

실내 사람 위치 추적 기반 LSTM 모델을 이용한 고객 혼잡 예측 연구

채희주 · 광경현 · 이다연 · 김은경[†]

An Approach Using LSTM Model to Forecasting Customer Congestion Based on Indoor Human Tracking

Hee-ju Chae · Kyeong-heon Kwak · Da-yeon Lee · Eunkyung Kim[†]

ABSTRACT

In this detailed and comprehensive study, our primary focus has been placed on accurately gauging the number of visitors and their real-time locations in commercial spaces. Particularly, in a real cafe, using security cameras, we have developed a system that can offer live updates on available seating and predict future congestion levels. By employing YOLO, a real-time object detection and tracking algorithm, the number of visitors and their respective locations in real-time are also monitored. This information is then used to update a cafe's indoor map, thereby enabling users to easily identify available seating. Moreover, we developed a model that predicts the congestion of a cafe in real time. The sophisticated model, designed to learn visitor count and movement patterns over diverse time intervals, is based on Long Short Term Memory (LSTM) to address the vanishing gradient problem and Sequence-to-Sequence (Seq2Seq) for processing data with temporal relationships. This innovative system has the potential to significantly improve cafe management efficiency and customer satisfaction by delivering reliable predictions of cafe congestion to all users. Our groundbreaking research not only demonstrates the effectiveness and utility of indoor location tracking technology implemented through security cameras but also proposes potential applications in other commercial spaces.

Key words : LSTM, Indoor human location tracking, Congestion prediction, YOLO tracking

요약

본 연구는 실내 상업적 공간, 특히 카페에서 보안 카메라를 이용해 방문자 수와 위치를 실시간으로 파악하고, 이를 통해 사용 가능한 좌석 정보와 혼잡도 예측을 제공하는 시스템의 개발을 목표로 한다. 우리는 실시간 객체 탐지 및 추적 알고리즘인 YOLO를 활용하여 방문자 수와 위치를 실시간으로 파악하며, 이 정보를 카페 실내 지도에 업데이트하여 카페 방문자가 사용 가능한 좌석을 확인할 수 있도록 한다. 또한, 우리는 vanishing gradient 문제를 해결한 장단기 메모리(Long Short Term Memory, LSTM)와 시간적인 관계를 가지는 데이터를 처리하는데 유용한 시퀀스-투-시퀀스(Sequence-to-Sequence, Seq2Seq) 기법을 활용해 다양한 시간 간격에 따른 방문자 수와 움직임 패턴을 학습하고, 이를 바탕으로 카페의 혼잡도를 실시간으로 예측하는 시스템을 개발하였다. 이 시스템은 카페의 관리자와 이용자 모두에게 예상 혼잡도를 제공함으로써, 카페의 운영 효율성을 향상시키고, 고객 만족도를 높일 수 있다. 본 연구에서는 보안 카메라를 활용한 실내 위치 추적 기술의 효용성을 입증하며, 상업적 공간에서의 활용 가능성과 더불어 미래 연구 방향을 제시한다.

주요어 : LSTM, 실내 사람 위치 추적, 혼잡도 예측, YOLO 트래킹

* 본 연구의 일부 내용은 한국시물레이션학회 2023년도 춘계학술대회에서 발표(Chae et al. 2023)하였음.
본 연구는 2023년 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업의 연구결과로 수행되었음 (2022-0-01068)

Received: 20 July 2023, **Revised:** 30 August 2023,
Accepted: 13 September 2023

† Corresponding Author: Eunkyung Kim

E-mail: ekim@hanbat.ac.kr
Department of Artificial Intelligence Software,
Hanbat National University

1. 서론

1.1 연구 배경 및 관련 연구

혼잡도는 “여럿이 한데 뒤섞이며 어수선했”의 의미로 공간 내에 존재하는 인구밀도나 객체의 수량을 나타내는 지표로 사용된다. 최근 혼잡도 예측은 교통, 지하철, 관광 지 등 다양한 분야에서 중요한 이슈로 떠올랐다. 특히

2016년 알파고 대 이세돌 대국 이후로 인공지능은 우리나라에서 새로운 부흥기를 맞이하였고, 이로써 인공지능과 딥러닝을 활용한 혼잡도 예측 연구가 활발히 진행되고 있다. 이러한 기술의 발전은 인공지능과 딥러닝 모델이 대량의 데이터를 활용하여 숨겨진 패턴을 발견하고 학습하는데 중요한 역할을 하며, 이는 혼잡도 예측의 정확도를 높이는 데에 중요한 기여를 하고 있다.

혼잡도 예측은 주로 교통흐름 예측에 사용된다(Lee et al., 2020; Kim et al., 2019). 교통 혼잡도 예측은 도로 사용자들의 이동 효율을 향상시키고, 교통 체증을 줄이는데 중요한 역할을 한다. 또한, 지하철의 쾌적한 이용과 편리성을 제공하기 위한 혼잡도 예측도 활용되고 있다(Kim, 2016; Kim et al., 2015).

최근에 코로나19 팬데믹에 의해 혼잡도 예측의 중요성이 더욱 부각되었다. 일례로 제주관광공사는 2020년 12월, 통신사의 기지국 데이터를 활용하여 실시간 혼잡도와 3시간 후의 증감률을 지도 위에 표시하여 도내 관광객의 편의와 감염 예방 및 관리를 위해 실시간 혼잡도 서비스를 도입하였다(Kim et al., 2021).

기존의 대다수 연구에서는 공공데이터나 CCTV를 이용한 사람의 위치 추적 모니터링을 통해 모든 데이터를 통해 혼잡도를 예측한다(Kim, 2016; Kim et al., 2015; Kim, 2020; Choi et al., 2021) 특히, Choi et al.(2021)은 공원내의 사람과 텐트의 개수 변화를 기반으로 공원의 혼잡도를 계산하며, 이 결과를 “여유”, “보통”, “혼잡” 세 단계 분류하는 시스템을 제안하였다.

실내 공간의 혼잡도 예측을 위한 연구도 활발히 진행되고 있는데, Kwon et al.(2021)은 Proberquest를 활용한 디바이스 수 감지를 통한 인원수 추정 방법을 Kim et al.(2019)과 Lee et al.(2018)는 초음파 센서 기반의 실시간 인원 계수 시스템을 각각 제안하였다. 두 연구는 비상구를 통한 입장 인원의 실시간 카운팅에 초점을 맞추었다. 이들은 실내 실시간 위치 모니터링에 유용하나, 정확한 측정을 위해서는 비콘 또는 초음파센서의 추가 설치가 필요하다는 한계를 지닌다.

그러나 Kim et al.(2021)은 YOLO를 활용하여 영상 데이터만으로 실시간으로 카페 출입자 수를 파악하였다. 그리고 혼잡상태를 다양한 색으로 구분하여 표시하는 연구를 수행하였다. 이 방법의 큰 장점은 추가 장비 설치 없이도 실내 혼잡도를 예측할 수 있다는 것이다.

본 연구는 이러한 기존 연구를 바탕으로, 실시간 실내 영상 데이터를 사용하여 현재 혼잡도를 측정하고 이를 활용한 혼잡도 예측을 진행하였다.

1.2 문제 정의

실내 상업적 공간에서의 혼잡도 예측은 고객의 접근성 및 운영 효율성 향상을 위해 고객 수의 정확한 파악과 예측이 필요하다. 필요한 재고와 재료의 양, 그리고 운영에 필요한 노동력을 적절하게 추정하고 조절하는 등의 효율적인 운영을 위해서는 고객 수의 정확한 파악과 예측은 핵심적인 요소가 된다. 또한, 고객의 입장에서도 카페 내 인원수가 과도하게 많아 서비스 만족도가 떨어지는 경우를 방지하기 위해 혼잡도 예측은 중요하다. 본 연구에서는 상업적 공간 안의 방범용 카메라를 활용하여 실시간 영상 정보를 통해 객체를 탐지하고 추적하는 방법을 도입하였다. 이를 통해 고객 수를 파악하고 예측을 제공하고자 한다.

본 연구에서는 실시간 실내 영상 정보를 활용하여 상업적 공간에서 사용되는 좌석의 현황을 파악하고, 이를 바탕으로 다양한 이용시간을 고려한 실시간 혼잡도 예측 시스템을 개발하였다. 이 시스템은 카페에서 발생하는 포장 주문에 무관하게 혼잡도를 예측할 수 있다. 포장 주문은 단순 주문 수로 혼잡도 예측할 때 혼선을 일으킬 수 있기 때문에, 이와는 별개로 혼잡도를 예측하는 것이 중요하다.

우리가 개발한 예측 시스템은 빠른 객체 탐지와 극단적인 상황에서도 안정적인 성능을 유지하는 YOLO(Ultralytics; Sultana et al., 2020)를 활용하여 실시간 객체 탐지를 수행한다. 특히 영상 처리는 YOLOv8 모델을 활용한 YOLOv8 Tracking코드를 사용하며, 이를 통해 실시간으로 카페 고객의 위치 정보를 추적한다(Brostom). 이 정보는 애플리케이션의 카페 실내 지도에 업데이트되어, 가게 운영자는 현재 카페 내부의 상황을 실시간으로 파악하고, 적절한 서비스를 고객들에게 제공할 수 있다. 또한, 고객의 위치 정보 데이터를 이용하여 가게의 이용객 수와 혼잡도의 변화를 파악하고 예측한다.

1.3 모델 설정

본 연구에서는 다양한 순환 신경망(Recurrent Neural Network, RNN) 모델과 기법들을 비교 분석하며, LSTM과 Sequence-to-Sequence(Seq2Seq)기법(Boukary, 2016)을 결합한 최적의 인원수 예측 모델을 제안한다. 이 모델은 카페 내부의 인원수를 효과적으로 예측하며, 장단기 메모리(Long Short-Term Memory, LSTM), 게이트 순환 유닛(Gate Recurrent Unit, GRU), Attention Mechanism과 같은 다양한 기법들에 비해 우수한 성능을 보여준다. 이에 대한 증명으로, 모델의 성능은 상세히 비교 분석되

고 결과가 제시될 것이다.

LSTM은 스마트 빌딩에서의 인원수 예측, 코로나 확진 양성자 수(patient count, PC) 예측 등 다양한 예측 분야에서 활용되고 있다(Qolomany et al., 2017; Iqbal et al., 2021). 이 모델의 독특한 특징 중 하나는 과거의 정보가 학습 과정에서 점차 손실되는 “vanishing gradient” 문제를 극복하며 네트워크의 상태를 저장하고 관리하는 ‘메모리 셀’을 활용한다는 점이다. LSTM은 시간이 지남에 따라 중요한 패턴과 정보를 학습하고 유지하는 능력을 가진다. 따라서 LSTM은 상대적으로 적은 양의 데이터를 가지고도 높은 성능을 발휘할 수 있다. 또한 이러한 제한적인 데이터 이용과, 가변 길이의 시퀀스 처리에 적합한 LSTM을 통해 예측 시간을 유연하게 설정할 수 있다. 이는 적은 데이터만으로도 최적의 모델 선택하는 데 중요한 요소로 작용한다.

Seq2Seq는 입력 시퀀스를 고정 길이의 벡터로 변환하고, 이를 이용해 출력 시퀀스를 생성하는 RNN 기반의 아키텍처다. 이 기법은 인코더와 디코더를 사용하여 하나의 시퀀스를 다른 시퀀스로 변환하는 과정을 처리한다. 이런 특성은 시간적인 관계를 가지는 여러 데이터를 처리하는데 매우 유용하다.

1.4 연구의 효용성

우리의 연구는 이전의 대량의 공공데이터를 활용한 혼잡도 예측 연구와 다르게, 상업적 공간에서 쉽게 획득할 수 있는 한정된 데이터로도 방문자 수를 정밀하게 예측을 가능케 하는 방법에 초점을 맞추었다. 교내 카페에서 얻은 2023년 4월 10일의 동영상 데이터 분석한 결과, 점심시간에는 큰 폭의 방문자 증가가 있었으나 그 외 시간대에는 작은 폭의 변동을 보였다.

본 연구의 주요 장점 중 하나는 이미 CCTV를 운영 중인 상업적 공간에서는 별도의 추가 장비 없이 본 연구의 결과를 쉽게 적용할 수 있다는 것이다. 특히 우리는 카페에서 실내 객체 탐지를 진행하였으며, 이에 따라 고객과 점주의 입장에서 필요한 기능을 구현하였다. 고객의 입장에서 사용할 수 있는 좌석을 알 수 있는 카페 실내 지도를 제공하며, 점주의 입장에서 앞으로의 카페 방문자 수를 예측할 수 있다. 이를 통해, 고객은 쾌적한 카페 이용이 가능하며, 점주는 재고 관리와 직원 고용 등을 효율적으로 관리할 수 있을 것으로 기대된다. 이러한 접근법은 카페뿐 아니라 다양한 상업적 공간에서의 혼잡도 관리에 큰 기여를 할 것으로 예상된다.

본 연구의 핵심은 다양한 인공지능 모델의 효과와 정확도를 카페 환경에서 검증하는 것이었다. 시뮬레이션 방법론을 통해 주어진 데이터 하에서 각 모델의 성능을 비교하였으며, 최적의 모델을 도출하기 위한 과정을 수행하였다.

결론적으로, 이 연구는 상업적 공간에서의 제한된 데이터를 활용하여 혼잡도를 예측하는 실용적이며 효과적인 방법을 제시하였다. 다양한 AI 모델의 성능 검증을 통해 실세계에서의 적용 가능성을 높였다.

2. 카메라 영상 활용 실내 사람 위치 추적

2.1 모델 선정

실내 객체 추적을 위해서는 YOLOv8 모델 중 경량화되어 있으면서도 높은 성능을 제공하고 실시간 탐지에 적합한 YOLOv8s를 이용한다. 특히 카페 방문객들의 위치 추적의 정확성과 안정성을 제공하기 위해 StrongSORT 정렬 알고리즘을 활용(Du et al., 2023)하여 다중 객체를 추적한다.

2.2 프로그램 기능

카페(실제 적용 카페, Figure 2 참조)에 적용 가능한 실내 위치 추적 프로그램은 다음의 네 가지 주요 기능을 포함한다.

2.2.1 테스트 동영상 파일 저장

동영상을 활용해 여러 모델을 테스트해 보면서 최적의 모델을 결정할 수 있다. 동영상에서 카페 내부의 이미지를 취득하여 좌석의 위치를 결정할 수도 있다.

2.2.2 좌석의 좌표 선택

시스템의 사용자는 카페 내부 사진을 통해 원하는 좌석의 인덱스(좌석 번호)와 범위를 선택할 수 있다. 좌표 설정 프로그램을 실행하면 카페 내부 사진을 사용자가 볼 수 있다. 사용자는 등록하고자 하는 좌석의 인덱스를 팝업창을 통해 정한 후, 마우스 드래그를 통해 좌석의 범위를 직접 지정할 수 있다. 여기서 각각의 좌석 범위는 사용자가 마우스 드래그를 여러 번 실행하여, 다수의 범위로 분할할 수 있으며, 이들은 단일 배열로 구성되어 저장된다. 선택된 좌석 정보들은 후속 작업에서 활용된다. Figure 1은 실제 카페의 내부 사진을 통해 좌석의 인덱스와 범위를 지정하는 모습을 나타낸다.

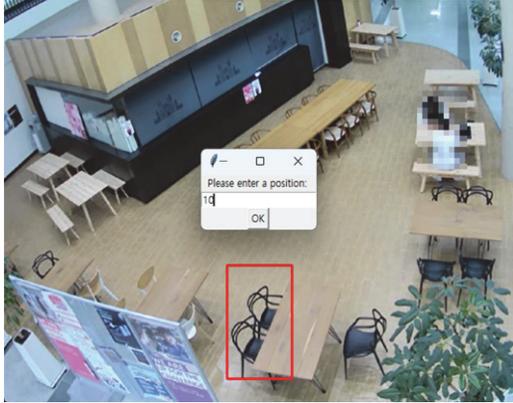


Fig. 1. Selection of seat coordinates

2.2.3 추적된 객체들의 위치 정보 업데이트

추적 시스템이 감지한 객체(사람)의 위치 좌표가 좌석 범위 안에 있는지 판단하여 객체가 좌석에 위치하였는지 판단한다. 이후 객체의 위치 정보를 해당 좌석의 인덱스로 업데이트한다.

Algorithm 1. Update location information of tracked objects

```

1. mid_x <- 추적된 객체의 중심 x좌표
2. mid_y <- 추적된 객체의 중심 y좌표
3.
4. OPEN 각 좌석의 좌표 범위 배열 AS FILE:
5.   array <- FILE
6.
7. i <- 좌석 인덱스
8. FOR i=0 TO size(array):
9.   j <- 등록된 좌표 인덱스
10.  FOR j=0 TO size(array[i]):
11.    IF 추적된 객체의 중심 좌표가 좌석의 좌표 범위에 위치:
12.      position <- i
13.      BREAK
    
```

Algorithm 1은 객체의 위치 정보를 업데이트하는 알고리즘이다. 먼저 추적된 객체의 중심 좌표를 구한다(1-2행). 이 중심 좌표는 추적된 객체의 위치를 나타낸다. 좌석의 좌표 선택 부분에서 저장한 좌석들의 범위 정보들을 가져와서 배열로 저장하여 활용한다(4-5행). 반복문을 통하여 추적된 객체가 위치한 좌석이 어디인지를 탐색한다(7-13행). 중심 좌표가 좌석의 범위 안에 존재할 시, 객체의 위치 정보를 업데이트한 후, 반복문을 종료한다. 만약 객체의 중심 좌표가 좌석의 범위 안에 존재하지 않는다면 position값을 -1로 설정한다. Figure 2에 나타난 바와 같이, 각 좌석에 앉아있는 추적된 객체와 좌석 번호가 표현된다. 제안하는 알고리즘을 통해 객체가 좌석에 앉아

있는지 아닌지를 쉽게 판단할 수 있다.

2.2.4 객체 위치 정보 가공 및 저장

우리가 개발한 실내 위치 프로그램은 또한 객체의 위치 정보를 필요한 형태로 가공하여 데이터베이스와 CSV 파일에 저장한다. 데이터베이스에는 각 좌석에 위치한 인원수의 30초 평균값을 데이터로 저장한다. CSV파일에는 데이터를 위치에 따라 그룹으로 나누어 저장하며 전체 인원수, 가운데에 위치한 인원수, 아래에 위치한 인원수, 오른쪽에 위치한 인원수로 나누어 저장하며, 이를 통해 전체 인원수 예측을 위해 각 그룹(가운데 인원수, 아래 인원수, 오른쪽 인원수)의 데이터를 활용하여, 그룹별로 어떠한 패턴이 전체 인원수에 영향을 미치는지 학습한다. 데이터베이스는 카페 실내 지도에서 사용 가능 좌석을 나타내기 위해 활용되며, CSV파일은 혼잡도 예측을 위해 사용된다.

2.3 데이터 가공 및 기대 효과

데이터베이스에 저장된 데이터는 카페의 실내 지도에 사용된다. 이 데이터는 각 좌석에 위치한 인원수의 30초 평균값으로, 데이터베이스에 1초마다 실시간으로 저장된다. 이 방법을 통해 앉아있는 사람과 지나가는 사람을 명확히 구분할 수 있으며, 객체 탐지 알고리즘의 성능을 보완할 수 있다.

또한, CSV 파일에 저장되는 데이터는 카페의 혼잡도를 예측하는 데 활용된다. 이 데이터는 그룹에 따른 객체의 움직임 패턴이 전체 혼잡도에 미치는 영향을 파악하기 위해 전체 방문객 수를 세 부분으로 나누어 저장하였으며, 이는 혼잡도 예측 모델을 개선하는 데 사용된다.

2.4 애플리케이션 실행 결과

Figure 2은 애플리케이션을 실행한 결과를 나타낸다. 왼쪽 그림은 객체 추적 화면을 오른쪽은 좌석의 점유 여부와 점유 시 인원수를 나타낸다. Figure 2의 왼쪽에 나타난 바와 같이 객체 추적 화면에서 표시되는 숫자는 (객체의 id):(객체가 위치한 좌석 인덱스)로 표시된다. 여기서 -1은 지정한 좌석에 위치하지 않은 상황에 해당한다. 또한, Figure 2의 오른쪽(애플리케이션 내의 카페 실내 지도)에 나타난 바와 같이 그림에서 좌석이 점유된 경우에만 좌석을 회색으로 표시하였고, 테이블 그림 안의 숫자는 해당 테이블을 점유한 인원수를 나타낸다.

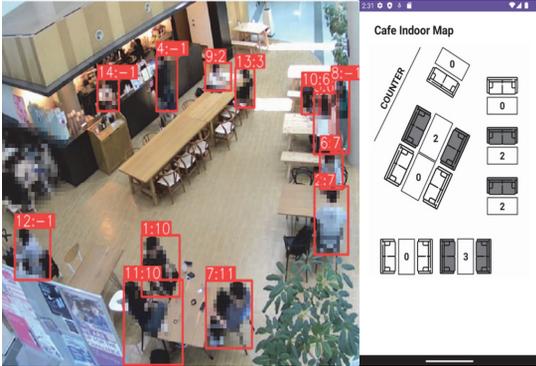
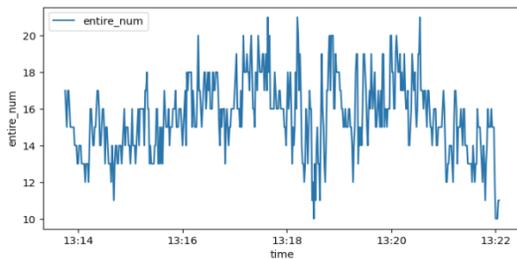


Fig. 2. Cafe Indoor Map

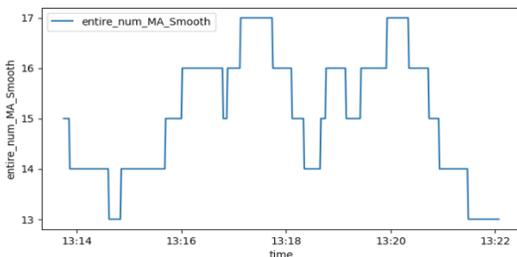
3. 방문자 데이터를 이용한 혼잡도 예측

3.1 가우시안 필터 사용

데이터는 YOLOv8를 통해 인식되고, 카페의 혼잡도를 예측하기 위해 축적된 인원수를 기반으로 분석된다. 데이터 전처리 과정에서는 노이즈 제거를 위해 가우시안 필터를 적용하며, 이후 정제된 데이터를 모델 성능 비교에 사용한다(Ito and Xiong, 2000). 본 연구에서 사용한 프로젝트와 프로젝트의 자세한 설명, 사용된 코드, 데이터 등은 GitHub에서 확인할 수 있다(poiuyreq0, 2023).



(a) Before



(b) After

Fig. 3. Collected data without Gaussian filter(above) and with Gaussian filter(below)

Figure 3은 카페에서 수집한 데이터(2.2.4 객체 위치 정보 가공 및 저장 참조)를 통해 전체 인원수에 가우시안 필터를 적용 전과 후를 비교한 데이터를 보여준다. 전체 데이터의 일부분만을 표현한 이 그래프는, 상단 부분에서 가우시안 필터 적용 전의 데이터를, 하단 부분에서는 필터 적용 후의 데이터를 나타낸다. 각 그래프의 x축은 13시 13분부터 13시 22분까지의 시간(시:분 형식)을 나타내며, y축은 해당 시간 동안 카페 내에 있는 총 인원수를 나타낸다. 하단 그래프의 y축 데이터는 전체 인원수 데이터에 가우시안 필터를 적용하여 얻은 결과이다.

상단 그래프를 통해 초 단위로 인원수가 변동하는 것을 관찰할 수 있다. 이러한 변동은 일상적인 카페 환경, 즉 단기간에 고객 수가 크게 변동하지 않는 특성과 맞지 않는다. 이에 따라, 데이터의 신뢰성을 유지하기 위해 보정 작업이 필요하다. 필터가 적용된 하단 그래프에서는 데이터가 더욱 안정적으로 인원수를 나타내는 것을 확인할 수 있다.

Algorithm 2에는 시간의 흐름에 따라 안정적으로 변하는 인원수 데이터를 얻기 위한 가우시안 필터의 평가 기준을 보여준다.

1초 단위로 측정된 데이터 중에서 세 개의 연속된 데이터가 있을 때, 중간 값만 다르다면 이는 인식 오류일 가능성이 크다. 이상적인 환경에서 이 경우는 지나가는 사람이 인식되었다가 사라질 때 또는 그 반대의 상황에서만 발생할 수 있기 때문이다. 알고리즘에서는 이때마다 count값을 하나씩 올려서 기준 값을 설정한다(1-8행). 이런 상황을 최소화하기 위해 가우시안 필터를 사용하여 데이터를 보정하였고, 약 23,000개의 데이터 중 단 4개만이 중간 값이 다른 것을 확인하였다. 이 결과는 가우시안 필터가 효과적으로 작동하였음을 시사한다.

Algorithm 2. Evaluation criteria for Gaussian filter

1. count < 이상치 수 0으로 초기화
- 2.
3. FOR i=1 TO len(df)-1:
4. diff1 < df[entire_num_MA_Smooth][i+1] - df[entire_num_MA_Smooth][i]
5. diff2 < df[entire_num_MA_Smooth][i] - df[entire_num_MA_Smooth][i-1]
- 6.
7. IF diff1과 diff2의 절대값이 1 이상이고, i+1번째 값 == i-1 번째 값:
8. count += 1

3.2 RNN 모델과 LSTM, GRU 및 관련 기법

순환 신경망(Recurrent Neural Network, RNN) 모델은 반복적인 피드백 연결을 통해 내부 상태 혹은 단기기

역을 유지하는 연결주의 모델로, 순차적인 문제를 다루는데 효과적이다(Koutnik et al., 2014). 특히, LSTM과 GRU 모델은 vanishing gradient 문제를 해결하는 고유한 메커니즘을 가진 RNN의 변형이다(Dey and Salem, 2017).

또한, Attention Mechanism과 Seq2Seq는 RNN에 적용될 수 있는 아키텍처 혹은 기법이다(Sojasingarayar, 2020). Attention Mechanism은 모델이 입력 시퀀스의 특정 부분에 집중할 수 있게 해주며, Seq2Seq는 하나의 시퀀스를 다른 시퀀스로 변환하는 과정을 처리한다. 이 기법들은 LSTM과 GRU와 함께 사용될 수 있다.

본 연구에서는 RNN 모델 중 LSTM과 GRU를 주로 살펴보았다. 이들 모델에는 Seq2Seq 및 Attention Mechanism 기법들이 적용되어 비교되었다. 모든 모델은 학습 과정에서 Mean Squared Logarithmic Error(MSLE, Equation (2) 참조)를 사용하여 안정적인 결과를 도출하고, 손실 수렴도를 높이는 목적을 가졌다(Park, 2022).

3.3 LSTM 및 GRU 모델 설정과 기법 비교

Tables 1-4은 GRU, LSTM 모델과 LSTM에 Seq2Seq와 Attention Mechanism을 각각 적용한 모델의 Squared Logarithmic Error(SLE, Equation (1) 참조)를 비교한 결과를 나타낸다. 성능 평가는 Mean Squared Logarithmic Error(MSLE, Equation (2) 참조), SLE 중앙값, 3분위 수, 1분위 수, 이상치 개수 등을 기준으로 하였으며, 이를 표에서 각 열에서 나타내었다. 각 행은 모델 예측의 시도 횟수를 나타내며 마지막 행은 모든 시도에 대한 평균값을 나타낸다. 사용된 데이터는 앞서 언급한 가우시안 필터를 적용한 후에 나눠서 생성한 검증 데이터이다(3.1 가우시안 필터 사용 참조).

$$SLE = (\log(y_t + 1) - \log(f_t + 1))^2 \quad (1)$$

f_t : 예측값
 t : 현재시점의 시간
 y_t : 실측값

$$MSLE = \frac{1}{T} \sum_{t=0}^T (\log(y_t + 1) - \log(f_t + 1))^2 \quad (2)$$

f_t : 예측값
 t : time, $t \in 0, 1, \dots, T$
 y_t : 실측값

Table 1. performance of GRU

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.212137996	0.109332476	0.298962198	0.016345973	501
SLE2	0.199682326	0.120031049	0.261210856	0.019439875	523
SLE3	0.221572557	0.121200383	0.319291744	0.013973313	358
TotalMean	0.211130959	0.116854636	0.293154932	0.016586387	460.6666667

Table 2. performance of LSTM

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.265063226	0.130517703	0.297238762	0.046355103	894
SLE2	0.164925661	0.076558535	0.191723838	0.014244271	789
SLE3	0.178124056	0.104803745	0.233056762	0.01175565	739
TotalMean	0.202704314	0.103959994	0.24067312	0.024118341	807.3333333

Table 3. performance of Seq2Seq

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.213583524	0.094480181	0.308837598	0.00736856	401
SLE2	0.155276978	0.067940752	0.254964216	0.009914067	193
SLE3	0.2119342	0.095714334	0.260723063	0.005212195	336
TotalMean	0.193598234	0.086045089	0.274841626	0.007498274	310

Table 4. performance of Attention Mechanism

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.176933724	0.040767221	0.287079832	0.01595081	339
SLE2	0.157834255	0.046459622	0.261243471	0.011148343	153
SLE3	1.99128861	1.921812056	2.590290394	1.206948961	0
TotalMean	0.775352196	0.669679633	1.046204566	0.411349371	164

최적 모델 선택의 평가 기준은 MSLE의 평균값을 사용하였으며, 이 선택에는 두 가지 주요 이유가 있다.

- 로그변환에 의한 비대칭성 감소

로그 변환은 큰 값들에 대한 가중치를 줄이고 작은 값들에 대한 가중치를 증가시킨다. 이를 통해 예측 값과 실제 값의 비대칭성을 줄인다. 이에 따라 오류를 절대적인 값이 아닌 상대적인 비율로 측정된다.

- 큰 오차에 대한 페널티 증가

로그 함수는 입력 값이 커질수록 증가율은 감소하는 특성을 가진다. 이는 큰 오차에 대해 상대적으로 큰 페널티를 부과하면서도 그 증가율은 점차 감소하는 효과를 만들어낸다. 이는 모델이 예측 값과 실제 값 간의 큰 차이를 줄이는데 효과적이다.

위에서 고려한 네 가지 모델 중에서, MSLE 평균값이 가장 낮은 모델은 LSTM에 Seq2Seq기법을 적용한 모델로, 이를 최적의 모델로 선정하였다. 우리가 세운 모델 결정 기준인 MSLE의 평균값은 Tables 1-4에서 초록색 박스로 강조하여 각 모델들의 성능을 한눈에 비교할 수 있게 하였다. 이를 통해 우리의 결정 과정이 명확하고 공정하게 이루어진 것을 확인할 수 있다.

따라서, 본 연구의 결과를 통해 LSTM을 기반으로 한 Seq2Seq 모델이 이 연구의 문제를 가장 잘 해결할 수 있는 모델임을 확인하였다. 이는 본 연구가 시퀀스 예측 문제에 가장 적합한 모델을 선정했음을 의미한다.

4. 성능 비교 및 혼잡도 예측 결과

4.1 스케일러 성능 비교

우리는 이상치를 최소화하는 동시에 가장 적합한 스케일러를 선택하여 정밀도와 정확도를 높였다. 스케일러는 데이터를 표준화하는 도구로, MinMax, Log, Robust 스케일러 등을 고려하였다. 이를 통해, 모델이 데이터의 분포를 더 잘 이해하고, 예측 성능을 향상시킬 수 있다. 다음은 각 스케일러의 식을 나타낸다(Equations (3)-(5) 참조).

$$Min - Max Scaler(x) = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3)$$

$$Log Scaler(x) = \log(1 + x) \quad (4)$$

$$Robust Scaler(x) = \frac{x_i - median(x)}{Q3 - Q1} \quad (5)$$

스케일러의 성능은 앞선 3.3 LSTM 및 GRU모델 설정에서와 동일한 기준으로 비교하였으며 성능평가에 사용된 데이터셋도 이와 동일하게 적용되었다(Tables 5-7 참조). 이때, MSLE의 평균값과 SLE의 이상치 개수를 중점적으로 고려하여 스케일러를 선택하였다. SLE의 이상치 개수를 비교함으로써 각 스케일러가 얼마나 높은 정밀도

를 보여주는지 판단하였다. MSLE의 평균값과 SLE의 이상치 개수는 각각 초록색 박스, 빨간색 박스로 표시되어 강조하였다. MinMaxScaler와 LogScaler를 비교한 결과, MinMaxScaler가 LogScaler보다 평균이상치가 222.4만큼 적고, 성능이 약 11%p 더 우수함을 확인하였다. 따라서 본 연구에서는 MinMaxScaler를 혼잡도 예측 모델에 적용하였다. 이 결정은 앞서 제시한 명확한 기준에 기반하였으며, 이를 통해 더욱 정밀한 예측 성능을 기대할 수 있다.

Table 5. performance of MinMaxScaler

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.151237316	0.071772331	0.215628486	0.007304748	296
SLE2	0.185171538	0.059815669	0.228386778	0.017051377	356
...
SLE30	0.158937509	0.060928794	0.321598546	0.015848057	52
TotalMean	0.179435013	0.075793441	0.269068784	0.015282916	395.9615385

Table 6. performance of LogScaler

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.286681477	0.098811894	0.293034372	0.035165438	1062
SLE2	0.228775024	0.098928393	0.282031888	0.011453559	858
...
SLE30	0.171454496	0.050260512	0.253617184	0.012780249	341
TotalMean	0.202170124	0.077190891	0.265292426	0.014370958	618.3846154

Table 7. performance of RobustScaler

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.266655105	0.121369352	0.449044479	0.027999017	109
SLE2	1.406721257	1.206948961	1.921812056	0.710354037	25
...
SLE30	0.666268022	0.256407752	1.206948961	0.027668715	202
TotalMean	0.652258554	0.468327944	0.936514432	0.212412497	407.1764706

결론적으로, 우리는 모델 성능 최적화를 위해 모델 선택과 데이터 스케일링 선택이라는 두 가지 핵심 요소를 차례대로 고려하였다. 우선적으로 LSTM에 Seq2Seq기법을 적용한 모델을 선택한 후, 데이터 스케일링 방법을 비교 및 선택하는 과정을 진행하였다. 이 두 가지 과정을

순차적으로 처리함으로써, 전체 시스템의 성능을 향상시키는 데 중요한 역할을 하였다. 이를 통해 우리는 실시간 혼잡도 예측 시스템의 성능을 최적화할 수 있었다.

4.2 혼잡도 예측 결과

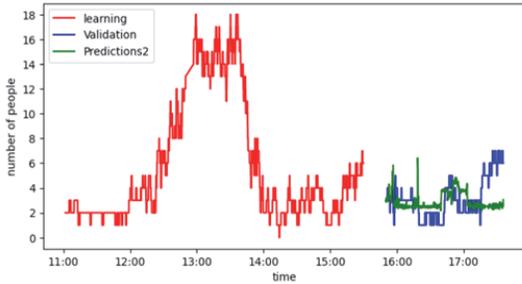


Fig. 4. Predictions of Customer Congestion

Figure 4은 우리가 사용한 Seq2Seq 기반 LSTM 모델을 이용한 혼잡도 예측 결과를 보여준다. x축은 오전 11시부터 오후 5시 30분까지의 시간을 나타내고, y축은 카페에 있는 전체 인원수를 나타낸다. 빨간색 그래프는 11시부터 현재 시점까지의 실제 카페 이용 인원을 나타낸다. 반면에, 초록색 그래프는 현재 시점부터 카페 운영 종료 20분 전까지 20분 후의 이용 인원을 모델이 예측한 결과를 보여준다. 이때 실제로 측정된 인원수는 파란색 그래프로 표시된다.

현재 시점을 기준으로, 가장 최근 200개의 데이터 포인트를 사용하여, 20분 후의 카페 혼잡도(초록색 그래프의 시작점)를 예측한다. 이때의 실제 데이터는 파란색 그래프의 시작점이 된다. 시간이 지나면서, 신규 데이터 포인트가 계속 추가되고, 이는 타임 윈도우에 포함된다. 동시에, 타임윈도우의 가장 오래된 데이터는 제거된다. 이런 식으로 타임 윈도우는 계속 갱신되고, 이를 바탕으로 모델은 현재 시점부터 20분 후의 예측을 계속해서 수행한다. 이에 따라, 예측 값(초록색)과 실제 값(파란색)은 그래프에 연속적으로 나타난다.

Table 8(테이블 테두리 수정했습니다 꼭 봐주세요)은 본 연구에서 개발한 최종 모델의 성능을 요약한 것이다. 이 표는 앞선 3.3 LSTM 및 GRU모델에서의 설정과 동일한 기준으로 성능을 나타냈으며, 동일한 데이터셋을 통해 성능평가가 이루어졌다. 여기서 빨간색 박스는 우리의 최종적인 성능 지표를 표시한다. 이 중에서 MSLE의 평균은 0.194507로, 이는 모델이 일관성 있고 안정적인 예측 성능을 보여줌을 입증한다.

Table 8. Predictions of Customer Congestion

Column	Mean	Median	Upper 25%	Lower 25%	Number of Outliers
SLE1	0.204947507	0.084350537	0.2783469	0.004118524	311
SLE2	0.340346615	0.158024758	0.567273643	0.027083423	201
...
SLE30	0.186433971	0.082265677	0.214023809	0.017987181	846
TotalMean	0.19450703	0.096618065	0.279677571	0.019699964	422.8519

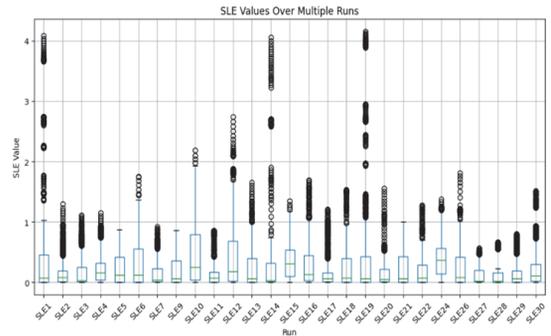


Fig. 5. SLE Values Over Multiple Runs

Figure 5는 각 모델 예측의 시도별로 박스플롯을 그려서, 모든 결과를 한눈에 확인할 수 있도록 하였다. x축은 각각의 예측 시도를 나타내고 각 예측 시도에 대한 SLE (Squared Logarithmic Error)값을 y축으로 표현한 박스플롯이 그려져 있다. SLE 값들이 주로 0 근처에 분포하고 있음을 통해, 모델이 카페 혼잡도를 성공적으로 예측했음을 확인할 수 있다.

5. 결론

본 연구에서 우리는 YOLOv8와 Seq2Seq기법을 기반으로 한 LSTM기술을 활용하여 사람의 움직임과 인원수를 실시간으로 추적하고 분석함으로써, 미래의 혼잡도를 예측하는 모델을 개발하였다. 특히 실시간으로 카페의 혼잡도를 예측하는 것이 가능해짐으로써, 운영자들에게는 효율적인 서비스 운영을 위한 참고 자료를, 이용자들에게는 편안한 이용 경험을 제공하기 위한 방문 시간 조절에 도움을 줄 수 있을 것으로 예상된다.

이 모델은 다양한 상업적 공간에 최소 2주일 이상의 데이터를 기반으로 확장 가능하며, 이를 통해 일일 패턴뿐만 아니라 장기적인 패턴도 학습하고 분석할 수 있는 것이다. 추가로, 상업적 공간의 유형별로 예측할 수 있는

가능성도 있으며, 타임윈도우의 유연한 조정을 통해 다양한 시간적 패턴을 분석하는 것도 가능하다.

따라서, 본 연구는 혼잡도 예측의 기존 방법론을 향상시키는 데 기여하며, 상업적 공간에서의 고객 관리와 서비스 향상에 도움을 줄 수 있는 신뢰할 수 있는 기반이 될 것이다. 또한, 이 연구는 후속 연구자들이 참고하고 확장시키는데 유용한 정보를 제공할 것이다.

이 모델은 매장 내에 인원을 기반으로 효과적으로 혼잡도를 예측한다. 그러나 현재의 모델은 매장 내부의 만석 상황에서도 대기하는 고객들을 고려하지 않는다. 이러한 외부 대기 고객은 이미 혼잡도가 매우 높음을 의미하는 반면, 특정 고객들을 여전히 대기를 원할 수 있다. 이를 위해 웨이팅 중인 고객 데이터를 추가적으로 활용해 후속연구에서 혼잡도와 대기 시간을 보다 정확하게 예측하는 방법을 탐구할 필요가 있다.

References

- Boukary, N. A. (2016) "A comparison of time series forecasting learning algorithms on the task of predicting event timing", *Master of Applied Science thesis*, Royal Military College of Canada.
- Brostrom, M. "YOLO Tracking", Available at https://github.com/mikel-brostrom/yolo_tracking (Accessed July 14, 2023).
- Chae, H., Kwak, K., Lee, D., and Kim, E. (2023) "An approach using LSTM model to forecasting customer congestion based on indoor human tracking in video streaming", *KSS Spring Conference*, June 2023. (채희주, 광경현, 이다연, 김은경 (2023) "비디오 스트리밍의 실내 사람 위치 추적 기반 LSTM 모델을 이용한 고객 혼잡 예측", *한국시뮬레이션학회 2023년도 춘계학술대회*, June 2023)
- Choi, G.W., Ahn, W.S., Yang, J.Y., and Kim, D.H. (2021) "Congestion measurement and visualization system for Han River Park", *Proceedings of the Korean Information Technology Society Conference*, 559-564. (최고운, 안우석, 양준영, 김동호 (2021) "한강공원 혼잡도 측정 및 시각화 시스템", *한국정보기술학회 종합학술발표논문집*, 559-564)
- Dey, R. and Salem, F. M. (2017) "Gate-variants of gated recurrent unit (GRU) neural networks", *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Boston, MA, USA, 1597-1600.
- Du, Y., Zhao, Z., Song, Y., Zhao, Y., Su, F., Gong, T., and Meng, H. (2023) "StrongSORT: make DeepSORT great again" *IEEE Transactions on Multimedia*, Early Access. doi: 10.1109/TMM.2023.3240881 (Accessed July 18, 2023).
- Iqbal, M., Al-Obeidat, F., Razaq, S., Anwar, S., Tubaishat, A., Khan, M. S. and Shah, B. (2021) "COVID-19 patient count prediction using LSTM", *IEEE Trans. on Computational Social Systems*, 8 (4), 974-981.
- Ito, K. and Xiong, K. (2000) "Gaussian filters for nonlinear filtering problems", *IEEE Trans. on Automatic Control*, 45(5), 910-927.
- Kim, B.S. (2020) "Optimization study of intelligent CCTV system for visitor detection", *Master's thesis*, Kangwon National University Graduate School, Gangneung. (김보섭 (2020) "출입자 검출을 위한 지능형 CCTV 시스템 최적화 연구", *강릉원주대학교 일반대학원 석사 학위논문*, 강릉)
- Kim, D.H., Hwang, K.Y., and Yoon, Y. (2019) "Prediction of traffic congestion by Deep Neural Networks (DNN) and multidimensional context information for Seoul city road links", *Journal of the Korean ITS Society*, 18(4), 44-57. (김동현, 황기연, 윤영 (2019) "심층인공신경망(DNN)과 다각도 상황 정보 기반의 서울시 도로 링크별 교통 혼잡도 예측", *한국ITS학회 논문지*, 제18권, 제4호, 44-57)
- Kim, G.W., No, G.S., Kim, D.W. and Lee, J.Y. (2015) "Exploratory study on improving subway congestion through big data fusion", *Journal of Digital Convergence*, 13(2), 35-42. (김근원, 노규성, 김동우, 이주연 (2015) "지하철 혼잡도 개선방안에 관한 빅데이터융합 기반의 탐색적 연구", *디지털융복합연구*, 제13권, 제2호, 35-42)
- Kim, J.S. (2016) "prediction and recommendation system for subway congestion using big data analysis", *Journal of Digital Convergence*, 14(11), 289-295.

- (김진수 (2016) “빅데이터 분석을 이용한 지하철 혼잡도 예측 및 추천시스템”, *디지털융복합연구*, 제14권 제11호, 289-295)
- Kim, J.W., Lee, T.W., Kim, D.Y., and Lee, J.H. (2019) “Implementation of real-time people counting and congestion detection system based on ultrasonic sensor”, *Proceedings of the Korean Institute of Communications and Information Sciences Conference*, 308-309.
- (김중우, 이태우, 김덕유, 이재호 (2019) “초음파 센서 기반의 실시간 인원 계수 및 혼잡도 검출 시스템 구현”, *2019년도 한국통신학회 동계종합학술발표회 논문집*, 308-309)
- Kim, M.J., Go, S.Y., and Jeong, N.H. (2021) “Case study of Jeju tourism organization’s real-time tourism site congestion analysis service”, *Journal of Information Technology Services*, 20(5), 29-41.
- (김민지, 고선영, 정남호 (2021) “제주관광공사의 실시간 관광지 혼잡도 분석 서비스 사례”, *한국IT서비스학회지*, 제20권 제5호, 29-41)
- Kim, S.H., Park, H.J., Oh, J.E., and Lee, K.Y. (2021) “Development of cafe congestion information application using deep Learning-based object detection technology”, *Proceedings of the Korean Information Science Society Conference*, 1342-1344.
- (김시하, 박현지, 오정은, 이기용 (2021) “딥러닝 기반 객체 탐지 기술을 이용한 카페 혼잡도 안내 애플리케이션 개발”, *한국정보과학회 학술발표논문집*, 1342-1344)
- Koutník, J., Greff, K., Gomez, and F., Schmidhuber, J. (2014) “A Clockwork RNN”, arXiv preprint arXiv: 1402.3511. Available at <https://doi.org/10.48550/arXiv.1402.3511> (Accessed July 18. 2023).
- Kwon, S.H., Lee, S.C., and Kim, H.S. (2021) “Development of congestion estimation program in spatial environment using IEEE 802.11 probe request”, *Proceedings of the Korean Computer Information Society Academic Conference*, 29(2), 257-260.
- (권순호, 이승찬, 김호숙 (2021) “IEEE 802.11 Probe request를 활용한 공간 상에서의 혼잡도 추정 프로그램 개발”, *한국컴퓨터정보학회 학술발표논문집*, 제29권 제2호, 257-260)
- Lee, H.S., Nam, B.C., and Seon, C.N. (2020) “Deep learning LSTM framework for urban traffic flow and fine dust prediction”, *Journal of Korean Information Science Society*, 47(3), 292-297.
- (이홍석, 부이 각 남, 선충녕 (2020) “도심지 교통흐름 및 미세먼지 예측을 위한 딥러닝 LSTM 프레임워크”, *정보과학회논문지*, 제47권 제3호, 292-297)
- Lee, T.W., Kim, J.W., Kim, D.Y., and Lee, J.H. (2018) “Personnel counting algorithm for emergency exits based on multiple ultrasonic sensors” *Proceedings of the Korean Communications Society Conference*, 299-300.
- (이태우, 김중우, 김덕유, 이재호 (2018) “다중 초음파 센서 기반의 비상구 출입인원 카운팅 알고리즘”, *한국통신학회 학술대회논문집*, 299-300)
- Park, Y. (2023) “Concise logarithmic loss function for robust training of anomaly detection model”, arXiv preprint arXiv: 2201.05748v2. Available at <https://doi.org/10.48550/arXiv.2201.05748> (Accessed July 17. 2023).
- poiuyreq0 (2023) “KOKO”, Available at <https://github.com/poiuyreq0/KOKO> (Accessed July 14. 2023).
- Qolomany, B., Al-Fuqaha, A., Benhaddou, D. and Gupta, A. (2017) “Role of deep LSTM neural networks and Wi-Fi networks in support of occupancy prediction in Smart Buildings”, *2017 IEEE 19th International Conference on High Performance Computing and Communications; IEEE 15th International Conference on Smart City; IEEE 3d Systems (HPCC/SmartCity/DSS)*, 50-57, doi: 10.1109/HPCC-SmartCity-DSS.2017.7 (Accessed July 16, 2023).
- Sojasingarayar, A. (2020) “Seq2Seq AI Chatbot with Attention Mechanism”, arXiv preprint arXiv: 2006.02767. Available at <https://doi.org/10.48550/arXiv.2006.02767> (Accessed July 16. 2023).
- Sultana, F., Sufian, A., Dutta, P. (2019) “A review of object detection models based on convolutional neural network”, arXiv preprint arXiv: 1905.01614. Available at <https://doi.org/10.48550/arXiv.1905.01614> (Accessed July 18. 2023).
- Ultralytics “YOLO” Available at <https://github.com/ultralytics/ultralytics/tree/15b3b0365ab2f12993a58985f3cb7f2137409a0c> (Accessed July 14. 2023).



채 희 주 (ORCID : <https://orcid.org/0009-0000-5160-5315> / 20201126@edu.hanbat.ac.kr)

2023 한밭대학교 컴퓨터공학과 학사 재학중

관심분야 : 인공지능



곽 경 현 (ORCID : <https://orcid.org/0009-0006-2964-8216> / poiuyreq0@gmail.com)

2023 한밭대학교 컴퓨터공학과 학사 재학중

관심분야 : 백엔드, 안드로이드



이 다 연 (ORCID : <https://orcid.org/0009-0003-0195-261X> / dlekds4553@gmail.com)

2023 한밭대학교 컴퓨터공학과 학사 재학중

관심분야 : 인공지능, 데이터 분석



김 은 경 (ORCID : <https://orcid.org/0000-0003-3558-7086> / ekim@hanbat.ac.kr)

2019 KAIST 전기및전자공학 박사

2005~2021 한국전자통신연구원 연구원/신임연구원/책임연구원

2021~현재 한밭대학교 인공지능소프트웨어학과 조교수

관심분야 : 인공지능 기반 통신 및 네트워크, AIoT, 지능형 소프트웨어