

드론 측위 오차 보정을 위한 Drift-aware LSTM 딥러닝 모델

김요셉, 신요안*

숭실대학교 전자정보공학부

yosep@soongsil.ac.kr, *yashin@ssu.ac.kr

(*교신저자)

Drift-aware LSTM Deep Learning Model for Drift Correction in Drone Localization

Yosep Kim and Yoan Shin*

School of Electronic Engineering, Soongsil University

(*Corresponding author)

요약

본 논문은 GPS 신호가 제한된 환경에서 IMU 센서만을 이용한 드론 측위 시 발생하는 누적 드리프트 오차를 해결하기 위해 Drift-aware LSTM 딥러닝 모델을 제안한다. 제안 모델은 기존 LSTM 구조에 드리프트 보정 헤드와 회전 인식 모듈을 추가하여 장시간 비행 중 발생하는 누적 오차를 효과적으로 완화하였으며, AirSim 시뮬레이터를 이용한 모의실험을 통해 오차 감소 효과를 확인하였다.

I. 서론

최근 UAV (Unmanned Aerial Vehicle) 관련 기술이 발전함에 따라 GPS (Global Positioning System) 위성 신호가 수신되지 않는 다양한 환경에서 IMU (Inertial Measurement Unit) 및 다양한 센서 데이터를 활용한 UAV 3차원 위치 측위 연구가 활발히 진행되고 있다[1,2].

그러나 IMU 센서만을 이용한 위치 추정 방법 특성상 미세한 측정 오차가 계속 누적되는 드리프트 (Drift) 오차가 필연적으로 발생한다[3]. 이는 드론의 비행 시간이 길어질수록 오차가 누적되어 정확한 위치 추정을 어렵게 한다.

본 논문에서 제안하는 Drift-aware LSTM (Long Short-Term Memory) 모델은 GPS 변화량을 예측하는 기존 LSTM 측위 모델에 드리프트 예측과 보정을 수행하는 추가적인 헤드를 도입하여 IMU 센서 기반 위치 측위에서 발생하는 드리프트 문제를 효과적으로 개선한다.

II. LSTM 기반 3차원 위치 측위 모델과 실험 환경

본 연구에서 활용한 기존 LSTM 기반 측위 모델은 IMU 센서 데이터와 기압계 데이터를 입력으로 받아 드론의 GPS 변화량을 예측한다. 입력 시퀀스는 0.5초 간격의 센서 데이터로 구성되며, 모델은 이를 바탕으로 위도, 경도, 고도의 변화량을 출력한다.

모델 학습에는 AirSim 시뮬레이터 기반으로 생성된 총 55,701개의 IMU 센서 데이터를 활용하였으며, 학습 궤적은 정형 경로, 불규칙 경로, 실제 조종 경로 등 다양한 형태의 드론 궤적으로 구성된다[4,5]. 또한 학습에 포함되지 않은 데이터를 실험 데이터로 분리하여 측위 성능을 평가했다. 이러한 구조의 실험에서 기존 LSTM 모델은 단기적 GPS 변화량 예측에 높은 정확성을 보였지만, IMU 센서 데이터의 미세한 오차가 누적됨에 따라, 장시간 비행 시 드리프트 오차가 점차 증가하는 결과를 보였다.

III. 제안한 Drift-aware LSTM 모델과 세부 구조

본 논문에서 제안한 Drift-aware LSTM 모델의 구조는 그림 1과 같으

며, 제안 모델은 단순 위치 변화량만 예측하는 기존 모델의 한계를 극복하기 위해 Drift 보정 헤드를 추가하여 드리프트 예측 및 보정을 수행하도록 설계했다.

Drift 보정 헤드는 LSTM 인코더의 마지막 은닉 상태를 입력으로 하여, 수평 방향의 위치 오차를 직접 예측한다. 이 때 예측된 드리프트 값은 실제 예측값과의 차이를 기반으로 동적으로 보정된다. 특히, Drift Gate 모듈은 예측된 드리프트 값을 0에서 1 사이의 비율로 가중 조절함으로써, 과도한 보정으로 인한 오버슈팅을 방지하는 역할을 수행한다.

또한 드론이 선회할 때 위치 예측 오차가 급격히 증가하는 경향이 있으며, 이 때 드리프트 보정의 중요성이 더욱 커지게 된다. 이를 고려하여 Turning Branch 모듈을 통해 드론의 회전 여부를 판단하고 보정 손실에 대한 가중치를 동적으로 조정하여 보정 효과를 강화하도록 했다.

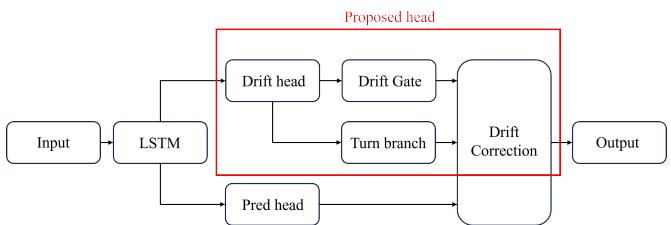


그림 1. 제안한 Drift-aware LSTM 모델 구조

IV. 모의실험 결과 및 결론

본 연구에서는 IMU 센서 데이터를 활용하여 제안된 Drift-aware LSTM 모델의 성능을 검증하였다. 실험에는 모델 학습에 사용되지 않은 궤적을 실험 데이터로 사용했다.

실험 결과, 제안한 Drift-aware LSTM 모델은 분당 누적 위치 오차를 2.76m 수준까지 효과적으로 감소시켰으며, 특히 드론이 회전하는 구간의 오차 보정 성능을 확인했다.

그림 2에서는 기존 LSTM 기반 측위 모델과 제안한 Drift-aware LSTM 모델의 위치 측위 결과를 비교한다. 기존 모델은 누적 오차가 점

차 증가하는 모습을 보이는 반면 Drift-aware LSTM 모델은 누적 오차를 효과적으로 억제하며 보다 안정적인 측위 정확성을 유지하는 것을 확인할 수 있다. 표 1에서는 두 모델의 평균 오차를 정량적으로 비교했다.

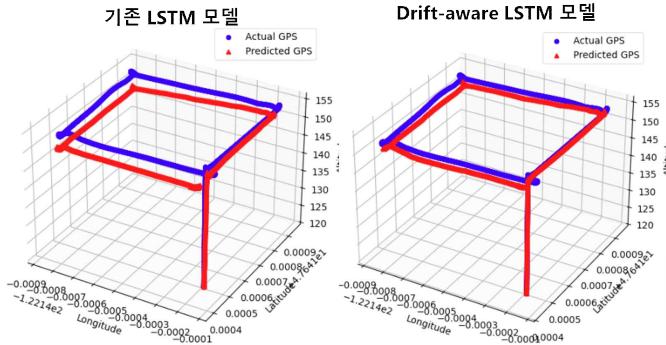


그림 2. 기존 모델과 제안한 모델의 위치 측위 결과.

표 1. 기존 모델과 제안한 모델의 평균 측위 오차 비교

항목	기존 LSTM	Drift-aware LSTM
평면 오차	5.08m	2.51m
수직 오차	1.28m	0.76m
3차원 오차	5.24m	2.62m
분당 누적 오차	5.52m/min	2.76m/min

본 연구는 GNSS 신호가 수신되지 않는 환경에서 IMU 센서만을 이용한 드론 위치 측위에서 장시간 비행 시 필연적으로 발생하는 누적 드리프트를 효과적으로 개선했다. 하지만 제안한 방법은 드리프트 오차를 크게 완화하였음에도 불구하고, 드리프트를 완전히 제거하지 못하는 한계가 존재한다. 이에 따라 향후 연구에서는 잔여 드리프트 오차를 더욱 정밀하게 보정 할 수 있는 상호 보완적 구조나 새로운 보정 전략을 탐색하여, 보다 안정적이고 신뢰도 높은 위치 측위 기술을 연구할 예정이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터사업의 연구결과로 수행되었음 (IITP-2025-RS-2023-00258639)

참고 문헌

- [1] A. Yusefi, A. Durdu, M. Aslan, and C. Sungur, "LSTM and filter based comparison analysis for indoor global localization in UAVs," *IEEE Access*, 9, pp. 10054–10069, Jan. 2021.
- [2] H. D. K. Motagh, F. Lotfi, H. D. Taghirad, and S. B. Germi, "Position estimation for drones based on visual SLAM and IMU in GPS-denied environment," *Proc. IEEE ICRoM 2019*, pp. 120–124, Tehran, Iran, Apr. 2019.
- [3] J. Borenstein, L. Ojeda, and S. Kwanmuang, "Heuristic reduction of gyro drift for personnel tracking systems," *Jour. Navigation*, vol. 62, no. 1, pp. 41–58, Jan. 2009.
- [4] E. Ebeid, M. Skriver, K. H. Terkildsen, K. Jensen, and U. Schultz, "A survey of open-source UAV flight controllers and flight simulators," *Microprocessors and Microsystems*, vol. 61, pp. 11–20, Sept. 2018.
- [5] S. Shah, D. Dey, C. Lovett, and A. Kapoor, "Airsim: High-fidelity visual and physical simulation for autonomous vehicles," M. Hutter and R. Siegwart (eds), *Field and Service Robotics*, Springer Proc. Advanced Robotics, vol. 5, pp. 621–635, Nov. 2017.