

# Reduced LS-SVM을 이용한 지역난방 동절기 공동주택 난방부하의 모델링

## Modeling of Winter Time Apartment Heating Load in District Heating System Using Reduced LS-SVM

박영철(Young Chil Park)<sup>†</sup>

서울과학기술대학교 전기정보공학과

Department of Electrical and Information Engineering, Seoul National University of Science and Technology,  
Seoul, 139-743, Korea

(Received February 25, 2015; revision received April 13, 2015; Accepted: April 15, 2015)

**Abstract** A model of apartment heating load in a district heating system could be useful in the management and utilization of energy resources, since it could predict energy usage and so could assist in the efficient use of energy resources. The heating load in a district heating system varies in a highly nonlinear manner and is subject to many different factors, such as heating area, number of people living in that complex, and ambient temperature. Thus there are few published papers with accurate models of heating load, especially in domestic literature. This work is concerned with the modeling of apartment heating load in a district heating system in winter, using the reduced least square support vector machine (LS-SVM), and with the purpose of using the model to predict heating energy usage in domestic city area. We collected 23,856 pieces of data on heating energy usage over a 12-week period in winter, from 12 heat exchangers in five apartments. Half of the collected data were used to construct the heating load model, and the other half were used to test the model's accuracy. The model was able to predict the heating energy usage pattern rather accurately. It could also estimate the usage of heating energy within of mean absolute percentage error. This implies that the model prediction accuracy needs to be improved further, but it still could be considered as an acceptable model if we consider the nonlinearity and uncertainty of apartment heating energy usage in a district heating system.

**Key words** District heating system(지역난방), Modeling of heating load(난방부하 모델링), Prediction of heating energy usage(난방열 사용량 예측), Reduced LS-SVM(축소된 최소 제곱 서포트 벡터 머신)

<sup>†</sup> Corresponding author, E-mail: [ycpark@seoultech.ac.kr](mailto:ycpark@seoultech.ac.kr)

### 1. 서 론

동절기 공동주택(apartment) 난방부하의 예측은 에너지 자원의 효율적 관리 및 활용의 관점에서 공급자는 물론 사용자 모두에게 중요한 의미를 가질 수 있다. 바꾸어 말해서 공동주택의 난방열 사용량 및 사용 패턴의 중·단기 수요 예측은 열에너지 생산 또는 소비 시설의 효율적 운영과 이를 통한 생산 또는 소비 비용의 절감과 같은 경제적 측면에서 뿐만 아니라, 에너지 사용 절감에 따른 유발 효과의 측면에서도 대단히 중요한 것일 수 있다.

공동주택의 동절기 난방부하는 공동주택의 유형(면적), 세대수 및 거주 인원, 외기온도 등과 같은 복합 요

인들에 따라 달라진다. 즉 공동주택의 난방열 사용량 및 사용 패턴은 다양한 인자들을 독립변수로 하는 대단히 비선형적 관계에 의해 결정되며, 따라서 공동주택 난방부하의 예측은, 그와 같은 복잡한 비선형적 관계 수립의 어려움과 비선형성에 따른 독립인자들의 변화에 대한 종속 변수 변화의 불확실성 등으로 인하여, 실제적으로 정확하게 추론되기가 대단히 어렵다.

그러나 비록 정확한 예측에서 많은 어려움이 있다고는 하나, 공동주택의 동절기 난방부하의 수요 예측은 여전히 중요하며, 따라서 이들 난방열 사용량 및 사용 패턴의 예측을 위한 모델 수립에 관한 연구가 제한적이긴 하나 지속되어 왔다. Werner<sup>(1)</sup>는 공동주택의 정상 상태(steady state)에서의 열사용량 예측을 위하여, 측정

된 평균 난방열, 급탕열, 열손실 등과 같은 개별 요소들의 선형적 결합으로 표시된 그러나 실제 정확한 의미의 해석적 모델이라고 보기에 어려운 점이 있는 난방부하모델을 수립하였으며, Heller<sup>(2)</sup>는 공동주택 열사용을 이론적으로 해석하고 이를 상용 해석 프로그램(TRNSYS)을 사용하여 풀어내는 컴퓨터 시뮬레이션에 의한 열사용량 예측에 관한 연구를 수행하였다. 그러나 Heller의 연구 결과는 이론적 해석에서 요구되는 많은 가정들을 포함하고 있으며, 또한 시뮬레이션에서 사용된 조건들의 보편성 등의 문제로 인하여 비록 특정 경우에 대하여 비교적 정확한 예측이 이루어지기는 하였으나, 연구 결과의 일반화에는 지극히 제한적일 수밖에 없는 결과이다.

공동주택 열사용량의 실험적 측정과 이들 측정된 데이터의 회귀(regression) 분석에 의한 해석 또는 black box 형태로의 모델링을 통하여 공동주택의 열사용량을 예측하는 연구 역시 제한적이긴 하나 일부 수행되었다. Koive et al.<sup>(3)</sup>은 측정된 공동주택의 급탕열 사용량을 실험적 회귀식으로 표시함으로써 연결 세대수에 따른 급탕열 사용량의 계산법을 제시하였으며, Evarts et al.<sup>(4)</sup>은 측정된 급탕열 사용량을 통계적으로 사용하여 예상되는 급탕열 수요를 예측하는 방법을 제시하였다.

최근 복잡한 상관관계를 갖는 비선형 시스템의 모델링과 이를 이용한 복잡시스템의 제어를 위하여 측정된 시스템 동작 데이터로부터 비선형모델을 수립하는 LS-SVM(least squares support vector machines)<sup>(5-8)</sup>이 다양한 분야에서 활용되고 있다. LS-SVM은, 비선형 시스템의 모델링을 위한 Vapnik<sup>(9)</sup>의 SVM의 문제점을 개선하여, 모델링 과정에서 요구되는 부등식(inequality equation)의 구속조건(constraint condition) 사용에 따른 convex quadratic programming problem 형태의 모델링 대신, 등식(equality equation)의 구속조건을 사용함으로써 해석적 형태를 갖는 모델을 구성할 수 있게 한다. 현재까지 참고문헌에 발표된 LS-SVM의 대표적인 활용 사례들은, 양성 후두 질환자의 지속모음합성,<sup>(10)</sup> 단기 전력 부하 예측,<sup>(11)</sup> HVAC 시스템의 모델 수립,<sup>(12)</sup> SOFC(solid oxide fuel cell)의 온도 제어를 위한 모델 수립,<sup>(13)</sup> 태양열 공기 히터(solar air heater)의 모델링,<sup>(14)</sup> 발전소 과열증기 온도 제어를 위한 시스템 모델링,<sup>(15)</sup> Wiener-Hammerstein 시스템의 인식(identification),<sup>(16)</sup> 일사량 예측<sup>(17)</sup>과 같은, 의학, 공학 및 수학의 다양한 분야에서 활용되고 있는 것들이다.

동절기 공동주택 난방부하는, 이미 전술한 것과 같이, 다양한 요소 인자들의 비선형적 결합에 의해 결정되는 시스템이다. 본 연구는 궁극적으로는 국내 공동주택의 열사용량 및 열사용 패턴 예측을 위한 모델 수립을 위한 일련의 연구의 첫 단계 결과로서, 경기도 남부 신도시지역에서 측정된 동절기 난방열 사용량을 Reduced

LS-SVM을 사용하여 모델링하고, 수립된 모델의 예측 정확도를 실제 측정 데이터와 비교 분석한 것이다.

## 2. Reduced LS-SVM

### 2.1 LS-SVM

LS-SVM은 커널(kernel) 기반의 모델링 기법으로, 비록 SVM의 sparseness 특성을 갖지 못하며 동시에 모델링 오차가 가우시안(Gaussian) 분포를 가질 때에만 최적의 모델이 형성되는 것과 같은 문제점을 가지고 있기는 하나, 그럼에도 불구하고 해석적 형태의 모델이 존재한다는 이점으로 인하여 다양한 비선형 시스템의 모델링에 사용되고 있다.

LS-SVM 기반의 시스템 모델링을 위하여 우선 측정된  $N$ 개의 데이터를 식(1)과 같이 정렬한다. 식(1)의  $y_i$ 는  $i$ 번째 측정된 데이터를 그리고  $\mathbf{x}_i$ 는  $y_i$ 를 결정하는  $n$ 개의 독립인자들로 구성된  $n$  차원의 입력데이터 벡터이다.

$$\{(\mathbf{x}_i, y_i)\}, i = 1, \dots, N, \mathbf{x}_i \in R^n, y_i \in R \quad (1)$$

LS-SVM은 식(1)에서와 같이 정의된 입력데이터 벡터로부터 비선형 사상함수(mapping function)  $\varphi(\mathbf{x})$ 를 사용하여 식(2)와 같은 회귀모델을 구성하는 것으로서, 식(2)의  $\mathbf{w}$ 는 가중치 벡터(weight vector)를,  $b$ 는 바이어스(bias)를 그리고  $e_i$ 는 상호 상관관계를 갖지 않는 모델 오차(noncorrelated error)를 나타낸다.

$$y_i = f(\mathbf{x}_i) + e_i = \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i, i = 1, \dots, N \quad (2)$$

$$E[e_i] = 0, E[e_i^2] = \sigma^2 < \infty$$

LS-SVM은 식(2)에서와 같이 정의된 측정 데이터와 입력데이터 벡터와의 관계를 결정하기 위하여 식(3)에서와 같은 손실함수  $J(\mathbf{w}, e)$ 의 최소화 과정을 사용하며, 식(3)의  $\gamma$ (regression parameter)는 손실함수 내의 가중치 벡터  $\mathbf{w}$ 와 회귀모델의 오차  $e_i$ 의 상호 가중치(relative weight)를 결정하기 위한 상수이다.

$$\min_{\mathbf{w}, b} \left\{ J(\mathbf{w}, e) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^N e_i^2, \gamma > 0 \right\} \quad (3)$$

subject to  $y_i = \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i, i = 1, \dots, N$

식(3)으로 표시된 최적화는 다시 Lagrange multiplier  $\alpha_i$ 를 사용하여 식(4)에서 정의되는 함수  $L(\boldsymbol{\alpha}, b)$ 의 최소화로 정의될 수 있으며, 따라서 식(4)를 만족하는  $b$

그리고  $\alpha_i$ 는 식(5)를 사용하여 얻어진다.

$$\min_{\alpha, b} \left\{ L(\alpha, b) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^N e_i^2 - \sum_{i=1}^N \alpha_i [\mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i - y_i] \right\} \quad (4)$$

$$\begin{bmatrix} 0 & \mathbf{1}_N^T \\ \mathbf{1}_N & \Omega + \frac{1}{\gamma} \mathbf{I}_N \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \mathbf{C} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (5)$$

식(5)의  $\mathbf{1}_N = [1 \ 1 \ \dots \ 1]^T$ 은  $N$ 개의 1을 요소로 갖는 벡터를,  $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N]^T$ 는  $N$ 개의  $\alpha_i$ 를 요소로 갖는 벡터를, 그리고  $\mathbf{y} = [y_1 \ y_2 \ \dots \ y_N]^T$ 는  $N$ 개의 측정 데이터를 요소로 갖는 벡터를 나타낸다. 또한  $\mathbf{I}_N$ 은  $N \times N$  차원의 단위행렬(unit matrix)을 나타내며,  $\Omega$ 는 식(6)에서와 같이 정의되는  $N \times N$  차원의 대칭행렬(symmetric matrix)이다.

$$\Omega = [\Omega_{ij}], \quad \Omega_{ij} = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j) = K(\mathbf{x}_i, \mathbf{x}_j) \quad (6)$$

식(6)의  $K(\mathbf{x}_i, \mathbf{x}_j)$ 는 입력데이터 벡터  $\mathbf{x}_i$ 와  $\mathbf{x}_j$ 에 의하여 정의되는 양한정(positive definite) 특성을 갖는 임의의 커널함수를 나타내며, 마지막으로 식(5)에 의하여 얻어지는  $\alpha$ 와  $b$ 를 사용하여 LS-SVM은 식(7)과 같은 모델을 형성한다.

$$y = \mathbf{w}^T \varphi(\mathbf{x}) + b = \sum_{i=1}^N \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (7)$$

## 2.2 Recursive LS-SVM

식(7)로 정의되는 LS-SVM 기반의 시스템 모델링 과정은 식(5)에서 정의된  $(N+1) \times (N+1)$  행렬  $\mathbf{C}$ 의 역행렬의 계산을 필요로 한다. 만약 모델링에 사용되는 측정 데이터의 수  $N$ 이 충분히 작다면 행렬  $\mathbf{C}$ 의 역행렬 계산은 가우시안 소거법 등과 같은 방법으로 문제 없이 수행될 수 있다. 그러나 만약 모델링에 사용되는 데이터의 수가 충분히 많아지면, 그와 같은 경우 행렬  $\mathbf{C}$ 의 역행렬 계산은 연산 측면에서 뿐만이 아니라 연산과정의 메모리 문제 등과 같은 다양한 어려움을 갖게 된다.

Recursive LS-SVM<sup>(18)</sup>은 당초 비선형 시스템의 제어를 위하여 실시간으로 측정되어지는 데이터를 연속적으로 시스템 모델에 포함시키기 위하여 개발된 변형된 형태의 LS-SVM으로서 다음과 같은 과정에 따라 시스템의 모델을 형성한 것이다. Recursive LS-SVM은 우선

초기 충분히 작은  $k$ 번째까지의 측정 데이터를 사용하여 식(5)를 아래의 식(8)에서와 같은 행렬식으로 만들고, 이를 이용하여 초기  $k$ 번째까지의 데이터를 사용한 시스템 모델을 식(7)에서와 같은 형태로 형성한다.

$$\mathbf{C}_k \mathbf{P}_k = \mathbf{T}_k \rightarrow \mathbf{P}_k = \mathbf{C}_k^{-1} \mathbf{T}_k \quad (8)$$

$$\mathbf{C}_k = \begin{bmatrix} 0 & \mathbf{1}_k^T \\ \mathbf{1}_k & \Omega_k + \frac{1}{\gamma} \mathbf{I}_k \end{bmatrix}, \quad \mathbf{P}_k = \begin{bmatrix} b_k \\ \alpha_k \end{bmatrix}, \quad \mathbf{T}_k = \begin{bmatrix} 0 \\ \mathbf{y}_k \end{bmatrix}$$

$$\alpha_k = [\alpha_1 \ \dots \ \alpha_k]^T, \quad \mathbf{y}_k = [y_1 \ \dots \ y_k]^T$$

$$\Omega_k = [\Omega_{ij}], \quad \Omega_{ij} = K(\mathbf{x}_i, \mathbf{x}_j), \quad i = 1, \dots, k, \quad j = 1, \dots, k$$

식(8)의  $\mathbf{1}_k = [1 \ 1 \ \dots \ 1]^T$ 은  $k$ 개의 1을 요소로 갖는 벡터이며,  $\mathbf{I}_k$ 은  $k \times k$  차원의 단위행렬을 나타낸다. 이제 초기  $k$ 번째까지의 데이터를 사용하여 형성된 모델로부터 추가되는 데이터, 즉  $k+1$ 번째 데이터까지를 포함하는 새로운 모델을 형성하기 위하여 식(5)를 식(9)과 같은 행렬식으로 표시한다.

$$\mathbf{C}_{k+1} \mathbf{P}_{k+1} = \mathbf{T}_{k+1} \quad (9)$$

$$\mathbf{C}_{k+1} = \begin{bmatrix} \mathbf{C}_k & \Psi \\ \Psi^T & K(\mathbf{x}_{k+1}, \mathbf{x}_{k+1}) + \frac{1}{\gamma} \end{bmatrix}$$

$$\mathbf{P}_{k+1} = \begin{bmatrix} b_{k+1} \\ \alpha_{k+1} \end{bmatrix}, \quad \mathbf{T}_{k+1} = \begin{bmatrix} 0 \\ \mathbf{y}_{k+1} \end{bmatrix}$$

$$\Psi = [1 \ K(\mathbf{x}_1, \mathbf{x}_{k+1}) \ K(\mathbf{x}_2, \mathbf{x}_{k+1}) \ \dots \ K(\mathbf{x}_k, \mathbf{x}_{k+1})]^T$$

$$\alpha_{k+1} = [\alpha_1 \ \dots \ \alpha_k \ \alpha_{k+1}]^T, \quad \mathbf{y}_{k+1} = [y_1 \ \dots \ y_k \ y_{k+1}]^T$$

그 후 식(9)에서 정의된  $k+1$ 번째까지의 데이터가 포함되어 있는 행렬  $\mathbf{C}_{k+1}$ 의 역행렬을, 행렬의 부분 행렬들에 의한 전체 행렬의 역행렬을 계산하는 과정<sup>(18)</sup>을 사용하여 식(10)에서와 같이 계산한다.

$$\mathbf{C}_{k+1}^{-1} = \begin{bmatrix} \mathbf{C}_k^{-1} + \frac{1}{\eta} \mathbf{C}_k^{-1} \Psi \Psi^T \mathbf{C}_k^{-1} & -\frac{1}{\eta} \mathbf{C}_k^{-1} \Psi \\ -\frac{1}{\eta} \Psi^T \mathbf{C}_k^{-1} & \frac{1}{\eta} \end{bmatrix} \quad (10)$$

$$\text{where } \eta = K(\mathbf{x}_{k+1}, \mathbf{x}_{k+1}) + \frac{1}{\gamma} - \Psi^T \mathbf{C}_k^{-1} \Psi$$

마지막으로 식(10)에 의하여 계산된 역행렬  $\mathbf{C}_{k+1}^{-1}$ 을 사용하여  $k+1$ 번째까지의 측정 데이터를 포함하는 모델링에서 요구되는 Lagrange multiplier 벡터  $\alpha_{k+1}$ 와 바이어스 상수  $b_{k+1}$ 를 식(11)과 같이 계산한다.

$$\begin{bmatrix} b_{k+1} \\ \alpha_{k+1} \end{bmatrix} = \mathbf{C}_{k+1}^{-1} \mathbf{T}_{k+1} = \mathbf{C}_{k+1}^{-1} \begin{bmatrix} \mathbf{T}_k \\ \mathbf{y}_{k+1} \end{bmatrix} \quad (11)$$

$$= \begin{bmatrix} P_k + \frac{1}{\eta} C_k^{-1} \Psi (\Psi^T P_k - y_{k+1}) \\ \frac{1}{\eta} (y_{k+1} - \Psi^T P_k) \end{bmatrix}$$

Recursive LS-SVM은 이상과 같은 과정을 측정 데이터의 수가 최종  $N$ 번째가 되도록 반복적으로 적용한 후 얻어지는 Lagrange multiplier 벡터  $\alpha$ 와 바이어스 상수  $b$ 를 사용하여 식(7)과 같은 LS-SVM 모델을 형성하는 것이다.

### 2.3 Reduced LS-SVM

만약 LS-SVM에 의한 시스템 모델링에서 사용되는 데이터의 수  $N$ 이 대단히 크면, LS-SVM에 의한 모델링은 비록 Recursive LS-SVM을 사용한다고 하더라도 실제 구현에 있어 여전히 많은 문제점을 가지게 된다. 바꾸어 말해서 만약 측정된 데이터의 수  $N$ 이 대단히 크면, 비록 식(5)에서 정의되는  $(N+1) \times (N+1)$  행렬  $C$ 의 역행렬 계산이 논리적으로는 가능하다고는 하나, 그와 같이 대단히 큰 행렬의 역행렬의 계산은 연산 시간 및 컴퓨터 메모리 확보 등과 같은 다양한 문제점들을 유발시키며, 따라서 실제 구현을 어렵게 만든다.

Reduced LS-SVM<sup>(19)</sup>은 이와 같이 대단히 많은 측정 데이터를 갖는 시스템의 모델링을 위하여 모델링에 사용되는 데이터의 수  $M$ 을 실제 측정된 데이터의 수  $N$ 보다 작은 수로 하고, 그러나 그와 같이 선택된 일부 데이터만을 사용하여 형성하는 모델이 전체 데이터를 사용할 경우 형성되는 모델이 갖는 예측 정확도에 최대한 근접하도록 하는 변형된 형태의 LS-SVM이다.

Reduced LS-SVM 기반의 모델링은 우선 식(12)에서와 같은,  $N$ 개의 측정 데이터로부터 이들 측정 데이터가 가지고 있는 상관관계적 특성을 잘 내포하고 있는  $M$  ( $M \ll N$ )개의 특징데이터(feature data)를 선택하는 것으로부터 시작한다.

$$\{(\mathbf{x}_{si}, y_{si})\}, i = 1 \cdots M, \mathbf{x}_{si} \in R^n, y_{si} \in R \quad (12)$$

또한 Reduced LS-SVM은 제한된 수량의 특징데이터를 사용하여 모델을 형성함으로써 식(2)에서 정의된 LS-SVM과는 다르게 아래의 식(13)에서와 같은 회귀모델을 형성하게 된다.

$$y_i = f(\mathbf{x}_i) + e_i = \sum_{j=1}^M [\alpha_j \varphi(\mathbf{x}_{sj}) \varphi(\mathbf{x}_i)] + b + e_i \quad (13)$$

식(13)의  $f(\cdot)$ 는, LS-SVM에서와 같이 비선형 사상함수를 나타내며,  $\varphi(\mathbf{x})$ 는 무한 차원을 가질 수 있는 기저

함수를,  $\alpha_j$ 는 LS-SVM의 Lagrange multiplier와 동일한 의미를 갖는 변수를, 그리고  $b$ 와  $e_i$ 는 각각 바이어스와 상호 상관관계를 갖지 않는 모델 오차를 나타낸다.

Reduced LS-SVM에 의한 모델링은 이제 식(13)에서 정의된 오차  $e_i$ 의 최적화를 위하여 식(14)에서와 같이 정의되는 함수  $L(\alpha, b)$ 을 최소화하는  $\alpha_j$ 와  $b$ 를 식(15)에서와 같은 행렬식을 풀어 계산한다.

$$\min_{\alpha, b} \left\{ L(\alpha, b) = \frac{1}{2} \sum_{j=1}^M \sum_{k=1}^M \alpha_j \alpha_k K(\mathbf{x}_{sj}, \mathbf{x}_{sk}) + \frac{\gamma}{2} \sum_{i=1}^N [y_i - \sum_{j=1}^M \alpha_j K(\mathbf{x}_{sj}, \mathbf{x}_i) - b]^2 \right\} \quad (14)$$

$$\begin{bmatrix} N & \Psi^T \\ \Psi & \Omega \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N y_i K(\mathbf{x}_{s1}, \mathbf{x}_i) \\ \vdots \\ \sum_{i=1}^N y_i K(\mathbf{x}_{sM}, \mathbf{x}_i) \end{bmatrix} \quad (15)$$

$$\Psi = \left[ \sum_{i=1}^N K(\mathbf{x}_{s1}, \mathbf{x}_i) \quad \sum_{i=1}^N K(\mathbf{x}_{s2}, \mathbf{x}_i) \quad \cdots \quad \sum_{i=1}^N K(\mathbf{x}_{sM}, \mathbf{x}_i) \right]^T$$

$$\alpha = [\alpha_1 \cdots \alpha_M]^T$$

$$\Omega = [\Omega_{jk}], \quad \Omega_{jk} = \frac{1}{\gamma} K(\mathbf{x}_{sj}, \mathbf{x}_{sk}) + \sum_{i=1}^N K(\mathbf{x}_i, \mathbf{x}_{sj}) K(\mathbf{x}_i, \mathbf{x}_{sk})$$

$$j = 1 \cdots M, k = 1 \cdots M$$

마지막으로 Reduced LS-SVM은 식(15)에서 계산된  $\alpha$ 와  $b$ 를 사용하여 식(16)에서와 같은 시스템 모델을 형성한다.

$$y = \sum_{j=1}^M \alpha_j K(\mathbf{x}_{sj}, \mathbf{x}) + b \quad (16)$$

식(16)으로 표시되는 Reduced LS-SVM 기반 모델링 과정에서, 만약 특징데이터의 수  $M$ 이 비록 전체 데이터의 수  $N$ 과 비교하여 대단히 작으나 그럼에도 불구하고 여전히 큰 값을 가질 경우에는 식(15)에서 정의된 행렬의 역행렬을 제 2.2절에서와 같이 recursive하게 계산함으로써 식(16)에서 요구되는  $\alpha$ 와  $b$ 의 계산이 가능하도록 할 수 있다.

### 2.4 특징 데이터의 선택

Reduced LS-SVM에 의한 모델링을 위하여 측정된 전체 데이터로부터 식(12)에서와 같은 특징 데이터를 선택하는 것이 필요하다. 특징데이터는, 비록 일부 선행연구에

서 전체 측정 데이터로부터 완전하게 임의로 선택(purely random selection)된 경우도 있기는 하나, 선택된 데이터들이 전체 데이터들이 가지고 있는 상관관계의 특징들을 충분히 반영할 수 있도록 선택되는 것이 중요하다. Suykens<sup>(5)</sup>와 Brabanter et al.<sup>(10)</sup>은 모델링에 사용되는 데이터의 엔트로피(entropy)를 정의하고 이를 기준으로 하여 특징 데이터를 선별하였으며, Baudat and Anouar<sup>(21)</sup>은 특징 데이터에 의하여 형성된 Reduced LS-SVM 기반의 모델이 측정된 전체 데이터를 추정하는 회귀오차가 최소화 되도록 하는 기준을 사용하여 특징 데이터를 선별하였다.

본 연구에서는, Baudat and Anouar의 연구 결과를 인용하여, 아래와 같이 특징 데이터를 선택한다. 전체 데이터에 속해 있는 임의의 데이터  $(\mathbf{x}_i, y_i)$ 의 사상값  $\varphi(\mathbf{x}_i)$ 를 식(17)에서와 같이 선택되는 특징 데이터들의 사상값들의 선형조합으로 표시한다.

$$\begin{aligned} \varphi(\widehat{\mathbf{x}}_i) &= \mathbf{a}_i^T \Phi(\mathbf{x}_S) \\ \mathbf{a}_i &= [a_{i1} \ a_{i2} \ \dots \ a_{iM}]^T \\ \Phi(\mathbf{x}_S) &= [\varphi(\mathbf{x}_{s1}) \ \varphi(\mathbf{x}_{s2}) \ \dots \ \varphi(\mathbf{x}_{sM})]^T \end{aligned} \quad (17)$$

식(17)의  $\varphi(\widehat{\mathbf{x}}_i)$ 는 실제 사상값  $\varphi(\mathbf{x}_i)$ 을 식(17)에서와 같은 특징 데이터 사상값들의 선형조합으로 나타내었을 때의 추정치이며, 특징 데이터는 이와 같은 추정치와 실제 사상값의 차가 식(18)로 정의되는 오차를 최소화하도록 선택함으로써 선별된다.

$$\min_{\mathbf{a}_i} \left\{ \delta_i = \frac{\|\varphi(\mathbf{x}_i) - \varphi(\widehat{\mathbf{x}}_i)\|^2}{\|\varphi(\mathbf{x}_i)\|^2} \right\} \quad (18)$$

식(18)을 특징 데이터 선택에서 사용되는 양특성을 갖는 커널함수를 사용하여 다시 정의하기 위하여, 식(17)에서 정의된  $\varphi(\widehat{\mathbf{x}}_i)$ 를 식(18)에 대입하고 이를 다시 정리하면 식(18)은 식(19)와 같이 표시된다.

$$\begin{aligned} \min_{\mathbf{a}_i} \left\{ \delta_i = 1 - \frac{\mathbf{K}_{si}^T \mathbf{K}_{ss} \mathbf{K}_{si}}{K(\mathbf{x}_i, \mathbf{x}_i)} \right\} \\ \mathbf{K}_{ss} = [K(\mathbf{x}_{sj}, \mathbf{x}_{sk})], \quad j=1, \dots, M, \quad k=1, \dots, M \\ \mathbf{K}_{si} = [K(\mathbf{x}_{s1}, \mathbf{x}_i) \ K(\mathbf{x}_{s2}, \mathbf{x}_i) \ \dots \ K(\mathbf{x}_{sM}, \mathbf{x}_i)]^T \end{aligned} \quad (19)$$

결국 특징 데이터는 측정된 전체 데이터에 대하여 식(19)에서 정의된 개별  $\delta_i$ 의 합이 최소가 되도록 하는 데이터들을 선별함으로써 선택될 수 있으며, 이는 다음의 식(20)에서와 같은 조건을 충족시키는 데이터들이 특징데이터가 됨을 의미한다.

$$\min \left\{ \sum_{i=1}^N \left( 1 - \frac{\mathbf{K}_{si}^T \mathbf{K}_{ss} \mathbf{K}_{si}}{K(\mathbf{x}_i, \mathbf{x}_i)} \right) \right\} \quad (20)$$

식(20)의 최적화를 실제 특징 데이터의 선별과정에서 필요로 하는 반복적 연산(iterative process)에서 사용하기 위하여 다음과 같은  $J_S$ 와  $J_{Si}$ 를 정의한다.

$$J_{Si} = \frac{\mathbf{K}_{si}^T \mathbf{K}_{ss} \mathbf{K}_{si}}{K(\mathbf{x}_i, \mathbf{x}_i)}, \quad J_S = \frac{1}{N} \sum_{i=1}^N J_{Si} \quad (21)$$

전체 데이터로부터 식(20)에서 정의된 조건을 충족시키는 또는 식(21)에서 정의된  $J_S$ 를 최대로 하는 특징데이터의 반복적 연산에 의한 선별을 위하여, 모든 데이터에 대해서 최초로 식(21)에서 정의된  $J_S$ 를 최대로 하는  $\mathbf{x}_j$ 를 선택하여 이를  $\mathbf{x}_{s1}$ 으로 한다. 그 후 두 번째부터의 특징 데이터의 선택은 전체 데이터에서  $\mathbf{x}_{s1}$ 을 제외한 나머지  $N-1$ 개의 데이터를 대상으로 특징 데이터를  $\{\mathbf{x}_{s1}, \mathbf{x}_j\}$ ,  $j=1, \dots, (N-1)$ 로 한 경우에 대한  $J_S$  값을 각각 계산하고, 이들  $J_S$  값 중 최대  $J_S$  값을 생성하는  $\mathbf{x}_j$ 를 다음의 특징 데이터  $\mathbf{x}_{s2}$ 로 선택한다. 요구되는 수량의 나머지 특징 데이터는 이상과 같은 과정을 반복적으로 수행함으로써  $M$ 개의 특징 데이터가 선택될 수 있게 된다.

### 3. 동절기 난방부하의 모델링

#### 3.1 측정 데이터

지역난방을 사용하는 공동주택 동절기 난방부하의 모델링을 위하여, 2012년 12월 1일부터 2013년 2월 28일까지 12주 동안 경기도 남부에 위치하는 신도시지역의 5개 공동주택 12개 난방열 교환기에서 총 23,856개의 난방열 사용 데이터를 표 1에서와 수집하였다.

Fig. 1, Fig. 2 그리고 Fig. 3은 측정된 23,856개의 단위면적당 난방열 사용량 데이터 중의 일부로서, 각각 소형(난방 면적 80  $m^2$  미만), 중형(난방 면적 80  $m^2$  ~ 100  $m^2$ ) 그리고 대형(난방 면적 100  $m^2$  이상) 공동주택의 동절기 난방열 사용 패턴을 보여주기 위한 것이다. 그림에서와 같이 공동주택의 난방열 사용 패턴은 일주일 단위를 주기로 유사한 형태 갖는다. 그러나 실제적 난방열 사용량은 공동주택의 형태, 계절의 변화(외기 온도 변화), 저층, 중층, 고층과 같은 사용자 위치 등에 따라 크게 다르며, 특히 비록 유사한 형태(면적)를 갖는 공동주택의 경우라 하더라도 해당 난방열 교환기에 연결되어 있는 사용자들의 난방열 사용 행태에 따라 큰 차이를 보이고 있다. 바꾸어 말해서 공동주택의 실

Table 1 Number of data collected for modeling

Size	Heat exchanger ID	Total heating area(m <sup>2</sup> )	Average heating area(m <sup>2</sup> )	Number of data
Small	SA S1	12,930.22	55.725	2,016
	SA S2	15,173.06	49.415	2,016
	SB lower level	14,122.911	69.017	2,016
	SB upper level	11,170.216	68.996	2,016
Middle	MA	22,786.12	95.74	2,016
	MB lower level	27,644.104	96.737	2,016
	MB middle level	27,155.56	96.72	2,016
	MB upper level	16,264.232	96.737	1,680
Large	LA lower level	21,620.25	121.77	2,016
	LA upper level	14,298.06	121.77	2,016
	LB lower level	12,930.32	166.41	2,016
	LB upper level	11,010.38	166.41	2,016

제적 난방열 사용량은 Fig. 1과 Fig. 3에서와 같이 고층에 거주하는 사용자들의 열사용량이 저층에 거주하는 사용자들보다 일반적으로 많다. 그러나 Fig. 2의 중형 공동주택의 경우에서와 같이 고층, 중층, 저층 거주자의 실제 열사용량의 차이가 그리 크지 않은 경우도 있으며, 또한 Fig. 1의 소형 공동주택인 경우에서와 같이 공동주택의 형태(난방면적)가 유사함에도 불구하고 해당 열교환기에 연결되어 있는 사용자들의 난방열 사용행태에 따라 실제 열사용량에서는 대단히 큰 차이를 보이기도 한다.

### 3.2 모델링 데이터 및 입력데이터 벡터

대단히 비선형적으로 변화하는 데이터의 모델링에서, 해당 데이터가 가지고 있는 특성을 충분히 반영하면서도 동시에 연산의 용이성을 고려하는 수준의 데이터 수량을 결정하는 것은 쉽지 않은 문제이다. 그러나 참고문헌<sup>(21)</sup>에 따르면 측정된 데이터가 갖는 비선형성이 대단히 큰 경우, 모델링에서 사용되는 데이터의 수가 증가함에 따라 모델의 예측정도가 향상되기는 하나 한계점이 존재한다. 이는 모델링에서 사용되는 데이터의 수가 증가함에 따라 식(2) 또는 식(13)의 모델 오차들이 정규분포로부터 크게 벗어나는 데이터의 수가 증가하게 되고 따라서 LS-SVM에 의한 모델링의 일반화 성능이 떨어지는 결과가 초래되기 때문이다.

본 연구에서는 동절기 12주 동안 측정된 23,856개의 난방열 측정 데이터 중에서 11,928개의 데이터를 모델링을 위한 데이터로 사용하고, 나머지 11,928개의 데이터를 형성된 모델의 예측 정확도를 확인하기 위한 시




Fig. 1 Small size apartment heating energy usage (2012. 12. 10~2012. 12. 26).

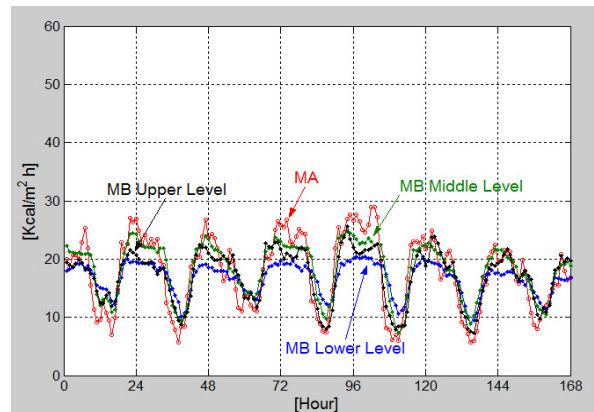


Fig. 2 Middle size apartment heating energy usage (2013. 1. 14~2013. 1. 20).

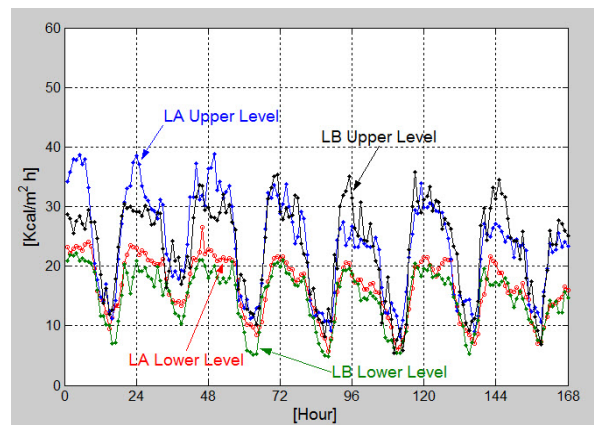


Fig. 3 Large size apartment heating energy usage (2012. 12. 31~2013. 1. 6).

험 데이터로 사용하였다. 동시에 측정된 전체 난방열 사용 데이터의 1/2에 해당되는 11,928개의 데이터들을 모

모델링을 위한 데이터로 사용하는 경우에도, 비록 모델링을 위한 데이터의 수가 전체 데이터의 절반에 해당되기는 하나 여전히 너무 많으며, 따라서 연산 과정의 문제점들을 고려하여 Reduced LS-SVM에 의한 난방열 사용량 및 사용 패턴의 모델링을 수행하였다.

동절기 난방부하의 모델링에서의 입력 데이터 벡터를 구성하기 위하여, 공동주택의 난방열 사용량 및 사용 패턴에 영향을 미치는 인자들을 Fig. 1~Fig. 3을 통하여 살펴보면, 계절 및 시간의 변화를 표시하는 월(month), 일(day), 시간(hour), 그리고 외기온도, 난방면적, 저층, 중층, 고층과 같은 사용자의 위치 마지막으로 난방열 사용량에 대, 중, 소와 같이 정성적으로 분류한 사용자 난방열 사용 행태 등과 같은 것들이 동절기 난방열 사용량에 영향을 미치는 인자들이 될 수 있음을 볼 수 있다. 이에 본 연구에서는 난방부하의 모델링을 위하여 아래의 식(22)에서와 같은 42개의 요소를 갖는 벡터를 구성하여 이를 입력데이터 벡터로 사용하였다.

$$\mathbf{x}_i = [\mathbf{M}, \mathbf{W}, \mathbf{H}, T_A, A, \mathbf{L}, \mathbf{U}] (42 \times 1), i = 1, \dots, 11928 \quad (22)$$

$$\begin{aligned} \mathbf{M} &\in R^3, \mathbf{W} \in R^7, \mathbf{H} \in R^{24} \\ T_A &\in R^1, A \in R^1, \mathbf{L} \in R^3, \mathbf{U} \in R^3 \end{aligned}$$

식(22)의  $\mathbf{M} = [0 \ 1 \ 0] (3 \times 1)$ 은 데이터의 측정 월(month)을 표시하는 벡터로서, 만약 데이터가 12월에 측정된 것일 경우  $[1 \ 0 \ 0]$ 로, 1월에 측정된 데이터의 경우  $[0 \ 1 \ 0]$ 로 표시되는 벡터이다.  $\mathbf{M}$ 과 유사하게  $\mathbf{W} = [0 \ \dots \ 1 \ 0] (7 \times 1)$ 은 요일(week)을 표시하는 벡터로서 7개의 요소를 가지고 있으며, 해당 요일의 요소를 1로 그리고 나머지 요소들을 0으로 하는 벡터이다. 시간(hour)을 표시하는 벡터  $\mathbf{H} = [0 \ \dots \ 1 \ 0 \ \dots] (24 \times 1)$ 은 하루 중의 시간을 표시하기 위한 벡터로서 24개의 요소를 가지고 있으며, 저층( $[1 \ 0 \ 0]$ ), 중층( $[0 \ 1 \ 0]$ ) 그리고 고층( $[0 \ 0 \ 1]$ )과 같은 사용자의 위치를 표시하는  $\mathbf{L} (3 \times 1)$  벡터는 3개의 요소를, 마지막으로 사용자의 난방열 사용 행태를 대( $[0 \ 0 \ 1]$ ), 중( $[0 \ 1 \ 0]$ ), 소( $[1 \ 0 \ 0]$ )와 같은 정성적 량으로 표시하기 위한  $\mathbf{U} (3 \times 1)$  벡터 역시 3개의 요소를 가지고 있다. 식(22)의  $T_A$ 는 외기 온도를 나타내는 것으로 식(23)에서와 같이 정의되는 값이며,  $A$ 는 해당 공동 주택의 난방면적을 표시하는 값이다.

$$T_A = 20 - (\text{Measured Ambient Temperature}) \quad (23)$$

### 3.3 커널함수(Kernel Function)

입력공간으로부터 특징공간(feature space)으로의 상을 수행하는 비선형 기저함수  $\varphi(\mathbf{x})$ 의 내적(inner pro-

duct)으로 정의되는 양한정의 특성을 갖는 커널함수  $K(\mathbf{x}_i, \mathbf{x}_j)$ 는, 시그모이드 함수 또는 가우시안 원형기준 함수(Gaussian radial basis function, RBF)와 같은 형태의 함수로부터 Mercer의 이론을 충족하는 여러 개의 파라미터를 갖는 많은 종류의 함수들이 존재한다. 그러나 선행연구 결과<sup>(6)</sup>에 의하면, 많은 파라미터를 갖는 커널함수는 일반적으로 데이터의 과대적합(over fitting)을 유발하고 따라서 모델의 예측 정확도와 관련 있는 모델의 일반화의 오류를 높이는 현상을 유발시킨다.

본 연구에서는 난방열 사용량과 같은 비선형성이 대단히 강한 데이터의 모델링을 위하여 참고 문헌에서 알려진 것과 같이 일반화의 오류를 최대한 적게 만드는 식(24)로 표시되는 가우시안 원형기준 함수를 커널 함수로 사용하였다.

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}\right) \quad (24)$$

식(24)의  $\sigma$ (RBF tuning parameter)는 원형기준 함수의 반경을 결정하기 위한 상수로서, 식(3) 또는 식(14)의 최적화 과정에서 도입된  $\gamma$ 와 함께 모델링 과정의 모델 탐색에서 결정되어 질 상수이다.

### 3.4 특징데이터

Reduced LS-SVM에 의한 난방부하의 모델링은, 모델링에 사용되는 11,928개의 데이터로부터 충분히 작은 수량의 특징 데이터를 선택하는 것을 필요로 한다. 본 연구에서는 11,928개의 데이터로부터 1,008개의 데이터를 선택하여 이들을 특징 데이터로 하였다. 이는 1,008개의 데이터가 전체 11,928개의 데이터와 비교하여 수량적 측면에서 충분히 작으면서도 동시에 측정된 데이터의 특성을 충실하게 반영할 수 있는 충분한 큰 규모로 간주되었기 때문이다.

1,008개의 특징 데이터의 선택은 제 2.4절에서 기술된 것과 같은 과정에 따라 수행되었다. 즉 본 연구에서는 11,928개의 데이터로부터 식(21)에서 정의된  $J_s$ 를 최대로 하는 입력 데이터를 순차적으로 선별하여, 선택된 수량이 1,008에 도달될 때까지 반복함으로서 1,008개의 특징 데이터를 선택하였다.

### 3.5 모델 탐색(Model Search)

모델 탐색은 Reduced LS-SVM 기반의 모델링에서 사용되는 두 개의 파라미터 ( $\sigma, \gamma$ )를 결정하는 과정이다. 현재 사용되고 있는 모델 탐색의 가장 보편적인 방법은, 모델링에 사용되는 데이터를 일정한 수량으로 균



등 분배하고, 이들 분배된 데이터의 한 등분을 제외한 나머지 데이터를 모델링을 위한 데이터로 하여 형성되는 모델들이 각각 남겨진 한 등분 데이터들에 대한 평균회귀오차들을 최소화시키는 값으로 선택하는 교차 확인법(cross validation method)<sup>(22, 23)</sup>이다.

본 연구에서는 교차확인법에 의한 모델 탐색을 위하여, 모델링을 위한 11,928개의 데이터에서 특징 데이터로 선택된 1,008개의 데이터가 제외된 10,920개의 데이터를 10개의 그룹으로 나누고, 따라서 각각 9,828개의 데이터를 모델링을 위한 데이터로 하는 10개의 개별 모델을 형성하여 이들 개별 모델들이 개별 모델링에서 남겨진 각각의 1,092개의 데이터에 대해 갖는 평균회귀오차들을 식(25)에서와 같이 계산하였다.

$$E = \sum_{i=1}^{10} \left[ \frac{1}{1092} \sum_{j=1}^{1092} |y_{ij} - \hat{y}_{ij}| \right] \quad (25)$$

식(25)의  $y_{ij}$ 는  $i$ 번째 모델링에서 남겨진 그룹의  $j$ 번째 실제 측정된 난방열 사용량이며,  $\hat{y}_{ij}$ 는  $i$ 번째 형성된 모델을 사용하여  $i$ 번째 모델링에서 남겨진 그룹의  $j$ 번째 측정 데이터를 예측한 값이다.

교차확인법에 의한 모델 탐색은 또한 식(25)에 의하여 계산된 평균 회귀오차의 최소값을 제공하는 파라미터의 탐색 구간 설정을 필요로 한다. 바꾸어 말해서 교차확

인법에서는 탐색되는 파라미터의 탐색 범위를 결정하는 것이 필요하며, 본 연구에서는 파라미터( $\sigma$ ,  $\gamma$ )에 대하여 각각 식(26)에서와 같은 구간에서 Fig. 4에서와 같은 격자 탐색(grid search)을 수행함으로써 각각의 파라미터를 식(27)에서와 같이 결정하였다.

$$0.1 \leq \sigma \leq 5, 1 \leq \gamma \leq 1000 \quad (26)$$

$$\sigma = 3.1, \gamma = 976.0 \quad (27)$$

### 3.6 모델 예측 성능 평가

1,008개의 특징데이터를 포함하여 총 11,928개의 난방열 사용량을 모델링을 위한 데이터로 사용하여 형성한 Reduced LS-SVM 기반의 동절기 난방부하 모델의 예측 정확도를 평가하기 위하여, 실제 측정된 데이터 중에서 모델링에 사용되지 않은 11,928개의 시험 데이터를 대상으로 식(28)과 식(29)와 같은 예측오차의 평균절대값오차(MAE, mean absolute error)와 평균절대비율오차(MAPE, mean absolute percentage error)를 계산하였다.

$$MAE = \frac{1}{11928} \sum_{i=1}^{11928} \left| y_i - \left[ \sum_{j=1}^{1008} \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right] \right| \quad (28)$$

$$= 2.86 [Kcal/m^2h]$$


$$MAPE = \frac{100}{11928} \sum_{i=1}^{11928} \left| \frac{y_i - \left[ \sum_{j=1}^{1008} \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right]}{y_i} \right| \quad (29)$$

$$= 15.93\%$$


식(28)과 식(29)의  $y_i$ 와  $\mathbf{x}_i$ 는 각각  $i$ 번째 시험 데이터의 열사용량 및 입력 데이터 벡터를 나타내며,  $\mathbf{x}_j$ 는  $j$ 번째 특징데이터 벡터이고,  $\alpha_j$ 와  $b$ 는 각각 식(15)에 의하여 얻어진  $j$ 번째 Lagrange multiplier와 바이어스 상수이다.

식(28)과 식(29)는 Reduced LS-SVM를 기반으로 수립된 난방부하 모델이 본 연구에서 사용된 시험 데이터에 대하여 평균 16% 이내의 오차를 갖는 예측 정확도를 가지고 있다는 것을 보여준다. 이와 같은 수치는, 비록 현재 수립된 모델의 예측 정확도가 향후 향상될 필요성이 있음을 나타내는 것이기도 하나, 그럼에도 불구하고 난방열 사용량 및 사용 패턴이 Fig. 1~Fig. 3에서와 같이 대단히 비선형적으로 변화하는 시스템임을 고려하면 본 연구에서 수립된 모델이 비교적 정확한 예측 정도를 갖는 모델임을 나타내고 있는 것으로 받아들여질 수 있는 수치이다.

Fig. 5, Fig. 6 그리고 Fig. 7은 각각 소형, 중형 그리고 대형 공동주택의 난방부하 모델의 예측 정확도를 보여



(a) Course search



(b) Fine search

Fig. 4 Model search.



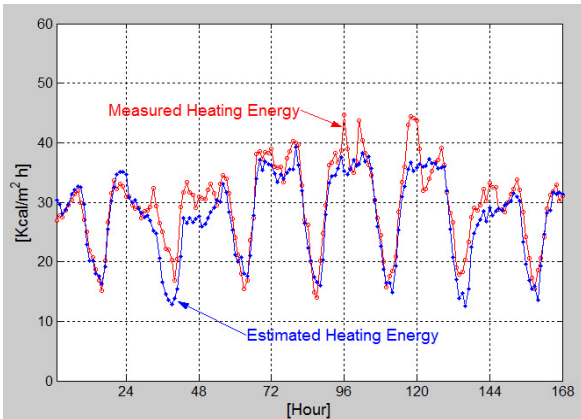


Fig. 5 Estimation of heating energy usage for small size apartment SB Upper Level(2012. 12. 31 ~2013. 1. 6).

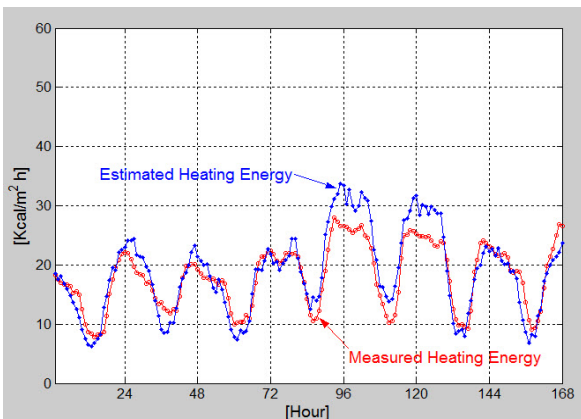


Fig. 6 Estimation of heating energy usage for middle size apartment MB Middle Level (2013. 2. 4~2013. 2. 10).

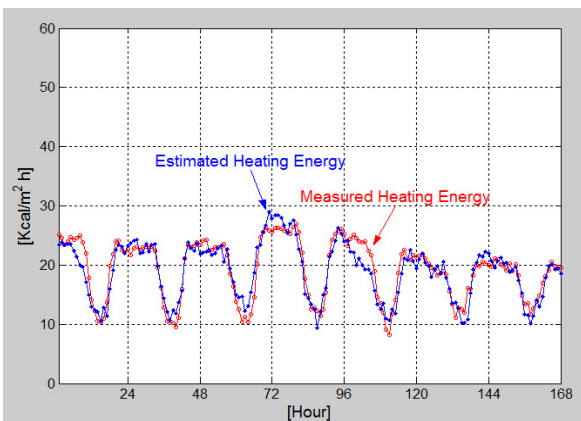


Fig. 7 Estimation of heating energy usage for large size apartment LA Lower Level (2013. 1. 7~2013. 1. 13).

주기 위한 것이다. 그림에서와 같이, 예측하고자 하는 공동주택의 난방열 사용량 및 사용 패턴이, 해당 공동주택과 유사한 형태(면적)를 갖는 공동주택들의 평균 사용량에 근접하고 있는 경우, 그와 같은 공동주택에 대한 예측된 난방부하는 실제 측정된 난방부하와 대단히 잘 일치하고 있다.

#### 4. 결 론

본 연구는 국내 공동주택 동절기 난방부하 수요 예측에 사용될 모델 구축을 위한 일련의 연구의 첫 단계 결과로서, 경기도 남부 신도시지역에 위치하는 5개 공동주택 12개 난방열 교환기에서 동절기 12주 동안 측정된 난방열 사용량을 Reduced LS-SVM을 사용하여 모델링하고, 수립된 모델의 예측 정확도를 해당 지역에서 측정된 데이터와 비교 분석한 것이다.

본 연구에서 얻어진 결과는 다음과 같다.

- (1) Reduced LS-SVM 기반의 난방부하 모델은 동절기 공동주택의 난방열 사용량 및 사용 패턴을 추론하기 위한 모델로 사용될 수 있다.
- (2) 본 연구에서 수립된 난방부하 모델은 측정된 시험 데이터에 대하여 평균 16% 이내의 오차를 갖는 예측 정확도를 가지고 있다.

난방부하 변화의 비선형성과 불확실성을 고려하면 본 연구에서 수립된 모델은 비록 완전하지는 못하나 활용 가능한 수준의 것으로 받아들여질 수 있다. 그럼에도 불구하고 예측 정확도를 높이기 위한 추가적 노력이 필요한 것은 명백하며, 따라서 현재 예측 정확도가 향상된 모델의 수립을 위한 추가적 연구가 진행되고 있다.

동시에 본 연구에서 제시된 난방열 사용량 모델은 특정 지역의 열사용량 데이터를 기반으로 하며, 따라서 해당 지역에서의 수요 예측을 위한 모델로 사용되는 것이 합당할 것으로 보인다. 이는, 바꾸어 말해서, 본 연구에서 수립된 모델의 기타 지역에서의 사용에 대한 제한이 있을 수 있으며, 따라서 지역 특성이 다른 타 지역에서의 난방열사용량 예측 모델은 해당 지역에서 측정된 열사용량 데이터를 사용하여 본 연구에서와 동일한 형태의 독립된 모델을 구축하는 것이 필요할 것으로 보인다.

추가적으로 본 연구가 궁극적으로 지향하고 있는 지역 특성이 포함된 공동주택의 동절기 열사용량 예측 모델의 수립을 위하여, 이미 보유하고 있는 경기 북부 신도시 지역 및 서울 지역의 난방부하 측정 데이터를 모델링에 포함시키는 연구를 현재 진행하고 있다.

## 후 기

이 연구는 서울과학기술대학교 교내연구비의 지원으로 수행되었습니다(2014-1588).

## References

1. Werner, S. E., 1984, The heat load in district heating systems, Ph. D. Thesis, Chalmers University of Technology, Sweden.
2. Heller, A. J., 2002, Heat load modeling for large systems, *Applied Energy*, Vol. 72, pp. 371-387.
3. Koive, T. A. and Toode, A., 2006, Trends in domestic hot water consumption in Estonian apartment building, *Proc. Estonian Academy of Science Engineering*, Vol. 12, No. 1, pp. 72-80.
4. Evarts, J. C. and Swan, L. G., 2013, Domestic hot water consumption estimates for solar heating thermal sizing, *Energy and Buildings*, Vol. 58, pp. 58-65.
5. Suykens, J. A. K., 2002, Least square support vector machine, Singapore, World Science Pub.
6. Suykens, J. A. K. et al., 2002, Weighted least squares support vector machines : robustness and space approximation, *Neurocomputing*, Vol. 48, pp. 85-105.
7. Kuh, A. and Wilde, P. D., 2007, Comments on pruning error minimization in least squares support vector machines, *IEEE Trans. on Neural Networks*, Vol. 18, No. 2, pp. 606-609.
8. Gavin, C. et al., 2002, Improved sparse least squares support vector machines, *Neurocomputing*, Vol. 48, pp. 1025-1031.
9. Vapnik, V., 1995, *The Nature of Statistical Learning Theory*, Springer.
10. Jang, S. J. et al., 2007, Sustained vowel modeling using nonlinear autoregressive method based on least squares-support vector regression, *Journal of Korean Institute of Intelligent System*, Vol. 17, No. 7, pp. 957-963.
11. Espinoza, M. et al., 2007, Electric load forecasting, *IEEE Control System Magazine*, October, pp. 43-57.
12. Xi, X. C., Poo, A. N., and Chou, S. K., 2007, Support vector regression model control on a HVAC plant, *Control Engineering Practices*, Vol. 15, pp. 897-908.
13. Kang, Y. W. et al., 2008, Dynamic temperature modeling of an SOFC using least squares support vector machines, *Journal of Power Sources*, Vol. 179, pp. 683-692.
14. Esen, H. et al., 2009, Modeling of a new solar air heater through least square support vector machines, *Expert Systems with Applications*, Vol. 36, pp. 10673-10682.
15. Haijiun, T. and Jingru, W., 2012, Modeling of power plant superheated steam temperature based on least square support vector machines, *Energy Procedia*, Vol. 17, pp. 61-67.
16. Falck, T. et al., 2012, Least squares support vector machines for the identification of Wiener-Hammersstein systems, *Control Engineering Practice*, Vol. 20, pp. 1165-1174.
17. Zeng, J. and Qiao, W., 2013, Short term solar power prediction using a support vector machine, *Rewable Energy*, Vol. 52, pp. 118-127.
18. Li, L. J., Su, H. Y., and Chu, J., 2007, Generalized predictive control with online least squares support vector machines, *Acta Automatica Sinica* Vol. 33 No. 11, pp. 1182-1188.
19. Zhao, Y. P. and Sun, J. G., 2009, Recursive reduced least squares support vector regression, *Pattern Recognition*, Vol. 42, pp. 837-842.
20. Brabanter, K. D. et al., 2010, Optimized fixed size kernel models for large data sets, *Computational Statistics and Data Analysis*, Vol. 54, pp. 1484-1504.
21. Baudat, G. and Anouar, F., 2003, Feature vector selection and projection using kernels, *Neurocomputing*, Vol. 55, pp. 21-38.
22. Cawley, G. C. and Talbot, N. C. L., 2004, Fast exact leave-one-out cross-validation of sparse least squares support vector machines, *Neural Networks*, Vol. 17, pp. 1467-1475.
23. An, S., Liu, W., and Venkatesh, S., 2007, Fast cross validation algorithms for least squares support vector machines and kernel ridge regression, *Pattern Recognition*, Vol. 40, pp. 2154-2162.