

## 최적 난방부하 예측 제어기 설계

### A Controller Design for the Prediction of Optimal Heating Load

정 기 철, 양 해 원  
(Kee-Chull Chung and Hai-Won Yang)

**Abstract** : This paper presents an approach for the prediction of optimal heating load using a diagonal recurrent neural networks(DRNN) and data base system of outdoor temperature. In the DRNN, a dynamic backpropagation(DBP) with delta-bar-delta learning method is used to train an optimal heating load identifier. And the data base system is utilized for outdoor temperature prediction. Compared to other kinds of methods, the proposed method gives better prediction performance of heating load. Also a hardware for the controller is developed using a microprocessor. The experimental results show that prediction enhancement for heating load can be achieved with the proposed method regardless of the its inherent nonlinearity and large time constant.

**Keywords** : heating load, neural networks, delta-bar-delta, outdoor temperature predictor

#### I. 서론

최근 에너지 절약에 대한 관심이 높아지고 있어 전력시스템을 경제적이고 안정적으로 운영하기 위한 방안의 하나인 심야전력을 이용하는 연구가 활발히 진행되고 있다 [1][2][3]. 특히 축열식 난방기기는 고밀도 철화합물이나 산화 마그네슘(MgO)등을 포함한 세라믹 소재를 이용하여 만든 축열벽들을 심야전력을 사용하여 600~800°C까지 가열, 축열하였다가 실내의 온도에 따라 방열하는 방식으로 현재 널리 활용되고 있다.

축열식 난방기기를 설치, 운용하는데는 건축물의 익일 난방부하를 정확히 예측하여 심야시간(22:00~08:00) 즉, 심야전력이 공급되는 시간동안 필요한 열량을 축열해야 한다. 그러나 건축물 구조체의 난방부하는 다른 시스템에 비하여 시정수가 대단히 클 뿐만 아니라 외기온도, 실내온도, 인접된 공간의 난방유무, 건축물의 재질 및 면적에 따라 열전달률에 의해 발생하는 손실, 외부공기 취입량에 따른 손실, 사용자 실내온도 설정 등 여러 가지 요인에 기인하고 있어 난방부하를 정확하게 예측하는데 어려움이 있다[3].

기존의 축열식 난방기기는 심야시간동안 축열벽들을 최고 온도까지 가열하여 익일의 주간시간(08:00~22:00) 즉, 비 심야시간동안의 난방에 사용하는 방식이기 때문에 불필요한 전력의 손실을 가져와 경제적인 운전이 불가능하다. 따라서 본 논문에서는 익일의 외기온도를 정확하게 예측하고 여러 가지 환경요인에 따라 변화 될 수 있는 건축물 구조체의 난방부하를 정확하게 식별하여 필요한 열량만을 축열, 에너지 손실을 최소화 할 수 있는 최적 난방부하 예측제어기를 제안하였다. 제안된 예측제어기는 DRNN(Diagonal Recurrent Neural Network)을 이용한 신경망 식별기[4][5]와 외기온도 예측기로 구성되어 있다. 식별기에 사용된 DRNN은 적응식 학습률 조정 알고리즘을 사용하여 학습속도 및 성능을 높여 시정수가 큰 건축물 난

방부하의 식별이 용이하도록 구성하였고 외기온도 예측기는 우리나라의 과거 10년간의 시간대별 외기온도 데이터를 토대로 데이터 베이스 시스템을 구축하여 익일 비 심야 시간대의 외기온도를 예측할 수 있도록 구성하였다. 또한 제안된 예측제어기의 성능을 입증하기 위하여 시험용 건축물 구조체를 대상으로 모의실험을 수행하였고 이를 토대로 마이크로 프로세서를 이용한 예측제어기를 구현하여 실증실험을 실시하였다.

본 논문의 구성은 2장에서는 최적 난방부하 예측제어기에 대하여 언급하고 3장에서는 제안된 예측제어기의 하드웨어 설계 및 구현방법에 대하여 제시하고 4장에서는 예측제어기의 성능을 알아보기 위한 모의실험과 실증실험 결과에 대하여 언급하고 마지막으로 5장에서는 결론을 맺는다.

#### II. 최적 난방부하 예측제어기

현재 사용되고 있는 축열식 난방기기는 심야시간동안 축열벽들을 최고 온도까지 가열하여 익일 주간시간 동안의 난방에 사용하기 때문에 불필요한 전력의 낭비를 초래하여 경제적인 운전이 어렵다. 여기서는 이러한 문제점을 해결하기 위하여 최적 난방부하 예측제어기를 제안하였다. 제안된 예측제어기는 축열기가 설치된 건축물의 난방부하를 식별할 수 있는 난방부하 식별기, 익일 비 심야시간대의 평균 외기온도를 예측할 수 있는 외기온도 예측기로 구성되어 있다. 그림 1에 제안된 예측제어기의 구성도를 나타내고 있다.

##### 1. 난방부하 식별기

축열식 난방기기의 최적운전을 위해서는 비 심야시간대의 건축물 구조체의 난방부하를 알아야 한다. 따라서 본 논문에서는 건축물 구조체의 정확한 난방부하를 알아내고, 이것을 익일의 난방부하 예측에 사용하기 위하여 신경망 식별기를 이용하였다. 기존의 신경망을 이용한 난방부하 식별기의 경우 학습신호가 비 심야시간동안의 총 난방부하가 되기 때문에 1일 1회 학습하게 된다[1]. 그러나 우리나라의 계절적인 특성 때문에 1일 1회의 학습으로는 학습

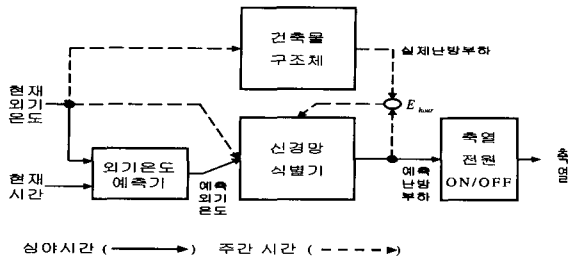


그림 1. 제안된 예측제어기의 구성도.  
Fig. 1. The configuration of the proposed controller for prediction.

속도가 느려서 실제 난방기에 적용하기는 어려움이 많다. 이러한 문제점을 해결하기 위하여 적응식 학습률 조정 알고리즘[6](delta-bar-delta)과 이동평균법[7](moving-average)을 이용한 신경망 식별기를 제안하여 식별기의 학습시간을 감소시켰을 뿐 아니라 성능을 향상 시켰다. 제안된 신경망 식별기의 구조는 그림 2와 같이 입력층, 은닉층과 출력층으로 구성되어 있다.

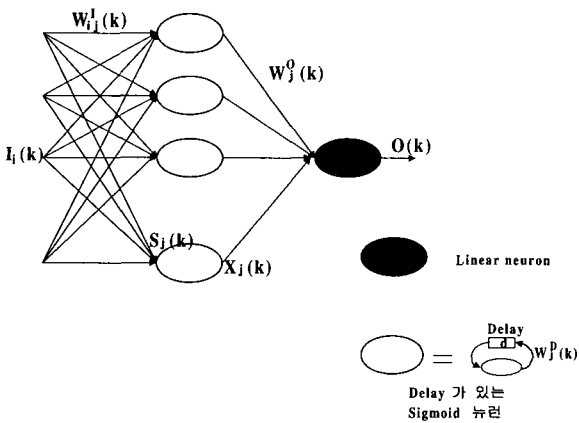


그림 2. Diagonal recurrent neural network의 구조.  
Fig. 2. The structure of the diagonal recurrent neural network.

주어진 DRNN의 입출력 관계는 다음과 같이 표현될 수 있다.

$$O(k) = \sum_j W_j^0 X_j(k) \quad (1)$$

$$X_j(k) = f(S_j(k)), \quad S_j(k) = W_j^D X_j(k-1) + \sum_i W_{ij}^I I_i(k) \quad (2)$$

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  $W^I \in R^{N_i \times N_h}$ ,  $W^O \in R^{N_h \times N_o}$ ,  $W^D \in R^{N_h \times N_h}$ 는 각각 입력, 출력, recurrent 뉴런의 연결강도이다.  $y(k)$ 를 교사신호로 하여 성능지수  $E_I$ 는 다음과 같이 정의한다.

$$E_I = \frac{1}{2} (y(k) - O(k))^2 \quad (3)$$

위 식에 경사감소법(gradient descent rule)을 적용하면 연결강도를 다음과 같이 학습시킬 수 있다.

$$W(k+1) = W(k) + H(k) \left( -\frac{\partial E_I}{\partial W} \right) + \alpha (W(k) - W(k-1)) \quad (4)$$

여기서  $\alpha$ 는 모멘텀 계수이고  $H(k)$ 는 적응 학습률이다. 본 논문에서는 적응 학습률 조정 알고리즘으로 delta-bar-delta ( $\Delta - \bar{\Delta}$ ) 방법을 사용하였다.  $k$  번째 학습 단계에서의  $\Delta$ 와  $\bar{\Delta}$ 를 다음과 같이 정의한다.

$$\Delta_j^o(k) = \frac{\partial E_I}{\partial W_j^o} \quad (5)$$

$$\Delta_j^D(k) = \frac{\partial E_I}{\partial W_j^D} \quad (6)$$

$$\Delta_{ij}^I(k) = \frac{\partial E_I}{\partial W_{ij}^I} \quad (7)$$

$E_I$ 는 식별기 오차이며

$$\bar{\Delta}(k) = (1 - \beta)\Delta(k) + \beta\bar{\Delta}(k-1) \quad (8)$$

이다. 이와 같은  $\Delta$ 와  $\bar{\Delta}$ 를 이용하여  $(k+1)$  단계에서 새로운 학습률  $H(k+1)$ 을 다음과 같이 구한다.

$$H(k+1) = \begin{cases} H(k) + \chi & \text{if } \bar{\Delta}(k-1)\Delta(k) > \zeta, \\ (1 - \gamma)H(k) & \text{if } \bar{\Delta}(k-1)\Delta(k) < -\zeta, \\ H(k) & \text{otherwise} \end{cases} \quad (9)$$

여기서  $\beta, \chi, \gamma, \zeta$ 는 임의의 상수이다. 시정수가 큰 건축물 구조체 난방부하의 빠른 식별을 위해 비 심야시간 동안 매시간 측정되는 난방부하의 이동 평균을 이용하여 1시간에 1번씩 식별기를 학습시켰다. 식별기가 학습하여야 할 난방부하의 이동평균  $y(k)$ 와 식별기 입력  $I_i(k)$ 는 다음과 같은 식으로 나타낼 수 있다.

$$y(k) = \frac{1}{14} \left\{ \sum_{l=9}^k L(l) + \sum_{l=k+1}^{22} L(l-24) \right\} \quad (10)$$

$$I_i(k) = \frac{1}{14} \left\{ \sum_{l=9}^{k-(i-1)} T(l) + \sum_{l=k-(i-2)}^{22} T(l-24) \right\}, \quad 1 \leq i \leq n \quad (11)$$

여기서  $n$ 은 식별기 입력의 개수이다. 또한  $k$ 는 현재시간을 나타내고  $L(l)$ 와  $T(l)$ 는 매시간 측정되는 난방부하와 외기온도를 나타내고 있다. 그림 3은 신경망 식별기의 블럭도이다.

### 2. 외기온도 예측기

우리나라는 지형이 복잡하여 지역과 계절에 따라 극적인 기상현상이 특이하게 발생하고 있고 특히 난방기를 많이 사용하는 겨울의 경우 기상 변화가 심하여 외기온도를 예측하기가 쉽지 않다. 그러나 외기온도는 난방부하를 결정하는 가장 큰 요인중의 하나이기 때문에 외기온도를 예측하는 것은 난방부하를 예측하여 필요한 열량을 측정하는데 필수적인 요소이다[8].

외기온도를 예측하여 정확한 난방부하를 산출하기 위하




그림 3. 난방부하 식별기 블럭도.  
Fig. 3. Block diagram of a heating-load identifier.

여 마르코프 과정(Markov process)의 기상예측법을 도입하여 외기온도 예측기를 설계 하였다[9]. 마르코프 과정은 상태 A가 상태 B로 천이(transition) 될 때 오직 상태 A에 만 의존하는 과정으로, 마르코프가 밀폐된 용기에서 기체 분자의 브라운 운동을 연구할 때 처음 사용하였다. 즉, 일기나 기상의 변화도 바로 앞시간에 관측된 상태(상태 A)에 전적으로 영향을 받아 변화(상태 B)하는 특성이 있기 때문에 본 논문에서는 이러한 마르코프 과정을 토대로 기상청에서 제시한 서울지역 10년간의 시간대별 온도 데이터를 이용하여 외기온도를 예측할 수 있는 데이터 베이스 시스템을 설계 하였다. 그림 4는 외기온도 예측기로 1시간 마다 측정된 외기온도와 측정시간을 입력으로 사용하여 익일 비 심야시간대의 평균 외기온도를 예측할 수 있는 데이터 베이스 시스템을 나타내고 있다. 온도 입력의 범위는  $-16^{\circ}\text{C} \sim 15^{\circ}\text{C}$ 까지이고 시간입력의 범위는 22시부터 익일 7시로 설정하였다.




그림 4. 외기온도 예측기의 데이터 베이스 시스템.  
Fig. 4. Data base system of out-door temperature predictor.

III. 하드웨어 설계

본 논문에서 제안된 최적 난방부하 예측제어기의 주요 하드웨어 구성요소는 시스템 전원부, CPU부, 리셋 및 배터리 백업부, 어드레스 디코더부, 프로그램 메모리부, 데이터 메모리부, 리얼타임 클럭부, 직렬통신부, 난방팬 속도제어부, 축열전원 단속부, 외기온도 감지부, 실내온도 감지부, 축열온도 감지부 등이다. 예측제어기의 입력출력과 측정 데이터는 직렬통신(RS-232C)를 통하여 Pentium II 컴퓨

터로 전송 받을 수 있도록 제작하였다. 제작된 예측제어기의 블럭도는 그림 5와 같다.

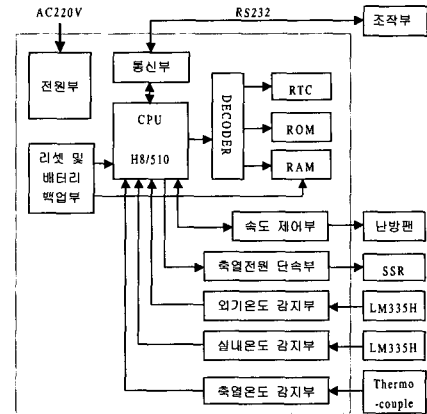


그림 5. 예측 제어기 하드웨어 구성.  
Fig. 5. Hardware structure of prediction controller.

예측 제어기 CPU는 두 개의 직렬통신 포트와 A/D 변환기가 내장되어 있는 일본 히다치(Hitachi)사의 16 비트 one-chip 마이크로 컨트롤러인 H8/510을 사용하였다. 식별 및 예측제어 프로그램을 저장하기 위하여 27C256을 사용하였고, 신경회로망의 연결강도 및 외기온도 예측 데이터 베이스 시스템 등을 저장하기 위해 배터리 백업회로가 구성된 62256LP를 사용하여 정전 및 전원 차단시에도 저장된 데이터의 값들을 손실 없이 보존할 수 있도록 하였다. 또한 리얼타임 클럭(72421B)를 이용하여 일정시간 마다 식별 및 예측알고리즘이 수행되도록 하였고 트라이악 (TRIAC)을 사용하여 난방팬의 속도를 비례제어하여 실내 온도를 조정하였다.

실내온도와 외기온도를 측정하기 위해서  $-40 \sim 100^{\circ}\text{C}$ 까지의 온도 측정이 가능한 LM335H를 사용하였다. LM335H는 출력전압이 0V일때를 절대온도 0도의 기준으로 하여 전압 10mV당 1도의 비율로 실제의 온도를 계산할 수 있다. 따라서 측정온도  $T_c$ 는 다음의 식에 의해서 결정할 수 있다.

$$T_c = V_i \times T_r / V_r \tag{12}$$

여기서  $V_i$ 는 측정온도에 대한 LM335H 출력전압이고,  $T_r$ 는 기준온도,  $V_r$ 는 기준온도에 대한 LM335H 출력전압이다. 고온인 축열재 내부의 온도를 측정하기 위해서  $-200 \sim 1200^{\circ}\text{C}$ 까지 측정할 수 있는 K형 열전대 (thermocouple)를 사용하였다. 열전대의 출력전압은  $-200^{\circ}\text{C}$ 에서  $-5.891\text{mV}$ 이고  $1200^{\circ}\text{C}$ 에서  $48.929\text{mV}$ 로 아주 작은 값이므로 정밀한 증폭회로와 노이즈 필터회로를 사용함으로써 정확한 온도의 측정이 가능하도록 하였다.

IV. 실험 및 결과

1. 모의 실험

본 연구에서는 제안된 난방부하 예측기의 성능을 알아

보기 위하여 모의실험을 수행하였다. 난방부하 식별기는 입력층 4, 은닉층 5, 출력층 1개의 뉴런을 사용하였으며 활성화 함수로는 양극성 시그모이드 함수를 사용하였다. 신경망 식별기는 주간시간 동안 매 시각 출력되는 건축물 난방부하를 교사신호로 하여 학습하였으며 제안된 식별기 구성시 초기 변수들은  $H(0)=0.00001$ ,  $x = 0.035$ ,  $\gamma = 0.333$ ,  $\beta = 0.7$ ,  $\zeta = 0.001$  을 사용하였다. 또한 본 실험에서 사용된 시험용 건축물 구조체의 외기온도는 기상청에서 제시한 서울지역의 96년 1월중 외기온도 변화 폭이 가장 큰 6일 동안의 외기온도 데이터를 사용하여 외기온도 조건을 만들었고, 외기온도에 따라 실내에 설치된 축열식 전기온풍기 내부의 축열재 하강온도를 측정하고 이를 난방부하로 환산하여 실험을 수행하였다. 그림6은 심야시간동안 제안된 예측기와 기존의 코호넨 신경망 예측기[3]를 사용하여 익일의 비 심야시간동안의 난방부하 평균을 예측하도록 하여 모의실험을 수행한 결과이다. 아래 그림에 나타나 있는 바와 같이 제안된 예측기가 기존의 코호넨 신경망을 이용한 예측기보다 학습 속도 및 성능이 우수한 것을 알 수 있다.

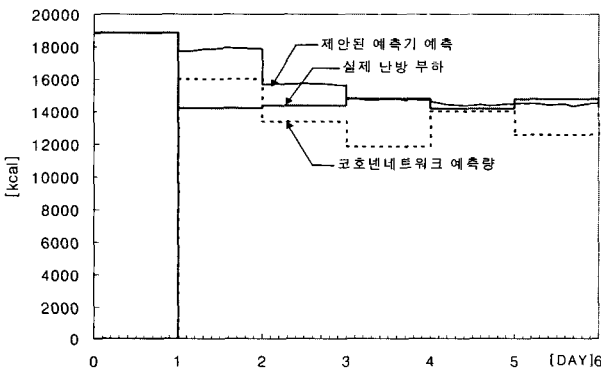


그림 6. 제안된 예측기 및 코호넨 예측기의 모의실험 결과.  
Fig. 6. The simulation results of the proposed predictor and Kohonen predictor.

2. 실험 환경

모의실험을 토대로 하여 제안된 예측 제어기의 성능을 알아보기 위하여 실증실험을 행하였다. 본 실험에서는 (주) 서일전기에서 제조한 축열식 전기온풍기(3.2Kwh)를 난방원으로 사용하였고 축열재 내부온도는 5cm 센서봉을 이용하여 측정하였다. 또한 축열식 전기온풍기의 축열전원으로는 한전에서 제공하는 심야전력을 사용하여 10시간 동안 (22:00~08:00) 축열한 후, 14시간(08:00~22:00)동안 방열 하도록 하였다.

실험을 위해 한국 에너지 기술연구소의 실내기후 실험동의 설비실험실에 축열기를 설치하여 가동하였다. 실험동은 그림 7과 같은 구조를 가진 건축물로 건물의 외부온도에 영향을 받지 않도록 단열 처리되고, 인공적으로 기후를 조절할 수 있도록 되어 있어 실제 외기온도와 관계없이 실

험동의 외기온도를 임의로 설정할 수 있도록 설계되어 있다. 본 실험이 진행된 설비실험실은 3.9m×3.0m = 11.7m<sup>2</sup>의 면적으로 실험동 1층에 설치되어 있다.




그림 7. 시험체 건물의 주단면도.  
Fig. 7. The main cross-sectional view of the experimental building.

실험에 들어가기 전 난방기 내부의 축열재가 정상상태의 온도특성을 지니게 하기 위하여 7일 동안 예비가동을 시킨 상태에서 외기온도 0℃, 축열기 내부온도 190℃, 실내 온도 21℃에서 실험을 시작하였다. 실험중 환기는 타이머를 이용한 자동창문 개폐장치로 1시간에 20초 동안 창문을 개방하도록 하여 실험을 진행하였다.

축열기의 축열온도는 센서봉의 위치와 길이에 따라 온도특성, 온도값의 크기 등이 매우 큰 차이를 보이므로, 정확한 온도측정을 위하여 그림 8에서 보는바와 같이 A, C 위치에 각각 5cm 센서봉을 장착하고 B, D의 위치에 30cm 길이의 센서봉을 장착하여 7일 동안 예비실험을 수행하여 그 결과 가장 좋은 온도특성과 온도값을 얻을 수 있는 C의 위치에 5cm의 센서봉을 위치시켜 축열재 온도를 측정하였다. 이 경우 축열기 최대 배출열량은 22.016[kcal](최대




그림 8. 축열기의 구조와 온도센서의 위치.  
Fig. 8. The structure of the thermal storage heater and the position of the temperature sensor.

효율기준 80%) 으로 내부온도 1℃ 하강시 54.83[kcal]의 열량이 배출되었다. 또한 외기온도는 설비 실험실의 창문 외부에서 15cm 떨어진 곳에 온도센서를 설치하여 측정된 값을 사용하였고, 실내온도는 실험실 내부의 온풍기에서 2m, 바닥에서 1.5m 떨어진 벽에 부착하여 측정하였다.

3. 실증 실험

제안된 예측제어기의 성능을 알아보기 위하여 총 13일 동안 실증실험을 수행하였고 실험 중 건축물의 실내온도는 21℃로 유지하도록 설정하여 시행하였다. 실증실험 처음 7일간은 축열기를 예비 가동을 하여 축열기 내부의 축열재가 정상적인 온도특성을 지니도록 하였고 이후 6일 동안은 제안된 예측 제어기를 구동하여 성능을 알아 보았다. 또한 예측제어기 가동 첫날은 제어기 학습이 되어있지 않은 상태이기 때문에 실험실의 외기온도를 고려하여 02:00~08:00 시간동안 축열하도록 축열 시작-종료시간의 초기상태를 설정하였다. 그림 9는 설비실험실 내부에서 예측 제어기의 외기온도 센서를 통하여 측정된 실험실의 외기온도 데이터를 나타내고 있다.




그림 9. 설비실험실의 외기온도.  
Fig. 9. The outdoor temperature of the equipment laboratory.




그림 10. 난방부하 식별기의 출력.  
Fig. 10. The output of the heating-load identifier.

그림 10은 비 심야시간 매 시간 학습되는 식별기의 난방부하 출력을 나타내고 있다. 그림에서 알 수 있는 것처럼 식별기가 건축물 구조체의 난방부하를 학습하는데는 하루에서 이틀정도의 시간이 소요되고 학습이 진행되면서 식별오차가 점점 줄어드는 것을 알 수 있다. 그림 11은 심야 시간동안 외기온도 예측기를 이용하여 익일의 평균 외기온도를 예측하고 이를 학습된 식별기 입력으로 사용하여 익일의 난방 부하를 예측한 결과를 나타내고 있다. 그림에 나타나 있는바와 같이 예측제어기 가동 첫날은 식별기가 아직 학습 되지 않았기 때문에 난방부하량을 정확히 예측할 수가 없었으나 식별기 학습이 진행되어 식별오차가 적

어지는 가동 3일 이후부터는 정확한 예측결과가 나오는 것을 알 수 있다.




그림 11. 예측제어기를 사용하여 예측된 익일의 난방 부하.

Fig. 11. Predicted heating load of the next day using a prediction-controller.




그림 12. 축열시작시간과 축열종료시간.  
Fig. 12. The start time and end time for thermal storage.

그림 12는 예측된 익일 난방부하에 따라 축열시작 및 종료시간을 조정하여 축열온도를 제어하는 것을 알 수 있다. 심야시간동안 자연 방열로 인한 에너지 손실을 최소화 하기위하여 축열 종료시간을 난방 개시시간에 맞추도록 설계 하였다. 따라서 축열이 시작 되기전에는 축열종료 시간을 아침 07:00시로 고정하고 매시간 변화되는 예측 난방부하에 따라 축열 시작시간을 수정하였고 일단 축열이 시작 되면 축열 종료시간을 변화시키는 방법을 사용하였다. 위 그림에서 3일, 6일째의 축열은 1차 축열 종료 후 갑작스런 외기온도의 하락으로 예측 난방부하가 급격히 증가되어 추가적인 축열이 발생된 것임을 알 수 있다.

축열식 전기온풍기의 축열 온도가 145℃ 이하로 떨어지게 되면 난방팬을 통하여 찬바람이 나오기 때문에 실제적인 난방이 불가능하다. 따라서 본 논문에서는 여러번의 실험에 의한 시행착오를 거쳐 축열기의 내부온도 145℃를 난방 임계값으로 설정하고 예측오차를 감안하여 예측 난방부하량의 112%를 축열하도록 하였다. 그림 13은 축열온도 변화를 나타내고 있다. 세로축(점선)과 축열온도 곡선의 교차부분(원 표시)은 난방종료시(22:00) 축열기 내부의 잔열량으로 난방 임계값인 145℃ 보다 약간 높게 나타나 있

는 것을 알 수 있다. 위 그림에서 알 수 있듯이 본 논문에서 제안한 예측제어기를 부착한 축열식 전기 온풍기의 운전중 난방부하가 변하여도 난방종료시점에는 축열기 내부에 항상 일정한 잔열량을 보유하고 있어 에너지 손실을 최소화하였음을 알 수 있다.




그림 13. 축열기 온도.  
Fig. 13. The thermal storage temperature.

**V. 결론**

본 논문에서는 DRNN을 이용한 난방부하 식별기와 과거 10년간의 시간대별 외기온도 데이터를 이용한 데이터베이스 시스템으로 구성된 최적난방부하 예측제어기를 제안하였고 모의실험을 통하여 제안된 예측제어기 성능의 우수성을 입증하였다. 또한 제안된 알고리즘을 토대로 마이크로 프로세서를 이용하여 하드웨어를 구현하였고 이를 축열식 전기온풍기에 부착하여 실증실험을 행하였다.

제안된 예측제어기는 축열식 난방기 설치장소에 따른 건축물 구조체의 손실, 사용자 운전패턴 및 외부공기 유입량에 의한 손실을 정확히 학습, 식별하여 외기온도 데이터베이스 시스템에서 예측된 익일의 외기온도를 토대로 익일 난방에 필요한 최적의 열량만을 축열할 수 있도록 하였다. 따라서 기존의 식별, 예측 기능이 없는 심야 난방기에 비해 전력손실을 최소화 함으로써 축열식 심야 전력기기의 효율을 향상시킬 수 있었다. 앞으로는 외기온도에 따른 예측 뿐만 아니라 학교나 사무실과 같이 날짜 및 요일

에 따라 변화되는 난방부하도 예측 할 수 있는 제어기에 대한 연구가 계속되어야 할 것으로 사료된다.

**참고문헌**

- [1] 정기철, 양해원, "DRNN을 이용한 최적 난방부하 식별," 대한 전기학회 논문지, 제48권 제10호, pp. 1231- 1238. 1999.
- [2] 임후장, 정기철, 이은옥, 최병윤, 양해원, "최적난방부하 예측 제어기에 관한 연구," 제어 계측 자동화 로봇틱스 연구회 합동 학술 회의, pp. 214-217, 1999.
- [3] 김동현, 양해원, 최병윤, 주용진, 이경호, "신경회로망을 이용한 최적 난방 부하예측 알고리즘 개발," 제어 계측 자동화 로봇틱스 연구회 합동 학술 회의, pp. 382-385, 1998.
- [4] C. C. Ku and K. Y. Lee, "System identification and control using diagonal recurrent neural networks," in *Proc. 1992 American Control Conf.*, Chicago, 24-26, pp. 545-549, June, 1992.
- [5] 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.
- [6] L. Fausett, "*Fundamentals of Neural Networks*," Prentice Hall, 1994.
- [7] 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.
- [8] A. G. Bakirtzls, V. Petridis, 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.
- [9] 조주영, 이우진, "마르코프 과정에 의한 단시간 국지 예보와 예보평가," 기상연구논문집 9(1), pp. 33-41, 1992.



**정 기 철**  
1962년 2월 6일생. 1988년 한양대 공대 전기공학과 졸업. 1990년 동 대학원 전기공학과 졸업(석사). 1990년~1993년 LG 산전 연구소. 1993년~현재 동 대학원 박사과정. 대덕 대학 마이크로 로봇 전공 교수.



**양 해 원**  
1950년 3월 20일생. 1971년 서울대 전기공학과 졸업. 1973년 동 대학원 전기공학과 졸업(석사). 1982년 일본 Kyoto 대학 전기공학과 졸업(박사). 1993년~현재 한양대학교 전자 및 컴퓨터 학부 교수. 제어 자동화 시스템 공학회 학술이사. 대한 전기학회 조사이사.