

The Study on Intelligent Cooling Load Forecast of Ice-storage System

高澤 範[†]
(Taek-Beom Koh)

Abstract : In the conventional operation of ice-storage system based on operator's experience and judgement, the failure in forecast of cooling load occurs frequently due to operator's misjudgement and unskilled operation. This study presents the method of constructing self-organizing fuzzy models which forecast tomorrow temperature, humidity and cooling load periodically for economic and efficient operation of ice-storage system. To check the effectiveness and feasibility of the suggested algorithm, the actual example for forecasting temperature, humidity and cooling load of ice-storage system in KEPCO training institute, Sokcho, is examined. The computer simulation results show that the accuracy of temperature, humidity, cooling load forecast of the suggested algorithm is higher than that of the conventional methods.

Key Words : Cooling load forecast, Ice-storage system, Self-organizing fuzzy model

1. 서 론

심야 전력을 이용하여 얼음을 얼려서 냉열을 축열조에 저장하고 주간에는 이 냉열을 건물에 공급하는 축열식 빙축열 시스템이 많이 보급되고 있다[1],[2]. 그 동안 빙축열 시스템의 운전 제어는 운전자의 운전 경험에 전적으로 의존하여 수행되었고, 운전자의 판단 실수나 미숙한 운전으로 인해 과잉 축열로 인한 전력 낭비나 냉방공급량 부족으로 사용자의 불편을 초래하는 사례가 자주 발생했다. 빙축열 시스템은 다음날의 주간부하를 감당할 냉열을 심야에 미리 저장하기 때문에 빙축열 시스템을 경제적이고 효율적으로 운용하기 위해서는 다음날의 냉방부하를 구간별로 예측하여 최적의 축열량을 결정하여야 한다. 그리고 냉방부하는 온도, 습도, 일조량, 강수량 등의 기후 특성에 영향을 받으므로 냉방부하를 정확하게 예측하기 위해서는 기후의 예측이 필요하다[3-5].

최근의 냉방부하예측 연구[6],[7]에서 선형회귀모델을 이용하여 온도와 습도를 예측하고 이를 기반으로 신경회로망 또는 퍼지 논리를 이용하여 냉방부하를 예측하는 방법을 제안하였으나, 냉방부하의 예측 오차가 커서 실제 현장에 적용하기 위해서는 예측 성능을 개선할 필요가 있다. 선형회귀모델을 이용한 온도와 습도의 예측에서 온도, 습도에 내재하는 비선형성을 정확하게 표현할 수 없었고, 온도와 습도의 예측 오차에 영향을 받는 냉방부하의 예측 오차도 커지는 문제점이 발생하였다. 냉방부하예측[5-7]에 적용하는 신경회

로망과 퍼지 모델에서는 일반적으로 모델 구조(신경회로망 모델의 경우 중간단자의 수와 중간층 수, 단자 사이의 연결 여부, 퍼지 모델의 경우 퍼지 규칙의 수와 소속 함수의 분할 수)를 선정하고 모델의 파라미터만 온라인으로 학습시키는 방법과 모델 구조를 임의로 변경시켜 가면서 오프라인으로 모델의 파라미터를 학습시켜 시행착오에 의해 최적의 모델 구조를 탐색하는 방법을 사용한다. 이와 같은 모델 구조의 탐색 방법은 시행착오에 의한 최적 구조의 탐색으로 인해 비효율적이며 탐색 시간이 지나치게 많이 걸릴 가능성이 크므로 실제 현장에 적용하기 어려우며, 당일의 운전 데이터를 토대로 다음날의 냉방부하를 예측하는 빙축열 시스템의 운전 특성상 냉방부하예측에 적합하지 않다.

빙축열 시스템을 운전하면서 수집한 당일의 운전 데이터를 학습하여 다음날의 냉방부하, 온도, 습도를 정확하게 예측하기 위해서는 예측 모델의 파라미터뿐만 아니라 모델의 구조도 온라인으로 학습할 수 있는 자기구성퍼지모델[8]이 적합하다. 본 연구에서는 자기구성퍼지모델을 적용하여 다음날의 온도, 습도를 예측하고 이 예측치를 기반으로 자기구성퍼지모델을 적용하여 다음날의 냉방부하를 예측하는 새로운 지능형 냉방부하예측방법을 제안한다. 성능과 유용성을 검증하기 위해 한국전력 속초생활연수원을 대상으로 선형회귀모델, 신경회로망모델, 퍼지 논리를 이용한 기존의 방법과 본 연구 방법을 적용하여 구한 예측 결과를 비교 분석한다.

2. 지능형 냉방부하예측

2.1 냉방부하예측 모델

축열식 빙축열 시스템은 기존의 공조 시스템과는 달리 심야에 다음날의 냉방부하를 감당할 냉열을 미리 저장하기 때

[†] 교신저자, 正會員 : 慶州大學校 電氣에너지電子工學科
副教授 · 工博

E mail : tbkoh@gnu.ac.kr

接受日字 : 2008年 8月 18日

最終完了 : 2008年 9月 8日

문에 다음날의 냉방부하를 정확하게 예측하여야 하며, 냉방부하는 온도, 습도에 영향을 받으므로 냉방부하를 정확하게 예측하기 위해서는 온도와 습도의 정확한 예측이 필요하다. 본 연구에서는 당일의 온도와 습도 측정 데이터를 토대로 다음날의 온도와 습도를 예측하는 30분 단위의 1~48번 자기구성퍼지모형을 구축한다.

2.1.1 온도와 습도의 예측

온도와 습도의 예측은 다음 단계에 의해 수행된다.

(단계1) 건물 주변의 온도와 습도를 일정 시간마다 측정하여 평활화 한다.

건물 주변의 온도와 습도는 급변하지 않으므로 센서의 오동작이나 외부 잡음 등에 의해 발생할 수 있는 급격한 변화를 제거하기 위하여 $(l+1)$ 개의 이전 데이터를 식 (1)과 같이 이동 평균을 구하여 평활화 한다.

$$X(t_i) = \frac{1}{l+1} \sum_{k=i-l}^i P(t_k) \tag{1}$$

여기서 $X(t_i)$ 는 시각 t_i 에서 평활화된 측정치이고, $P(t_k)$ 는 시각 t_k 에서 측정된 계측치이다.

(단계2) 평활화된 측정치를 0~1의 범위로 표준화한다.

최저온도 0℃, 최고온도 40℃, 최저습도 0%, 최고습도 100%로 하여 측정 온도와 습도를 0~1의 범위로 표준화한다.

(단계3) 구간별 온도와 습도예측 모델을 구축한다.

표준화된 측정 데이터를 토대로 자기구성퍼지모형을 학습시켜 온도와 습도예측 모델을 구축한다. n 번째 온도와 습도예측 모델의 입력은 m 개의 과거온도($T_{n-1}, T_{n-2}, \dots, T_{n-m}$)와 m 개의 과거습도($H_{n-1}, H_{n-2}, \dots, H_{n-m}$)이고, 출력은 예측시점의 온도(T_n)과 습도(H_n)이며, $m=4$ 로 선정하여 자기구성퍼지모형을 구축하였다.

(단계4) 1일을 30분 구간으로 분할한 1~48번의 자기구성퍼지모형을 단계3의 방법으로 일정회수 반복 학습한다.

온도와 습도예측 모델의 초기 학습은 기준일로부터 학습에 이용되는 기간 동안의 과거 데이터를 일정회수 반복 학습하고, 기준일의 다음날부터 실제 운전이 시작되면 매일 24시 당일의 온도와 습도 데이터를 반복 학습한다. 학습 완료 후 구축된 온도와 습도예측 모델을 이용하여 다음날의 온도와 습도를 구간별로 예측한다.

2.1.2 냉방부하 예측

1일을 30분 구간으로 분할한 1~48번의 자기구성퍼지모형을 학습시켜 냉방부하예측 모델을 구축하고, 이 모델을 이용하여 다음날의 구간별 냉방부하를 예측한다. n 번째 냉방부하예측모델의 입력은 $(p+1)$ 개의 온도($T_n, T_{n-1}, \dots, T_{n-p}$), $(p+1)$ 개의 습도($H_n, H_{n-1}, \dots, H_{n-p}$)와 p 개의 냉방부하($L_{n-1}, L_{n-2}, \dots, L_{n-p}$)이며, 출력은 예측 시점의 냉방부하

L_n 이다. 최저냉방부하는 0[kcal/h], 최고냉방부하는 200[kcal/h]로 설정하여 냉방 부하의 측정치를 표준화하였고, $p=2$ 로 선정하여 자기구성퍼지모형을 구축하였다. 냉방부하예측 모델의 초기 학습은 기준일로부터 학습에 이용되는 기간 동안의 과거 실적자료를 일정회수 반복 학습하며, 기준일의 다음날부터 실제 운전이 시작되면 매일 24시 당일의 온도와 습도측정 자료 및 냉방부하 실적자료를 반복 학습한다. 학습 완료 후 구축된 냉방부하예측 모델을 이용하여 다음날의 냉방부하를 구간별로 예측한다.

2.2 자기구성퍼지모형

자기구성퍼지모형은 모델의 구조와 파라미터를 모두 온라인으로 학습할 수 있으므로 빙축열 시스템의 운전 중에 수집한 당일의 운전 데이터를 학습하여 다음날의 냉방부하와 온도, 습도를 정확하게 예측하기 위해 본 연구에서는 자기구성퍼지모형[8]을 적용한다. 자기구성퍼지모형은 모델의 구조와 파라미터를 동정하기 위하여 모델 파라미터의 동정과정(개략동정과 정밀동정)과 클러스터의 생성(퍼지 규칙의 추가)에 의한 모델 구조의 동정과정을 반복 수행한다. 모델 구조의 동정과정에서 퍼지 엔트로피의 분석을 통한 새로운 클러스터의 생성에 의해 퍼지 규칙을 추가함으로써 애매모호한 정도(fuzziness)를 감소시키는 퍼지규칙의 추가에 의해 모델의 예측 성능을 향상시킨다.

2.2.1 모델 파라미터의 동정

예측 모델을 구축하기 위해 식 (2), (3)의 Takagi-Sugeno형 퍼지모형[9]을 이용한다.

$$\begin{aligned} R^i: & \text{If } x_1 \text{ is } A_1^i(p_{11}^i, p_{12}^i) \text{ and } x_2 \text{ is } A_2^i(p_{21}^i, p_{22}^i) \\ & \text{and } \dots \text{ and } x_m \text{ is } A_m^i(p_{m1}^i, p_{m2}^i), \\ \text{then } & y^i = a_0^i + a_1^i x_1 + \dots + a_m^i x_m \end{aligned} \tag{2}$$

$$y_m = \frac{\sum_{i=1}^c w^i y^i}{\sum_{i=1}^c w^i}, \quad w^i = \text{MIN}_{j=1}^m A_j^i(x_j) \tag{3}$$

여기서 $A_j^i = \exp\left[-\left(\frac{x-p_{j1}^i}{p_{j2}^i}\right)^2\right]$ 는 종형 소속함수이다.

m 차원의 입력과 단일 출력의 경우 i 번째 다차원 평면 클러스터는 다음과 같이 표현된다.

$$y^i = X^T P^i$$

여기서 $X = [1 \ x_1 \ \dots \ x_m]^T$, $P^i = [a_0^i \ a_1^i \ \dots \ a_m^i]^T$ 이다.

다차원 평면 클러스터가 FCRM(fuzzy C-regression model) 클러스터링[10]과 WRLS(weighted recursive least squared) 알고리즘[11]에 의해 조정됨으로써 모델 파라미터가 개략적으로 동정된 후 gradient descent 알고리즘에 의해 정밀하게 동정된다.

2.2.2 모델 구조의 동정

퍼지 집합을 정의역 $X = \{x_1, \dots, x_m\}$ 과 치역 $[0,1]$ 의 대응이라고 하면, X 의 모든 퍼지 부분집합의 전체 집합은 다차원 입방체와 같고, 하나의 퍼지 집합은 이 다차원 입방체의 한 점과 같다[12].




그림 1 퍼지 엔트로피

Fig. 1 Fuzzy entropy

퍼지 집합의 애매모호한 정도는 다음 식으로 표현되는 퍼지 엔트로피로 정의할 수 있다.

$$E(A) = \frac{a}{b} = \frac{l^2(A, A_{near})}{l^2(A, A_{far})}$$

여기서 $l^2(A, B) = \sqrt{\sum_{i=1}^m (m_A(x_i) - m_B(x_i))^2}$ 는 fuzzy Euclidean distance, $a = l^2(A, A_{near})$ 는 퍼지 집합 A 를 나타낸 점과 가장 가까운 정점 사이의 거리, $b = l^2(A, A_{far})$ 는 퍼지 집합 A 를 나타낸 점과 가장 먼 정점 사이의 거리이다.

퍼지 엔트로피가 상대적으로 큰 데이터 집단에 대하여 새로운 클러스터(퍼지 규칙)를 생성하면 퍼지 모델의 애매모호한 정도가 작아지므로 모델링 오차가 작아질 가능성이 크다. 각 표본 데이터 (X_k, y_k) , $1 \leq k \leq n$ 의 퍼지 엔트로피를 구하는 대신에 표본 데이터가 각 클러스터에 속하는 정도를 나타내는 소속도 행렬을 참조하여 애매모호한 정도가 상대적으로 큰 데이터 집단을 다음과 같이 구성하고, 이 데이터 집단에 다중선형회귀분석을 적용하여 새로운 클러스터(퍼지 규칙)를 생성한다.

$$Fuzziness_k = \frac{MIN_{i=1}^r u_k^i}{MAX_{i=1}^r u_k^i}$$

If $Fuzziness_k > MAX$, then $(X_k, y_k) \in Cluster_{near}$

여기서 u_k^i 는 k 번째 표본 데이터 (X_k, y_k) 가 i 번째 클러스터 y 에 속하는 정도를 나타낸다.

2.3 실험결과 및 고찰

한국전력공사 속초생활원수원 건물을 대상으로 축열식 방 축열 시스템을 이용한 냉방부하예측 실험을 수행하였다. 건

물의 쾌적 조건으로 실내온도 26℃, 습도 50%로 선정하였으며, 건물 바닥을 통한 열 손실은 없는 것으로 가정하였다. 1997년 5월 1일부터 9월 30일까지 수집한 온도, 습도와 냉방부하 데이터를 토대로 다음날의 온도, 습도와 냉방부하를 예측하는 30분 단위의 1~48번 자기구성퍼지모델과 신경회로망모델(입력단자 8개, 중간단자 16개, 출력단자 1개의 구조)을 구축하였다. 모델의 초기학습은 7월 19일 이전의 온도, 습도, 냉방부하 실적 데이터를 토대로 수행되었고, 이후 건물에 설치된 방 축열 시스템을 운전하면서 실시간으로 온도, 습도, 냉방부하 데이터를 수집하여 당일 24시에 수집된 데이터를 학습하고 다음날의 온도, 습도, 냉방부하를 예측하는 실험을 수행하였다. 표 1에 온도, 습도, 냉방부하 예측에서 자기구성퍼지모델, 신경회로망모델과 기존 연구의 예측방법을, 그림 2에 냉방부하 예측모델의 구조를 보인다.

표 1 냉방부하예측 방법 비교

Table 1 Comparison of methods for cooling load forecast

예측번호	자기구성 퍼지모델	신경망 모델	연구1 [6]	연구2 [7]
온도	자기구성 퍼지	신경망	선형회귀	선형회귀
습도	자기구성 퍼지	신경망	선형회귀	선형회귀
냉방부하	자기구성 퍼지	신경망	신경망	퍼지논리

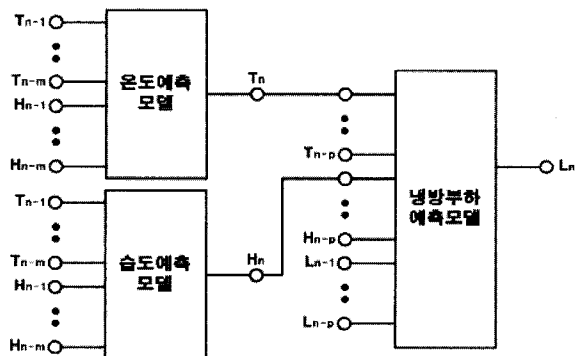


그림 2 냉방부하 예측모델의 구조

Fig. 2 Structure of models for cooling load forecast

그림 3~그림 5에 보인 바와 같이 7월 20일부터 8월 10일까지 9시~17시(연구2는 9시~18시)동안 구한 온도, 습도, 냉방부하의 일별 예측오차%에서 자기구성퍼지모델과 신경회로망모델의 예측오차%가 기존의 연구1과 연구2의 예측오차%보다 훨씬 작고 예측기간동안 고르게 분포하고 있다. 기존의 연구1과 연구2는 온도와 습도의 예측에서 똑같은 선형회귀모델을 사용하여 그림 3의 일별 온도예측오차%와 그림 4의 일별 습도예측오차% 그래프에서 동일하게 나타난다.

냉방부하가 많이 사용되는 7월 20일부터 8월 10일까지 9시~17시 동안 신경회로망모델과 자기구성퍼지모델로 예측한 온도, 습도, 냉방부하의 일일예측평균오차%와 전체예측평균오차%를 일자별로 표 2에 나타낸다.




그림 3 온도예측오차%
Fig. 3 Temperature prediction error%




그림 4 습도에측오차%
Fig. 4 Humidity prediction error%




그림 5 냉방부하예측오차%
Fig. 5 Cooling load prediction error%

표 2 일별예측오차%

Table 2 daily prediction error%

일자	온도오차%		습도오차%		냉방부하오차%	
	신경망 모델	자기구성 퍼지모델	신경망 모델	자기구성 퍼지모델	신경망 모델	자기구성 퍼지모델
7.20	0.88	0.0428	4.97	0.1293	2.48	1.981
7.21	1.58	0.0654	6.25	0.2577	1.29	0.8947
7.22	0.55	0.0382	2.88	0.1353	0.61	0.9186
7.23	1.42	0.0556	2.50	0.1473	1.48	0.7617
7.24	0.79	0.0922	1.73	0.1768	1.44	0.4868
7.25	0.84	0.0691	1.20	0.1174	0.93	0.7570
7.26	1.19	0.0321	1.28	0.0863	2.64	1.9649
7.27	0.91	0.1051	1.43	0.1158	3.81	3.1888
7.28	0.54	0.0379	1.97	0.1659	1.21	0.4165
7.29	0.89	0.0960	1.99	0.2508	0.67	0.4747
7.30	1.27	0.0339	1.16	0.0740	1.83	0.6244
7.31	0.72	0.0375	1.11	0.1021	0.90	0.3611
8. 1	1.42	0.0554	0.96	0.1139	1.15	0.6838
8. 2	2.93	0.1181	5.72	0.3328	4.67	2.3433
8. 3	2.89	0.1414	4.85	0.2253	3.20	1.8422
8. 4	2.84	0.0801	2.27	0.0966	2.93	0.9317
8. 5	2.62	0.0602	5.11	0.1214	3.50	0.5783
8. 6	0.61	0.0519	5.70	0.0634	1.87	0.3840
8. 7	0.82	0.0349	3.26	0.0768	2.43	0.6755
8. 8	1.49	0.0538	3.16	0.2011	2.80	1.4471
8. 9	3.31	0.1140	5.88	0.0941	2.67	3.2389
8.10	1.80	0.1746	4.06	0.1354	2.04	3.4436
평균	1.47	0.0723	3.16	0.1463	2.12	1.2553

냉방부하가 많이 사용되는 7월 20일~8월 10일의 9시부터 17시(연구2는 18시)까지 자기구성퍼지모델, 신경회로망모델, 기존의 연구1과 연구2의 방법을 적용하여 모의실험을 수행하고 구한 평균예측오차%를 표 3에 보인다.

표 3 예측오차 비교

Table 3 Comparison of prediction error

평균오차%	자기구성 퍼지모델	신경망 모델	연구1 [6]	연구2 [7]
온도	0.072	1.47	4.33	4.33
습도	0.146	3.16	11.65	11.65
냉방부하	1.255	2.12	6.28	12.92

표 3과 그림 3~그림 5에서 예측오차%를 살펴보면 온도와 습도의 예측에서 자기구성퍼지모델과 신경회로망모델의 예측오차%가 연구1과 연구2의 선형회귀모델의 예측오차%에 비해 아주 작게 나타났다. 이것은 온도와 습도에 내재하는 비선형 부분을 자기구성퍼지모델과 신경회로망모델이 연구1과 연구2의 선형회귀모델에 비해 더 정확하게 표현한 것으로 판단된다. 냉방부하의 예측 정확도는 온도, 습도의 예측 정확도에 영향을 받으므로 온도, 습도의 예측오차%가 상대적으로 작은 자기구성퍼지모델과 신경회로망모델의 냉방부하예측오차%가 연구1의 선형회로망 모델과 연구2의 퍼지

모델의 냉방부하예측오차%보다 아주 작게 나타났다고 볼 수 있다. 냉방부하예측에 사용되는 신경회로망모델과 연구1의 신경회로망모델은 그 구조와 학습 알고리즘이 동일함에도 냉방부하예측모델의 입력에 사용되는 온도와 습도의 예측치의 정확도가 다르기 때문에 온도, 습도, 냉방부하의 예측에 모두 신경회로망모델을 사용하는 방법의 냉방부하예측 오차%가 온도와 습도의 예측에 선형회귀모델을 사용하고 냉방부하의 예측에만 신경회로망 모델을 사용하는 연구1의 냉방부하예측오차%의 $\frac{1}{3}$ 정도로 작게 나타났다. 본 연구에서는 자기구성퍼지모델의 구조 동정에서 퍼지 규칙 수(클러스터 수)의 범위를 2~4개로 제한하여 자기구성퍼지모델을 구축하였다. 구축된 자기구성퍼지모델의 예측오차%가 선정된 구조에서 파라미터 동정만을 수행하는 연구1, 연구2와 신경회로망모델의 예측오차%에 비해 작게 나타난 결과는 자기구성퍼지모델의 효율적인 구조 동정에 의한 것으로 판단된다. 특히 퍼지 논리를 사용하는 연구2의 냉방부하 예측과 비교할 때 2~4개 범위의 퍼지 규칙을 사용하는 자기구성퍼지모델의 냉방부하예측오차%가 315개의 퍼지 규칙을 사용하는 연구2의 냉방부하예측오차%의 $\frac{1}{10}$ 보다 작았다. 비선형 입출력 관계를 정확하게 표현하는 자기구성퍼지모델과 신경회로망모델을 비교해 보면 온도, 습도, 냉방부하의 모든 예측에서 구조 동정과 파라미터 동정을 수행하는 자기구성퍼지모델의 예측오차%가 선정된 구조에서 파라미터 동정만을 수행하는 신경회로망모델의 예측오차%의 $\frac{1}{2}$ 정도로 작게 나타났다.

3. 결 론

본 연구에서는 빙축열 시스템을 사용하는 단위 건물의 경제적이고 효율적인 하절기 냉방제어를 위해 냉방부하와 온도, 습도를 정확하게 예측하는 자기구성퍼지모델을 구축하고, 한국전력 속초 생활연수원 건물을 대상으로 냉방부하예측 실험을 수행하였다. 냉방부하가 많이 사용되는 7월 20일~8월 10일 9시부터 17시까지 자기구성퍼지모델로 예측한 냉방부하와 온도, 습도의 예측평균오차%는 각각 1.255%, 0.072%, 0.146%로 나타났다. 모델의 구조 동정과 파라미터 동정을 수행하는 자기구성퍼지모델의 예측오차%가 선정된 구조에서 파라미터 동정만을 수행하는 신경회로망모델, 퍼지 모델, 선형회귀모델의 예측오차%보다 작게 나타나 자기구성퍼지모델의 구조 동정과 파라미터 동정이 효과적이며, 또한 온라인 구조 동정이 가능하므로 비선형 시계열 특성을 갖는 빙축열 시스템의 운전 중에 수집한 당일의 운전 데이터를 학습하여 다음날의 냉방부하, 온도, 습도를 정확하게 예측하는 빙축열 시스템의 냉방부하예측에 적합함을 보였다.

향후 히트 펌프를 이용한 냉난방부하의 축열/방열 제어를 위한 모델기반 예측제어에 자기구성퍼지모델을 활용할 수 있을 것으로 사료된다.

참 고 문 헌

[1] Mitchel, John W., "The Control of Ice Storage

System", ASHRAE Transaction, CH-95-22-3, pp. 1345-1352, 1995.

[2] Gregor Pitter Daniel Dominikus Henze, "Evaluation of Optimal Control for Ice Storage Systems", UMI dissertation, 1997.

[3] Morensen, R. E., "A Stochastic Computer Model for Heating and Cooling Loads", IEEE Transaction on Power Systems, Vol.3, No.3, pp. 1213-1217, 1988.

[4] Hagan, Martin T., "The Time series approach to Short Term Load Forecasting", IEEE Transaction on Power System, Vol.PWRS-2, No.3, pp. 785-791, 1987.

[5] Chan, Shin-Tzo, "Weather Sensitivity Short Term Load Forecast Using Nonfully Connector Artificial Neural Network", IEEE Transaction on Power System, Vol.7, No.3, pp. 1098-1105, 1992.

[6] 신관우, 이윤섭, "신경회로망을 이용한 냉방부하예측에 관한 연구", 설비공학논문집, 제14권, 제8호, pp. 626-633, 2002.

[7] 신관우, 이윤섭, "퍼지 논리를 이용한 일일 냉방부하 예측에 관한 연구", 제어자동화시스템공학회, 제8권, 제11호, pp. 948-953, 2002년 11월.

[8] 고택범, "클러스터 생성을 이용한 자기구성 퍼지 모델링", 한국퍼지 및 지능시스템 학회, Vol.12, No.4, pp. 334-340, 2002.

[9] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its application to modeling and control." IEEE Trans. on Syst. Man & Cybern., vol.15, pp.116-132, 1985.

[10] J. C. Bezdek, Pattern Recognition with Fuzzy Objective Functional Algorithm, New York: Plenum, 1981.

[11] L. Ljung, System Identification: Theory for the User. Englewood Cliffs. NJ: Prentice-Hall, 1987.

[12] B. Kosko, Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence. Englewood Cliffs. NJ: Prentice-Hall, 1992.

저 자 소 개



고 택 범 (高澤範)

1955년 10월 28일생. 1981년 연세대학교 전기공학과 졸업. 1996년 동 대학원 전기공학과 졸업(공박). 1999년~현재 경주대학교 전기에너지전자공학과 부교수

Tel : 054-770-5260(연구실)

Fax : 054-744-5295

E-mail : tbkoh@gju.ac.kr