

사용자 피드백을 반영한 스마트 조명 목표 디밍 레벨 예측 모델

김서연¹, 이준희², 김대호², 성정식², 전윤호³

^{1,3}국립한밭대학교, ²한국전자통신연구원 자율형 IoT 연구실

¹syeeon@edu.hanbat.ac.kr, ²{aloha, dhkim7256, jssung}@etri.re.kr, ³yhjeon@hanbat.ac.kr

User Feedback based Prediction Model for Target Dimming Levels in Smart Light

Seoyeon Kim¹, Junhee Lee², Daeho Kim², Jung-Sik Sung², and Yunho Jeon¹

¹Hanbat National University, ²Autonomous IoT Research Section ETRI

요약

스마트 조명 시스템의 자동 제어 방식은 불필요한 에너지 소비를 줄이는 데 효과적이지만, 사용자 선호를 충분히 반영하지 못하는 한계가 있다. 본 논문에서는 사용자의 조명 사용 패턴과 피드백 데이터를 기반으로 조명의 목표 디밍 레벨을 자동 예측하는 시스템을 제안한다. 이를 위해 데이터 불균형 문제를 고려한 2단계 예측 모델 구조를 적용하였으며, 그 결과 사용자 선호를 반영한 보다 정밀한 목표 디밍 레벨 예측이 가능함을 확인하였다.

I. 서론

스마트 조명 시스템은 에너지 절감과 사용자 편의성 향상을 동시에 달성하는 중요한 기술이다. 기존의 단순한 조명 제어 방식과 달리 스마트 조명 시스템은 조명 기기와 센서들이 유·무선 네트워크로 연결되어 있으며 사전에 정의된 시나리오에 의해 조명 디밍 레벨(밝기)을 자동 조절하거나 모션 감지 센서를 기반으로 점·소등 및 밝기 조절을 수행함으로써 사용자의 개입 없이도 효율적인 조명 환경을 제공할 수 있다[1]. 이러한 시스템은 불필요한 에너지 소비를 효과적으로 줄일 수 있다는 장점이 있지만 사용자의 피드백을 반영하지 못한다는 한계가 있다. 일부 사용자들은 자동 제어되는 조명 밝기에 만족하지 못해 수동으로 조명을 제어한다. 그러므로 사용자의 조명 사용 패턴과 선호도를 반영한 사용자 피드백 데이터를 기반으로 조명의 목표 디밍 레벨을 자동으로 예측하는 기능이 필요하다. 여기서 목표 디밍 레벨이란 특정 시점에서 조명이 도달해야 하는 목표 밝기값으로 현재 환경에서 수집된 센서 값, 사용자 선호도 등을 반영해 결정되어야 한다. 시스템은 환경 요인과 사용자 패턴을 학습하여 유사한 조건에서 요구되는 밝기 수준을 자동으로 예측하고, 이를 기반으로 목표 디밍 레벨을 향해 조명의 밝기가 자연스럽게 조정될 필요가 있다.

따라서 본 논문에서는 스마트 조명 시스템에서 사용자의 선호를 반영한 목표 디밍 레벨을 예측하는 방법을 제안한다. 이를 위해 데이터 불균형 문제를 고려한 2단계 예측 구조를 설계하고, 각 단계에 머신러닝 기법을 적용하였다. 1단계에서는 조명의 점등 여부를 예측하고, 2단계에서는 조명이 켜져 있는 경우에 한해 목표 디밍 레벨을 예측하도록 설계하였다. 이러한 순차적 예측 과정을 통해 데이터 불균형의 영향을 완화하면서도 보다 정확한 밝기 수준 예측이 가능하다. 본 연구의 궁극적 목표는 사용자가 수동으로 직접 밝기를 조절해야 하는 불편을 줄이는 동시에 에너지 절감과 사용자 만족도 향상에 기여하는 스마트 조명 시스템을 구현하는 데 있다. 두 과정이 순차적으로 이루어져 데이터 불균형의 영향을 줄이면서 비교적 정확한 밝기 예측이 가능하다. 이를 활용하여 사용자가 수동으로 밝기를 조절해야 하는 불편을 줄일 뿐만 아니라 에너지를 절감하며 사용자 만족도를 높이는 방향으로 시스템을 발전시키는 것을 목표로 한다.

II. 주거 조명 데이터 전처리

1. 데이터 정보

스마트 조명 시스템의 사용자 맞춤형 목표 디밍 레벨을 예측하기 위해 아파트 거주 한 가구의 침실 조명 데이터를 사용하였다. [2]는 이 아파트 거주 가구들의 조명 에너지 소비 특성을 다양한 패턴으로 분석한 연구로, 본 논문에서 다루는 데이터의 특성과 해석을 이해하는데 중요한 참고가 된다. 본 연구에서 사용된 데이터는 2023년 8월 1일부터 2024년 12월 31일 까지의 기간 동안 수집된 데이터로, 5분 간격으로 주기적으로 수집되는 리포트 데이터와 상태 변화가 발생하면 수집되는 상태 데이터들로 구성되어 있으며 총 약 14만 건의 데이터가 존재한다.

2. 데이터 전처리

시계열 데이터이기 때문에 시간의 흐름을 반영하고자 시간 정보를 분 단위로 표현하였다. 또한, 날짜 데이터와 사용자 조작 여부, 직전 디밍 레벨, 최근 20회 디밍 레벨의 평균 및 분산, 디밍 레벨의 지속시간, 변화량 등 시계열 관련 특징 변수(feature)를 추가하였다. 본 연구에서 사용된 모든 특징 변수는 데이터 누수(data leakage)를 방지하기 위해 과거 시점의 값으로만 구성하였으며, 이를 통해 시계열 데이터의 특성을 효과적으로 반영하도록 설계하였다. 실제 조명 시스템 환경에서는 설정이나 센서 특성으로 인해 결측값이 발생할 수 있다. 결측값을 임의로 채워줄 경우, 실제 조명 상태와 일치하지 않는 왜곡된 값이 생성될 수 있으며 채워진 값이 옳바르다는 보장이 없다[3]. 따라서 결측값을 별도로 처리하지 않고, 결측값을 자연스럽게 학습 과정에서 처리할 수 있는 트리 기반 모델을 사용하였다. 모델이 미래 정보를 미리 학습하지 않으며 실제 환경과 유사한 조건에서 학습될 수 있도록 데이터를 전처리하였다.

3. 데이터 분할

총 14만 개의 데이터에서 약 8:1:1 비율로 train(학습):val(검증):test(확인) 데이터를 구성하였다. 2024년 9월 1일 데이터를 기준으로 train과 val을 나누고 2024년 11월 14일을 기준으로 val과 test를 구분하였다. 이러한 분할 방식으로 시간 순서를 유지하였다.

III. 조명 목표 디밍 레벨 산출 2단계 예측 모델

1. 2단계 예측 모델 설계 배경

조명 디밍 레벨을 살펴본 결과, 각 구간별 비율은 [표 1]과 같다.

[표 1] 조명 디밍 레벨의 각 구간별 비율

조명 디밍 레벨 구간	비율(%)
0	91.07
1-10	0.53
11-30	0.82
31-60	1.32
61-80	1.21
81-100	5.04

조명 디밍 레벨의 구간이 0이 경우가 약 91%로 대부분을 차지한다. 이는 조명이 켜져 있는 경우가 12,781개, 조명이 꺼져 있는 경우가 130,384개로 매우 불균형하며 주기적으로 수집되는 리포트 데이터로 인해 on과 off 데이터의 수의 차이가 크게 나타나기 때문이다. 전체 데이터를 대상으로 목표 디밍 레벨을 예측할 경우, off 상태의 데이터가 예측 성능을 저해할 수 있다. 이를 해결하기 위해 예측 과정을 두 단계로 구분하였다. 1단계에서는 조명의 on/off 상태를 분류하고, 2단계에서는 on 상태에 한하여 목표 디밍 레벨을 회귀하도록 설계하였다.

2단계 구조에서 각각의 단계에 적용할 모델로는 Random Forest, XGBoost, LightGBM, Catboost를 사용하여 비교하였으며, 최종적으로 각 단계에서 성능이 가장 우수한 모델을 선택하여 사용하였다. 비교 과정에서 따로 파라미터를 설정하지 않고 각 모델의 기본 설정으로 학습하였으며, 결과의 재현성을 위해 랜덤 seed만 고정하여 진행하였다.

2. 조명 on/off 분류 모델

1단계에서는 전체 데이터를 활용하며 조명의 on/off 상태를 정확히 판단하는 것을 목표로 한다. 조명이 꺼져 있는 데이터가 많이 있기에 이 단계에서 정확하게 on 상태를 식별하는 것이 2단계 목표 디밍 레벨 예측의 성능에 매우 중요하다. 조명의 점·소등 예측 단계에서 모델 성능을 평가하기 위해 전체 정확도(Accuracy)와 on/off 클래스별 F1-score를 사용하였다.

[표 2] on/off 분류 예측 성능

Model	Accuracy	F1_on	F1_off
RandomForest	0.9999	0.9996	0.9999
XGBoost	0.9997	0.9992	0.9998
LightGBM	0.9901	0.9703	0.9941
Catboost	0.9999	0.9996	0.9999

on/off 분류 예측 성능은 모든 모델이 높은 정확도를 보였으나, 데이터가 불균형하므로 상대적으로 샘플 수가 적은 on 클래스의 F1-score를 주요 성능 지표로 삼았다. Random Forest 모델과 Catboost 모델이 on 클래스 F1-score 0.9996, off 클래스 F1-score 0.9999로 가장 우수한 성능을 보였다. on/off 예측 단계에 Random Forest 모델을 채택하였다.

3. 조명 목표 디밍 레벨 예측 모델

2단계에서는 1단계에서 on으로 분류된 데이터만을 대상으로 목표 디밍 레벨을 회귀 방식으로 예측한다. 즉, 조명이 실제로 켜져 있는 상황에서만 목표 디밍 레벨을 예측하도록 함으로써 off 데이터가 목표 디밍 레벨 예측에 영향을 주는 문제를 방지한다.

[표 3] 디밍 레벨 회귀 예측 성능

Model	RMSE_on
RandomForest	2.969
XGBoost	1.906
LightGBM	2.121
Catboost	1.070

조명이 켜져 있을 때는 디밍 레벨 값이 다양해 정확하게 예측하는 것이 중요하므로 모델 성능 평가 지표는 조명이 켜져 있을 때 RMSE를 사용하였다. CatBoost는 on 상태에서 rmse가 가장 낮아 조명 목표 디밍 레벨 예측 모델로 선택하였다.

4. 실험 및 평가

조명의 on/off 상태를 예측하는 1단계에서는 RandomForest를, 2단계에서는 목표 디밍 레벨을 예측하기 위해 CatBoost를 사용하였다. 또한, 최적의 하이퍼파라미터를 찾기 위해 베이지안 최적화 기반의 자동화 라이브러리인 Optuna를 활용하여 파라미터를 탐색하였다. 2단계로 나누어 진행했으므로 on/off 분류 정확도와 on 상태에서의 디밍 레벨 예측 정확도를 주요 성능 지표로 활용하였다.

[표 4] test data 예측 성능

	단일모델	2단계 모델
on/off 분류 성능	-	0.9989
on 상태 rmse	3.916	1.525
전체 RMSE	1.729	1.235

표 4는 test 데이터를 제안 시스템에 적용한 예측 결과를 나타낸다. 단일모델과 본 논문에서 제안한 2단계 모델 방식에 대해 성능을 비교하였다. on/off 분류 정확도는 0.9989로 매우 높게 나타났으며, 2단계 모델은 단일모델에 비해 RMSE를 낮추어 전반적인 예측 성능을 향상시켰다. 특히, on 상태에서의 RMSE가 3.916에서 1.525로 개선되어 목표 디밍 레벨 예측 정확도가 크게 높아졌고, 전체 RMSE 또한 1.729에서 1.235로 낮아져 제안한 2단계 구조의 효과성을 확인할 수 있었다.

IV. 결론

본 논문에서는 스마트 조명 시스템에서 사용자의 선호를 반영한 목표 디밍 레벨을 예측하는 시스템을 제안하였다. 제안된 시스템은 조명의 on/off 여부를 판단한 후 켜진 경우에만 목표 디밍 레벨을 예측하는 2단계 학습 구조를 통해 데이터 불균형 문제를 완화하고 기존 단일 단계 모델 대비 우수한 성능을 보였다. 다만, 한 세대 데이터만을 사용하므로 모델이 특정 사용자 패턴에 과적합될 가능성이 존재한다. 또한, 실시간으로 사용자 피드백이 발생하는 경우 기존 모델은 새로운 데이터를 즉시 반영할 수 없고 추가 학습이 필요하다는 한계가 존재한다. 향후 연구에서는 다양한 세대와 환경의 데이터를 포함하여 모델의 일반화 성능을 검증할 필요가 있으며, 시스템을 실시간으로 적응시키기 위해 강화학습을 적용하여 실시간으로 사용자 행동과 선호 변화에 따라 자동으로 목표 디밍 레벨을 조정할 수 있는 적응형 스마트 조명 시스템을 연구할 예정이다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다. (No. RS-2024-00441420)

참 고 문 헌

- [1] 정정식, 김대호, “스마트 조명 시스템의 통합 운영을 위한 요구사항, 구조 및 주소 체계,” 조명·전기설비 제38권, 제4호, pp29-34, 2024.
- [2] A. Khan et al., “Dynamic Temporal Analysis and Modeling of Residential Lighting Consumption for Energy Efficiency and Sustainability,” IEEE Access, Vol. 12, pp154365-154380, 2024.
- [3] 이경제, 임현우, “건물 에너지 데이터 분석에서 결측치 처리방식에 따른 차원 축소 및 모델 예측 성능 비교,” 한국태양에너지학회 논문집, 제44권, 제1호, pp59-75, 2024.