

Comparative Analysis of Deep Learning Models for Trajectory Prediction in Urban Air Mobility

Jung-Hoon Kim*†, Hye-Won Yoon**†, Seung-Won Yoon**, Da-Hyun Jang**,
Tae-Won Park**, Jun-Won Lee**, Kyu-Chul Lee***

*Lead Researcher, M&S Team, S/W Development Center, Research Institute, Korean Air, Daejeon, Korea

**Student, Dept. of Computer Science, Chung-nam National University, Daejeon, Korea

***Professor, Dept. of Computer Science, Chung-nam National University, Daejeon, Korea

[Abstract]

Urban Air Mobility (UAM) has garnered significant attention as a sustainable and efficient alternative for urban transportation. However, ensuring safe operations in complex urban environments necessitates research aimed at improving the accuracy and efficiency of flight trajectory prediction. This study addresses this need by proposing a deep learning-based trajectory prediction model that overcomes the limitations of conventional machine learning and simple regression models. Using data generated directly by the Korean Air Aerospace Technology Research Institute, the study conducts a comparative analysis of Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM), and Gated Recurrent Unit (GRU) models, while optimizing hyperparameters to maximize model performance. The experimental results demonstrate that the GRU model achieved the lowest RMSE and shortest inference time, making it the most suitable for real-time UAM trajectory prediction systems. Additionally, validation experiments using new, unseen data further confirmed the practical applicability of the GRU model. This study not only evaluates the performance of trajectory prediction models based on UAM latitude, longitude, and altitude data but also proposes a practical framework capable of real-time trajectory prediction in urban environments. Through these contributions, this research aims to enhance the safety and efficiency of UAM operations and establish a technical foundation for developing a new paradigm in urban transportation.

▶ **Key words:** Urban Air Mobility (UAM), Trajectory prediction, Deep Learning, GRU (Gated Recurrent Unit), Time Series prediction

-
- Co-First Author: Jung-Hoon Kim, Hye-Won Yoon, Corresponding Author: Kyu-Chul Lee
 - *Jung-Hoon Kim (kim.jungh@koreanair.com), M&S Team, S/W Development Center, Research Institute, Korean Air
 - **Hye-Won Yoon (hyewony1001@gmail.com), Dept. of Computer Science, Chung-nam National University
 - **Seung-Won Yoon (yoonenoch11@gmail.com), Dept. of Computer Science, Chung-nam National University
 - **Da-Hyun Jang (dahyunjang11@gmail.com), Dept. of Computer Science, Chung-nam National University
 - **Tae-Won Park (taewon1876@gmail.com), Dept. of Computer Science, Chung-nam National University
 - **Jun-Won Lee (djm04174@naver.com), Dept. of Computer Science, Chung-nam National University
 - ***Kyu-Chul Lee (kcllee@cnu.ac.kr), Dept. of Computer Science, Chung-nam National University
 - Received: 2024. 11. 14, Revised: 2024. 12. 04, Accepted: 2024. 12. 05.
 - † These authors contributed equally to this work.

[요 약]

도심 항공 모빌리티(Urban Air Mobility, UAM)는 지속 가능하고 효율적인 교통 대안으로 주목받고 있다. 그러나 복잡한 도심 환경에서의 안전한 운용을 위해 비행 경로 예측의 정확성과 효율성을 향상시키는 연구가 필요하다. 본 연구는 이러한 필요성에 따라, 기존의 머신러닝이나 단순 회귀 모델의 한계를 극복하기 위해 딥러닝 기반 경로 예측 모델을 제안한다. 대한항공 항공 기술연구원에서 직접 생성한 데이터를 사용하여 Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU) 모델을 비교 분석하였으며, 최적의 하이퍼파라미터를 탐색하여 모델 성능을 극대화하였다. 실험 결과, GRU 모델은 가장 낮은 RMSE와 짧은 추론 시간을 기록하여 실시간 UAM 경로 예측 체계 운용에 적합한 모델로 확인되었다. 또한, 학습에 사용되지 않은 새로운 데이터를 통해 비교 실험을 수행하여 GRU 모델의 실제 적용 가능성을 검증하였다. 본 연구는 UAM의 위도, 경도, 고도 데이터를 기반으로 한 경로 예측 모델의 성능을 평가할 뿐만 아니라, 도심 환경에서 실시간으로 경로를 예측하는 실용적인 프레임워크를 제안한다. 이를 통해 UAM의 안전성과 효율성을 향상시키고, 도심 교통의 새로운 패러다임을 구축하기 위한 기술적 기반 마련에 기여할 것으로 기대된다.

▶ **주제어:** 도심 항공 모빌리티, 경로 예측, 딥러닝, GRU, 시계열 예측

I. Introduction

도심 항공 모빌리티(Urban Air Mobility, UAM)는 도심 지역과 그 주변에서 승객과 화물을 이동시키기 위해 고도화된 항공 시스템을 활용하는 새로운 교통 패러다임을 의미한다. 이 개념은 도심 교통 혼잡을 완화하고 신속하고 효율적인 운송 해결책을 제공하며, 도심 내 이동성을 혁신할 잠재력 덕분에 산업계와 학계에서 큰 관심을 받고 있다 [1]. UAM은 수직 이착륙(VTOL) 항공기를 사용하는데, 이러한 항공기는 비행 택시 또는 자율 항공기로 불리며, 도로 혼잡을 완화하고 이동 시간을 단축할 것으로 기대된다 [2]. UAM의 주요 목적은 기존 도로 교통 시스템에 대한 지속 가능하고 확장 가능한 대안을 제공하는 데 있다. 또한 도심 내 교통 흐름과 물류 및 승객 이동의 효율성을 높일 수 있는 잠재력을 지니고 있다[3].

Uber Elevate[4]와 NASA의 무인 교통 관리(UTM) 프로젝트[5]와 같은 다양한 공공 및 민간에서 UAM 시스템의 실용적 배치를 검증하고 있다. 대한민국에서는 새로운 항공 분야이기 때문에 안전기준 마련과 인증에 따른 시간 소요로 최초 상용화는 2025년, 본격 확대는 2030~2035년 경을 목표로 하고 있다[6]. UAM의 안전하고 효율적인 운용을 위해 경로 예측은 단순한 기능이 아니라 필수적인 요소로 자리 잡고 있다. 복잡한 도심 환경에서는 다수의 유인 및 무인 항공기가 제한된 공역을 동시에 운행하게 되며, 이에 따라 충돌 위험성이 높아진다. 이러한 위험성을

줄이기 위해서는 정밀한 경로 예측이 요구된다[7]. 또한 경로 예측은 공중 교통 혼잡을 완화하고 도심 공역 관리 최적화에 중요한 역할을 한다. 다수의 UAM이 동시에 운행될 때 정확한 경로 예측은 원활한 교통 흐름을 보장하고 도심 공역에서 안전성과 운용 효율성을 극대화하는 데 필수적이다.

본 연구는 복잡한 도심 환경에서 UAM의 안전성을 확보하기 위해 딥러닝 기반 경로 예측 모델을 제안한다. 기존의 UAM 경로 예측 연구가 머신러닝과 같은 단순 회귀 모델에 의존했던 것과 달리, 본 연구는 GRU, LSTM, RNN과 같은 시계열 딥러닝 모델을 활용하여 복잡한 도심 환경에서 발생하는 비선형적이고 동적인 경로 변화까지 정밀하게 반영할 수 있는 모델을 제안한다. 또한 다양한 look-back 및 forward-length 설정에 따른 딥러닝 모델의 성능을 비교 및 분석함으로써, UAM의 경로 예측에 최적화된 설정값을 도출하는 실증적 접근을 제시한다. UAM의 위도, 경도, 고도 데이터를 기반으로 한 경로 예측 모델의 성능을 평가할 뿐만 아니라, 도심 환경에서의 실시간 경로 예측과 충돌 방지 체계 설계에 직접적으로 적용 가능한 실용적인 프레임워크를 제안한다. 이를 통해 UAM의 안전성 및 효율성을 향상시키고, UAM 상용화를 위한 기술적 기반 마련에 기여한다.

2장에서는 GPS 데이터를 활용한 경로 예측에 관한 선

행 연구에서 사용된 방법론을 분석한다. 3장에서는 본 연구의 방법론을 설명하며, 사용된 데이터셋, 딥러닝 모델(GRU, LSTM, RNN), 데이터 전처리 기법 및 모델 학습 절차를 기술한다. 4장에서는 제안된 모델의 평가 결과를 제시하며, Look-back 및 Forward-length 값 변화에 따른 다양한 딥러닝 모델의 성능을 분석한다. 마지막으로 5장에서는 주요 연구 결과를 요약하고, 항공기의 경로 예측을 위한 딥러닝 모델의 효율성을 논의하며, 향후 연구 방향을 제시한다.

II. Related Works

GPS 데이터를 활용한 딥러닝 기반 경로 예측은 오랜 기간 동안 활발히 연구되어 온 주제이다. 하지만 현재까지 UAM과 관련된 경로 예측 연구는 아직 충분히 이루어지지 않았으며, 이에 해당 분야에서의 딥러닝 기반 경로 예측 연구는 제한적이다. 현재 UAM의 실용적 배치가 이루어지지 않은 관계로, 실제 비행경로 데이터는 아직 부족한 상황이다.

이에 비행체의 경로 예측 연구는 무인 항공기(Unmanned Aerial Vehicle, UAV), 또는 드론에 초점이 맞추어져 있다. UAV 관련 연구에서는 다양한 회귀 모델과 기계 학습 알고리즘을 활용하여 항공기의 비행경로를 예측하는 방법이 개발되었다.

초기 접근법은 주로 회귀 모델을 통해 무인 항공기의 비행경로를 예측하는 데 집중하였다[8]. 이러한 회귀 기반 방법들은 UAV 경로를 예측하기 위해 항공기의 속도, 기상 조건, 바람의 방향과 강도 등 다양한 영향을 미치는 요인을 분석하였다. 회귀 모델은 간결성과 사용의 용이성을 제공하지만, 복잡한 비선형 패턴이나 장기적 종속성을 충분히 포착하는 데 한계를 가진다. 이후에 머신러닝 방법으로 경로 예측 연구가 진행되었다. Support Vector Regression(SVR)은, 여러 변수 간의 관계를 학습하여 전통적인 회귀 모델보다 향상된 예측 정확도를 나타내었다[9]. 하지만 이러한 머신러닝 모델들은 시계열 데이터에 내재된 복잡한 패턴을 완전히 포착하는 데 어려움이 있다.

딥러닝을 사용한 경로 예측 연구로는 RNN, LSTM, GRU 모델을 사용하여 경로 예측 연구가 진행되고 있다. RNN 모델을 활용한 연구에서는 칼만 필터(Kalman filters)를 통합하여 경도, 위도, 고도, 속도, 헤딩 각, 피치 각 등의 변수를 포함한 자동 종속 감시-광역 방송(Automatic Dependent Surveillance-Broadcast,

ADS-B) 데이터를 사용하여 UAV 경로를 예측하였다[10]. GPS 데이터를 활용한 GRU 모델은 경도, 위도, 속도, 방향 등의 정보를 포함한 자동 식별 시스템(Automatic Identification System, AIS) 데이터를 통해 선박 경로를 예측하는 데 사용되었으며, 이러한 연구들은 GRU 모델이 특히 단기 경로 예측에서 다른 모델에 비해 우수한 성능을 보인다는 점을 입증하였다[11].

이러한 기존의 경로 예측 연구들은 주로 단기적인 다음 위치 예측에 집중하고 있다. 반면, 본 연구에서는 다양한 거리에서의 예측 성능을 종합적으로 평가하고, 최적의 학습 데이터 길이를 제시함으로써 중장기적 예측의 정확성을 높였다. 이러한 접근을 통해 본 연구는 실시간 경로 예측이 가능한 UAM 모델을 제안하며, 이를 통해 UAM의 경로 관리와 충돌 회피 성능을 강화하는 데 기여하고자 한다.

III. Proposed Method

1. Overall

Fig 1은 본 연구에서 UAM 경로 예측에 사용된 종합적인 학습 아키텍처를 나타낸다. 모델은 위도, 경도, 고도를 입력 변수로 사용하며, 전체 과정은 데이터 전처리, 모델 학습, 예측의 세 가지 주요 단계로 구성된다.

데이터 전처리 단계에서는 입력 데이터의 일관성과 정확성을 보장하기 위해 데이터 라벨링과 정규화 기법이 적용된다. 예측 단계에서는 위도, 경도, 고도와 같은 미래 경로 값을 예측하기 위해 순환 신경망(Recurrent Neural Network, RNN) 기반 모델이 사용된다.




Fig. 1. Overall Framework

2. Dataset

2.1 Data Overview

본 연구에서 사용된 데이터셋은 대한항공 항공 기술연구원과 협업하여 생성된 데이터셋을 사용하였다. 대한항공에서 내부 검증을 위해 사용하는 도구인 Virtual Traffic Generator (VTG) 소프트웨어에 의해 생성되었다. 가상 비행경로는 실제 비행 없이 컴퓨터 소프트웨어로 생성된 항공기의 시뮬레이션 경로를 나타내며, 이를 통해 다양한 항공기 이동 시나리오를 모델링할 수 있다. 이러한 시뮬레

이선은 실제 운영 환경에서 발생할 수 있는 여러 항공기 이동 상황을 재현하여 충돌 위험 분석과 항공 교통 관리 시스템 성능 평가에 유용한 자료를 제공한다.

본 연구는 UAM의 딥러닝 기반 경로 예측을 위해 VTG로 생성된 데이터를 사용하여 다수의 항공기가 동시에 운항하는 상황에서 경로를 예측하는 기계 학습 모델을 학습하고 평가하였다.

2.2 Detailed Data Description

본 연구에서 사용된 데이터는 항공 교통 관리와 딥러닝 기반 경로 예측 연구에 유용한 여러 주요 특성을 보인다. 해당 데이터는 결측값이나 불규칙한 간격이 없이 일정한 간격으로 이루어진 데이터로, 보간법이 필요 없어 데이터 전처리 과정이 최소화될 수 있다. 또한, 단일 경로가 아닌 8개의 다중 경로로 구성되어 있어, 실제 항공 교통 상황과 유사한 환경에서 항공기 위치 및 속도의 실시간 변화를 분석하는 데 효과적인 모델 학습 환경을 제공한다.

2.3 Data Characteristics

본 연구에서 사용된 데이터는 다음과 같은 주요 속성들로 구성된다:

- 경도 (Longitude): 항공기의 동서 방향 위치 좌표.
- 위도 (Latitude): 항공기의 남북 방향 위치 좌표.
- 고도 (Altitude): 지면으로부터 항공기의 높이.
- 수평 속도 (Horizontal Speed): 지면과 평행하게 이동하는 항공기의 속도.
- 수직 속도 (Vertical Speed): 항공기가 상승하거나 하강하는 속도.
- 방위각 (Heading): 항공기가 비행하는 방향으로, 자북으로부터 0도에서 360도 사이로 측정됨.
- Call Sign: 각 항공기에 부여된 고유 식별자.

• 항로명 (Route Name): 항공기가 따르는 특정 비행경로
데이터는 총 146,814개의 데이터 포인트로 구성되어 있으며 이는 항공기별로 매초 당 10회씩 기록된다. 이러한 세분화된 데이터 구성은 충돌예측의 이상치를 최소화하는데 기여하며, 항공기 위치의 미세한 변화까지도 정밀하게 분석할 수 있게 한다.

2.4 Data labeling & Preprocessing

경로 예측 딥러닝 모델이 미래 좌표를 정확하게 예측하기 위해서 적절한 데이터 라벨링과 정규화가 필수적이다. 데이터 라벨링은 모델이 신뢰할 수 있는 학습 데이터를 학습하여 미래값을 예측할 수 있게 한다.

본 연구에서는 정확한 라벨링을 하기 위하여 Look-back 및 Forward-length 개념을 제안한다. 본 모델은 GPS 좌표(위도, 경도, 고도)를 입력으로 받아 다음 시점의 좌표를 예측하도록 설계되었으며, 전체 데이터셋을 한 번에 처리하는 대신 특정 시간(Look-back)의 데이터를 학습하여 특정 기간까지의 미래 위치를 예측(Forward-length)할 수 있다. Fig 2는 UAM의 경로 예측을 위해서 Look-back과 Forward-length 개념을 적용한 예측 과정을 시각적으로 보여준다. 학습 과정에서 모델은 Look-back 길이만큼 과거 데이터를 기반으로 학습하며, forward length만큼의 미래 시점 예측을 통해 과거 위치 정보를 바탕으로 정확한 예측을 수행할 수 있게 된다.




Fig. 2. Data Labeling

본 연구에서는 항공기 경로 예측 모델의 입력 데이터로 사용되는 위도, 경도, 고도 값을 정규화하여 모델의 성능을 향상하고자 하였다. 특히 고도 값의 경우, 데이터의 표준편차가 높아 모델 학습에 영향을 줄 수 있는 스케일 불균형이 존재하였으며, 이를 해결하기 위해 MinMaxScaler를 사용하여 데이터를 0과 1 사이로 정규화하였다. MinMaxScaler는 최솟값을 0, 최댓값을 1로 조정하여 모든 데이터 포인트가 동일한 범위 내에 위치하도록 한다. 이를 통해 입력 변수의 스케일 차이로 인한 모델의 학습 어려움을 방지하고, 각 변수가 학습 과정에 균등하게 기여할 수 있게 한다.

3. Model Architecture

본 연구에서는 UAM 항공기의 비행 데이터를 활용하여 딥러닝모델 연구를 진행하였다. 이에 시계열 데이터에 대표적인 세 가지 딥러닝 모델인 RNN, LSTM, GRU 모델의 아키텍처를 설계하고 각 모델의 성능을 비교 분석하였다.

3.1 RNN Model

RNN (Recurrent Neural Network) [12] 은 이전 시간 단계의 정보를 숨겨진 상태에 유지하여 순차적 데이터 또는 시계열 데이터를 처리하는 데 특화된 신경망 아키텍처이다. RNN 구조는 시간적 특징을 학습할 수 있게 하여, 데이터의 순차적 특성을 기반으로 예측을 가능하게 한다.

그러나 RNN은 긴 시계열 데이터에 적용될 경우 소실 기울기 문제(Vanishing gradient problem)가 존재한다. 이 문제는 역전파 과정에서 발생하는데, 초기 시간 단계와 관련된 기울기가 점차 감소하여 네트워크가 장기 종속성을 학습하는 능력을 제한한다. 결과적으로, 초기 시간 단계의 정보는 종종 손실되어 모델이 최신 데이터에 더 높은 우선 순위를 두게 된다. 이 한계로 인해 RNN은 긴 시계열 데이터에서 장기 패턴이나 복잡한 상관관계를 효과적으로 포착하지 못하며, 장기 종속성이 중요한 경우 성능이 저하되는 경향이 있다. 이러한 문제를 해결하기 위해 LSTM이나 GRU와 같은 모델이 설계되었다.

3.2 LSTM Model

LSTM (Long Short-Term Memory) [13] 모델은 긴 시계열 데이터에서 발생하는 RNN의 장기 종속성을 보완하기 위해 개발되었다. LSTM의 주요 특징은 망각 게이트, 입력 게이트, 출력 게이트로 구성된 게이트 메커니즘 통해 정보의 흐름을 효율적으로 제어한다. 이러한 게이트 구조는 정보를 선택적으로 유지하거나 폐기해 장기 종속성을 관리하며, 기울기 소실 문제를 완화한다.

망각 게이트는 이전 정보 중 필요한 부분을 남기고, 입력 게이트는 새로 추가할 정보를 결정하며, 출력 게이트는 다음 숨겨진 상태를 생성하여 정보의 흐름을 조정한다. 이를 통해 LSTM은 초기 정보의 중요 요소를 유지하면서도 데이터의 길이가 길어도 안정적인 예측을 가능하게 한다.

이처럼 LSTM은 게이트 기반의 메모리 관리와 출력 조절을 통해 긴 시퀀스 데이터의 예측 문제를 효과적으로 해결하며, 학습 과정에서 중요한 시간적 패턴을 지속적으로 유지할 수 있다. 이러한 특성 덕분에 LSTM은 항공기 경로 예측처럼 복잡한 종속성을 포착해야 하는 시계열 예측 작업에 적합한 도구로 활용된다. Fig 3은 LSTM 모델 구조를 나타낸다.

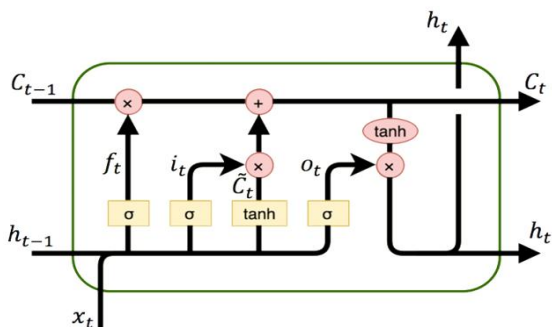


Fig. 3. LSTM Model

3.3 GRU Model

LSTM (Long Short-Term Memory) 모델은 시계열 데이터를 효과적으로 처리할 수 있지만, 몇 가지 한계를 가진다. LSTM의 여러 게이트와 셀 상태 등 여러 구성 요소를 포함하여 많은 파라미터를 필요로 한다. 이러한 복잡성은 높은 계산 요구와 긴 학습 시간으로 이어지며, 특히 대용량 시계열 데이터에서 실시간 성능에 영향을 미칠 수 있다.

이러한 한계를 해결하는 GRU (Gated Recurrent Unit) [14]는 간결한 구조로 인해 계산 효율성이 높다. LSTM과 달리 GRU는 별도의 셀 상태 없이 하나의 상태로 정보를 전달하며, 업데이트 게이트와 리셋 게이트 두 가지로 정보를 유지한다. LSTM보다 간결한 구조인 GRU는 더 적은 파라미터로 LSTM에 상응하는 성능을 발휘할 수 있으며, 학습 시간과 메모리 사용량을 절감할 수 있다. Fig 4는 GRU 모델의 구조를 보여준다.

업데이트 게이트는 과거 정보 중 필수적인 요소만 유지함으로써 불필요한 데이터를 걸러내고, 리셋 게이트는 이전 상태에서 불필요한 정보를 배제하여 새로운 패턴에 적응할 수 있도록 돕는다. 이러한 간소화된 게이트 메커니즘을 통해 GRU는 장기 종속성을 효과적으로 처리하는 동시에 계산 효율성을 크게 향상시킬 수 있다.




Fig. 4. GRU Model

IV. Experimental Results

4.1 Experimental Setting

본 연구에서 사용된 데이터 셋은 복잡한 도시 환경에서 UAM 항공기의 이동 패턴을 학습하는 데 적합한 다수의 항공기 경로 데이터를 포함하고 있다. 각 경로는 위도, 경도, 고도 정보를 포함하며, 총 146,814개의 데이터 포인트로 구성되어 있다. 모델 학습을 위해 학습, 검증, 테스트 세트로 각각 60%, 20%, 20%의 비율로 분할하여 진행한

다. 이와 같은 분할 방식은 과적합을 방지하고 학습 데이터를 효과적으로 활용할 수 있게 한다.

모델 학습은 최대 100 에포크 동안 진행되었으며, 과적합 방지를 위해 조기 종료 학습 방식을 채택했다. 배치 크기는 32로 설정하였고, 학습률 0.001, Adam 옵티마이저가 사용되었다. 본 연구에서는 제한된 모델의 학습을 위해 손실 함수로 평균 제곱 오차(Mean Squared Error, MSE)를 사용한다. MSE는 딥러닝 모델에서 널리 사용되는 손실 함수로, 예측값과 실제값 사이의 차이를 정량화하여 모델의 성능을 평가하는 데 유용하다. 이는 예측값과 실제값 간 오차의 제곱을 평균한 값으로 계산되며, 모델의 예측이 실제값에 얼마나 근접한지를 측정하는 지표로 사용한다.

RNN, LSTM, GRU 모델의 입력 데이터는 (Look-back, 3) 형태로 구성된다. Look-back의 크기를 통해 과거의 데이터를 학습하여, 경도, 위도, 고도의 데이터를 학습한다. 각 모델은 총 3개의 은닉층으로 구성되어 시계열 데이터의 특성을 효과적으로 학습하도록 설계되었으며, 출력 데이터는 (3,) 형태로 경도, 위도, 고도를 각각 예측한다. 이러한 공통 구조를 기반으로 RNN, LSTM, GRU 모델의 성능을 비교하여 UAM 경로 예측에 가장 적합한 모델을 도출하고자 하였다.

실험에 사용된 모든 모델의 매개변수 설정은 Table 1에 제시 되어있다. 본 연구의 실험은 Intel® Core™ i7-14700KF, RAM 64GB, NVIDIA GeForce RTX 4060 환경에서 진행하였다.

Table 1. Model Architecture Configuration

Parameter	Value
Hidden Layer Nodes	32
Optimizer	Adam
Epoch	100
Batch Size	32
Learning Rate	0.001
Loss Function	Mean Squared Error
Input Shape	(Look-back, 3)
Hidden Layer	3
Output Shape	3

4.2 Evaluation Metric

모델의 성능 평가는 테스트 데이터셋을 사용하여 예측을 생성하였고, 평가 지표로 루트 평균 제곱 오차(RMSE)를 사용하였다. RMSE는 예측 오차가 클수록 가중치를 더 하여 큰 오차의 영향을 정량화하는 데 효과적이며, 경로 예측의 정확성을 평가하는 데 유리하다. 또한 RMSE는 실제 값과 동일한 단위를 유지하기 때문에 예측 결과의 해석을 용이하게 한다. 이러한 이유로 RMSE는 본 연구에서

제한된 경로 예측 모델의 성능을 평가하기 위한 적합한 지표로 선택되었다.

4.3 Comparison of Models at Different Look-back Periods

Table 2는 다양한 Look-back 값에 따른 실험 결과를 보여준다. 본 실험은 Look-back 값을 10, 30, 60, 100으로 설정하고, Forward-length는 0으로 고정하여 수행하였다. 다양한 Look-back 값에 대해 실험한 결과 Look-back 이 30일 때 가장 좋은 성능을 보였다.

Look-back 값이 커질수록 모델이 더 먼 과거의 데이터를 학습하게 되는데, 이 과정에서 과거 정보가 현재 예측에 불필요한 정보가 포함될 가능성이 높아진다. 특히, 항공기의 경로 예측과 같은 시계열 데이터에서는 시간에 따른 변화가 중요한데, 지나치게 긴 Look-back은 현재 상태와의 직접적인 연관성이 낮아 예측 정확성을 저하할 수 있다. Look-back이 짧을 경우, 과거 정보가 부족하여 데이터 패턴 학습이 제한되며, 이에 따라 예측 성능이 저하되는 양상을 보였다. 이러한 결과는 Look-back 길이의 적절한 설정이 경로 예측 모델에 중요함을 나타낸다.

GRU 모델은 Look-back이 30일 때 RMSE 0.0014를 달성하여 다른 시계열 모델보다 낮은 예측 오류를 보였으며, 가장 우수한 성능을 보였으며 GRU 모델이 일관되게 우수한 성능을 보였다.

Table 2. Comparison of Models at Different Look-back

Look-back \ Model	10	30	60	100
GRU	0.0236	0.0014	0.0016	0.0263
LSTM	0.0838	0.1280	0.1391	0.1402
RNN	0.0289	0.0228	0.0289	0.0280

4.4 Model Comparison at Different Forward Lengths

본 실험은 바로 다음의 시점뿐만 아니라 더 먼 시점을 예측하기 위해 Forward-length를 10, 15, 20으로 설정하여 보다 장기적인 예측 성능을 평가하고자 하였다. Look-back은 이전 실험에서 최적의 값으로 도출된 30으로 고정하여 실험을 진행하였다. Table 3은 Forward-length 값에 따른 실험 결과를 제시한다. Forward-length가 증가함에 따라 예측 범위가 넓어지면 성능 저하가 발생하는 경향을 보였으나, GRU 모델은 다른 모델에 비해 지속적으로 낮은 RMSE를 보이며 안정적인 예측 정확성을 유지하였다. GRU 모델은

Forward-length가 증가해도 우수한 성능을 유지하였다.

이러한 결과는 GRU 모델이 다양한 Forward-length에도 예측 정확성과 모델 복잡성의 균형을 효과적으로 유지함을 보여준다.

Table 3. Comparison of Models at Different Forward-Lengths

Forward-length Model	10	15	20
GRU	0.0024	0.0029	0.0032
LSTM	0.1245	0.1241	0.1330
RNN	0.0478	0.0432	0.0454

4.5 Model Performance Comparison Across

Multiple UAM Aircraft

본 연구는 제안하는 모델의 일반화 성능 및 실제 적용 가능성을 평가하기 위해, 모델 학습과 평가에 사용하지 않은 새로운 도심 항공 비행체의 독립적인 비행경로 데이터로 경로 예측 실험을 진행하였다. 이 전의 실험을 통해 증명된 가장 성능이 좋은 GRU 모델을 사용하였으며, Look-back을 30, Forward-length를 10으로 고정하여 GRU 모델이 다양한 항공기의 경로를 얼마나 정확하게 예측할 수 있는지 분석하였다.

Table 4의 결과에 따르면, GRU 모델은 모든 항공기 데이터셋에서 일관되게 낮은 RMSE를 기록하여 경로 예측에 있어 탁월한 성능을 보였다.

GRU 모델의 평균 예측 시간은 1.527초로, 실시간에 가까운 예측이 가능함을 보여준다. 이는 실시간 응답성이 중요한 UAM 운용 환경에서는 GRU 모델의 빠른 계산 속도가 큰 이점을 제공한다. 이를 통해, GRU 모델이 UAM 경로 예측에서 높은 예측 정확도뿐만 아니라 빠른 처리 속도 측면에서도 최적의 모델임을 입증하며, 실제 운용 환경에서의 활용 가능성을 더욱 강조한다.

Table 4. Model Architecture Configuration

Call-sign	RMSE	Prediction Time (s)
GSPN_01	0.0016	2.5227
RNGS_01	0.0015	1.8113
RNBS_01	0.0018	1.6103
RSRN_01	0.0018	1.7096
PNGS_01	0.001	1.7688
PSGN_01	0.0025	1.4886
BNPN_01	0.0038	0.9811
RSGS_01	0.0014	0.8594
BNPS_01	0.0016	1.1711
PNBN_01	0.0028	1.3537
Average	0.00198	1.52766

V. Conclusions

본 연구는 UAM(Urban Air Mobility) 경로 예측을 위해 GRU, LSTM, RNN 모델을 비교하여 GRU 모델이 UAM 경로 예측에서 가장 우수한 성능임을 확인하였다. GRU 모델은 다양한 실험에서 가장 낮은 RMSE를 기록하여 예측 정확도 측면에서 우수한 성능을 보였으며, 새로운 데이터에 대한 추가적인 검증을 통해 GRU 모델의 실제 적용 가능성도 확인하였다.

본 연구에서 사용된 데이터셋은 가상 교통 생성기 (Virtual Traffic Generator, VTG)를 통해 실제 항공기 경로와 유사한 상황을 재현한 데이터로 구성되었다. 이를 통해 데이터셋은 높은 정확성과 완전성을 제공하였다. 이를 통해 본 연구는 UAM 환경에서의 경로 예측과 충돌 방지 시스템 구축을 위한 실질적인 기초 자료로 활용 가능성을 제시하였다.

하지만 현재의 모델은 Forward-length 값을 증가시키는 경우 장기 예측에서 성능 저하가 발생하는 한계점이 존재한다. 향후 연구에서는 이를 해결하기 위해 모델의 복잡성을 낮추면서도 높은 예측 정확도와 안정성을 유지할 수 있는 경량화된 딥러닝 모델의 개발이 필요하다. 특히, 장기 예측에서도 안정적으로 성능을 유지할 수 있는 모델 구조와 학습 기법에 대한 추가 연구가 요구된다.

향후 연구는 UAM 교통 관리를 위한 감시 자료 처리 시스템 (Surveillance data processor, SDP)와 통합하여 UAM 항공기의 실시간 경로를 추적하고 충돌예측 및 회피를 위한 SafetyNet 시스템의 일부로 발전시킴과 동시에, 다중 항공기 운용 환경에서도 일관된 안전성과 높은 예측 정확성을 유지할 수 있는 방향으로 진행할 예정이다.

ACKNOWLEDGEMENT

This study was supported by the Ministry of Land, Infrastructure and Transport/Korea Agency for Infrastructure Technology Advancement (Project No. RS-2022-00143625).

REFERENCES

- [1] A. Bauranov and J. Rakas, "Designing airspace for urban air mobility: A review of concepts and approaches," Progress in Aerospace Sciences, Vol. 125, p. 100726, 2021. DOI: 10.1016/

j.paerosci.2021.100726.

- [2] H. Pak, et al., "Can Urban Air Mobility become reality? Opportunities and challenges of UAM as an innovative mode of transport and DLR contribution to ongoing research," CEAS Aeronautical Journal, Vol. 2024, pp. 1-31, 2024.
- [3] Q. Zhou and F. Tan, "Avionics of Electric Vertical Take-off and Landing in the Urban Air Mobility: A Review," IEEE Aerospace and Electronic Systems Magazine, 2024.
- [4] J. Holden and N. Goel, "Fast-forwarding to a future of on-demand urban air transportation," San Francisco, CA, 2016.
- [5] P. Kopardekar, J. Rios, T. Prevot, M. Johnson, J. Jung, and J. E. Robinson, "Unmanned aircraft system traffic management (utm) concept of operations," in Proc. AIAA AVIATION Forum and Exposition, Washington, DC, USA, June 2016.
- [6] Ministry of Land, Infrastructure and Transport (MOLIT), Korean Urban Air Mobility (K-UAM) Roadmap
- [7] X. Yang and P. Wei, "Autonomous free flight operations in urban air mobility with computational guidance and collision avoidance," IEEE Trans. on Intelligent Transportation Systems, Vol. 22, No. 9, pp. 5962-5975, Sept. 2021. DOI: 10.1109/TITS.2020.3048360.
- [8] W. Kun and P. Wei, "A 4-d trajectory prediction model based on radar data," in Proc. 27th Chinese Control Conf., pp. 591-594, Kunming, China, July 2008. DOI: 10.1109/CHICC.2008.4605732.
- [9] S. M. Hashemi, R. M. Botez, and T. L. Grigorie, "New reliability studies of data-driven aircraft trajectory prediction," Aerospace, Vol. 7, No. 10, p. 145, Oct. 2020.
- [10] Y. Zhu, Z. Jia, Q. Wu, et al., "UAV trajectory tracking via RNN-enhanced IMM-KF with ADS-B data," in Proc. IEEE Wireless Communications and Networking Conf. (WCNC), pp. 1-6, Seoul, South Korea, April 2024. DOI: 10.1109/WCNC57260.2024.10570914.
- [11] L. You, S. Xiao, Q. Peng, et al., "ST-Seq2Seq: A spatio-temporal feature-optimized seq2seq model for short-term vessel trajectory prediction," IEEE Access, Vol. 8, pp. 218565-218574, Dec. 2020. DOI: 10.1109/ACCESS.2020.3041762.
- [12] L. R. Medsker and L. Jain, "Recurrent neural networks," Design and Applications, Vol. 5, pp. 64-67, 2001.
- [13] S. Hochreiter, "Long short-term memory," Neural Computation MIT-Press, 1997.
- [14] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical evaluation of gated recurrent neural networks on sequence modeling," arXiv preprint arXiv:1412.3555, 2014.

Authors



Jung-Hoon Kim received the B.S. degree in Computer Science from the University of Seoul, Korea, in 2013. He is currently with Korean Air, working in the Modeling and Simulation section of the Software

Development Team, focusing on urban air mobility. His research interests include urban air mobility and communication systems integrated with artificial intelligence.



Hye-Won Yoon received the B.S. degree in Computer Engineering from Chungnam National University, Korea, in 2018. She is currently pursuing the integrated M.S. and Ph.D. degree in Computer Engineering at

Chungnam National University, Korea, since March 2018. Her research interests include deep learning, machine learning, bioinformatics, and trajectory prediction.



Seung-Won Yoon received the B.S. degrees in Computer Science and Engineering from Chung-nam National University, Korea, in 2018. Seung-Won Yoon is currently studying for an Intergrated PhD in the Department of

Computer Science, Chung-nam National University. He is interested in Deep Learning, Machine Learning, and Trajectory Prediction.



Da-Hyun Jang received the B.S. degrees in Mathematics from Chung-nam National University, Korea, in 2023. Da-Hyun Jang is currently studying for a M.S degree in the Department of Computer Science, Chung-nam

National University. She is interested in Deep Learning, Machine Learning, and Trajectory Prediction.



Tae-Won Park received a B.S. degree in Computer Engineering from Hanbat National University, Korea, in 2023. He is currently pursuing an M.S. degree in the Department of Computer Engineering at Chungnam

National University. His research interests include Deep Learning, Machine Learning, Trajectory Prediction, and Healthcare.



Jun-Won Lee received the B.S. degree in Computer Information and Communication Engineering from Chung-buk National University, Korea in August 2022. He is currently studying for a M.S degree in the

Department of Computer Science, Chung-nam National University. His research interests include Deep Learning, Machine Learning, Image Restoration and Trajectory Prediction.



Kyu-Chul Lee received the B.S., M.S., and Ph.D. degrees in Computer Science and Engineering from Seoul National University, Korea, in 1984, 1986, and 1989, respectively. He is currently a Professor in the Department

of Computer Science at Chungnam National University, Korea. His research interests include databases, artificial intelligence, and big data.