

# Machine Learning 기법을 이용한 BEMS 에너지 데이터 분석 사례

건물에 설치된 BEMS에서 수집되고 있는 다양한 에너지 소비 데이터를 이용하여 건물 에너지 성능 분석을 수행하기 위한 방법으로 Machine Learning 기법을 제시하고 적용 사례를 소개하고자 한다.

## 서론

국의 연구 보고에 따르면, 최적화된 건물 에너지 관리를 통해 건물에너지사용량의 약 20%까지 절감이 가능한 것으로 조사되었으며, 미국 공조냉동공학회(ASHRAE)에서는 건물 132개를 기준으로 건물에서 에너지 절약이 가능한 잠재적 요인을 분석한 결과 건물 운용 단계에서 최적 제어로 절약할 수 있는 부분이 전체 저감 가능 에너지량의 77%에 달하는 것으로 보고되고 있다. 최근 국내에서도 BAS, BEMS 등의 건물운영관리 시스템의 도입으로, 건물 운영자 및 관리자의 경험 및 능력에 의존하던 기존의 건물 관리 방식에서 벗어나 정량적인 데이터들을 건물 운영에 활용함으로써 건물의 에너지 사용 절감을 유도할 수 있는 다양한 노력이 시도되고 있다.

하지만 현재 보급되고 있는 BEMS의 경우, 각종 기기의 운전상태, 에너지 사용량 등을 수집하여 시각화하는 기능이 주를 이루고 있으며, 수집되는 건물에너지 관련 데이터를 효과적으로 활용 및 분석하는 기능이 부족한 것이 현실이다. **그림 1**은 이러한 현황을 간단한 그림으로 표현한 것이다. 특히, 에너지 데이터를 분석한 결과를 바탕으로 건물 운영의 최

윤영란

단국대학교

건축공학과 박사과정

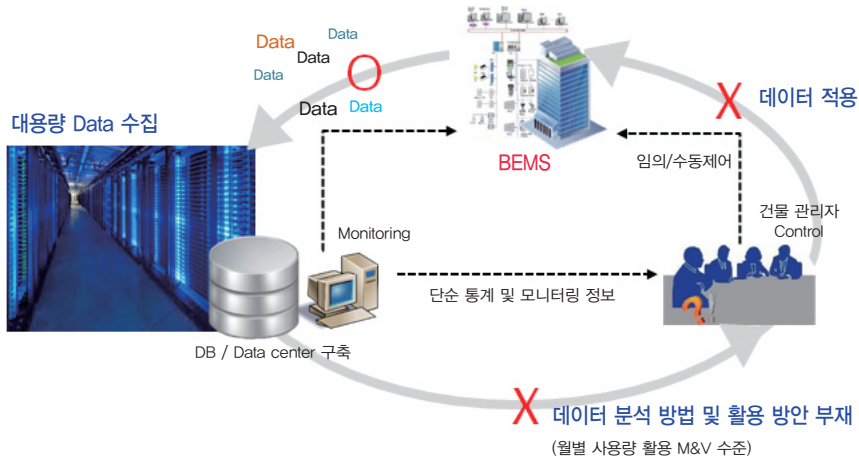
yryoon81@gmail.com

문현준

단국대학교

건축공학과 교수

hjunmoon@gmail.com



[그림 1] 건물 에너지 분석 현황

적 방안을 도출하고 고장진단, 이상 진단, 알람 발생, 예측 제어 등과 더불어 BAS와 연계된 자동제어를 수행하기에는 아직 많은 부분이 연구되어야 한다.

또한, BEMS의 수준에 따라 다르지만 계측 포인트에 따라 초/분 단위로 수집 및 모니터링되고 있는 방대한 양의 데이터로부터 가치 있는 정보를 발견하고 이를 체계적인 지식으로 전환하기 위한 새로운 분석 방법으로서의 접근이 필요하다. 본고에서는 건물에 설치된 BEMS에서 수집되고 있는 다양한 에너지 소비 데이터를 이용하여 건물 에너지 성능 분석을 수행하기 위한 방법으로 Machine Learning 기법을 제시하고 적용 사례를 소개한다.

### 기계학습(Machine Learning)

데이터를 활용한 기계학습은, 분석 기법이나 목적 측면에서 데이터 마이닝(Data Mining)과 혼용되어 사용되기도 한다. 그러나 기계학습(Machine Learning)은 훈련된 데이터(Training Data)를 통해 학습된 “알려진 속성”을 기반으로 예측에 초점을 두고 있는 반면, 데이터 마이닝은 데이터의

“알지 못했던” 어떤 정보를 발견하는 것에 집중해 ‘데이터에서 지식발견(Knowledge Discovery in Databases, KDD)’으로 호칭하기도 한다.<sup>1)</sup> 그래서 데이터 마이닝은 “데이터 분석을 통해 데이터에 이미 존재하고 있던 문제를 해결하는 과정”이라고도 한다.<sup>2)</sup>

두 가지 모두 자료에 대한 탐색을 통해 이를 통계적으로 모형화함으로써 이전에 알려지지 않은 유용한 지식을 추출할 수 있는 도구로서의 역할을 충실히 하고 있다는 것에는 이견이 없을 것이다. 다만, 기계학습은 데이터로부터 모델, 패턴, 어떤 규칙성 등을 발견하기 위한 기법적인 의미로서,<sup>3)</sup> 센서 데이터 및 DB로부터 자료를 이용하여 판단하도록 하는 알고리즘을 개발하는데 주목적이 있다. 이는 자료에 기반하여 복잡한 패턴을 인식하고 의사 결정을 내릴 수 있게 자동적으로 학습하는데, 이러한 특징은 건물의 에너지 사용 특성을 파악하여 제어 및 운영에 적용할 수 있는 알고리즘 등에 활용이 가능하다.

따라서 본고에서는 건물 데이터 분석에 활용될 수 있는 다양한 기계학습 기법과 이를 적용하여 분석한 사례를 중심으로 서술하고자 한다.

## 기계학습을 활용한 건물 BEMS 데이터 패턴 분석 사례

기계 학습 기법을 활용한 에너지 소비 패턴 분석 방법은 비지도학습(Unsupervised learning)으로 분류되는 군집 분석(Clustering) 방법과 지도 학습(Supervised learning)으로 구분되는 분류 분석(Classification) 방법으로 구분할 수 있다. Classification 기법을 활용한 분석 방법은 분석하고자 하는 대상에 미리 알고 있는 에너지 소비 패턴이 있는 경우 주로 사용될 수 있으며, Clustering 기법을 활용한 분석 방법은 특정 분류 기준을 사용하지 않고 대표적인 에너지 소비 패턴으로 구분하고 싶은 경우 주로 활용된다. 또한 Clustering 기법을 활용한 분석 방법의 경우 미지의 에너지 소비 패턴의 발견 가능성이 있다.

본고에서는 Classification 기법 중 Artificial Neural Network(ANN), Support Vector Machine(SVM), K-Nearest Neighbor(KNN) 기법과 Clustering 기법 중 K-means clustering, K-medoids clustering 기법을 중심으로 이를 적용한 에너지 소비 패턴 추출 및 분석한 사례를 소개하고자 한다. 대상 건물은 BEMS가 설치된 서울 근교의 5층 규모 사무용 건물로, 공조기, 열원, 조명, 급탕 등의 부분 별 에너지 소비 데이터와 실내·외 환경 정보가 실시간으로 수집되고 있으며, 2014년 1월부터 10월까지의 조명 및 공조기 부문의 에너지 소비 데이터를 중심으로 분석되었다.

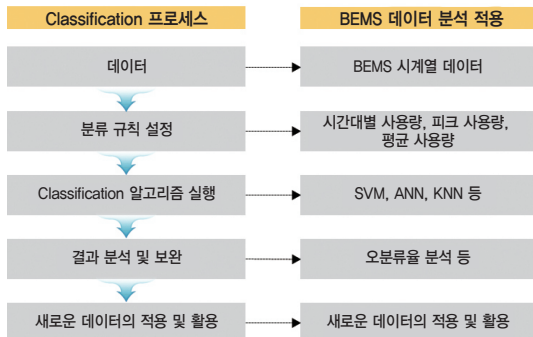
## Classification 기법을 활용한 조명 에너지 소비 패턴 추출 사례

Classification 기법을 활용한 에너지 소비 패턴 추출 방법의 경우, 각 패턴을 분류하는 분류 규칙을 사전에 정의해야 하며, 분류 결과가 사전 정의된 분류 규칙에 영향을 많이 받는 단점을 갖는다. 하지만 새로운 패턴이 속하는 그룹을 찾기 쉽

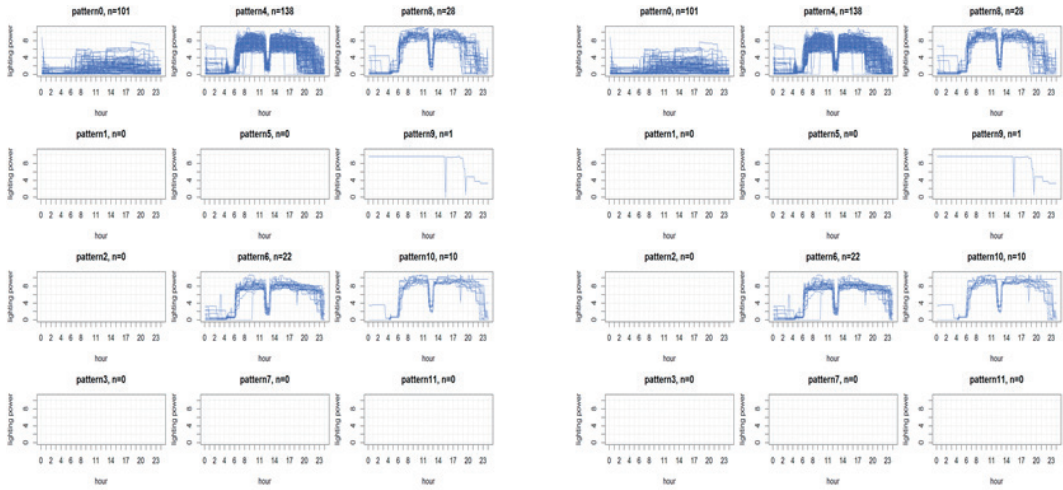
고 분류 규칙을 알기 때문에 도출되는 각 패턴의 의미를 이해하기 쉬운 장점이 있다. Classification 기법을 활용한 에너지 소비 패턴 추출을 위해서는 각 패턴을 분류할 수 있는 분류 규칙이 필요한데, 본 사례에서는 오피스 건물의 운영 특성에 기반하여 근무 시간, 야근 시간, 출근 시간 전의 조명 에너지 사용량과 피크 사용량, 분산을 기반으로 분류 규칙을 사전 정의하여 분석을 수행하였다. **그림 2**는 Classification의 프로세스와 건물의 BEMS 데이터 적용 시 관계를 그림으로 나타내고 있다.

**그림 3**은 ANN 알고리즘을 사용한 대상 건물의 조명 에너지 소비 패턴 추출 결과를 나타내고 있다. 그림의 왼쪽은 ANN 알고리즘 기반의 조명 에너지 소비 패턴 추출 모델 개발을 위해 사전 정의된 분류 규칙에 따라 분류된 학습 데이터를 나타내며 그림의 오른쪽은 학습데이터에 의해 학습된 ANN 모델을 통해 분류된 대상 건물의 조명 에너지 소비 패턴을 보여준다. 양쪽의 그래프는 거의 일치하는 형태를 보여주고 있으며, ANN 알고리즘은 학습 데이터를 완벽하게 분류할 수 있을 정도로 뛰어난 학습력을 나타냈다.

SVM 알고리즘을 사용한 조명 에너지 소비 패턴 분류 결과에서도, 대상 건물의 조명 에너지 사용 패턴은 약 5개의 대표적인 패턴으로 분류가 가



[그림 2] Classification 프로세스 및 BEMS 데이터 적용




사전 정의된 분류 규칙에 따라 분류된 학습 데이터

ANN 모델을 통해 분류된 조명 에너지 소비 패턴

[그림 3] ANN 알고리즘을 사용한 조명 에너지 소비 패턴 분류 결과 예

능한 것으로 확인되었다. 다만, SVM의 경우 조명 에너지 사용량과 분산 항목은 조명 에너지 소비 패턴 분류에 미미한 변별력을 갖는 것으로 확인되어 분류 규칙에서 이를 제외하고 재분석을 진행해야 했다. 위 사례에서 보듯이 Classification 분석은 어떤 알고리즘을 적용했는지, 그리고 어떤 분류 기준을 적용 했는지가 분석 결과에 중요한 영향을 미치기 때문에, 초기에 분류 기준 설정에 주의가 필요하다.

KNN 알고리즘의 경우, SVM이나 ANN 알고리

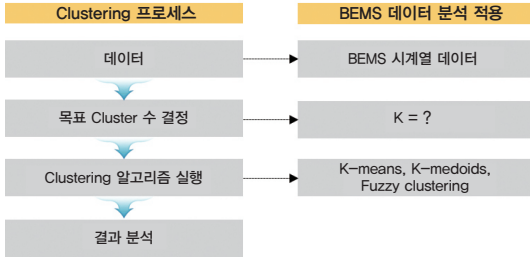


[그림 4] K값에 따른 KNN 알고리즘을 사용한 조명 에너지 소비 패턴 오분류율 결과

즘과 같이 학습을 먼저 하지 않고 새로운 패턴과 가장 가까운 K개의 패턴을 찾아서 에너지 소비 패턴을 분류한다. KNN 알고리즘의 경우, 적절한 크기의 K 값을 사용하는 것이 필요하며, 여러 K값에 대한 오분류율을 구한 후 낮은 오분류율을 보이는 K 값을 선택하는 과정을 거쳐야 한다. 다음의 그림 4는 값이 1부터 100까지인 경우의 오분류율을 분석한 그래프로, 분석 결과 대상 건물의 조명 에너지 소비 패턴의 경우, K값이 8일 때, 즉 에너지 소비 패턴의 수가 8개일 때 가장 낮은 오분류율(6.3%)을 갖는 것으로 나타났다. 또한, KNN 알고리즘의 경우, random process를 포함하기 때문에 여러 번의 테스트가 필요하다.

### Clustering 기법을 활용한 냉난방 에너지 소비 패턴 추출 사례

군집화(clustering) 또는 군집분석(cluster analysis)은 대표적인 비지도 학습법으로서, 적절한 기준에 대하여 동일한 군집에 속하는 관측값들을 서로 유사한 여러 개의 부분집합으로 할당하는 방법



[그림 5] Clustering 프로세스 및 BEMS 데이터 적용

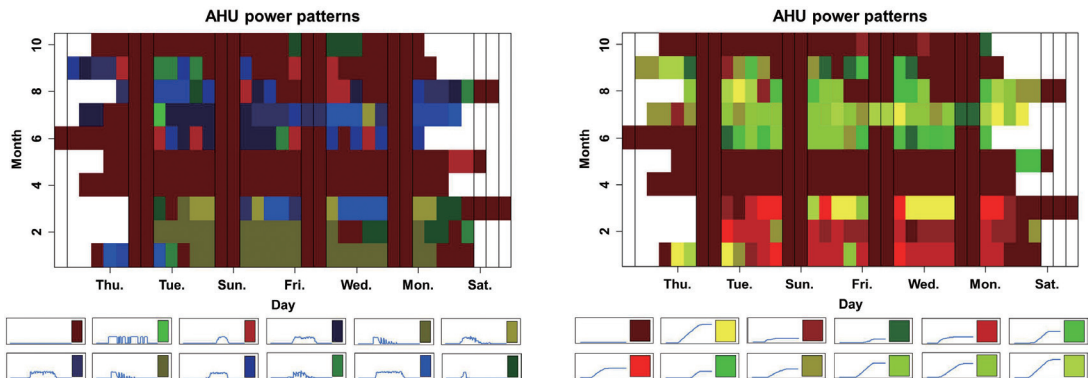
이다. 관측값들은 서로 유사하도록 군집이라 불리는 여러 개의 부분집합들로 나뉘는데, 이렇게 나뉜 군집별 특성을 파악함으로써 전체 자료에 대한 이해가 가능하다. 이러한 군집분석은 재실패턴, 장비 특성 등과 관련된 다양한 변수를 이용하여 건물 특성에 따라 세분화가 가능하기 때문에 건물에 대한 정보가 없을 때 매우 유용하게 활용될 수 있다. 그림 5는 클러스터링의 프로세스와 이를 BEMS 데이터에 적용했을 때의 프로세스를 보여주고 있다. BEMS로부터 수집된 시계열 데이터를 바탕으로 목표 클러스터 수를 선정하여 다양한 클러스터링 알고리즘을 적용하여 분석을 수행할 수 있다.

특히 사전 정보가 없는 자료에 대한 탐색적 방법으로 건물 정보가 부족하고, 에너지 계측 데이터만 존재할 때 데이터의 이상점(outlier) 등의 특이값

을 갖는 개체의 발견이나 데이터의 누락으로 인한 결측 값의 보정(imputation) 등에 활용이 가능할 것으로 판단된다. 또한, 군집 분석방법은 Classification과 달리 각 패턴을 분류하는 분류 규칙을 사전에 정의하지 않아도 되는 장점을 갖는 반면, 목표 Cluster 수를 미리 결정해야 하는 단점을 갖는다.

K-means clustering 알고리즘은 clustering 기법 중 가장 기본이 되는 기법으로 분류하고자 하는 데이터를 사전 정의된 목표 cluster 수인 K개만큼의 그룹으로 분류한다. K-means clustering 알고리즘의 경우, 앞서 언급한 KNN 알고리즘과 같이 적절한 크기의 목표 군집 수 K값을 선택해야만 하며, 이를 위해서 2부터 수십 개의 K값에 대한 variance 비율을 구하고, 일정 비율 이상을 가지는 K값을 선택하는 과정이 필요하다. 이때 variance 비율은 군집으로 설명되는 variance를 전체 데이터의 variance로 나눈 값을 의미한다. K-medoids clustering 알고리즘은 K-means clustering 알고리즘과 유사하나, random하지 않은 분류 결과를 도출하는 특징을 갖는다.

그림 6은 K-medoids clustering 알고리즘을 활용하여 분석한 그래프를 보여주고 있다. 왼쪽 그래프는 냉·난방 에너지 소비 데이터 자체(raw data)를 이용한 군집 분석 결과를 나타내고 있으며, 오른쪽 그래프는 일별 오전 오후 평균 사용량을 사용



[그림 6] 일별 평균과 분산(좌) 및 일별 오전 오후 평균 사용량(우)을 사용한 냉·난방 에너지 사용량 군집 분석 결과<sup>4)</sup>



한 군집 분석 결과를 보여주고 있다. 오른쪽의 일별 오전 오후 평균 사용량 그래프가 냉·난방 에너지 소비 데이터 자체(raw data)를 이용한 군집 분석 결과 사용한 그래프와 비교하여 보다 직관적인 군집 분석이 가능한 것으로 확인되었다. 또한, 난방은 오전에 냉방은 주로 오후에 사용된다는 사실을 분석 결과를 통해 확인할 수 있었다.

Machine Learning 기법을 활용한 건물에너지 소비 패턴 추출 및 분석의 경우, 지도 학습 방법인 Classification 방법(SVM, ANN, KNN 등)은 패턴을 미리 분류해 학습시키거나 비슷한 패턴을 찾아내는 방법이기 때문에 분석자가 패턴을 지정해주는 방법에 크게 영향을 받으며, 학습력 또는 예측력에 차이를 보일 수 있다. 따라서 분석에 필요한 사전 패턴 지정에 군집분석 방법을 선행하여 이 결과를 활용할 경우보다 효과적인 분석 결과를 도출할 수 있다. 또한, 본 사례 분석 결과에서 보이듯 냉난방 에너지 소비 데이터 분석 시에는 row data를 직접 활용하는 것보다 2차 가공하여 분석할 경우에 보다 더 효율적인 군집 분석이 가능하다.

## 기계학습을 활용한 건물 BEMS 데이터 예측 알고리즘 개발 사례

데이터 기반의 예측 모델은 기계학습(machine learning) 분석 기법 중 하나로, 기존의 시뮬레이션 틀을 활용한 모델링에서 야기되는 입력 및 출력 변수에 대한 추정이나 모델의 보정이 없이 건물의 에너

지 사용량 예측이 가능하다는 장점이 있다. 또한, Physics 기반의 시뮬레이션 분석 시 분석 대상 건물이 바뀔 때마다 모델링을 위한 시간과 비용이 많이 소요되고, 전문 지식을 필요로 하기 때문에 전문 인력이 없는 경우 성능을 분석하는데 어려움이 있다.

그러나 계측 데이터 기반의 예측 모델을 구축하여 성능 분석에 활용할 경우 모니터링되는 건물 데이터를 활용한 Data-driven 모델(Kernel regression 및 Gaussian process 기반)로서 적은 수의 트레이닝 데이터 세트에 예측 정확도를 향상시킬 수 있다. 또한, 입력 데이터에 대한 정보가 없이 건물에서 계측되고 있는 데이터만을 기반으로 분석이 가능하기 때문에 기존 건물의 에너지 성능 평가 방법으로 활용도가 높을 것으로 사료된다. 특히, BEMS, BAS 등에서 모니터링되고 있는 방대한 양의 데이터를 활용할 수 있는 성능 분석 방법으로, 실제 데이터를 확보할 수 있는 기존 건축물의 성능 분석에 매우 유용하게 쓰일 수 있다.

국내·외의 많은 연구에서 데이터 마이닝 기법을 활용하여 건물의 계측 데이터를 기반으로 한 예측 모델을 도출하는 다양한 연구가 수행 중에 있다. 가장 대표적인 건물 에너지 성능 예측 모델로 ANN(Neural network model), SVM(Support vector machine), Statistical, Simplified eng., Elaborate eng., GP(Gaussian process) Model 등의 방법이 주로 사용되는 것으로 나타난다.

특히 분석자의 숙련도가 필요하기는 하나, 모델의 적합도가 우수하고 input 데이터로 Historical data

〈표 1〉 건물 에너지 사용량 예측 방법의 비교 분석<sup>5)</sup>

Methods	Model complexity	Easy to use	Running speed	Inputs needed	Accuracy
Elaborate eng.	Fairly high	No	Low	Detailed	Fairly high
Simplified eng.	High	Yes	High	Simplified	High
statistical	Fair	Yes	Fairly high	Historical data	Fair
ANN	High	No	High	Historical data	High
SVMs	Fairly high	No	Low	Historical data	Fairly high

를 활용하기 때문에, 일정 시간 간격으로 모니터링되고 있는 계측 데이터를 활용하는 방법으로 ANN 모델과 SVM 모델이 건물 에너지 분야에서 적용되고 있으며(표 1), 최근 GP Model(Gaussian Process Model)에 대한 연구도 활발히 진행 중이다.


본절에서는 BEMS 데이터를 활용한 예측 모델 개발 사례로, 가우시안 프로세스 모델 및 재실 예측 모델 개발 사례를 소개하고자 한다.

### Gaussian Process Model을 활용한 건물에너지 소비량 예측


가우시안 프로세스는 ANN(Artificial Neural Network), SVM(Support Vector Machine) 등과 같이 입력값과 출력값의 관계를 블랙박스 형태의 수학적 모델로 도출하는 데이터 기반의 인버스 모델 중 하나로,<sup>6)</sup> 회귀 분석에 주로 활용된

다. 계측된 데이터를 활용하여 모델을 구축할 수 있으며, 비선형의 데이터들에서도 매우 유연하게 모델을 구현하는 장점이 있다.<sup>7)</sup> 때문에, 건물의 에너지 절감량에 대한 성과 검증을 위한 M&V(Measurement and verification) 베이스라인 모델 구축에 단순 회귀식의 대안으로 가우시안 프로세스 모델을 활용하거나,<sup>8) 9)</sup> 시계열 형태의 데이터를 활용해 월별 전기 에너지 부하 예측에 이를 활용하는 등 다양한 연구가 진행중이다<sup>10)</sup> 가우시안 프로세스의 자세한 이론적 설명 및 수식은 Rasmussen의 ‘Gaussian Process for Machine Learning’을 참고하기<sup>11)</sup> 바란다.

그림 7은 경기도의 임대형 오피스 건물로, BEMS로부터 수집되는 계측 데이터들을 가우시안 프로세스 모델의 입력값으로 활용하여 일주일간의 실내온도를 예측한 그래프이다. 실내 공조시스



[그림 7] Gaussian Process Model을 활용한 실내 온도 예측




[그림 8] Gaussian Process Model을 활용한 입주 세대별 에너지 사용량 예측<sup>11)</sup>

템에 관련된 외기온도, 외기습도, 급기온도, 혼합 온도, 공급 배관온도 외 8개의 변수를 입력값으로 하여, 오피스 건물의 실내 온도를 예측하였다. 아래 빨간색 점이 계측값이고, 파란색 선이 예측값을 나타낸다. 그리고 점선은 예측값의 95%의 신뢰구간으로, 예측값의 불확실성에 대한 정보를 포함하고 있는 장점이 있다. 또한, **그림 7**과 같이 비선형의 모델을 구축하는데 매우 효과적임을 알 수 있다.

**그림 8**은 서울에 있는 임대형 오피스 건물을 대상으로, 세대별 운영 변수인 재실자, 건물 운영 시간, 냉난방시스템/조명시스템 종류 및 개수 등의 변수를 활용하여 겨울철(2012년 1월) 오피스의 세대별 에너지 사용량을 예측한 그래프이다. 파란색 박스가 실제 계측된 전기에너지 사용량이고, 빨간색 박스가 예측값을 나타내는데 CVMSE(Coefficient of Variation of the Root Mean Square Error) 값이 0.28 수준으로 모델의 정확성이 상당히 높은 것을 알 수 있다.

### HVAC 시스템 예측 제어를 위한 실내 환경 데이터 기반 재실 예측 사례

외기 다음으로 건물의 에너지 성능에 많은 영



[그림 9] BEMS 데이터를 활용한 실내 환경 데이터 기반 재실 예측

향을 미치는 요인으로는 재실자를 들 수 있다. 그러나 재실자에 대한 정보는 개인정보 보호 등의 이유로 데이터의 수집이 어려울 뿐 아니라, 재실자의 행위(예를 들어 독서, 수면, 운동 등 실내에서의 활동량의 정도)에 대한 정보 파악이 어려워 이를 건물의 성능 평가에 직접적으로 반영하는 것은 현실적으로 불가능하다.

**그림 9**는 이러한 문제를 해결하기 위하여 기계 학습 기법인 Decision Tree Model, Hidden Markov Model을 기반으로, BEMS로부터 모니터링되는 실내·외 이산화탄소 농도, 실내조명 및 기기의 에너지 소비 정보를 활용하여 재실 예측 모델을 개발한 사례를 보여준다.<sup>12)</sup> 이렇게 개발된 재실 상태 예측 모델은 HVAC 시스템 제어에 활용되어, 업무용 건물의 공조기 및 냉수 펌프 시스템의 에너지 소비 저감 및 재실자의 온열쾌적감 향상에 기여할 수 있는 것으로 나타났다.

### 결론 및 향후 연구

BEMS의 도입은 건물 운영자 및 관리자의 경험 및 능력에 의존하던 기존의 건물 관리 방식에서 벗어나 정량적인 데이터들을 근간으로 건물 운영을 최적화할 수 있도록 새로운 장을 열어주었다. 그러나 아직까지는 모니터링 기능 위주의 단순통계처리 및 리포트 기능에 한정되어 있으며, 건물 에너지 절감 효과를 정량적으로 평가할 수 있는 분석 방법의 개발이 미흡한 실정이다.

본고에서는 이러한 문제에 대한 대안으로, BEMS로부터 모니터링 되고 있는 방대한 양의 데이터를 활용한 건물의 에너지 성능



분석 방법으로 기계 학습 기법을 적용한 다양한 분석 사례를 소개하였다. 본고에서 서술한 분석 방법은 기계학습 기법의 일부로써, 건물에 적용할 수 있는 방법들을 위주로 설명하였으며, 국내·외에서 이외의 다양한 기법들을 적용해 건물의 운영에 활용할 수 있도록 활발히 연구가 진행 중이다.

이러한 분석 방법들은 결국, 데이터들로부터 건물의 에너지 절약 및 효율적 운영에 필요한 정보들을 추출하기 위한 과정이다. 즉, 분석 자체가 목적이 아니라 이를 활용할 수 있는 방법, 분석 결과로부터 원하는 정보를 추출할 수 있는 전문가적 인사이트(Insight)가 수반되어야 할 것이다.

## 참고문헌

1. Fayyad, U., Piatetsky S.G., Smyth, P., 2008, From data mining to Knowledge Discovery in Database. Retrieved 17 December.
2. Mitchell, T.M., 1997, Machine Learning
3. Witten, L.H., Frank, E., Hall, M.A., 2005, Data Mining : Practical machine learning tools and techniques
4. 문현준, 정성권, 유승호, 2015, BEMS 데이터를 활용한 Machine Learning 기반 업무용 건물 냉·난방 에너지 소비 패턴 분석, 대한설비공학회 2015 동계학술발표대회 논문집. pp. 69-70.
5. Zhao, H., Magoulès, F., 2014, A review on the prediction of building energy consumption, Renewable and Sustainable Energy Reviews, Vol. 16. pp. 3586-3592.
6. Abushakra, B., 1997, An inverse model to predict and evaluate the energy performance of large commercial and institutional buildings. Proceedings of the Fifth International IBPSA Conference. Prague, Czech Republic. Building Simulation, Vol. 3, pp. 403-413.
7. Heo, Y.S., Zavala, V.M., 2012, Gaussian process modeling for measurement and verification of building energy savings. Energy and Buildings, Vol. 53, pp. 7-18.
8. Yuna, Z., Zheng, O., Bing, D., Godfried, A., 2015, Comparisons of inverse modeling approaches for predicting building energy performance. Building and Environment, Vol. 86, pp.177-190.
9. Zhang, S., Zhou, W., Qin, H., 2013, Inverse Gaussian process-based corrosion growth model for energy pipelines considering the sizing error in inspection data. Corrosion Science, Vol. 73, pp. 309-320.
10. Rasmussen, C.E., Williams, C.K.I., 2006, Gaussian Processes for Machine Learning. Massachusetts: The MIT Press.
11. 윤영란, 문현준, 2016, 입주세대별 에너지 사용 요인 기반 가우시안 프로세스 예측 모델 개발, 한국친환경설비학회논문집 10권 2호, pp.138-143
12. Ryu, S.H., 2016, Development of an occupancy prediction model using indoor environmental data for predictive HVAC control. Dankook University Ph.D. Thesis. 