 연구비에 의하여 연구되었음

참 고 문 헌

- [1] 김동현, 양해원, 최병윤, 주용진, 이경호, "신경회로망을 이용한 최적난방 부하예측 알고리즘 개발", 제어계측 자동화 로보틱스 연구회 합동 학술회의, pp. 382-385, 1998.
- [2] Kawashima, M. 1994. Artificial neural network backpropagation model with three-phase annealing developed for the building energy predictor shoot-out. *ASHRAE Transactions* 100(2).
- [3] K.S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Trans. Neural Networks*, vol.1, no.1, pp.4-27, Mar. 1990.
- [4] C. C. Ku and K. Y. Lee, "System identification and control using diagonal recurrent neural networks," in *Proc. 1992 American Control Conf.*, Chicago, June 24-26, 1992, pp.545-549.
- [5] A. Kimbra, et al. "A Modeling of An Environmental Chamber" *ASHRAE Transaction : Research*, pp 262-273, vol 101, 1995
- [6] L. Fausett. *Fundamentals of Neural Networks*. Prentice Hall International, Inc. 1994
- [7] A. G. Bakirtzls, V. Petrldls, S. J. Klartzls and M. C. Alexladls, "A Neural Network Short Term Load Forecasting Model for the Greek Power System", *IEEE Trans. on Power Systems*, vol. 11, no. 2, pp. 858-863, 1996.
- [8] M. Kawashima, C. E. Dorgan and John W. Mitchell, "Hourly thermal load prediction for the next 24 hours by ARIMA, EWMA, LR, and an artificial neural network", *ASHRAE Transactions : Research*, pp. 186-200, 1995.

저 자 소 개



정 기 철 (鄭 基 澈)

1962년 2월 6일생. 1988년 한양대 공대 전기공학과 졸업. 1990년 동 대학원 전기 공학과 졸업(석사). 1990년~1993년 LG산전 연구소. 1993년~현재 동 대학원 박사과정. 대덕 대학 마이크로 로봇 전공교수.

Tel : (042) 866-0375

E-mail : kchung@mail.ddc.ac.kr



양 해 원 (梁 海 元)

1950년 3월 20일생. 1971년 서울대 전기공학과 졸업. 1973년 동 대학원 전기공학과 졸업(석사). 1982년 일본 Kyoto 대학 전기공학과 졸업(공학박). 1993년~현재 한양 전자 및 컴퓨터 공학부장. 제어 자동화 시스템 공학회 학술이사. 대한 전기학회 조사이사.

Tel : (0345) 400-5162

E-mail : hwyang@email.hanyang.ac.kr