



## 통합 기계학습 기반 급기온도 최적 운전에 따른 HVAC 시스템 에너지 절감 효과 분석

### *Analysis of Energy Reduction in HVAC Systems under Optimal Supply Air Temperature Control Based on Integrated Machine Learning*

성남철\* · 김대웅\*\*

Namchul Seong\* · Daeung Kim\*\*

\* Main author, Researcher, CJU Industry-Academic Cooperation Foundation, Cheongju Univ., South Korea (inamchul@cju.ac.kr)

\*\* Corresponding author, Professor, Dept. of Architectural Engineering, Cheongju Univ., South Korea (dkim@cju.ac.kr)

#### ABSTRACT

**Purpose:** This study aims to evaluate the energy reduction performance of HVAC systems by applying optimal supply air temperature control based on an integrated machine learning approach. In conventional HVAC operation, fixed supply air temperature settings or reactive control strategies are commonly used, limiting the ability to respond effectively to varying load conditions and resulting in suboptimal energy performance. To address this limitation, a predictive and adaptive control strategy is proposed to dynamically adjust supply air temperature according to system conditions. **Method:** An integrated machine learning algorithm (IMLA) was developed by combining two machine learning models: an artificial neural network for system condition estimation and an optimization-based learning algorithm for determining control variables. The proposed method determines the optimal control variable at each time step based on predicted system conditions, enabling adaptive operation under varying load profiles. The performance of the method was evaluated using a central HVAC system under typical cooling season conditions. **Result:** The results show that total energy consumption decreased from 85,381.8kWh to 80,307.5kWh, corresponding to a reduction of 5.9% (5,074.3kWh) compared to baseline operation. Component-wise analysis indicates that chiller energy decreased by 7.2% (79,492.0kWh to 73,748.5kWh) and pump energy decreased by 9.1% (2,732.6kWh to 2,483.7kWh), while fan energy increased by 29.1% (3,157.2kWh to 4,075.3kWh). Monthly results further show higher energy reduction during partial-load periods, with savings of 12.9% in June and 10.3% in September. Despite the increase in fan energy, the overall reduction was achieved due to the dominant decrease in chiller energy.

#### KEYWORD

공조시스템  
급기온도  
통합 기계학습 알고리즘  
최적제어

HVAC System  
Supply Air Temperature  
Integrated Machine Learning Algorithm  
Optimal Control

#### ACCEPTANCE INFO

Received Apr. 6, 2026  
Final revision received Apr. 10, 2026  
Accepted Apr. 16, 2026

© 2026. KIEAE all rights reserved.

## 1. 서론

건물 부문은 전 세계 에너지 소비에서 상당한 비중을 차지하며, 특히 공조 시스템(HVAC system)은 건물 에너지 소비의 주요 원인으로 알려져 있다[1,2]. 최근에는 건물 에너지 효율 향상과 탄소 저감을 위한 요구가 증가함에 따라 HVAC 시스템의 효율적인 운전 전략에 대한 연구가 더욱 활발히 이루어지고 있다[3,4]. 특히 냉난방을 위해 공급되는 공기의 급기온도(Supply Air Temperature, SAT)는 HVAC 시스템의 대표적인 제어변수 중 하나로, 시스템 에너지 소비에 직접적인 영향을 미치는 중요한 변수로 보고되고 있다[5].

기존 HVAC 시스템에서는 급기온도를 일정한 고정값으로 설정하는 방식이 일반적으로 사용되어 왔다. 그러나 이러한 방식은 실제 운전 조건을 충분히 반영하지 못하여 비효율적인 에너지 소비를 유발할 수 있다[6]. 이에 따라 외기 조건 및 부하 변화에 따라 급기온도를 조정하는 reset 제어 전략이 제안되었으며, 이를 통해 에너지 성능 개선 가능성이 보고되고 있다[7].

이러한 제어 문제를 해결하기 위해 최적화 기법 및 기계학습 기반

제어 방법이 연구되고 있다[3,8]. 예를 들어, 유전 알고리즘 및 메타휴리스틱 기반 최적화 기법을 활용하여 HVAC 운전 변수의 최적값을 도출하는 연구가 수행되었으며[9,10], 모델 예측 제어(Model Predictive Control, MPC)를 이용한 에너지 절감 연구도 진행되었다[11,12]. 또한, 인공지능 및 딥러닝 기반 제어 기법을 통해 HVAC 시스템의 운전 조건을 예측하고 이를 기반으로 제어변수를 결정하는 연구도 보고되고 있다[13,14]. 이러한 연구들은 기계학습 기반 제어가 HVAC 시스템의 에너지 성능 향상에 효과적으로 적용될 수 있음을 보여준다.

그러나 기존 연구들은 예측과 최적화 과정이 분리되어 수행되는 경우가 대다수로, 통합된 제어 구조를 기반으로 한 접근은 상대적으로 부족하다[15,16]. 또한, 시간에 따라 변화하는 시스템 상태를 연속적으로 반영하는 데에는 한계가 있으며, 제어변수 결정 과정에서 예측 정보가 충분히 활용되지 못하는 문제가 존재한다[17,18]. 이러한 한계는 실제 HVAC 시스템의 동적 운전 특성을 반영한 최적제어 성능 확보를 어렵게 만드는 요인으로 작용한다.

따라서 본 연구에서는 이러한 한계를 개선하기 위해 통합 기계학습 알고리즘(Integrated Machine Learning Algorithm, IMLA)을 제안한다. 제안된 방법은 기계학습 기반 예측과 최적화 기능을 결합

한 구조를 통해, 시간에 따라 변화하는 시스템 상태를 반영하여 각 시간 단계에서 최적의 제어변수를 도출하도록 구성되었다. 제안된 알고리즘을 활용하여, 제어변수인 급기온도를 대상으로 최적 제어를 수행하고, 이를 통해 HVAC 시스템의 에너지 소비 변화를 정량적으로 분석하였으며, 기존의 고정 설정값 기반 운전 방식과의 비교를 통해 제안된 방법의 적용 가능성과 에너지 성능 개선 효과를 평가하였다.

또한 급기온도를 제어변수로 선정한 최적제어 접근을 통해 급기온도 제어가 HVAC 시스템 에너지 성능에 미치는 영향을 명확하게 분석하고자 하였으며, 급기온도의 변화와 에너지 소비 간의 관계를 정량적으로 평가하여 향후 기계학습 기반 지능형 제어의 다변수 제어 확장을 위한 기초적 방향을 제시하고자 한다.

## 2. 통합 기계학습 알고리즘 기반 최적 운전 방법

### 2.1. 통합기계학습 개요

본 연구에서는 HVAC 시스템의 급기온도 최적 운전을 도출하기 위하여 통합 기계학습 알고리즘(Integrated Machine Learning Algorithm, IMLA)을 개발하여 적용하였다. IMLA는 데이터 기반 예측 기법과 물리 기반 HVAC 해석, 그리고 최적화 알고리즘을 결합하여 미래 조건을 고려한 최적 제어 변수를 도출하는 통합된 구조의 알고리즘이다.

기존의 HVAC 운전은 현재 시점의 부하 조건에 기반하여 제어변

수를 결정하는 방식이 일반적이며, 급격한 부하 변화에 선제적으로 대응하기 어렵다는 한계를 가진다. 이에 본 연구에서는 미래 부하를 고려한 운전 전략 수립을 위해 신경망을 활용한 부하 예측과 HVAC 해석 기반 최적 운전 도출을 한 번에 수행이 가능한 통합 기계학습 알고리즘을 활용한 최적제어 운전을 수행하였다.

먼저, 과거 시간 단계까지의 부하 및 외기 조건 데이터를 기반으로 다음 시간 단계( $t+1$ )의 냉방부하를 예측한다. 이때 예측된 부하는 단순한 참고 정보가 아니라, 해당 시점의 HVAC 운전 조건을 구성하는 주요 입력 변수로 활용된다. 이후, 예측된 부하를 기반으로 HVAC 해석 모델을 구성하고, 다양한 운전 조건에 대한 에너지 소비를 평가함으로써 최적 운전 변수를 선택하여 도출한다. 이와 같은 통합 구조를 통해 데이터 기반 방법의 예측 기능과 물리 모델의 해석 기능, 그리고 최적화 연산을 동시에 활용할 수 있으며, 시스템의 동적 부하 변화에 효과적으로 대응할 수 있다. 또한, 미래 부하를 반영한 운전 변수 결정이 가능하므로, 기존의 반응형 제어 방식과 달리 선제적 운전 전략을 구현할 수 있다.

결과적으로 통합 기계학습 알고리즘은 부하 예측과 최적 운전 도출을 연계함으로써 HVAC 시스템의 에너지 성능을 향상시키는 데 활용될 수 있는 방법으로 정의된다. Fig. 1.은 본 연구에서 적용한 통합 기계학습 알고리즘 기반 최적 운전 제어의 구조를 나타낸다.

### 2.2. 최적 운전 도출 절차

통합 기계학습 알고리즘 기반 최적 운전은 각 시간 단계에서 순차적으로 수행되며, 미래시점의 부하 예측과 최적 운전 변수를 탐색하는 과정으로 구성되어 진행된다. 전체 일련의 과정은 시간의 흐름에 따라 반복적으로 적용되며, 각 시점의 운전 조건은 이전 단계의 결과를 기반으로 갱신된다. 본 연구에서 최적 급기온도 도출 절차는 다음과 같다.

먼저, 현재 시점까지의 부하 및 외기 조건 데이터를 이용하여 인공신경망을 통해 다음 시간 단계( $t+1$ )의 냉방부하를 예측한다. 이 과정에서 도출된 예측 부하는 해당 시간 단계의 HVAC 운전 조건을 구성하는 입력으로 활용된다. 이후, 예측된 부하를 기반으로 HVAC 해석 모델을 구성하고, 급기온도를 제어 변수로 설정하여 유전 알고리즘(Genetic Algorithm, GA)을 적용한 최적화를 수행한다. 본 연구에서 급기온도는 연속 변수로 정의되며, 사전에 설정된 허용 범위 내에서 개체가 생성되도록 구성하였다. 각 개체는 특정 급기온도 조건을 의미하며, 해당 조건에 대해 HVAC 해석 모델을 이용하여 시스템의 총 에너지 소비를 계산하고 이를 목적함수로 설정하였다.

GA는 각 시간 단계에서 독립적으로 수행되며, 예측된 시간 단계( $t+1$ )의 부하 조건을 기반으로 최적 급기온도를 탐색한다. 이러한 과정을 통해 에너지 소비를 최소화하는 급기온도가 도출되며, 해당 값이 해당 시간 단계의 최적 운전 변수로 결정된다.

최종적으로 도출된 급기온도는 다음 시간 단계의 운전 조건으로 적용되며, 동일한 절차가 전체 해석 기간 동안 반복 수행된다. 이와 같은 과정에 따라 HVAC 시스템은 시간에 따라 변화하는 부하 조건과 외기 상태에 대응하여 동적으로 운전되며, 결과적으로 최적 운전 패턴이 형성된다.

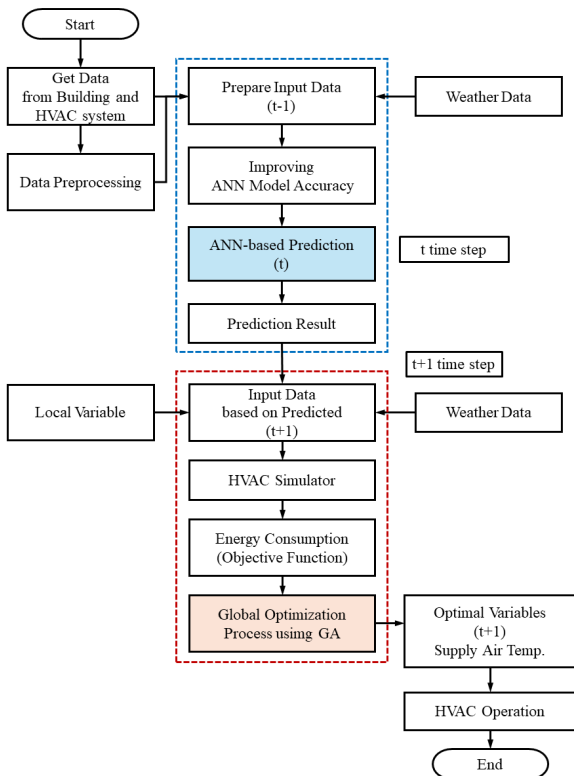


Fig. 1. Framework of the integrated machine learning algorithm (IMLA) for load prediction and optimal supply air temperature control

### 2.3. 목적함수 및 제어변수 설정

다음과 같은 목적함수와 제어변수 설정을 기반으로, 각 시간 단계에서 HVAC 시스템의 에너지 소비를 최소화하는 급기온도가 도출되며, 이를 통해 시스템 전체의 에너지 성능을 향상시킬 수 있다.

#### 1) 목적함수 설정

본 연구에서는 HVAC 시스템의 에너지 소비를 최소화하는 동시에, 실제 운전 환경에서 요구되는 제어 안정성을 반영하기 위해 다음과 같이 목적함수를 구성하였다. HVAC 시스템은 냉동기, 펌프, 팬 등 다양한 설비로 구성되며, 각 설비의 에너지 소비는 상호 영향을 미치는 구조를 가지므로, 특정 설비의 에너지 소비만을 최소화하는 방식은 시스템 전체의 효율적인 운전을 보장하기 어렵다. 이에 따라 본 연구에서는 각 설비의 에너지 소비를 동시에 고려하는 형태의 목적함수를 정의하였다. 본 연구에서 사용된 목적함수는 Eq. 1과 같다.

$$J = w_f E_f + w_c E_c + w_p E_p + P + \lambda (t_{s,t} - t_{s,t-1})^2 \quad (\text{Eq. 1})$$

여기서,

$J$ : 목적함수 값(총 에너지 소비 및 페널티 포함)

$E_f$ : 팬(송풍기) 에너지 소비량[kWh]

$E_c$ : 냉동기 에너지 소비량[kWh]

$E_p$ : 펌프 에너지 소비량[kWh]

$w_f$ : 팬(송풍기) 에너지 소비에 대한 가중치

$w_c$ : 냉동기 에너지 소비에 대한 가중치

$w_p$ : 펌프 에너지 소비에 대한 가중치

$P$ : 제약조건 위반 페널티(Penalty)

$\lambda$ : 급기온도 위반 페널티 계수

$t_{s,t}$ : 시간  $t$ 에서의 최적 급기온도 설정값[°C]

$t_{s,t-1}$ : 직전 시간( $t-1$ )에서 결정된 급기온도 설정값[°C]

$w_f, w_c, w_p$ 는 각각 팬, 냉동기, 펌프의 에너지 소비에 대한 가중치로, 본 연구에서는 설비 간 에너지 소비 특성을 그대로 반영하기 위하여 Eq. 2와 같이 모든 가중치를 1로 설정하였다. 이는 특정 설비의 영향을 인위적으로 조정하지 않고, 시스템 전체 에너지 소비 최소화를 직접적으로 반영하기 위함이다.

$$w_f = w_c = w_p = 1.0 \quad (\text{Eq. 2})$$

또한, 본 연구에서는 시간에 따라 급기온도가 급격하게 변하는 비현실적인 제어를 방지하기 위해, 급기온도 변화에 대한 안정성을 고려한 항  $\lambda(t_{s,t} - t_{s,t-1})^2$ 을 목적함수에 추가하였다. 해당 안정성 항은 현재 시간의 급기온도와 이전 시간의 급기온도 간의 차이를 최소화하도록 구성되며, 이를 통해 연속적인 제어 특성을 반영할 수 있다. 본 연구에서는 에너지 최소화 및 제어 안정성 간의 균형을 고려하여 급기온도 변화에 대한 페널티 계수  $\lambda$ 를 설정하였다.

급기온도 변화에 대한 페널티 계수  $\lambda$ 는 제어 안정성과 에너지 절감 간의 상충 관계를 조절하는 중요한 파라미터로 작용한다.  $\lambda$  값이 너무 작은 경우 급기온도의 급격한 변동이 발생하며, 반대로 값이 과도하게 클 경우 급기온도 변화가 억제되어 에너지 최적화 효과가 감소하는 경향이 나타난다. 이에 본 연구에서는 0부터 1000까지의 다양한  $\lambda$  값을 적용한 사전 시뮬레이션을 수행하여 급기온도의 변동성과 에너지 소비를 분석하였다. 그 결과 제어 안정성과 에너지 성능 간의 균형을 고려하여 안정적인 운전과 에너지 절감 효과를 동시에 확보할 수 있는 값으로  $\lambda = 500$ 을 최종적으로 적용하였다.

#### 2) 제어변수 설정

급기온도는 본 연구에서 단일 제어변수로 설정되었다. 급기온도는 HVAC 시스템의 에너지 소비 특성에 직접적인 영향을 미치는 주요 제어변수로, 공조기 출구에서 결정되어 공급 덕트를 통해 각 층으로 전달되는 공기의 상태를 정의하는 변수 중 하나이다. 시스템의 풍량, 냉각코일 부하, 냉동기 에너지 소비 및 재열 부하 등에 직접적인 영향을 미치며, 설정 범위에 따라 냉동기 및 팬 에너지 소비 간의 상충 관계가 발생한다. 일반적으로 급기온도가 낮을 경우 냉각코일 부하 증가로 인해 냉동기 에너지 소비가 증가하는 반면, 급기온도가 높을 경우 동일 부하를 만족하기 위한 공급 풍량 증가로 인해 팬 에너지 소비가 증가하는 경향을 보인다. 또한, 급기온도는 실내 열쾌적 및 제습 성능과도 밀접한 관련이 있으므로, 과도하게 높은 또는 낮은 설정은 시스템 운전의 안정성을 저하시킬 수 있다.

따라서 일반적인 공조 시스템에서는 약 12~13°C (12.8°C) 수준의 급기온도가 일반적으로 사용되며, 최근에는 외기 조건 및 부하 변화에 따라 급기온도를 가변적으로 조절하는 급기온도 재설정(SAT Reset)이 적용되고 있다. 이러한 연구들과 운전 관행을 고려할 때, 급기온도의 제어 범위는 기존 설계 기준을 포함하면서도 운전 유연성을 확보할 수 있는 범위로 설정하는 것이 필요하다.

이에 본 연구에서는 기존 운전 기준을 포함한 범위 내에서 에너지 절감 가능성을 고려한 확장된 운전 범위를 반영하여 급기온도 제어 범위를 12°C에서 18°C로 설정하였다. 해당 범위는 냉동기와 팬 에너지 간의 상충 관계를 충분히 반영할 수 있으며, 동시에 실제 시스템 적용 가능성을 고려한 현실적인 운전 범위로 판단된다.

## 3. 적용 대상 및 해석 조건

### 3.1. 대상 건물 및 시스템 구성

본 연구에서는 상업용 중형 건물을 대표하는 DOE Medium Office[19]를 대상 건물로 설정하였으며, 냉방 기간인 6월부터 9월까지의 HVAC 시스템 운전을 분석하였다. 시스템의 운전시간은 실제 사무용 건물의 운영 특성을 반영하여 09:00부터 18:00까지로 설정하였으며, 해당 시간 동안 실내 냉방 설정온도는 26°C로 유지되도록 하였다. 이러한 운전 조건은 일반적인 사무용 건물의 냉방 운전 환경을 반영하기 위한 것으로, 시간에 따른 부하 변화와 외기 조건 변화가 시스템 운전 에 미치는 영향을 분석할 수 있도록 하였다.

대상 건물의 공조 시스템은 냉동기와 공조기(Air Handling Unit, AHU)로 구성된 중앙공조시스템으로 가정하였다. 외기는 외기패퍼

를 통해 공조기로 유입되며, 환기 요구량을 만족하기 위해 일정 비율의 외기가 도입된다. 유입된 외기는 반환 공기(Return air)와 혼합되어 혼합 공기(Mixed air)를 형성하며, 이후 냉각코일을 통과하면서 공기의 온도 및 습도가 조절된다. 냉각코일에서 처리된 공기는 공급 팬에 의해 가압되어 덕트를 통해 각 존으로 전달되며, 존에서는 내부 열부하를 처리하게 된다. 이후 일부 공기는 배출되며, 나머지는 환류되어 다시 공조기로 반환되는 순환 구조를 가진다.

이와 같은 시스템 구성은 일반적인 사무용 건물에서 적용되는 단일 덕트 기반 중앙공조시스템의 운전 형태를 반영한 것으로, 공기 흐름과 열부하 처리 과정이 명확하게 정의되는 특징을 가진다. 또한, 냉동기는 냉각코일에 필요한 냉수를 생산하여 공급하는 형태로 공기 냉각을 담당하며, 시스템 전체의 냉방부하를 처리하는 주요 설비로 작동한다.

Fig. 2.는 본 연구에서 적용한 HVAC 시스템의 구성과 공기 흐름, 그리고 급기온도 제어 위치를 나타낸다. 그림에서와 같이 급기온도는 공조기 출구에서 제어되며, 이는 각 존으로 공급되는 공기의 상태를 결정하는 기준점으로 작용한다. 대상 건물 및 HVAC 시스템의 주요 조건과 설계 사양을 정리하면 Table 1.과 같다.

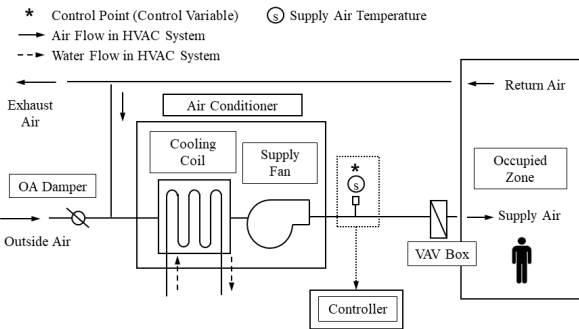


Fig. 2. Schematic of the HVAC system and control point for supply air temperature

Table 1. Design conditions and system parameters of the HVAC system used in this study

Component	Parameter	Value	Unit
Building	Number of zones	15	-
	Floor area	4982	m <sup>2</sup>
	Occupancy density	18.58	m <sup>2</sup> /person
	Lighting density	6.0	W/m <sup>2</sup>
	Equipment load	8.0	W/m <sup>2</sup>
	Cooling setpoint	26	°C
	Operating hours	09:00~18:00	-
	Infiltration rate	0.3	ACH
Air system	Supply air temperature	12~18	°C
	Design airflow rate	14.01	m <sup>3</sup> /s
	Fan efficiency	0.7	-
Chiller	Reference capacity		W
	COP	5.0	-
	Leaving chilled water temp	6.7	°C
Pump	Design flow rate	0.008381	m <sup>3</sup> /s
	Design pump head	179352	Pa
	Pump efficiency	0.7	-

공기계통은 급기온도 12~18°C 범위, 설계 풍량 14.01m<sup>3</sup>/s 및 팬 효율 0.7을 기준으로 설정하였다. 냉동기는 수냉식 전기식 냉동기를 대상으로 하였으며, 냉수 출구온도 6.7°C 및 응축수 입구온도 29.4°C 조건에서 COP 5.0의 기준 성능을 적용하였다. 또한 펌프는 설계 유량 0.008381m<sup>3</sup>/s, 설계 양정 179,352Pa 및 효율 0.7을 적용하였다.

### 3.2. 입력 데이터

본 연구에서는 HVAC 시스템 운전 해석을 위해 시간 단위의 부하 및 외기 데이터 등을 주 입력 데이터로 사용하였다. 외기 데이터는 기상청의 종관기상관측자료[20]에서 다운로드한 2025년도 서울지역의 외기 데이터를 이용하였으며, 건물의 시간 단위의 냉방부하는 EnergyPlus를 이용하여 결과데이터를 생성하였다. 입력 데이터는 1시간 간격으로 구성되었으며, 냉방 기간 동안 시간별 변동 특성을 반영할 수 있도록 설정하였다.

외기 데이터는 건기온도와 상대습도를 포함하도록 구성하였다. 건기온도는 외기 열부하 및 냉각 요구량에 직접적인 영향을 미치는 주요 변수이며, 상대습도는 공기 상태 및 냉각코일 부하에 영향을 주는 요소로 에너지 해석 시에 계산을 위한 변수로 사용된다. 이러한 외기 조건은 시간에 따라 변화하는 환경 조건을 반영하여 시스템 운전 입력된다.

부하 데이터는 건물 내 열부하를 나타내는 값으로, 시간에 따라 변화하는 냉방 요구량을 반영한다. 본 연구에서는 시간별 냉방부하를 입력 변수로 사용하였으며, 이는 통합 기계학습 기반 부하 예측 모델의 입력 및 HVAC 해석 모델의 주요 입력으로 활용된다.

입력 데이터는 전체 해석 기간 동안 시간 순서에 따라 순차적으로 적용되며, 각 시간 단계에서의 부하 및 외기 조건이 시스템 운전 조건을 결정하는 기준으로 사용된다. 이러한 데이터 구성은 시간에 따른 부하 변동과 외기 조건 변화가 HVAC 시스템 운전에 미치는 영향을 분석할 수 있도록 한다.

### 3.3. 운전 및 비교 조건

본 연구에서는 통합 기계학습 알고리즘 기반 최적 운전의 효과를 평가하기 위하여 기준 운전(Baseline)과 최적 운전 조건을 설정하였다.

기준 운전은 급기온도를 일정한 값으로 유지하는 방식으로 정의하였으며, 이는 일반적인 급기온도가 12.8°C로 일정하게 유지되는 운전 조건을 나타낸다. 반면, 최적 운전은 통합 기계학습 알고리즘을 통해 시간별로 급기온도를 결정하는 방식(ILMA Control)으로 정의하였다. 이 경우 각 시간 단계에서 예측된 부하를 기반으로 에너지 소비를 최소화하는 급기온도가 도출되며, 해당 값이 해당 시간의 운전 변수로 적용된다.

급기온도는 사전에 정의된 범위 내에서 제어되도록 설정하였다. 이는 시스템 운전의 안정성과 실현 가능성을 고려한 조건으로, 과도한 저온 또는 고온 운전을 방지하기 위함이다. 또한, 본 연구에서는 냉방기간 동안 공조 시스템 운전시간을 대상으로 해석을 수행하였으며, 해당 시간 구간에 대해 기준 운전과 최적 운전 결과를 비교하였다. 이를 통해 시간에 따른 운전 변화와 에너지 소비 특성을 종합적으로 평가하였다.

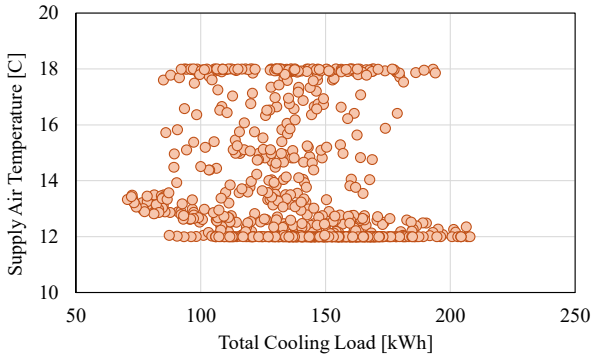


Fig. 3. Distribution of optimal supply air temperature with respect to total cooling load

## 4. 결과 및 분석

### 4.1. 급기온도 최적 운전 결과

통합 기계학습 알고리즘을 통해 도출된 시간별 최적 급기온도의 분포 특성을 분석하였다. Fig. 3.은 전체 해석 기간 동안의 총 냉방부하와 이에 대응하는 최적 급기온도의 관계를 나타낸다.

Fig. 3.에서 확인할 수 있듯이, 최적 급기온도는 연속적인 분포를 보이기보다는 특정 구간에 집중되는 경향을 나타냈다. 특히 약 12°C와 18°C 부근에서 높은 빈도로 나타나며, 이는 급기온도에 따른 에너지 소비 특성이 비선형적으로 작용한 결과로 해석된다.

저부하 영역에서는 급기온도가 설정된 하한의 급기온도 보다 상대적으로 높은 값이 주로 선택되는 경향을 보인다. 이는 냉방부하가 작을 경우 냉동기 에너지 소비의 영향은 감소하고, 공급 풍량 증가에 따른 팬 에너지 증가가 상대적으로 크지 않기 때문에 높은 급기온도가 에너지 측면에서 유리하게 작용하기 때문이다.

반면, 고부하 영역에서는 약 12°C 근처의 낮은 급기온도가 선택되는 경향이 뚜렷하게 나타난다. 이는 냉방부하가 커질수록 요구되는 냉각량을 만족하기 위해 낮은 급기온도가 훨씬 유리하며, 이 경우 팬 에너지 증가량보다 냉동기 효율 개선으로 인한 열원의 절감 효과가 상대적으로 크게 작용하기 때문이다.

일부 구간에서는 13~16°C 범위의 중간 급기온도가 선택되는 경우도 확인되며, 이는 냉동기와 팬 에너지 간의 trade-off가 유사한 수준으로 나타나는 조건에서 발생한 것으로 판단된다. 그러나 전체적으로는 특정 운전 조건에 따라 두 가지 대표적인 운전 모드(저온 운전 또는 고온 운전)가 형성되는 경향이 지배적인 경계 쏠림 현상(Boundary-Hugging)이 주로 나타났다.

이와 같은 결과는 급기온도가 단일 고정값으로 운전되기보다, 부하 조건에 따라 가변적으로 제어될 필요가 있음을 시사하며, 통합 기계학습 알고리즘 기반 최적 운전 방법이 이러한 동적 운전 특성을 효과적으로 반영할 수 있음을 보여준다. 한편으로는 이러한 운전 패턴이 실제 제어에서는 운전 시 제어장치(Actuator)에 부담을 줄 수 있어 실제 제어나 알고리즘을 개선 시 참고가 될 수 있다.

### 4.2. 에너지 소비 비교

본 연구에서는 통합 기계학습 알고리즘 기반 최적 운전(ILMA

Table 2. Component-wise and total energy consumption comparison between baseline and ILMA control

Component	Baseline (kWh)	ILMA control (kWh)	Reduction (kWh)	Reduction rate (%)
Chiller	79492.0	73748.5	5743.6	7.2%
Pump	2732.6	2483.7	248.9	9.1%
Fan	3157.2	4075.3	-918.1	-29.1%
Total	85381.8	80307.5	5074.3	5.9%

Control)에 따른 HVAC 시스템의 에너지 소비 특성을 정량적으로 평가하기 위해 전체 에너지 소비량과 냉동기, 펌프 및 팬의 설비별 에너지 소비량을 비교 분석하였다.

#### 1) 전체 에너지 소비량 비교

Table 2.는 기준 운전과 ILMA Control에 따른 설비별 및 총 에너지 소비를 비교한 결과를 나타낸다.

전체 에너지 소비의 결과, 기준 운전(Baseline)에서 총 에너지 소비는 85,381.8kWh로 나타났으며, ILMA Control 적용 시 80,307.5kWh로 감소하였다. 이는 약 5,074.3kWh의 절감에 해당하며, 약 5.9%의 에너지 절감 효과를 나타낸다. 이러한 결과는 급기온도를 부하 조건에 따라 가변적으로 최적화하여 제어함으로써 HVAC 시스템의 전체 에너지 소비를 효과적으로 저감할 수 있음을 보여준다.

냉동기 에너지는 79,492.0kWh에서 73,748.5kWh로 감소하여 약 5,743.6kWh, 7.2%가 절감되었으며, 펌프 에너지는 2,732.6kWh에서 2,483.7kWh로 약 248.9kWh, 9.1%가 절감되었다. 반면, 팬 에너지는 3,157.2kWh에서 4,075.3kWh로 약 918.1kWh, 29.1%가 증가하였다. 전체적으로는 냉동기 에너지 절감 효과가 팬 에너지 증가를 상회하여 시스템 전체의 에너지 소비 감소로 이어진 것으로 나타났다.

#### 2) 월별 에너지 소비량 비교

Fig. 4.는 6월부터 9월까지 시스템의 전체 에너지 소비량을 월별로 분석한 결과이다. 6월의 경우 기준 운전에서 16,428.1kWh에서 ILMA Control 적용 시 14,311.5kWh로 감소하여 약 2,116.6kWh, 12.9%의 절감이 나타났다. 7월에는 27,247.3kWh에서 26,412.9kWh로 감소하여 약 834.4kWh인 3.1%가 절감되었으며, 8월에는 23,648.7kWh에서 23,387.1kWh로 약 261.5kWh, 1.1% 감소하였다. 9월에는 18,057.7kWh에서 16,196.0kWh로 약 1,861.8kWh, 10.3%의 절감이 나타났다. 전반적으로 부분부하 조건이 지배적인 기간인 6월과 9월에 상대적으로 더 큰 절감 효과가 나타났으며, 고부하 조건인 7월과 8월에는 절감률이 다소 제한적인 경향을 보였다.

설비별 에너지 소비 특성을 분석하면 다음과 같다. Fig. 5.는 6월부터 9월까지 냉동기의 에너지 소비량을 월별로 분석한 결과이다. 냉동기 에너지 소비량은 모든 기간 감소하는 경향을 나타냈다. 월별로는 6월에 16.4%, 7월 3.3%, 8월 0.9%, 9월 13.1%의 감소율을 보여, 전체 시스템의 에너지 감소와 유사한 패턴을 나타낸다. 이는 냉방부하 크기에 따른 급기온도 상승이 냉각코일 부하를 감소시켜 냉동기 에너지 절감에 효과적으로 기여한 결과로 해석된다.

Fig. 6.은 6월부터 9월까지 공조 시스템 냉수 순환 펌프의 에너지

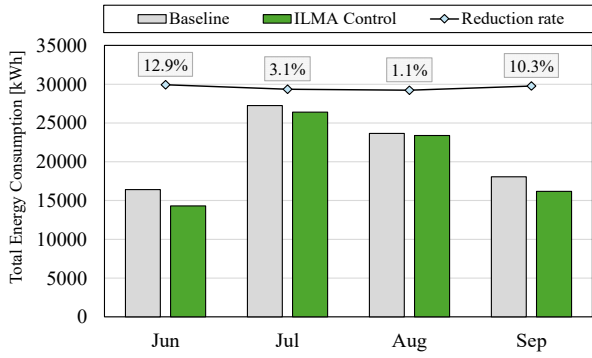


Fig. 4. Monthly total energy consumption under baseline and ILMA control conditions




Fig. 5. Monthly chiller energy consumption under baseline and ILMA control conditions

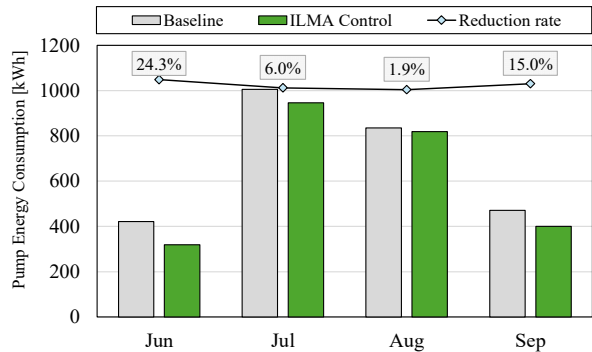


Fig. 6. Monthly pump energy consumption under baseline and ILMA control conditions

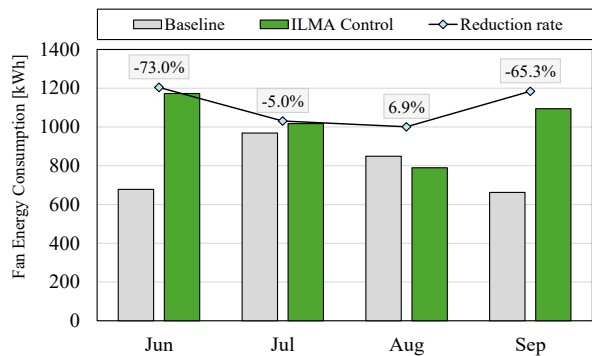


Fig. 7. Monthly fan energy consumption under baseline and ILMA control conditions

소비량을 월별로 분석한 결과이다. 펌프 에너지 소비량 또한 모든 기간에 감소하는 경향을 나타냈다. 월별로는 6월에 24.3%, 7월에서 약 6.0%, 8월에서 약 1.9%, 9월에서 약 15.0% 감소하였다. 이는 냉동기 운전이 줄어들면서 공조기 내의 냉각코일에 공급되는 냉수 유량이 감소하여 펌프 동력도 함께 줄어든 결과로 판단된다.

Fig. 7.은 6월부터 9월까지 공조 시스템 팬의 에너지 소비량을 월별로 분석한 결과이다. 팬 에너지 소비량은 냉동기와 펌프와는 달리 일부 기간에서 증가하는 경향을 보였다. 특히 6월에서는 677.9kWh에서 1,172.9kWh로 약 495.0 kWh, 73.0%가 증가하였고, 9월에서는 662.0kWh에서 1,094.6kWh로 약 432.5kWh, 65.3%가 증가하였다. 이는 급기온도 상승에 따라 동일한 냉방부하를 처리하기 위해 공급 풍량이 늘어나면서 팬 동력이 증가한 결과로 해석된다. 반면, 7월에서는 약 5.0% 증가, 8월에서는 약 6.9% 감소가 나타나 부하 조건에 따라 팬 에너지 변화 양상이 다르게 나타났다.

종합적으로, 통합 기계학습 알고리즘 기반 최적제어는 냉동기 및 펌프 에너지 소비를 감소시키는 동시에 일부 조건에서 팬 에너지 증가를 동반하는 특성을 나타냈으며, 전체적으로는 냉동기와 펌프를 포함하는 열원 측(water-side)의 에너지 절감 효과가 팬을 포함한 송풍 측(air-side)의 에너지 증가를 상회하여 전체 시스템의 에너지 소비 감소로 이어지는 것으로 분석된다. 이는 급기온도 제어에 따른 설비 간 에너지 소비의 상충 관계(trade-off)가 반영된 결과로, 제안된 통합 기계학습 기반 최적 운전 방법이 이러한 상호작용을 효과적으로 고려하고 있음을 보여준다.

## 5. 결론

본 연구에서는 HVAC 시스템의 에너지 절감을 위해 통합 기계학습 알고리즘(Integrated Machine Learning Algorithm, IMLA)을 기반으로 한 급기온도 최적 제어 방법을 제안하였다. 제안된 방법은 인공지능영향을 활용한 부하 예측과 최적화 기법을 통합하여, 미래 부하를 반영한 급기온도 운전 전략을 도출할 수 있도록 구성하였다. 이를 통해 기존의 현재 부하 기반 반응형 제어 방식에서 벗어나, 선제적 운전 전략 수립이 가능하도록 하였다.

연구 결과, 통합 기계학습 알고리즘 기반 급기온도 최적제어를 적용하였을 때, 전체 에너지 소비는 기존 운전 대비 85,381.8kWh에서 80,307.5kWh로 감소하여 약 5,074.3kWh가 감소되었으며, 5.9%의 에너지 절감 효과가 나타났다. 월별 분석 결과에서도 모든 기간에서 에너지 소비 감소가 확인되었으며, 특히 부분부하 조건이 유리하고 부하가 상대적으로 작은 6월과 9월에는 상대적으로 높은 절감률이 나타났다. 이는 냉방부하의 부하량이 작은 기간에 기계학습 기반 알고리즘이 높은 급기온도를 선택함으로써 인해서, 급기온도 상승에 따른 냉동기 운전 감소의 효과가 크게 작용한 결과로, 부하 수준에 따라 급기온도 제어의 에너지 절감 효과가 달라짐을 확인할 수 있다.

실비별 에너지 소비 분석 결과, 냉동기 및 펌프 에너지는 전반적으로 감소하는 반면, 팬 에너지는 일부 조건에서 증가하는 경향을 보였다. 이는 급기온도 제어에 따라 냉동기와 팬 에너지 소비량 간의 상충 관계가 형성되기 때문이며, 전체적으로는 열원 측인 냉동기 및 펌프의 에너지 소비량 절감 효과가 송풍 측인 팬 에너지 소비량의 증

가를 상회하여 전체 에너지 절감으로 이어지는 것으로 나타났다. 이러한 결과는 HVAC 시스템의 에너지 최적화 및 최적제어가 개별 설비 단위가 아닌, 시스템 전체 관점에서 접근되어야 함을 보여준다.

또한, 최적 급기온도는 단일 값으로 수립하기보다 부하 조건에 따라 서로 다른 영역에서 선택되는 경향을 나타냈으며, 이는 HVAC 시스템의 최적 운전이 고정된 설정값이 아닌, 운전 조건에 따라 변화하는 동적 제어 전략으로 이루어져야 함을 시사한다. 즉, 급기온도 제어는 단순한 설정값 조정이 아니라, 시스템 전체의 에너지 흐름을 조정하는 제어 변수로 작용함을 확인할 수 있다.

본 연구에서 제안한 통합 기계학습 알고리즘 기반 최적 운전 방법은 HVAC 시스템의 에너지 절감뿐 아니라 설비 간 에너지 상호작용을 반영한 효율적인 운전 전략을 도출하는 데 효과적인 접근 방법임을 확인하였다. 또한, 예측 기반 제어, 물리 모델 기반 해석, 최적화 방법을 통합함으로써, 실제 건물 운영 환경에서도 적용 가능한 실용적인 제어 프레임워크로 활용될 수 있는 가능성을 제시하였다. 향후 연구에서는 개발된 통합 기계학습 알고리즘의 특징점을 활용하여 다양한 기후 조건 및 건물 유형에 대한 적용은 물론, 냉동기의 냉수 공급 온도 제어, 덕트 정압 제어와 같은 추가적인 공조설비의 제어 변수 확장을 통해 최적제어 변수 도출을 통한 공조설비의 에너지 절약 성능을 다방면으로 검토하여 보다 고도화되고 고성능의 공조 시스템 최적 운전 전략을 개발할 예정이다.

## Acknowledgement

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. RS-2023-00248898).

## References

- [1] International Energy Agency, Energy efficiency 2023, IEA, 2023.
- [2] D. Ürge-Vorsatz et al., Heating and cooling energy trends and drivers in buildings, *Renewable and Sustainable Energy Reviews*, 41, 2015, pp.85-98.
- [3] S.L. Zhou et al., A comprehensive review of the applications of machine learning for HVAC, *DeCarbon*, 2, 2023, 100023.
- [4] J. Drgoňa et al., All you need to know about model predictive control for buildings, *Annual Reviews in Control*, 50, 2020, pp.190-232.
- [5] P. Raftery et al., Evaluation of a cost-responsive supply air temperature reset strategy in an office building, *Energy and Buildings*, 158, 2018, pp.356-370.
- [6] H. Elehwany et al., Evaluating common supply air temperature setpoint reset strategies with varying occupancy patterns and behaviours, *Building and Environment*, 266, 2024, 112129.
- [7] N. Nassif et al., New optimal supply air temperature and minimum zone air flow resetting strategies for VAV systems, *Buildings*, 12(3), 2022, 348.
- [8] R. Jin et al., Review of optimization control methods for HVAC systems in demand response: Transition from model-driven to model-free approaches and challenges, *Building and Environment*, 280, 2025, 113045.
- [9] Y. Miao et al., Research on optimal control of HVAC system using swarm intelligence algorithms, *Building and Environment*, 241, 2023, 110467.
- [10] Y. Sun et al., Optimal control strategy for building HVAC systems: Satisfying flexible demand response with different value-based selection, *Energy and Buildings*, 323, 2024, 114823.
- [11] D. Kim et al., Energy modeling and model predictive control for

- HVAC in buildings: A review of current research trends, *Energies*, 15(19), 2022, 7231.
- [12] K. Bamdad et al., Model predictive control for energy optimization of HVAC systems using EnergyPlus and ACO algorithm, *Buildings*, 13(12), 2023, 3084.
- [13] P. Michailidis et al., Model-free HVAC control in buildings: A review, *Energies*, 16(20), 2023, 7124.
- [14] K. Al Sayed et al., Reinforcement learning for HVAC control in intelligent buildings: A technical and conceptual review, *Journal of Building Engineering*, 95, 2024, 110085.
- [15] H. Huang, B.R. Hughes, Review of HVAC forecasting and control strategies for improved building performance, *Building and Environment*, 287, 2025, 113797.
- [16] M. Kim, S. Kwon, Real-time HVAC control for utilizing demand response and renewable energy using optimization-informed supervised learning, *Energy and Buildings*, 344, 2025, 115954.
- [17] H. Wang et al., A machine learning-based control strategy for improved performance of HVAC systems in providing large capacity of frequency regulation service, *Applied Energy*, 326, 2022, 119962.
- [18] C. Liao et al., Year-round operational optimization of HVAC systems using hierarchical deep reinforcement learning for enhancing indoor air quality and reducing energy consumption, *Applied Energy*, 390, 2025, 125816.
- [19] M. Deru et al., U.S. Department of Energy commercial reference building models of the national building stock, National Renewable Energy Laboratory, 2011.
- [20] 기상청, 기상자료개방포털, <https://data.kma.go.kr>, 2026.03.08. // (Korea Meteorological Administration, Open MET data portal, <https://data.kma.go.kr>, 2026.03.08.)