Journal of KIAEBS Vol.12, No.6, December pp. 579-590

RESEARCH ARTICLE

SVDD를 활용한 상업용 건물에너지 소비패턴의 이상현상 감지

채영태*

청주대학교 공과대학 휴먼환경디자인학부 건축공학전공

Anomaly Detection and Diagnostics (ADD) Based on Support Vector Data Description (SVDD) for Energy Consumption in Commercial Building

Chae, Young-Tae*

Department of Architectural Engineering, School of Engineering, Cheongju University, Cheongju, Korea

***Corresponding author:** Chae, Young-Tae, Tel: +82-43-229-8479, E-mail: ychae@cju.ac.kr

ABSTRACT

Anomaly detection on building energy consumption has been regarded as an effective tool to reduce energy saving on building operation and maintenance. However, it requires energy model and FDD expert for quantitative model approach or large amount of training data for qualitative/history data approach. Both method needs additional time and labors. This study propose a machine learning and data science approach to define faulty conditions on hourly building energy consumption with reducing data amount and input requirement. It suggests an application of Support Vector Data Description (SVDD) method on training normal condition of hourly building energy consumption incorporated with hourly outdoor air temperature and time integer in a week, 168 data points and identifying hourly abnormal condition in the next day. The result shows the developed model has a better performance when the ν (probability of error in the training set) is 0.05 and γ (radius of hyper plane) 0.2. The model accuracy to identify anomaly operation ranges from 70% (10% increase anomaly) to 95% (20% decrease anomaly) for daily total (24 hours) and from 80% (10% decrease anomaly) to 10%(15% increase anomaly) for occupied hours, respectively.

주요어 : 건물에너지, 이상현상감지, 서포트 벡터 머신, 비감시 기계학습

Keywords: Building energy consumption, Anomaly detection, Support vector data description (SVDD), Unsupervised machine learning

OPEN ACCESS

Journal of KIAEBS 2018 December, 12(6): 579-590
https://doi.org/10.22696/jkiaebs.20180048

pISSN : 1976-6483
eISSN : 2586-0666

Received: October 31, 2018
Revised: December 7, 2018
Accepted: December 7, 2018

Ⓒ 2018 Korean Institute of Architectural Sustainable Environment and Building Systems.

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/4.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

서 론

우리나라의 국가 총 에너지 소비량의 약 20%가 건물부문(가정, 상업, 공공)에서 소비되고 있으며, 온실가스 발생량의 23%를 건물부분에서 차지하고 있어(한국에너지단, 2017) 이를 절감하려는 노력이 지속되고 있다. 신축건물의 경우 설계단계 및 운영유지관리 계획에 따라 에너지 절감에 대한 단계적이고 구체적인 접근이 가능하나, 기존건물의 경우 건물의 에너지 성능을 평가를 통해 성능저하를 방지하거나 운영효율을 향상시키는 구체적인 실행수단이 제한적이다.

기존 건물의 건물에너지 소비량 중 약 1%에서 2.5%가 장비의 오작동 및 이상현상에 의해서 발생하는 것으로 조사되고 있으며(Wiggins and Brodrick, 2012), 기계설비 및 건물 전체 에너지 소비량의 이상현상 감지는 건물의 운영과 유지관리에 소요되는 에너지 소비량을 효과적으로 줄일 수 있는 것으로 나타났다(Liu et al., 2002; Bynum, et al., 2012). 하지만, 건물 운영 및 에너지 소비요소의 복잡성으로 인해 건물에너지 소비패턴의 적성성과 비적정성을 정확하게 구별하고 제시하여 건물운영주체가 적절한 의사결정을 유도하는 것은 어려운 현실이다. 이러한 제약조건을 극복하기 위하여 다양한 형태의 건물에너지 이상현상 감지 및 분석 방법들이 개발되고 적용되고 있다(Katipamula and Brambley, 2005).

정밀모델에 기초한 이상현상 감지기법은 건물구조체와 설비에 대한 자세한 시뮬레이션 모델을 제작하고, 이를 통해 건물의 정상운전조건에서의 각 요소별 운전특성에 대한 정상/비정상 지표를 산출한다. 실제 건물운전에서 발생하는 데이터를 모델에서 작성된 데이터와 비교분석하여 정상/비정상 상태에 대한 결과를 출력하는 과정을 거친다. 정밀성이 높고 정상/비정상 판별에 대해 간략하지만 다양한 수식(Rule-based)을 통해 신속히 결과를 산출할 수 있는 장점이 있는 반면, 건물에너지 모델과 이상현상 판별을 위해 숙련된 전문가가 필요하고 각 건물 및 장비별로 모델 구현을 위한 추가적인 비용과 시간이 투입되어야 한다(Xu et al., 2005).

정성모델 또는 과거 데이터 분석기법은 특정기간 또는 장기간에 걸친 건물 및 설비 시스템의 운전자료를 분석하여 정상상태와 이상상태의 판별경계를 통계적 처리방법 또는 기계학습을 활용(Najafi et al., 2012)하여 작성한다. 이후 운전에 있어서 이러한 판별경계를 벗어나는 경우 이상현상으로 감지하여 출력하게 된다. 해당 모델의 경우 개별 건물 또는 장비별로 물리적인 모델을 구축할 필요가 없고, 에너지 모델 및 이상현상 판별에 대한 전문가의 개입이 낮아 일반화가 쉬운 이점을 가지고 있지만, 모델의 신뢰성을 확보하기 위하여 상당히 많은 현장 데이터가 필요하며, 이상현상을 감지하고 하는 대상의 데이터 확보를 위해 추가적인 센서나 미터의 설치와 함께, 데이터의 누락과 멸실에 대한 처리가 필요한 단점이 있다. 최근 데이터 공학 및 기계학습 기술의 발달로 비교적 적은 양의 데이터로도 학습성능과 응답특성을 향상시키는 연구가 진행되고 있다(Rowe et al., 2011).

본 연구는 대다수의 상업용 건물에서 취득이 가능한 시간별 건물에너지 소비량, 외기온, 그리고 시각이라는 최소 데이터를 활용하여 건물에너지 소비패턴의 이상현상을 감지할 수 있는 기법을 제안한다. 최근 건물분야에서 다양하게 활용되고 있는 기계학습방법을 활용하여, 건물에너지 소비패턴의 정상 및 비정상상태를 구분하고 검출하는 모델을 계획하고설정변수의 최적화 방안을 탐색한다. 개발된 모델에 대하여 특정일에 대한 에너지 소비량 이상현상의 발생시 응답특성과 검출성능을 평가하고자 한다.

연구방법

대상건물

에너지 소비패턴의 일반성, 구축된 모델에 대한 정량적인 평가를 위하여 미국 환경부(US EIA)가 조사하는 상업용 건물의 에너지사용량 조사에 근거한 미국 에너지부(DOE)의 중소

형 상업용 건물 표준모델을 활용하였다(Field et al., 2010). 해석 대상 건물은 3층 규모의 사무소 건물로, 외주부 4개소와 내주부 1개소로 1개층을 형성하고 있다. 창면적비는 0.33, 창호 및 외벽체의 열관류율은 국내의 에너지 절약계획서를 참고로 하여 변수를 조정하였다. 해석에 사용된 기상데이터는 인천지역의 표준기상년(Typical Meteorology Year : TMY)으로 8760시간에 대한 각 시간별 건물 전체 에너지 소비량 및 외기온도를 검출하였다. 해당 건물은 개별 보일러와 압축식 냉동기를 이용하는 중앙공조방식으로 VAV (Variable Air Volume) 공조기가 각 층에 설치되어 있으며, 5개의 실내 유닛(ATU:Air Terminal Unit)을 활용하여 설정온도를 제어한다. 대상건물의 기하학적 형상과 기본 운전조건 및 입력조건은 다음 Table 1과 Figure 1에 제시하였다.

Table 1. Input variables for benchmark model

Input Type	Variables
Building type	Medium sized office building
Conditioned Area	4082.204 ㎡
Internal load condition	People :18.58 ㎡/person Lighting: 10.76 W/㎡ Equipment: 10.76 W/㎡
Building Envelop*	Window SHGC : 0.583 Window U-value : 1.5 W/㎡·K Wall U-value : 0.240 W/㎡·K
HVAC	System: VAV with air terminal units (5 zone) Operating hours : 06:00~20:00 Indoor set point temperature : 20 ℃ for heating, 26 ℃ for cooling
Primary system	Boiler efficiency : 0.78 Electric Chiller COP: 3.4
Weather data	Inchoen TMY

* : National Standard in Republic of Korea

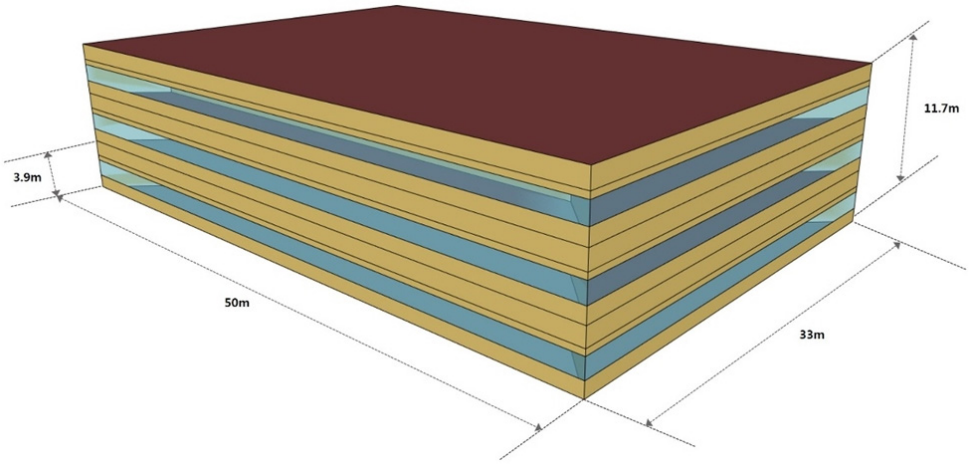

Figure 1. Geometry conditions of target building

SVDD 모델

건물에너지 소비패턴에 대한 이상현상을 판별자(Label)가 없어도 판독할 수 있도록 기계학습 알고리즘을 활용한 모델을 구축하였다. 학습데이터를 활용하여 새롭게 발생한 데이터의 신규성이나 정상/비정상 판별을 위해 일반적으로 One-class Support Vector Machine (SVM) (Hsu and Lin, 2002), Isolation Forest (Liu et al., 2008), Local Outlier Factor (Pokrajac, et al., 2007)등이 활용되고 있으며, 본 연구에서는 One-class SVM을 개량한 SVDD (Support Vector Data Description) (Liu et al., 2015) 알고리즘을 활용하여 모델을 구현한다.

One-class SVM은 비감시 학습(unsupervised learning)의 일종으로, 학습데이터 구간 내에 '정상'데이터가 '비정상'데이터 보다 월등히 많은 경우 특정된 '비정상'데이터를 추출하기에 적합한 구조를 이루고 있으며 건물에너지의 '비정상'패턴을 인식하는데 효과적이라고 할 수 있다. 관측 또는 학습 데이터(xi)가 $x_1, x_2, \cdots\cdots x_n, x_i \in R^N$ 이고, R→F의 피쳐맵(Feature map)을 비선형 형태의 경계면을 가지는 차원인 $\varnothing$로 정의하면, 각 입력치(x_i)에 따른 결과치 (y_i)가 이루는 공간내의 내적은 다음의 커널(kernel; k) 함수를 통해 계산할 수 있다.

$$k(x,y) = (\varnothing(x) \cdot \varnothing(y)) \tag{1}$$

각 데이터 포인트를 기준평면(Origin)에서 분리하고 초평면(hyper plane, *w*)의 최소거리를 계산하는 것이 본 알고리즘의 목적으로 One-class SVM은 다음의 식(2)와 식(3)과 같이 정의할 수 있다(Malisiewicz et al., 2011).

$$\min_{w,\xi_i,\rho} \frac{1}{2} \| w \|^2 + \frac{1}{\nu n} \sum_{i=1}^{n} \xi_i - \rho \tag{2}$$

$$s.t. (w \cdot \Phi(x_i)) \geq \rho - \xi_i, \xi_i \geq 0 \tag{3}$$

여기서 $\nu \in (0,1]$은 '비정상'조건에서의 결정계수(ν)로 활용하고, 슬랙변수(slack variables)인 ξ를 해당 목적함수의 패널티 값으로 활용하는 경우 *w*, ρ로 구성되는 결정함수(decision function)는 라그랑지언 계수(α_i)와 식 (1)을 활용하여 다음과 같이 구성할 수 있다 (Valavanis and Kosmopoulos, 2010).

$$f(x) = sgn((w \cdot \Phi(x)) - \rho) = sgn(\sum_i \alpha_i k(x_i, x) - \rho) \tag{4}$$

α_i값은 최적화 알고리즘인 QP (quadratic programming)을 통해 도출할 수 있으며, ρ값은 해당 공간내의 서포트 벡터를 적용시 식(4)의 함수가 0인 것을 이용하여 도출한다. 이러한 초평면(hyperplane)을 사용하는 One-class SVM을 입체형인 초구(hypersphere)로 활용하는

것이 SVDD (Support Vector Data Description)이다(Tax and Duin, 1999). SVDD는 다음 식 (5)로 나타낼 수 있으며,

$$max_{R,a}\, R^2 + C\sum_{i=1}^{n} \xi_i \quad (5)$$

$$\| x_i - a \|^2 \leq R^2 + \xi_i, \forall i = 1, \ldots, n \quad \xi_i \geq 0, \forall i = 1, \ldots, n \quad (6)$$

여기서 a는 구의 중심이고 R은 구의 반지름, C는 데이터와 형성된 경계면에 대한 보정상수를 나타낸다. 해당 최적화 문제의 해를 구하기 위해 라그랑지언 계수(α_i)를 도입하고 식(1)에 제시된 커널 함수를 Radial Based Function (RBF)로 적용하는 경우 즉, $k(x_i, x) = 1$를 만족하게 된다면 식 (4)를 활용하여 조건부 최적화 문제를 해석할 수 있다(Sanchez-Hernandez et al., 2007).

데이터 입력과 처리

건물에너지 시뮬레이션 결과에서 운전시간, 해당시간의 외기온도조건을 기준변수로 하여 시간별 건물 전체 전기 에너지 소비량을 입력 및 학습데이터로 활용한다. 다음 Figure 2는 표준기상데이터상에서 대상건물의 8월 3일에서 8월 11일중 주말을 제외한 주중 7일에 대한 외기온의 변화와 에너지 소비량을 나타낸다. 8월 12일은 모델검증을 위한 대상일로 정상시뮬레이션 결과와 각 시간별로 전기 에너지 소비량이 -25% 에서 +25%까지 5%씩 증감하는 이상현상조건을 발행시켜 모델의 응답특성을 확인하였다.

데이터의 각 피쳐가 가지는 실수값의 범위가 서로 다르기 때문에 다음 식(7)를 활용해 표준화(Standardization)를 수행하였으며, 결과(Z-score)를 활용하여 신규데이터와 학습모델간의 거리를 기하학적으로 분석할 수 있도록 하였다(Hazen et al., 2014).

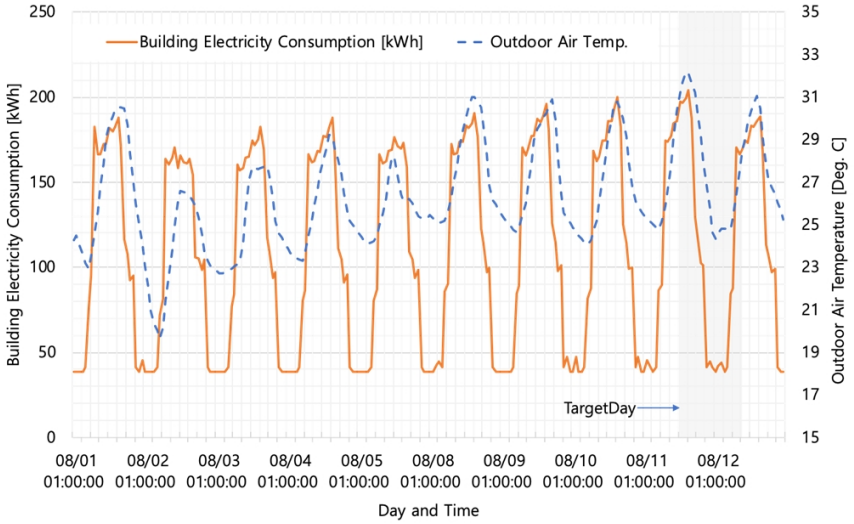

Figure 2. Hourly building electricity consumptions with outdoor air temperature variance in learning periods(8/1-8/11) and target day(8/12)

$$Z_i = X - \mu/\sigma \quad (7)$$

여기서, X는 관측 데이터이고, μ는 학습데이터내의 평균, σ는 학습데이터 내의 표준편차를 의미한다.

결과 및 토의

SVDD 모델 변수 도출

모델변수에 의한 영향도를 파악하기 위하여 식(2)에서 제시된 ν를 0.8에서 0.0001까지 즉, 주어진 학습데이터 내에서 잠정 오류도(ν)를 0.01%에서 80%로 변동하는 경우와 RBF커널 계수인 γ를 0.5에서 4.0으로 0.5씩 변동하는 경우에 대한 모델응답특성을 분석하였다. 학습데이터는 총 168개로, 70%의 데이터인 117개는 학습데이터(training data)로 활용하여 정상조건과 비정상조건을 구분하는 판결경계 (learned boundary) 학습에 사용한다. 30%의 데이터인 51개는 학습된 판결경계의 적정성을 시험하기 위한 검증 데이터(test data)로 활용한다. 검증대상일의 24개 데이터는 새로운 검증데이터(new normal data)로 해당 데이터의 95%이상이 판별경계내에 형성될 때를 최적 모델 조건으로 설정한다.

Figure 3과 Figure 4 는 정상상태 데이터를 기준으로 모델 변수의 변화가 모델의 정확도 즉 정상상태를 정상상태로 인식하는 학습결과 및 검증결과를 제시하고 있다. ν값이 상승할 수록 모델 학습에 사용되는 정상조건데이터의 일부가 판별경계 밖에서 형성되는 빈도가 높아지고, γ계수가 높아질수록 정상조건의 경계가 좁아지는 것으로 나타났다. 언급한 두개의 변수는 이상현상 감지모델의 민감도와 연관지어 설명할 수 있다. 즉, 학습데이터내의 오류가 포함될 가능성인 ν값을 증가시켜 학습데이터내의 자유도를 높이는 경우 정상상태의 데이터가 학습조건 밖에서 형성되는 비율이 높아지며, 정상조건에서의 판별경계 영역을 구획하는 γ값을 증가시켜 초평면 모델의 민감도를 높이는 경우 비정상데이터를 정상데이터와 잘 구별 할 수 있으나, 정상데이터 역시 비정상데이터로 판별할 확률이 높아지는 것으로 나타났다.

Figure 3 에서 나타난 바와 같이 건물의 전력소비량과 외기온의 상관성을 기준으로 전력소비량의 이상현상을 판별하는 경우, 외기온의 조건과 건물의 재실상황 및 운전조건에 따라 크게 세 영역으로 형성되며 ν값이 0.05, γ값이 2.0인 경우에 학습데이터의 99%, 검증데이터의 98%가 판별경계내에 형성되었으며, 대상일의 정상운전 데이터(new normal data) 전체가 판별경계내에 형성되어 정상상태로 인지한다.

건물의 운영시간과 전력소비량의 관계를 통한 이상현상 판별모델 경우, Figure 4 에서 제시된 바와 같이 건물의 전력소비량과 운전시간과의 관계는 크게 비재실시간, 재실시작 및 종료시간, 재실시간의 네 영역으로 형성하고 있다. 앞선 외기온 기준 평가모델과 유사하게 ν값이 0.05, γ값이 2.0인 경우에 학습데이터의 100%, 검증데이터의 100%가 판별경계내에 형성되었으며, 대상일의 정상운전 데이터(new normal data) 역시 전구간에서 정상상태 범주에 형성되는 것으로 나타났다.

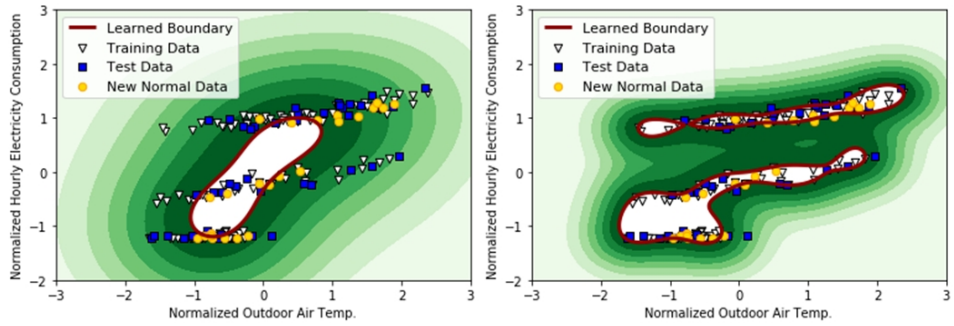

(a) ν=0.8, γ=0.5 (e) ν=0.05, γ=2.5

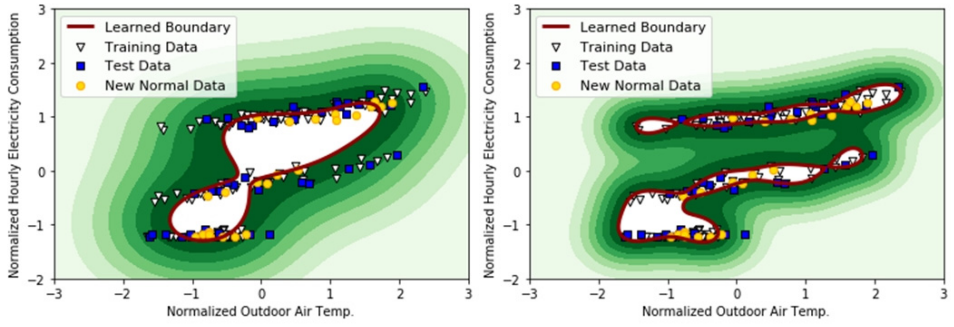

(b) ν=0.5, γ=1.0 (f) ν=0.01, γ=3.0

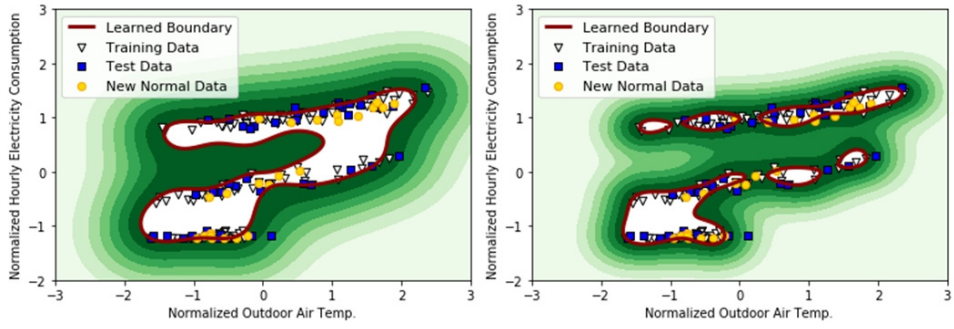

(c) ν=0.1, γ=1.5 (g) ν=0.001, γ=3.5

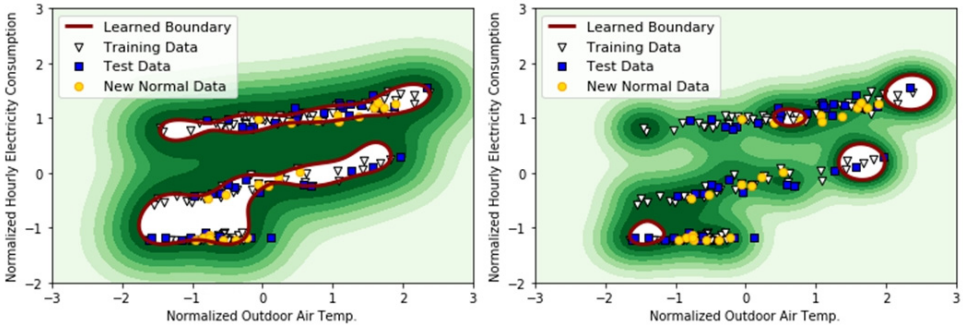

(d) ν=0.07, γ=2.0 (h) ν=0.0001, γ=4.0

Figure 3. Training and validation results of normal building electric consumption with normalized outdoor temperature conditions depends on ν and γ

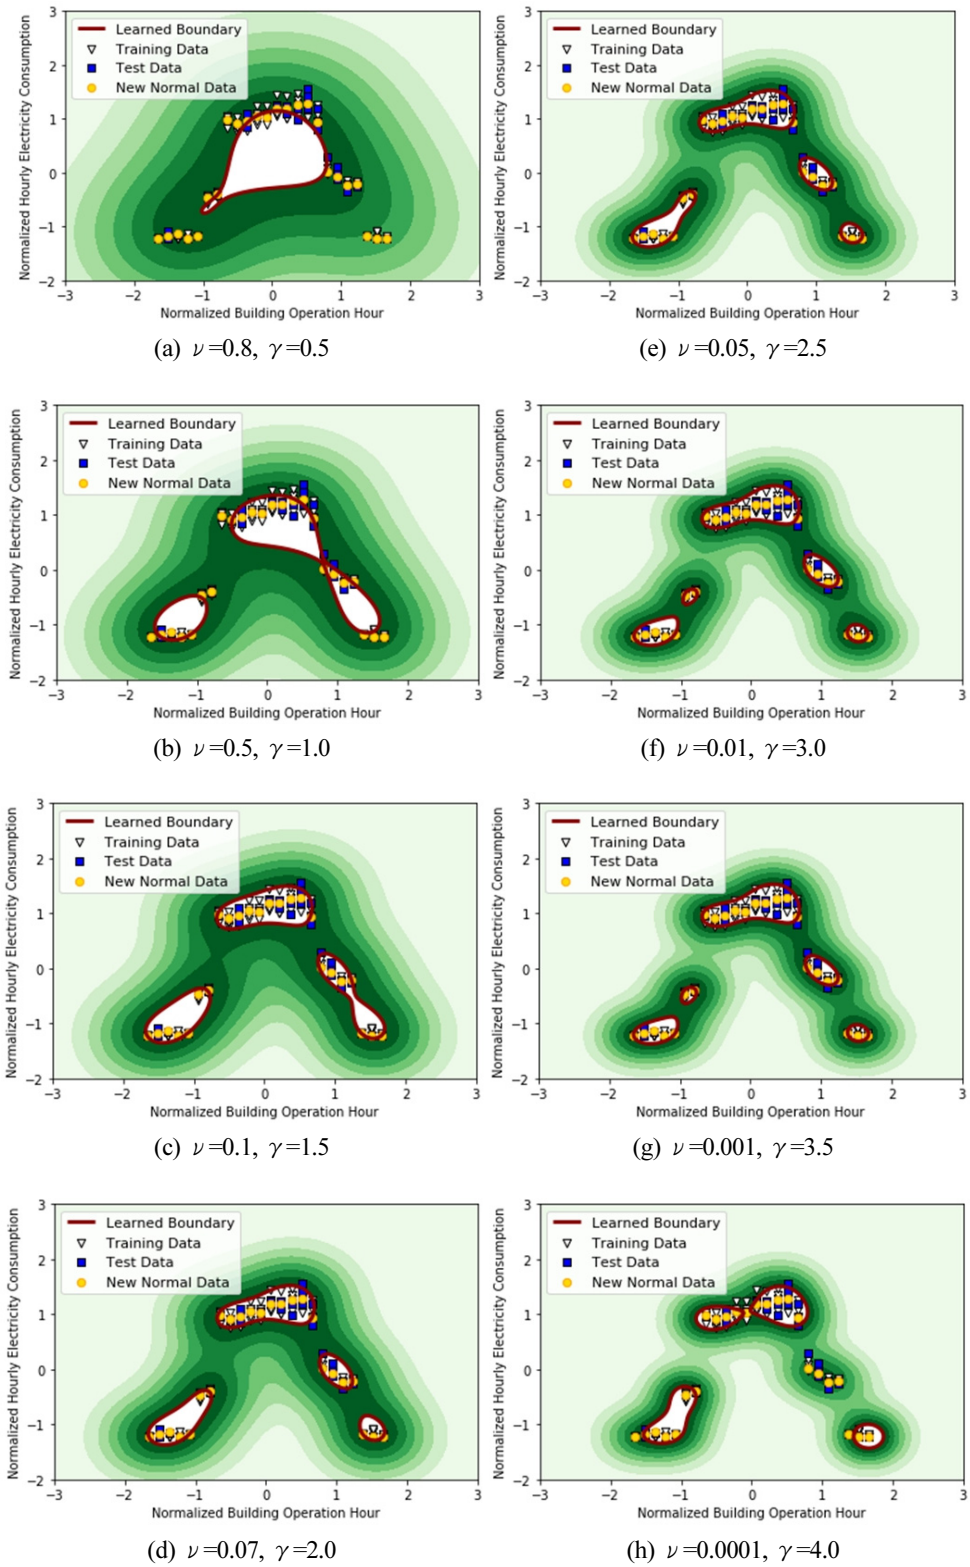

(a) ν=0.8, γ=0.5 (e) ν=0.05, γ=2.5

(b) ν=0.5, γ=1.0 (f) ν=0.01, γ=3.0

(c) ν=0.1, γ=1.5 (g) ν=0.001, γ=3.5

(d) ν=0.07, γ=2.0 (h) ν=0.0001, γ=4.0

Figure 4. Training and validation results of normal building electric consumption with normalized building operation hour depends on ν and γ in SVDD

이상현상 탐지 성능

대상일의 정상상태조건에서 매 시간별로 -20%에서 +20%까지 5%의 단계로 건물 전기에너지 소비량이 비정상적으로 증감하는 조건에 대한 개발모델의 이상현상 탐지 성능을 다음 Table 2에 제시하였다. 총 8가지 조건에 대하여 Figure 5와 같이 외기온 기준 또는 시간기준의 두 가지의 판별기준 중 하나 이상이 학습영역 밖으로 검출하는 경우 이상현상으로 판정하였다. SVDD 모델의 결정변수는 ν값이 0.05, γ값이 2.0으로 설정되었으며 대상일의 전일조건(24시간기준)과 공조시간 한정기준(6시에서 20시, 총 15시간)에 대한 판별성능을 분석하였다.

조명, 실내기기 또는 공조기의 고장 등의 다양한 원인에 따라 시간별 전기에너지 소비량이 정상보다 적은 경우, -5%의 조건에서는 재실시간 일부(9~13시)를 포함하여 이상현상을 감지하는 성공률이 전일기준 약 50%, 공조시간 기준 60%대로 나타났다. 정상상태 대비 -15%의 조건에서는 비재실시간인 3시, 공조개시시간인 6시를 제외하고 이상현상으로 감지하여, 전일기준 91%, 공조시간기준 93%의 탐지율을 나타났다. 정상상태대비 -20%의 조건에서는 공조개시시간인 오전 6시를 제외하고 모두 이상현상으로 탐지하며, 전일기준 96%, 공조시간기준 93%의 이상현상 탐지율을 확보할 수 있다.

공조기의 고장이나 수요측의 부하가 비정상적으로 크게 발생하여 시간별 전력에너지 소비량이 과대한 조건의 경우, +5%의 조건에서는 전일기준 약 37%, 공조시간기준 약 47%의 탐지율을 보이며, 동일한 수준에서 과소조건(-5%)에 비해 탐지성능이 낮아지는 것으로 나타났다. +10%의 조건에서는 전일기준 약 70%, 공조시간 기준 약 86%로 동일수준의 과소조건(-10%)에 비하여 공조시간내의 이상현상 검출성능은 높아지는 것으로 나타났다. +15%와 +20%의 경우 전일기준의 탐지율은 약 80%이며, 공조시간 기준 탐지율은 100%로 유사한 양상이 나타났다.

공조시간을 기준으로 과소조건 보다는 과대조건에서 탐지효율성이 높아지는 현상은 대상건물의 전력에너지 소비량의 적정성을 시각과 외기온을 이용하는 학습방법의 특성과 밀접하게 관련이 되어 있다. 학습영역을 형성하는 데이터들의 경계는 특정외기온과 시간에 대한 다수의 기존 전력에너지 소비량으로 구성되기 때문에 과소조건의 경우 일부 비정상상태가 학습영역내 공간에 위치하여 정상조건으로 해석하는 경우가 발생하나, 과대조건의 경우 학습영역 밖에서 형성되기 때문에 비정상조건으로 해석된다.

Table 2. Anomaly detection rate in daily total and occupied hours with different abnormal hourly energy consumption levels

Hourly anomaly in Elec. usage (Increase)	Daily total detection rate	Occupied period* detection rate	Hourly anomaly in Elec. usage (Decrease)	Daily total detection rate	Occupied period* detection rate
+5%	37.58%	46.67%	-5%	54.17%	60.00%
+10%	70.83%	86.67%	-10%	80.33%	80.00%
+15%	79.15%	100.00%	-15%	91.67%	93.33%
+20%	80.33%	100.00%	-20%	95.83%	93.33%

Occupied period* : HVAC operating hours 06:00~20:00

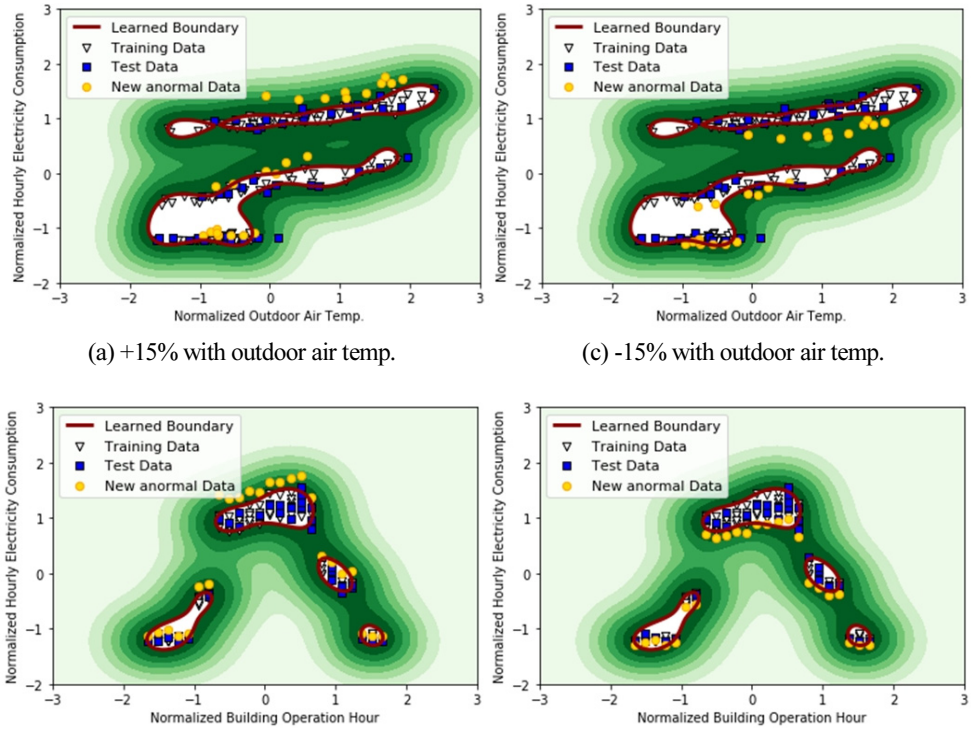

(a) +15% with outdoor air temp.

(c) -15% with outdoor air temp.

(b) +15% with hours

(d) -15% with hours

Figure 5. Anomaly detection results with different energy consumption levels

결 론

건물에너지 소비패턴의 이상현상을 실시간으로 분석하고 표시하는 것은 효과적인 건물에너지관리를 위한 중요한 도구이다. 구조체의 열응답특성과 설비의 기계적 에너지 소비량을 예측할 수 있는 물리모델을 활용한 방법, 건물의 에너지사용 고지서에 대한 통계처리를 통한 방법 등 다양한 접근방법이 시도되고 있으나, 건물별로 모델을 개발해야 하는 일반화에 대한 제약성, 오랜 기간에 대한 누적된 데이터의 필요성으로 인해 실제 건물에서 효과적으로 활용되기 어렵다.

본 연구는 중소형 상업 건물을 대상으로 최소한의 계측데이터(에너지소비량, 외기온도,시간)를 활용하여 시간별 건물에너지 소비의 정상상태와 비정상상태를 판별할 수 있는 데이터 기반의 이상 현상 판별 모델을 구축하고 그 성능을 평가하였다. 개발된 SVDD모델은 학습데이터의 잠정오류도(ν)가 5%, 초평면의 외부영역지수(γ)가 2.0인 입력조건에서 학습성능 및 이상현상 판별성능이 가장 우수한 것으로 나타났다. 이는 학습데이터 또는 정상상태 데이터가 개별적으로는 완전 하지만 모델내부에서의 일정한 영역을 형성하는 것은 추가적인 데이터 프로세싱의 필요성을 의미한다. 해당 모델을 활용하여 7일간의 정상상태에 대한 시간별 에너지 소비량데이터를 확보하는 경우, 연속하는 적용대상일의 재실시간 구간에 있어서 시간별 에너지 소비량이 정상상태 대비 15%이상 증가하거나 감소하는 이상현상이 발생하는 경우 93%이상 검출할 수 있는 것으로 나타났다. 건물에너지를 과소하게 사용하는 경우보다,

정상상태 대비 추가적으로 사용하는 경우의 탐지성능이 높은 것으로 나타나 비정상적인 수요증가에 대한 검출에 보다 효과적이라고 판단된다.

본 연구의 결과를 개선하고 실용성을 높이기 위한 추가적인 연구는 크게 두가지로 구분할 수 있다. 우선, 판별경계에서 벗어나는 이상현상에 대한 자동분석모델을 개발하고 판결경계에서 떨어진 거리에 따라 이상현상의 우선순위에 대한 연구 수행이 필요하다. 또한, 실제건물에 적용하는 경우 건물 사용유형에 따라 달라지는 에너지 소비패턴의 변동에 따른 설정변수의 탐색방법 및 모델응답특성에 대한 검토가 필요하며, 정상적인 에너지소비량의 변동을 이상상태로 잘못 평가할 수 있는 상황이 발생할 수 있기 때문에, 추가적인 판별자를 활용한 다차원 분석을 통해 진단성능의 정확도를 향상시킬 필요가 있다.

후 기

이 논문은 2017-2018 청주대학교 특별연구비로 수행한 연구임.

References

1. 한국에너지공단. (2017). 에너지통계핸드북.
2. Bynum, J.D., Claridge, D.E., Curtin, J.M. (2012). Development and testing of an automated building commissioning analysis tool (ABCAT). Energy and Buildings, 55, 607-617.
3. Field, K., Deru, M., Studer, D. (2010). Using DOE commercial reference buildings for simulation studies. Proceedings of SimBuild, 4(1), 85-93.
4. Hazen, B.T., Boone, C.A., Ezell, J.D., Jones-Farmer, L.A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. International Journal of Production Economics, 154, 72-80.
5. Hsu, C.W., Lin, C.J. (2002). A comparison of methods for multiclass support vector machines. IEEE transactions on Neural Networks, 13(2), 415-425.
6. Katipamula, S., Brambley, M.R. (2005). Methods for fault detection, diagnostics, and prognostics for building systems—a review, part I. Hvac&R Research, 11(1), 3-25.
7. Liu, B., Xiao, Y., Cao, L., Hao, Z., Deng, F. (2013). SVDD-based outlier detection on uncertain data. Knowledge and information systems, 34(3), 597-618.
8. Liu, M., Song, L., Claridge, D. E. (2002). Development of whole-building fault detection methods. High Performance Commerical Building Systems, 62, 63.
9. Najafi, M., Auslander, D.M., Bartlett, P.L., Haves, P., Sohn, M.D. (2012). Application of machine learning in the fault diagnostics of air handling units. Applied Energy, 96, 347-358.
10. Rowe, A., Berges, M.E., Bhatia, G., Goldman, E., Rajkumar, R., Garrett, J.H., Moura, J.M.F., Soibelman, L. (2011). Sensor Andrew: Large-scale campus-wide sensing and actuation. IBM Journal of Research and Development, 55(1.2), 6-1.

11. Sanchez-Hernandez, C., Boyd, D.S., Foody, G.M. (2007). One-class classification for mapping a specific land-cover class: SVDD classification of fenland. IEEE Transactions on Geoscience and Remote Sensing, 45(4), 1061-1073.
12. Tax, D.M., Duin, R.P. (1999, April). Data domain description using support vectors. In ESANN, Vol. 99, pp. 251-256.
13. Valavanis, I., Kosmopoulos, D. (2010). Multiclass defect detection and classification in weld radiographic images using geometric and texture features. Expert Systems with Applications, 37(12), 7606-7614.
14. Wiggins, M., Brodrick, J. (2012). HVAC fault detection. ASHRAE Journal, 54(2), 78-80.
15. Xu, P., Haves, P., Kim, M. (2005). Model-Based Automated Functional Testing－Methodology and Application to Air-Handling Units. ASHRAE Transactions, 111(1).
16. Liu, F.T., Ting, K.M., Zhou, Z.H. (2008, December). Isolation forest. In 2008 Eighth IEEE International Conference on Data Mining (pp. 413-422). IEEE.
17. Malisiewicz, T., Gupta, A., Efros, A.A. (2011, November). Ensemble of exemplar-svms for object detection and beyond. In Computer Vision (ICCV), 2011 IEEE International Conference on (pp. 89-96). IEEE.
18. Pokrajac, D., Lazarevic, A., Latecki, L.J. (2007, March). Incremental local outlier detection for data streams. In Computational intelligence and data mining, 2007. CIDM 2007. IEEE symposium on (pp. 504-515). IEEE.