



## 머신러닝 기술을 활용한 건축물 사례기반 온실가스 감축 의사결정 지원 모델 구축

### Building Case-based Greenhouse Gas Reduction Decision Support Model using Machine Learning

이성우\* · 태성호\*\*

Sung Woo Lee\* · Sung Ho Tae\*\*

\* Graduate Student, Dept. of Architectural Engineering, HanYang Univ., South Korea (greennaver@gmail.com)

\*\* Corresponding author, Professor, Dept. of Architecture and Architectural Engineering, HanYang Univ., South Korea (jnb55@hanyang.ac.kr)

**ABSTRACT**

**Purpose:** Many countries have implemented policies to reduce greenhouse gas (GHG) emissions in public buildings, emphasizing the leading role of the public sector. In Korea, in order to achieve a 30% reduction in GHG emissions by 2030, public agencies must set annual targets or quotas. However, the lack of experts and support are the biggest obstacles to achieving this reduction target. **Methods:** This study constructed a GHG evaluation database (DB) and Data set based on energy end uses, GHG reduction technology with the aim of decision making about GHG reduction with minimal building information and limited expert knowledge. The GHG evaluation DB was built using data from the Commercial Building Energy Consumption Survey (CBECS), an energy consumption survey of 6,720 public and commercial buildings by the US Department of Energy. In addition, a DB for evaluating the reduction amount of greenhouse gas reduction technology was established with reference to 1,206 greenhouse gas reduction technology application projects by the Korea Energy Survey. The database was used for constructing data set, we developed a machine learning-based GHG reduction decision support model. **Result:** Additionally, the case study of domestic public buildings, the economic and environmental benefit of applying greenhouse gas reduction technology were evaluated. The evaluated building can reduce about 111 tonCO<sub>2</sub>-eq and convert it into economic profit of 36 million won, confirming the applicability of the model.

**KEYWORD**배출권거래제  
건물 에너지  
머신러닝K-ETS  
Building Energy  
Machine Learning**ACCEPTANCE INFO**Received May. 6, 2020  
Final revision received May. 29, 2020  
Accepted Jun. 3, 2020

© 2020. KIEAE all rights reserved.

**1. 서론****1.1. 연구의 배경 및 목적**

온실가스 감축 목표 달성을 위한 건물 부문의 에너지 절약이 국내외적으로 강조되고 있으며, 많은 국가가 온실가스 감축을 위한 정책 및 기술지원 등을 크게 강화하고 있다.

또한, 정부는 공공기관의 선도적 역할을 강조하며 공공건축물에 대한 설계기준 강화, 제로에너지 건물 등을 의무화하고 있다.

미국의 경우 공공건축물 신축 시 LEED 인증을 의무화하고 있으며 이를 지원하기 위한 시스템을 제공하고 있다. EU는 2020년 까지 신축 공공건축물에 대해 100% 제로 에너지를 추진하고 있으며, 이에 따른 에너지 성능 보고서를 제출하고 있다[1]. 한국의 경우, 공공기관의 선도적 역할을 통한 국가 온실가스 감축을 이루고자 ‘신기후체제에 대한 건실한 이행체계’를 10대 국정과제에 포함하여 공공기관의 온실가스 감축을 의무화하였다. 하지만, 관련 분야 전문가의 부재, 제도의 이해 부족은 제도운영의 가장 큰 문제점으로 자리하고 있다.

이에, 본 연구에서는 공공기관의 효율적인 건축물 온실가스 감축 계획 수립을 지원하고 목표 온실가스 배출량의 달성을 위한 온실가

스 평가 데이터베이스를 구축하고 이를 활용하여 머신러닝 기반 온실가스 감축 의사결정 지원모델을 구축하였다.

**1.2. 연구의 방법 및 범위**

본 연구에서는 공공기관의 효율적인 건축물 온실가스 감축계획 수립을 지원하고자 배출목표 달성을 위한 공공건축물 에너지 사용 용도별 온실가스 평가 데이터베이스와 평가결과에 따른 온실가스 감축기술 적용을 위한 감축 인정량 평가 DB를 구축하였다. 이는 전문적 지식이 없는 사용자를 위해 건물의 연면적, 감축기술 적용 예산과 같은 기본정보만으로 온실가스 배출량과 감축 인정량 산정이 가능하도록 하였다.

또한, 감축기술의 적용 의사결정을 지원하기 위해 머신러닝 알고리즘 활용 모델을 제안하였다. 머신러닝 알고리즘 모델을 구축하기 위해 구축한 평가 DB 및 실제 에너지 사용량을 기반으로 데이터 셋을 구축하였으며 머신러닝 알고리즘 중 대표적인 알고리즘 중 DNN(Deep Neural Network), GBRT(Gradient Boosting Regression Model), SVM(Support Vector Machine)을 활용하여 가장 정확도가 높은 모델을 선정하여 이를 온실가스 감축 의사결정 지원 모델로 제안하였다[2].

## 2. 선행연구고찰

### 2.1. 국내의 온실가스 관리 시스템

한국의 공공기관은 배출권거래제(K-ETS)와 목표관리제(Target Management System)를 지원하는 국가 온실가스 종합관리시스템을 통해 이행년도 별 감축목표를 설정하고 온실가스 배출량 입력을 하고 있으나 감축률 및 온실가스 배출량 정보를 입력하고 확인하는 수준에 머물러 있다[3].

이에 반해 선진국은 정부에서 운영하는 모든 시설을 관리대상으로 설정하여 목표를 설정하고 이를 지원할 수 있는 방안으로 온실가스 평가 시스템과 예산 지원 프로그램을 운영하고 있다[4].

미국 에너지부(DOE)는 건물 에너지 예측 및 기존 유사 건물의 환경정보를 제공하는 소프트웨어 프로그램인 Standard Energy Efficiency Data Platform(SEED)를 제공한다[5]. 해당 프로그램은 건물유형, 준공년도, 연면적 정보의 입력으로 유사 건물의 에너지 및 비용정보를 제공한다. 또한, 미 환경청(EPA)의 Energy star portfolio는 공공기관의 에너지 효율을 진단하고 효율적 감축 계획 수립을 지원하는 것이 특징이며 연방정부, 주정부 기관이 지원대상이고 우선순위에 따라 에너지 성능 개선사업을 수행할 수 있도록 지원하고 있다[6].

영국 에너지·기후변화부(DECC)의 2050 pathway는 웹과 소프트웨어로 제공되며 국가의 온실가스 배출량 산정 및 전망을 지원하기 위한 시스템으로 각 산업 분야별 에너지 생산 및 소비에 따른 온실가스 전망 및 배출량 검토 결과를 제공한다[7].

한국의 공공건축물 온실가스 관리제도의 성공적 운영 및 지원을 위해 건물 에너지 사용 용도별 평가 결과의 해석, 활용성 등이 우수한 공공건축물 온실가스 관리기술 제안이 요구된다.

### 2.2. 온실가스 평가·예측모형의 구분

온실가스 감축과 관련하여 가장 기본적인 사항은 과거부터 미래의 온실가스 배출량을 정량적으로 파악하고 배출전망치에 의한 감축계획 및 실행방안을 마련 그리고 합리적인 감축목표의 설정과 이를 달성하기 위한 노력이다.

온실가스 배출 전망 및 감축 잠재량 분석은 현재 거시적 경제상황

및 산업연관 효과 등에 초점을 맞춘 하향식 접근기법과 채택 가능한 에너지기술 및 정책방안 등으로부터 경제적 감축 잠재성을 도출하려는 상향식 접근 방법이 있다.

상향식 모형이란 개별 에너지 사용의 형태와 관련한 기술을 세부적으로 묘사하여 기술, 사회변화, 정책 등이 변수에 미치는 영향을 분석하는 접근 방법이다. 세부적인 기술 특성을 반영하기 때문에 다양한 정책 수단이 미치는 영향을 분석하는데 용이하다. 또한 기술의 상세한 설명, 발전, 채택, 대체 현상 등 다양한 요인을 반영한 온실가스 감축 잠재량 분석이 가능하다.

하향식 모형은 자본, 노동, 토지, 에너지 등 각종 생산요소를 보다 포괄적으로 고려하고 온실가스 감축이 재화의 산출변화에 영향을 주어 상향식 모형에 비해 감축비용이 높은 경향을 보인다. 본 연구에서는 상향식 모형을 기초로 하여 세부적인 온실가스 감축기술을 건축물에 적용하였을 때 환경성 및 경제성 결과에 대한 사전검토가 가능하도록 하였다[8].

### 2.2. 국내의 온실가스 평가 및 예측모형

국내외에서 주로 사용되는 온실가스 감축 잠재량 분석 및 에너지 수요전망은 주로 CGE(Computable general equilibrium model), Times, MARKAL(MARKet ALlocation), LEAP(Long-range Energy Alternative Planning system), MESSAGE(Model of Energy Supply Strategy Alternatives and their General Environmental Impact) 모형 등이 있다. 국외 주요 선진국은 국가 수준 에너지 전환, 산업, 교통을 포함하는 다양한 온실가스 분석모형을 구축하고 있다. 미국의 경우, 최적 선형 계획법에 의한 MARKAL 모형과 시나리오 분석형 LEAP 모형을 활용하며 일본은 자체개발한 AIM(Asia-Pacific Integrated Model) 모형을 구축하였다. 국제에너지기구(IEA)는 에너지 기술 분석, 에너지 전망, 감축 시나리오 개발을 위해 MARKAL 모형과 Message 모형을 운영하고 있다.

LEAP는 Stockholm Environment Institute에서 개발된 시나리오 분석형 온실가스 모델링 소프트웨어로 산업과 경제 분야의 에너지 소비와 생산, 자원 채취의 흐름 등을 구조화하고 분석하며 도식화가 가능하다.

Message 모형의 경우 중장기 에너지 최적화 모형으로 IPCC(Intergovernmental Panel on Climate Change) World Energy Council 등 국제기구에서 활용하고 있다. AIM은 아시아 특성을 고려한 최적화 모형으로 아시아 지역 12개 국가에서 시나리오 분석을 위해 활용하고 있다. 이와 같이 선진국에서는 온실가스 감축모형 구축을 위해 Message, MARKAL, LEAP, AIM 등의 기존모형을 복합적으로 또는 단일 사용하고 있으나 이는 건축물에 특화된 평가보다는 전 산업을 아우르는 모형이며, 국내실태를 반영하지 못하였다[9].

특히, 건물의 경우 고비용 고감축 결과만을 도출하며 다른 산업에 비해 현실성이 부족한 결과를 도출하는 문제점을 갖고 있다.

본 연구에서는 실제 국내외 에너지사용량 기반 데이터를 활용하여 국내 건축물의 온실가스 감축계획 수립이 가능한 시스템을 제안하고자 한다.

Table 1. Support for greenhouse gas reduction systems in the public sector of major countries

	System	Web base	Evaluation	Prediction	Economic Analysis
Korea	National GHG Management System	■	□	□	□
	Bio grace	□	■	□	□
EU	2050 Pathways calculator	■	■	■	■
	Standard Energy Efficiency Data platform (SEED)	■	■	■	□
USA	Energy Star Portfolio Manager(ESPM)	■	■	□	□
	B3 Benchmarking	□	■	■	□

이는 국내 실정을 반영하고 실질의 온실가스 감축을 위한 기존 건축물의 벤치마킹을 통해 실제 적용 가능한 온실가스 감축계획 수립을 지원할 것이다.

### 3. 온실가스 평가 데이터베이스 구축

#### 3.1. 에너지 사용용도별 평가 DB 구축

##### 1) 기초데이터 설정

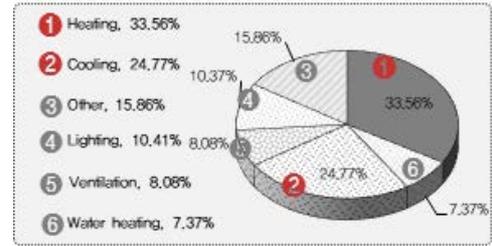
한국은 공공과 상업건물을 구분하지 않고 전체 에너지 총 사용량을 데이터를 공개하고 있다. 하지만 해당 데이터를 기초데이터로 활용하기 위해 공공과 상업건물을 구분하는 기준이 모호하고 건축물별 에너지사용량을 공개하고 있지 않아 본 연구의 평가DB 구축의 기초데이터로 활용하는데 어려움이 있다.

한편, 미국에서는 상업과 공공건축물에 대한 조사를 함께 진행하지만 건물기능 및 에너지 사용용도별 사용량에 대하여 raw data 형식으로 제공하고 있다. 미 DOE에서 2012년도에 구축한 CBCES의 경우, 상업과 공공부문 대상 6,720개의 건물에 대하여 건물형태, 재료, 사용자 수, 기후, 설비, 용도별 유지보수 여부, 에너지사용량 및 비용 등 1,119가지 환경성능정보를 조사하였다[10]. 본 연구에서는 평가 DB 구축대상을 공공건축물로 한정하고 한국과 유사한 기후를 가진 지역과 1970년 이후 준공된 총 225개의 건물을 선정하였다. 건물 선정 시 Census region은 North east로 선정하였으며 기후는 humid temperate climate인 지역을 선정하였다. 주요건축물 기능은 국내 공공부문 온실가스 에너지 목표관리제(TMS) 대상기준과 동일하게 공공부문이 소유한 건축물에 한정하였다. 평가 DB의 에너지 사용 용도는 한국의 건축물 에너지 효율등급 인증제도 및 건축물 에너지소비 총량제의 6가지 용도인 난방, 냉방, 급탕, 조명, 환기, 기타로 분류 하였다. 에너지사용량은 설비시스템에 투입되는 에너지 즉, 과금 대상 에너지사용량이다. 또한 사용량 계측은 건물 전체가 아닌 기준층(지상 2층 이상의 층 중 평면형태가 유사하고 일반 업무용도 공간이 반복되는 층)들을 대상으로 층별로 구해 합산하는 것을 원칙으로 하였으며, 조명과 환기 에너지사용량의 경우에는 건물 내 지하층의 에너지 사용량을 대상 공간에 포함하였다.

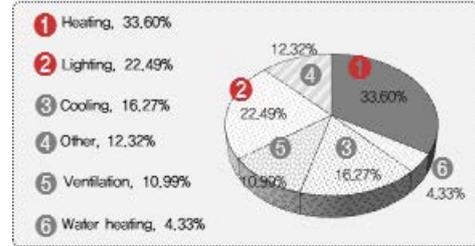
##### 2) 에너지 사용용도별 평가 DB 구축

Fig. 1.은 구축한 에너지 사용용도 평가 DB의 건물기능별 분포를 나타낸다. 공공건축물 기능 구분은 한국의 건축법에서 규정하는 건축물대장의 건물구분 중 업무시설, 교육시설, 연구시설, 의료시설에 해당하는 공공건축물의 에너지사용량 데이터를 선정하여 구축하였다. 본 연구의 에너지 사용용도별 온실가스 평가 DB는 건물기능과 준공년도로 구분하여 1차 에너지원별(전력, 도시가스, 경유, 지역난방) 온실가스 배출량을 산정하고 이를 원단위 인자인 연면적으로 나누어 구축하였다.

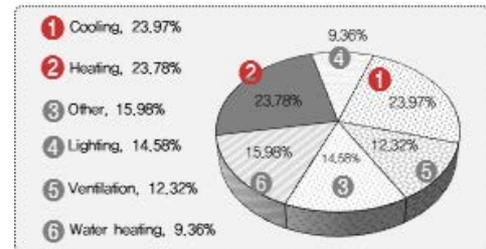
본 연구에서 수행한 표본설계는 일정 수준의 허용오차를 가지고 건물의 용도별 온실가스 예상 배출량을 추정하기 위한 것이므로, 원단위 분포 특성을 대표하는 값은 평균값으로 하였다.



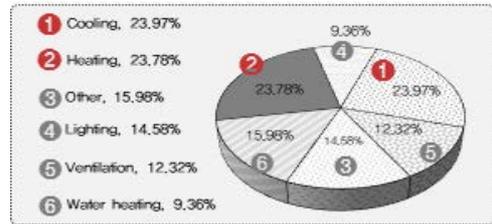
a. office



b. medical



c. education



d. research

Fig. 1. Energy use ratio by building function of energy use evaluation DB

에너지 사용 용도별 평가 DB 구축 결과 각 건물기능의 에너지 사용용도는 난방, 냉방, 기타가 각각 29%, 21%, 16%이다. 계절성을 갖는 난방, 냉방의 경우 원단위가 특히 크게 나타났으며 의료시설은 난방과 조명이 46%를 차지하였다.

##### 3) 확률론적 방법론에 따른 평가DB 불확실성 검토

평가 DB의 유의성을 검토하고자 배출량의 불확도를 분석하였다. 이를 위해 크리스탈 볼의 몬테카를로 시뮬레이션 기법을 이용하여 각각의 가정변수(연면적, 배출계수)들이 예측변수(온실가스 배출량)에 미치는 불확도를 분석하였다.

IPCC의 불확도 분석 방법론은 입력자료(상관계수)의 불확도와 조합을 중심으로 산정 절차를 제시하고 있다.

몬테카를로 시뮬레이션에서는 모든 가정변수와 예측변수 간의 스피어만 순위 상관계수를 계산하여 불확도를 분석하게 된다. 이때 계산된 불확도는 개별 가정변수가 예측변수에 미치는 영향만을 통계적으로 살펴보는 것이 아니라 가정변수 간의 상관관계를 반영한

예측변수에 대한 영향력을 보여준다.

불확도는 배출량 산정 결과의 신뢰도를 나타내는 정량적인 지표로서 합리적으로 추정된 값의 분산상태를 나타내는 단위가 된다. 이를 위해 확률밀도함수와 신뢰구간이라는 2가지 통계적 개념을 활용하게 된다. IPCC에서는 무작위 오차의 계량화를 위해 95% 신뢰구간을 요구한다. 95% 신뢰구간은 모평균을 구하기 위해 100번의 신뢰구간을 추정하면, 95개의 추정된 신뢰구간 안에 참값이 존재한다는 것을 의미한다. (Eq. 1)에서 불확도(U) 값은 온실가스 배출량 모델의 불확실성을 측정하기 위해 IPCC에서 제안하는 불확도 산정법으로 절반의 95% 신뢰구간을 최종 배출량으로 나눈 비율을 적용한다[11].

$$U = \frac{(GHGEmissions\ within\ 95\% \ CI) / 2}{GHGEmissions} \times 100 \quad (Eq. 1)$$

Table 2.와 같이 확률분포를 설정하였다. 분포 적합 도구로는 크리스탈 볼(Crystal Ball)을 활용하였고 본 도구에서 제공하는 적합 통계량의 산출결과 중 현업에서 가장 많이 사용되는 A-D 검정의 적합 통계량을 기준으로 결정하였다[12].

공공건축물의 용도별 평가DB를 활용하여 분포를 가정한 변수들 기반 총 10,000회의 몬테카를로 시뮬레이션을 수행하여 최종적인 온실가스 배출량의 결과를 Table 3., Fig. 2.와 같이 나타내었다. 온실가스 배출량 분포의 형태를 통해 분포의 백분위 수 10에서 95%까지의 불확실성을 평가하였다.

각 에너지 사용 용도별 온실가스 배출량의 95% 신뢰구간의 불확도는 약 20%로 산정되었다.

공공건축물의 에너지 사용 용도별 온실가스 배출량은 비교적 좌우 대칭인 모습을 나타내었다. 이는 공공건축물의 에너지사용량과 연면적에 따른 확률분포는 그 편차가 적고 고른 분포를 나타낸다는 것을 의미한다.

Table 2. Distribution of emission estimation parameters  
unit: tonCO<sub>2</sub>-eq/m<sup>2</sup>)

Classification	Heating	Cooling	Water heating	Lighting	Ventilation
Probability distribution					
Sample	246	235	295	302	303
Distribution	Log normal	Normal	Normal	Log normal	Normal
Correlation coefficient	Floor Area				
Average	4.81×10 <sup>-2</sup>	1.95×10 <sup>-2</sup>	1.38×10 <sup>-3</sup>	1.61×10 <sup>-2</sup>	1.51×10 <sup>-2</sup>
Mode	4.93×10 <sup>-2</sup>	1.95×10 <sup>-2</sup>	1.39×10 <sup>-3</sup>	6.90×10 <sup>-3</sup>	1.51×10 <sup>-2</sup>
Median	2.25×10 <sup>-2</sup>	1.95×10 <sup>-2</sup>	1.39×10 <sup>-3</sup>	1.23×10 <sup>-2</sup>	1.51×10 <sup>-2</sup>

Table 3. Emissions uncertainty analysis results  
unit: tonCO<sub>2</sub>-eq

Classification	Max.	Min.	95% Confidence interval		
			From	To	Uncertainty
Heating	1,427	616	867.2	1,207	20.95%
Cooling	437	180	258	360.5	19.94%
Water heating	246	102	150.7	209.8	20.52%
Ventilation	348	161	214.1	299.4	22.80%
Lighting	384	154	227.0	317.8	19.73%

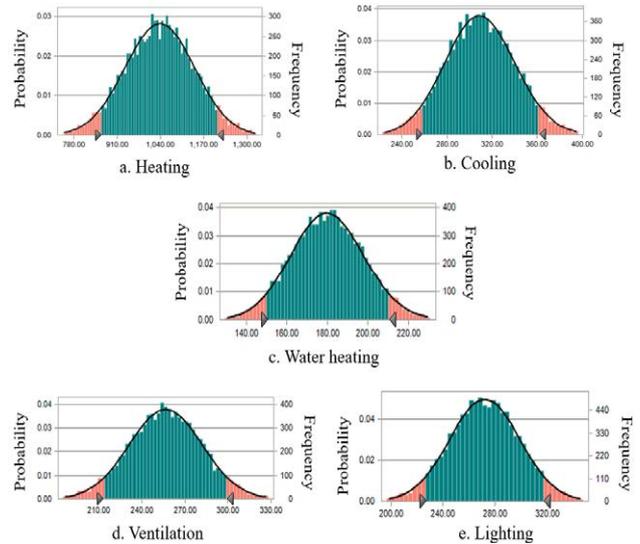


Fig. 2. Uncertainty analysis of greenhouse gas emissions by energy use by Monte Carlo

### 3.2. 온실가스 감축기술 인정량 평가DB 구축

본 연구에서는 온실가스 감축사업 수립의 의사결정을 지원하고자 실제 온실가스 감축기술 사업에 따른 환경성능 평가DB 구축을 제안하였다.

#### 1) 온실가스 감축기술 기초데이터

공공건축물에 지원대상이 되는 태양광, 태양열, 지열 등 신재생에너지와 고효율조명교체, LED 조명 등의 고효율 기술적 온실가스 감축 인정량 평가DB를 제안하였다. 한국에너지공단의 에너지 총조사 보고서(2017)의 온실가스 감축 기술의 에너지 생산량 및 절감량 데이터를 기반으로 구축하였으며 1,206건의 실제 온실가스 감축 기술 적용사업을 대상으로 하였다[13].

평가 데이터베이스 구축을 위해 활용한 기초데이터의 표본은 Table 4.와 같다.

총 1,206건 중 태양광 에너지 도입이 436건(36%)로 가장 많았으며, 다음으로 고효율조명 교체가 194건(16%)로 이는 전체사업 중 태양광 에너지 도입과 고효율조명 교체사업이 전체사업 중 절반 이상을 나타내는 수치이다. 태양광 에너지의 경우 설치 및 유지보수비용이 저렴하고 제도적인 지원이 있어 해당 기술의 사례는 점점 증가할 것으로 판단된다[14].

Table 4. Greenhouse Gas Reduction Technology Basic Data Sample

GHG Reduction Tech		Samples (EA,%)
Sum		1,206
Renewable energy	Photovoltaic system	436(36%)
	Solar thermal energy system	123(10%)
	Geothermal energy system	113(9%)
	Green roof	18(1.5%)
High Efficiency equipment replacement	LED street light	123(10%)
	High efficiency light	194(16%)
	Green remodeling	6(0.4%)
	Electric vehicle	139(11%)
Natural gas automobile		54(4%)

2) 온실가스 감축 인정량 산정방법 제안

온실가스 감축기술 적용사업 수행에 따른 에너지 생산량 및 절감량을 산정하여 온실가스 감축 인정량으로 도출하였다[15].

태양광 발전, 태양열 에너지 사용, 지열에너지사업은 에너지 생산량 산정에 적용가능하다. 감축기술에 따른 전력생산량은 설비용량과 에너지원의 사용에 따라 산정가능하며 온실가스 감축기술의 전력이용률은 그린홈에서 제공하는 13.3%를 적용하여 산정하였다. 에너지 절감기술의 산정은 사업의 착수 전과 후의 에너지사용량을 비교하는 방식으로 산정가능하다. 고효율조명 및 LED 가로등 교체 사업은 조명기기의 소비전력, 기기의 설치대수 그리고 점등시간을 고려하여 산정하였다. 산정에 필요한 일일점등기준시간은 2008 에너지공단 조명기기 보급실태조사를 근거로 사무소 기준 8시간을 적용하였다[16].

옥상녹화사업은 조성면적과 적용 후 단위면적당 감축전력을 고려하여 에너지 절감량을 기준으로 온실가스 감축 인정량을 산정하였다.

3) 온실가스 감축기술 인정량 평가DB 구축

한국에서 수행 중인 온실가스 감축사업의 환경성 및 경제성을 검토 가능하게 하는 감축기술 인정량 평가 DB를 구축하였다.

총 1,206건의 온실가스 감축기술을 대상으로 온실가스 감축 인정량을 산정하였다.

감축 인정량 원단위데이터는 각 사업의 온실가스 감축 인정량을 산정하여 각 감축사업의 구축비용과 5년간의 유지보수 비용을 원단위 인자로 하여 구축하였다. 표준이 되는 데이터는 감축기술의 구축비용과 감축 인정량 DB의 가장 평균값을 결과로 하였으며, 보수적인 산정을 위해 raw data 중 상위 10% 데이터는 제거하여 사용하였다.

평가 DB 구축결과는 Table 5.와 같다. 건물에서의 신재생에너지의 보급을 통한 정량적 분석을 위해 전력, 도시가스과 같은 에너지원별 감축효과와 냉방, 난방, 급탕, 조명, 환기 등의 에너지 사용용도에 따른 에너지 사용 상쇄 효과에 대한 평가가 필요하다. 이에 본 연구에서는 한국에너지공단 에너지 총조사 보고사의 2,000TOE 이상 사용 건축물 전수조사 결과를 통해 도출된 온실가스 감축기술의 상쇄비율을 적용하여 온실가스 감축기술의 에너지 사용용도 및 에너지원별 상쇄 원단위 DB를 구축하였다.

Table 5. GHG reduction tech. evaluation DB

Unit : tonCO<sub>2</sub>eq/won

Classification	Photovoltaic system	Solar thermal energy system	Geothermal energy System	High efficiency light	LED street light	Green roof
GHG assessment DB	2.65×10 <sup>-4</sup>	7.55×10 <sup>-5</sup>	1.86×10 <sup>-4</sup>	1.04×10 <sup>-3</sup>	8.25×10 <sup>-4</sup>	3.96×10 <sup>-4</sup>
Heating	9.51×10 <sup>-5</sup>	-	1.73×10 <sup>-4</sup>	-	-	1.42×10 <sup>-4</sup>
Cooling	6.56×10 <sup>-5</sup>	-	1.31×10 <sup>-5</sup>	-	-	9.81×10 <sup>-5</sup>
Water heating	2.70×10 <sup>-5</sup>	7.55×10 <sup>-5</sup>	-	-	-	4.04×10 <sup>-5</sup>
Lighting	4.39×10 <sup>-5</sup>	-	-	1.04×10 <sup>-3</sup>	8.25×10 <sup>-4</sup>	6.56×10 <sup>-5</sup>
Ventilation	3.34×10 <sup>-5</sup>	-	-	-	-	5.00×10 <sup>-5</sup>
Electricity	2.65×10 <sup>-4</sup>	-	9.32×10 <sup>-5</sup>	1.04×10 <sup>-3</sup>	8.25×10 <sup>-4</sup>	3.96×10 <sup>-4</sup>
City gas	-	6.95×10 <sup>-5</sup>	7.64×10 <sup>-5</sup>	-	-	-
Heat	-	6.04×10 <sup>-6</sup>	1.49×10 <sup>-5</sup>	-	-	-

에너지 총조사 보고서에 따르면 태양광은 전력을 대체하게 되며, 그 에너지원은 모든 에너지 사용용도(난방, 냉방, 급탕, 환기, 조명) 별 에너지 사용을 대체할 수 있다. 태양열은 급탕을 대체하고 있으며, 급탕에 사용되는 에너지원인 도시가스와 열에너지를 저감할 수 있다. 비율은 도시가스 92%, 열에너지에서 8%로 나타내고 있다. 지열은 냉방과 난방에서 사용되는 에너지를 저감 시킬 수 있으며 냉난방 에너지는 도시가스 50%, 전력 41%, 열에너지 8%로 구분 가능하다.

온실가스 감축 성능은 고효율 조명교체사업이 1.0472E-03 tCO<sub>2</sub>eq/원로 원단위 비교에서 가장 높은 사업으로 산정되었으며, LED교체사업이 8.25E-04 tCO<sub>2</sub>eq/원, 태양광사업이 2.65158E-04 tCO<sub>2</sub>eq/원, 옥상녹화가 3.96676E-04 tCO<sub>2</sub>eq/원, 지열에너지가 1.86473E-04 tCO<sub>2</sub>eq/원의 원단위를 나타내었다.

3.3. 분석 데이터 셋 구축

머신러닝 모델 구축을 위한 데이터는 실제 지자체에서 운영하고 있는 10,923개의 공공건축물과 그에 따른 305,844개의 데이터로 구성되어 있다. 또한 실제 1년 동안 월별로 실측한 에너지감축량을 포함하고 있다. 머신러닝 모듈에서는 온실가스 배출량 관련하여 수집된 건물정보, 온실가스 배출량 등에 의해 해당 건물에 최적이 되는 온실가스 감축사업과 사업예산을 예측한다.

Table 6.과 같이 총 10,923개의 건물정보를 토대로 머신러닝 모델 개발을 위한 데이터셋을 구축하였다. 온실가스 감축기술의 인정량 데이터의 경우 실제 사업에 따른 감축 인정량 데이터를 활용하였다. 에너지 사용용도별 사용량의 경우 실측 데이터의 부재로 건물의 연면적 정보와 본 연구에서 구축한 평가DB를 활용하여 산정하였다.

4. 온실가스 감축 의사결정 지원 모델 구축

4.1. 데이터 전처리

지도학습에 사용되는 모델링 기법에는 매우 다양한 방법이 있지만 본 연구에서는 국외선행연구(Hachesu, Ahmadi, Alizadeh & Sadoughi, 2013; Morton, Marzban, Giannoulis & Patel)에서 예측 모형개발을 위해 사용한 분석기법인 GBRT (Gradient Boosting Regression Tree), SVM(Support Vector Machine), DNN(Deep Neural Network)을 이용하여 분석하였다[16].

모형 구축에 앞서 데이터 셋이 표현하는 현상을 파악하고 문제점을 발견하기 위해 다음과 같이 데이터 전처리를 실시하였다.

첫째, 독립변수 및 종속변수에 해당하는 누락정보는 제외하였다. 둘째, 박스도표(Box-plot)을 이용하여 통계적 이상치(Outlier)를 제거하였다. 셋째, 변수간의 상관관계 분석을 통해 종속변수에 영향을 미치는 독립변수를 도출하였다. 넷째, 전처리 데이터 셋 중 약 70%는 훈련(train)데이터, 약 30%는 시험(test)데이터로 활용하였다[17].

또한 최종 기계학습 모형을 선택하기 전에 학습된 모형의 일반화 오차를 검증할 필요가 있다. 이에 K겹 교차검증 방법을 적용하여 훈련데이터를 k=10등분하고 등분된 훈련데이터 중 k-1개를 훈련데

Table 6. Dataset for constructing machine learning models

Building function	Sample (EA)	Classification		Data information	Unit	Data collection
Office	3,511	Building Information		Building name	-	Case-based
Medical	1,936			Floor Area	m <sup>2</sup>	Case-based
Education	870			Business budget	won	Case-based
Research	123	Dependent variable	Recognized amount by GHG reduction technology	Photovoltaic system	tCO <sub>2</sub> eq	Case-based
Neighbor	2,288			Solar thermal energy system		Case-based
Training	450			Geothermal energy System		Case-based
Warehouse	57			High efficiency light		Case-based
Labor	170			LED street light		Case-based
Waste treatment	409			Green roof		Case-based
Tourist	124			Cooling		Evaluation DB
Factory	12			Heating		Evaluation DB
Sales	37			Water heating		Evaluation DB
Accommodation	27			Lighting		Evaluation DB
Transportation	10	Ventilation	Evaluation DB			
Cultural	862	Independent variable	Korean Offset Credit (KOC)			Output
Automotive	37		GHG reduction			

이터로 사용하여 나머지 1개의 데이터를 이용하여 모형의 성능을 k=10번 반복하였다.

#### 4.2. 머신러닝 기반 의사결정 지원모델 구축

데이터 셋 기반 머신러닝 알고리즘 활용 최적 온실가스 감축기술 모형을 구축하였다. 예측 모형의 타당성과 예측력을 비교하고 검증하기 위해 Mean Absolute Error, Root Mean Squared Error 값을 이용하여 각 알고리즘의 분석결과를 비교하였다[18].

Fig. 3.은 머신러닝 알고리즘별 모델 구축결과를 나타낸다. GBRT의 중요한 초모수는 트리수와 이전 트리의 오차를 얼마나 강하게 보정할 것인지를 제어하는 학습률(learning rate, lr)이다. 최적의 GBRT모형을 결정하기 위해 학습률은 0.1로 결정하였으며 트리수를 변화시키면서 최종모형을 결정하였다.

트리수가 증가할수록 MAE 및 RMSE는 감소하는 모습을 보이고 있다. 가장 낮은 MAE 및 RMSE 값을 나타내는 트리수 200개와 트리수 300개를 최종모형으로 결정하였다.

SVM모형을 최적화하기 위해서는 적용할 커널함수(Kernel function) 오류에 대한 벌칙(Penalty)을 제어하는 초모수인 C 그리고

Table 7. Model determination

Classification	Cross-validation		Test		Acc (%)	Primary super parameters
	MAE	RMSE	MAE	RMSE		
GBRT	55.707	82.149	102.925	148.996	91.5	estimators 200
	53.135	80.604	103.101	149.085	92.5	estimators 300
SVM	95.739	143.473	112.191	163.907	89.4	C 2
						$\gamma$ 0.4
	94.907	142.536	110.896	154.654	88.6	$\epsilon$ 0.01
						C 2
DNN	55.16	81.075	101.057	147.739	94.2	400-400-400
	52.525	78.604	98.032	147.378	95.1	450-450-450

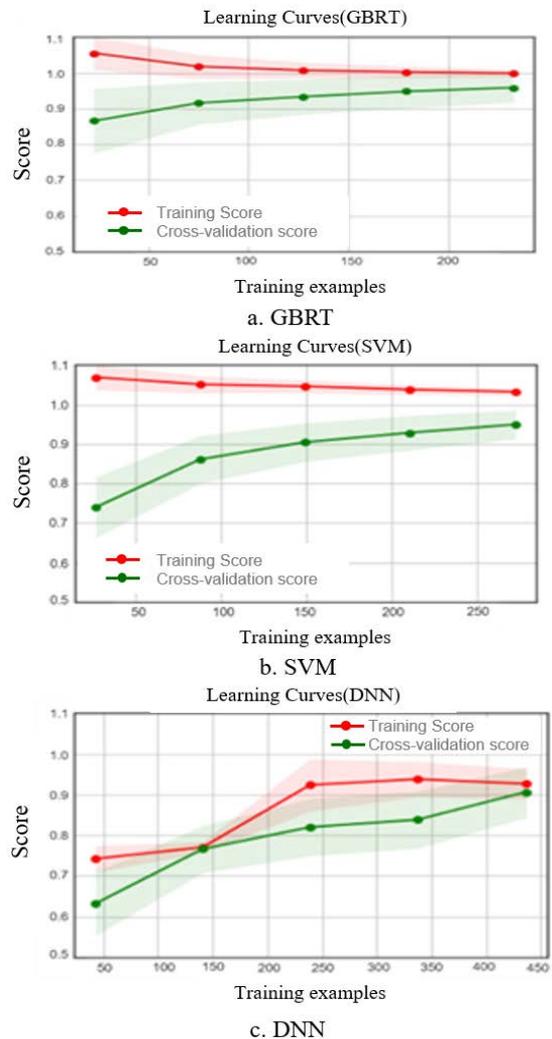


Fig. 3. Model construction results for each machine learning algorithm

고 훈련데이터의 영향도와 영향력의 범위와 관련된  $\gamma$ , 그리고 허용 에러율과 관련된  $\epsilon$ 에 대한 결정이 필요하다.

커널함수로 방사기저함수(radial basis function, RBF)커널을 적용하였으며, C를 변화시키면서 k겹 교차검증에 의해 산출된 검증 데이터의 MAE 및 RMSE가 최소가 되는 모형을 SVM 최종모형으로 결정하였다.  $\gamma$ 이 0.5,  $\epsilon$ 이 0.01인 경우 예측력이 대체로 우수했다. DNN을 최적화하기 위해서는 투입변수(input), 은닉층(hidden layer)의 수, 활성화 함수(activation function), 가중치에 대한 최적화방법(optimizer), 테스트 회수(epoch), 배치(batch), 과적합 방지를 위한 드롭아웃(dropout) 등을 결정해야 한다. 투입변수는 30개, 출력변수는 1개, 은닉층은 3개, 테스트횟수는 200회 배치사이즈는 50, 활성화함수는 렐루함수, 최적화방법은 아담알고리즘, dropout은 20%를 적용하였다.

k겹 교차 검증에 의한 검증 데이터의 MAE 및 RMSE 값이 최소가 되는 모형을 최종모형으로 결정하였다. DNN 분석결과 은닉층 내 노드수가 증가할수록 MAE 및 RMSE는 점차 감소하는 경향을 보이고 있으며, 노드수가 300개를 초과하면 MAE 및 RMSE가 오히려 증가하고 있다.

### 5. 의사결정 지원 모델 적용성 검토

#### 5.1. 검토개요

DNN을 통해 구축된 온실가스 감축 의사결정 지원모델 및 온실가스 평가 데이터베이스의 적용성검토를 위해 사례평가를 진행하였다. Table 8.은 사례평가에 선정된 평가대상 건물개요를 나타낸다. 평가대상건물은 지방자치단체가 소유한 의료시설로 에너지 사용용도별 및 에너지사용원별 온실가스 배출량, 사업예산 정보를 토대로 최적의 온실가스 감축사업을 도출하였다. 또한 온실가스 감축사업을 통해 발생한 온실가스 감축 인정량을 토대로 배출권거래제에서 얻을 수 있는 경제적 이익을 분석하였다.

#### 5.2. 검토결과

건물의 연면적, 에너지 사용용도별 배출량 정보, 사업예산 정보에 따라 적합하게 도출된 사업은 고효율조명교체, 태양광발전, 지열에너지 사용이다. Fig 4.와 Table 9.는 해당사업 수행에 따른 온실가스 감축량과 경제적 이익을 나타내며 온실가스 감축 인정량은 111 tonCO<sub>2</sub>eq으로 확인하였다.

분석결과를 통해 고효율조명교체에서 48 ton CO<sub>2</sub>eq, 태양광발전부문에서 53 tonCO<sub>2</sub>eq, 지열부문에서 10 tonCO<sub>2</sub>eq라는 결과를 확인 가능하다.

Table 8. Overview of the evaluated building

<b>Building name</b>	S city medical center
<b>Floor area</b>	77,191 m <sup>2</sup>
<b>Zoning district</b>	Medical zone
<b>Purpose</b>	State owned medical facility
<b>Service life</b>	5 years
<b>Emission report</b>	Heating, cooling, lighting, ventilation, water heating, other
<b>Budget</b>	20 million won

Fig. 4.는 온실가스 감축기술 적용에 따른 에너지 사용 용도별 온실가스 감축 인정량 비교결과이다. 머신러닝 기반 온실가스 감축기술 선정 시 사례평가 대상건물은 전체 에너지 사용 용도에서 감축이 가능하나 특히 난방, 냉방, 조명부문에서 약 68tonCO<sub>2</sub>eq의 감축잠재량이 존재하다는 것을 확인하였다.

온실가스 감축에 의한 K-ETS 및 에너지 절감을 통한 경제적 이익을 산출하였다. 한국거래소에 따르면 2020년 배출권 1ton 당 금액은 평균 38,000원이다

온실가스 감축기술을 통해 배출권 거래시장에서 얻는 경제적 이익은 421만 8천원으로 산정가능하다.

에너지 사용절감 및 생산에 따른 절감 이익은 서울 비주거용건물의 의료시설 복지할인 기준 864 백만원 로 산정하였으며 이에 따른 배출권거래이익과 에너지 절감비용의 합은 56,196,000원이다.

사업금액 20백만원으로 해당 건물에서 얻을 수 있는 경제적 이익은 약 36백만원으로 도출하였다.

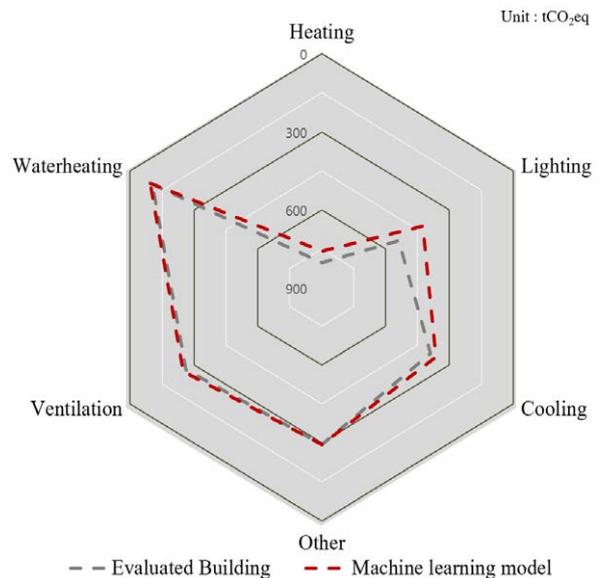


Fig. 4. Reduction Results of Energy end Use by Selection of Reduction Technology based on machine learning model

Table 9. Reduction costs by GHG reduction Technology

Cost unit: thousand won

GHG Reduction Tech.	Reduction Energy Info.	Unit	Reduction Cost
High Efficiency lighting	Electricity	1.09	TJ
	Lighting	1.09	TJ
	GHG Reduction	48	ton
Solar power	Electricity	0.98	TJ
	GHG Reduction	53	ton
Geothermal energy	City gas	0.38	TJ
	Heat	0.000008	TJ
	Heating	8.6	ton
	Cooling	0.65	ton

## 6. 결론

본 연구는 다양한 머신러닝 기법을 이용하여 온실가스 감축기술을 추정하기 위한 모형 간 예측력을 비교하였으며, 온실가스 감축기술의 환경성과 경제성 산정과 관련하여 머신러닝의 활용 가능성을 검토하였다는 점에서 의의가 있다. 본 연구결과를 요약하면 다음과 같다.

1. 미 DOE에서 조사한 CBECS를 토대로 온실가스 에너지 사용 용도별 평가DB를 구축하였으며 실제 온실가스 감축기술 적용 사업 기반 감축기술 인정량 평가DB를 제시하였다.
2. 실제 건축물 10,923개 동의 에너지 사용량 사례기반 데이터 셋을 구축하였다. 에너지 사용 용도별 에너지 사용량과 같은 데이터 부재의 경우 본 논문에서 구축한 평가DB를 활용하였다.
3. 구축된 데이터 셋을 활용 실제 사례에 기반 머신러닝 모형을 구축하였다. 구축모형 들의 예측력 비교결과 MAE, RMSE가 52.525, 78.604로 3가지 머신러닝 분석기법 중 MAE와 RMSE 결과가 가장 낮은 DNN이 예측률 95.1%로 가장 높게 도출되었다.
4. DNN 기반 모형의 적용성을 검토하고자 사례평가를 실시하였다. 사용자가 선정한 예산과 건물의 에너지 사용행태를 고려하여 111 tonCO<sub>2</sub>eq를 절감할 수 있는 최적의 온실가스 감축기술인 고효율 조명교체, 태양광발전, 지열에너지 활용을 도출하면서 적용성을 확인하였다.
5. 선행연구가 모형 간 예측력을 비교하는 정도까지 진행되었다면 본 연구는 기계학습 방법에 의해 산출된 온실가스 감축기술의 환경성과 경제성 분석을 통해 머신러닝의 활용성을 검토하였다는 점에서 차별성이 있다. 하지만 다양한 사례분석결과를 활용하여 모형 성능 향상방안을 도출하는 후속연구가 요구된다.

## Acknowledgement

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2015R1A5A1037548).

## Reference

- [1] 안형준, 상업공공건물용 투광형 BIPV창호의 에너지 성능·환경·경제 종합평가 연구, 서울대학교 대학원 박사학위 논문, pp.19-34, 2019. // (H.J. An, Energy Performance, Environmental and Economic Assessment of Transparent BIPV Window Applied to Office Buildings, Seoul National university, Doctor degree, pp.19-34, 2019.)
- [2] 박종호 외 1인, 머신러닝을 이용한 신경계통의 질환 퇴원환자의 중증도 보정 재원일수 예측모형 개발, 한국보건의사회연구학회지, 제39권 제1호, 2019, pp.390-427. // (J.H. Park et al., Patients discharged from

- diseases of the nervous system using machine learning Development of a model for predicting the severity of hospitalization, Korea: Health and Social Welfare Review, 39(1), 2019, pp.390-427.)
- [3] 국가온실가스종합관리시스템(NGMS), <https://ngms.gir.go.kr>, 2020.04.02
- [4] 한국에너지공단, 2018 KEA 에너지 편람, 2018. // ( Korea Energy Agency, 2018 Korea Energy Agency Handbook, 2018.)
- [5] UNFCCC. NC7; National Communication Submissions from Annex1 parties: EU, 2017.
- [6] DOE (Department of Energy, US), Energy star Portfolio Manager, <http://portfoliomanager.energystar.gov/>, 2020.03.01.
- [7] DECC (Department of Energy & Climate Change, UK). <http://2050-calculator-tool.decc.gov.uk>, 2020.03.02.
- [8] 라휘문, 지방자치단체 평가모형의 재설계, 한국정책연구, 제17권 제3호, 2017, pp.23-41. // (H.M. La, Re-design of Evaluation Model for Local Government, The Korean association for Policy Studies, 17(3), 2017, pp.23-41.)
- [9] 윤성권 외 3인, 에너지시스템 분석 모형을 통한 국내 건물부문 온실가스 감축시나리오 분석, 한국기후변화학회 제5권, 제2호, 2014, pp.153-163. // (S.G Yun et al, GHG Mitigation Scenario Analysis in Building Sector using Energy System Model, Journal of Climate Change Research, 5(2), 2014, pp.153-163.)
- [10] U.S. Energy Information Administration. Commercial Buildings Energy Consumption Survey (CBECS), [www.eia.gov/consumption/](http://www.eia.gov/consumption/), 2020.02.08
- [11] IPCC (International Panel on Climate Change), IPCC Guidelines for National Greenhouse Gas Inventories, 2006.
- [12] S. LEE, Development of a stochastic financial analysis model for building development projects, PhD Thesis. Ph. D. Dissertation, Korea University, 2007.
- [13] 환경부 고시 제2018-98호, 「외부사업 타당성 평가 및 감축량 인증에 관한 지침」.
- [14] 산업통상자원부, 에너지총조사보고서, 산업통상자원부; 2017, pp.860-896. // (Ministry of Trade, Industry and Energy, Energy Consumption Survey, Korea: Ministry of Trade, Industry and Energy, 2017. pp.860-896.)
- [15] 한국에너지공단 그린홈, <https://greenhome.kemco.or.kr/index.do>, 2020.03.01.
- [16] A.Morton et al., A comparison of supervised machine learning techniques for predicting short-term in-hospital length of stay among diabetic patients: In Proceedings of the 2014 13th International Conference on Machine Learning and Applications pp.428-431.
- [17] P. R. Hachesu et al., Use of Data Mining Techniques to Determine and Predict Length of Stay of Cardiac Patients, Health Inform Res., 19(2), 2013. pp.121-129.
- [18] 채명수, 데이터마이닝을 이용한 그린리모델링 최적 대상 선정 모델, 연세대학교 대학원 석사학위 논문, 2017 // ( M.S. Chae, Selection Model for Optimal Target Building for Green Remodeling Using Data-Mining Techniques: Focused on Multi - Family Housing Complex, Master degree, 2017.)