

항적 패턴 클러스터링을 이용한 항적 예측 연구

Predicting Trajectory Patterns using Trajectory Data Clustering

한성민^{1*} · 류계광¹ · 김민제¹ · 유한솔¹ · 류재영¹ · 이학태¹

¹인하대학교 항공우주공학과

Seong-min Han^{1*} · Je-gwang Ryu¹ · Min-je Kim¹ · Han-sol Yu¹ · Jae young Ryu¹ · Hak-Tae Lee¹

¹Department of Aerospace Engineering, Inha University, Incheon, Korea

[Abstract]

Trajectory prediction is one of the most important subjects in the field of air traffic management. Recently, data-driven approaches are becoming popular for predicting estimated time of arrivals or future conflicts. However, the movements of aircraft inside busy terminal areas are complex due to frequent radar vectoring by the air traffic controllers. Consequently, future trajectory of each aircraft is affected by all the other aircraft. In this study, instead of trying to predict individual trajectory, an attempt is made to predict the whole snapshot of the given airspace using clustering. One year trajectory data around Incheon International Airport and Gimpo International Airport are converted to images. For a given time interval, 365 days of images are clustered to around ten patterns and the transition probabilities network is constructed among the clusters. The network was able to generate a reasonable prediction with data not used for the clustering, which demonstrates the potential of the approach described in this paper.

I. 서론

항공 교통 관리 관련 연구에서 항적의 예측은 가장 중요한 요소이다. 이에 대하여 최근에는 데이터 기반의 연구가 많이 수행되고 있다 [1],[2].

교통량이 많은 공항과 접근 관제 구역 내의 항적은 관제사의 빈번한 벡터링에 의해 매우 복잡한 양상을 띠게 되는데 [3], 모든 항공기의 미래 항적은 다른 항공기들의 위치에 영향을 받게 된다. 따라서 기존의 방법처럼 항공기에 대한 개별적인 항적을 예측하는 것이 아니고 [4], 본 논문에서는 고정된 영역 내의 일정 시간 간격 동안의 항적을 이미지 형태로 표현해서 시간에 따라 이미지가 변해가는 과정에서 일정한 패턴을 찾고자 한다.

이를 위하여 인천국제공항, 김포국제공항 주변의 교통량이 많은 영역을 선정하고 2019년 1년간의 항적 데이터를 이용하였다. 계층적 클러스터링에 기반한 클러스터링 기법을 이용하여 클러스터들 간의 확률 전이 네트워크를 생성하였다. 이를 기반으로 클러스터 생성에 포함되지 않았던 데이터를 테스트한 결과, 본 논문에서 제시한 기법이 타당할 수 있음을 보여주었다.

2장에서는 항적 데이터와 이를 이용한 이미지 데이터 생성에 관하여 설명하고, 3장에서는 같은 시간대의 이미지를 클러스터링

하는 과정을 설명한다. 4장에서는 클러스터들 간의 정량적 확률 전이 네트워크를 생성하는 과정을 설명하고, 5장에서는 이를 이용하여 항적 패턴을 예측한 결과를 제시한다. 마지막으로 6장에서 결론을 제시한다.

II. 항적 데이터

항적 데이터는 항공 교통량이 정상적이었던 2019년 1년간의 ADS-B 데이터를 사용하였다. 그림 1과 같이 가장 교통량이 많은 인천국제공항, 김포국제공항 주변의 일정한 영역의 항적을 30분 단위로 나누어, 30분 동안의 항적을 모두 겹쳐 그리는 형태로 하루 당 48 개, 1년간 총 17,520 개의 이미지를 생성하였다. 고도는 색깔을 이용해서 표현하였는데, 붉은색에 가까울수록 고도가 낮고 노란색에 가까울수록 고도가 높다.

III. 클러스터링

본 연구의 주목적은, 같은 시간대의 서로 다른 날짜의 365개의 이미지를 클러스터링하여 특정한 패턴에 속하는 날짜들을 파악하는 것이다.

이러한 문제는 클러스터의 개수를 사전에 알 수 없기 때문에 널리 사용되는 k-means와 같은 기법은 사용하기가 어렵다. 클러

* Corresponding Author

스터의 개수 자체가 결과로 나오는 DBSCAN과 계층적 클러스터링(Hierarchical Clustering) 등 다양한 알고리즘을 테스트하였다 [5]-[7].

빠른 처리를 위해서 이미지 데이터는 256×256 행렬 형태로 변환하였고, 2 개의 이미지 간의 거리는 이 두 행렬 사이의 유클리드 거리로 정의하였다.

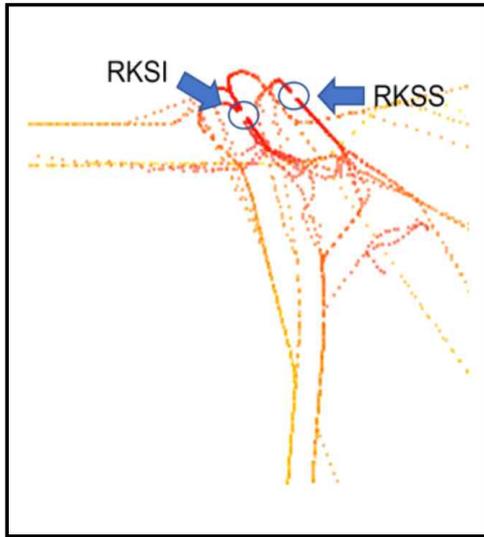


그림 1. Sample Trajectory Image

테스트 결과 그림 2에 나타난 계층적 클러스터링 기법이 가장 적절한 결과를 보여주어서, 모든 시간대에 대해 동일한 방법을 이용하여 클러스터링을 수행하였다.

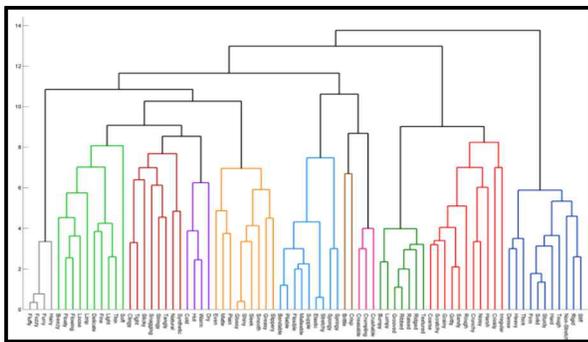


그림 2. Hierarchical Clustering

그림 3은 0시에서 0시 30분까지의 시간대에 대한 365개의 이미지를 클러스터링한 결과 중에서 하나의 클러스터에 속한 것으로 계산된 78개의 이미지 중 일부를 보여준다. 각 클러스터의 대표 이미지는 클러스터에 속하는 모든 이미지를 겹쳐서 평균을 내는 방식으로 생성하였다.

IV. 전이 확률 네트워크 생성

같은 날짜에 해당하는 이미지의 경우 한 시간대의 이미지는 다음 시간대의 이미지로 전이한다는 사실이 정해져 있기 때문에 이를 이용하여 클러스터들끼리의 연결 상태와 연결의 정도를 정량적 표현한 전이 확률 네트워크를 구성할 수 있다.

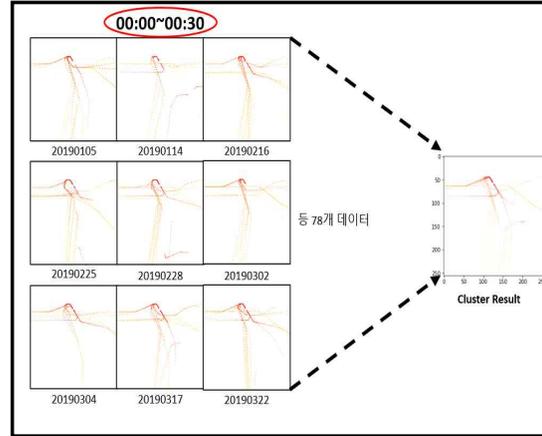


그림 3. Cluster Sample

17520개의 이미지를 시간대에 윗첨자 n , 날짜에 아래첨자 d 를 사용하여 I_d^n 라고 표현하면, 같은 날짜에 대해 이미지의 진행은 자연스럽게 다음 시간대로 이어지게 된다.

$$I_d^n \rightarrow I_d^{n+1} \quad (1)$$

n 번 시간대의 클러스터의 개수가 m_n 이라고 하고, 이 중 j 번째 클러스터에 속하는 이미지의 개수가 k_j^n 이라고 하면, 이 k_j^n 의 이미지들은 $n+1$ 시간대에서의 이미지들은 이미 정해져 있다. 이 이미지 들이 $n+1$ 시간대의 m_{n+1} 개의 클러스터에 대하여 각각 몇 개씩 포함되었는가 개수를 세면 클러스터 간의 연결 관계를 정량적으로 정의할 수가 있다.

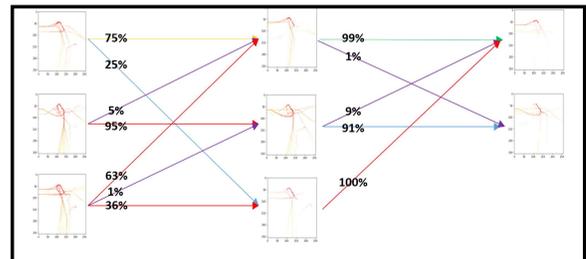


그림 4. Network Construction Example

예를 들어 n 시간대의 클러스터 C_1^n 에 50개의 이미지가 속해 있다고 가정하고, 이 이미지들의 다음 시간대 이미지 50개 중 10



그림 6. Constructed Transition Probability Network

개가 $n+1$ 시간대의 C_2^{n+1} 에 속하고 나머지 40개가 C_3^{n+1} 에 속한다면, C_1^n 패턴에서 C_2^{n+1} 패턴으로 진행될 확률은 20%, C_1^n 패턴에서 C_3^{n+1} 패턴으로 진행될 확률은 80%라고 정의하였다. 그림 4는 이러한 관계를 도식적으로 보여주었고, 실제 데이터를 이용해서 도출된 클러스터들 간의 0시부터 8시까지의 전이 확률 네트워크는 그림 6에 나타나 있다.

V. 항적 패턴 예측

항적 패턴 예측은 현재 상태가 주어지면 해당 시간대의 클러스터 중에서 어느 클러스터에 속하는 가를 판별하고, 판별된 클러스터에서부터 가장 확률이 높은 다음 시간대의 클러스터로 전이된다고 가정하여 예측하는 방법을 시도하였다. 이는 그림 6에 도시되어 있다. 추후 단순히 가장 확률이 높은 클러스터로 전이하는 것이 아니라 확률 값의 가중 평균을 이용하는 방법을 고려 중이다.

그림 7은 전이 확률 네트워크의 구성에 사용되지 않았던 2022년의 데이터를 이용하여 항적 패턴의 예측을 시도한 결과를 보여준다. 오전 7시 30분에서 오전 8시까지의 데이터를 기반으로 실제로 진행된 항적 패턴이 그림의 아랫줄에 나타나 있고, 클러스터링 결과를 이용한 전이 확률 네트워크를 이용해서 가장 확률이 높은 클러스터로 전이된다고 가정했을 때의 결과가 윗줄에 나타나 있다. 완전히 일치하지는 않지만, 3시간 후의 예측까지도 상당한 정도의 유사성을 보이고 있다.

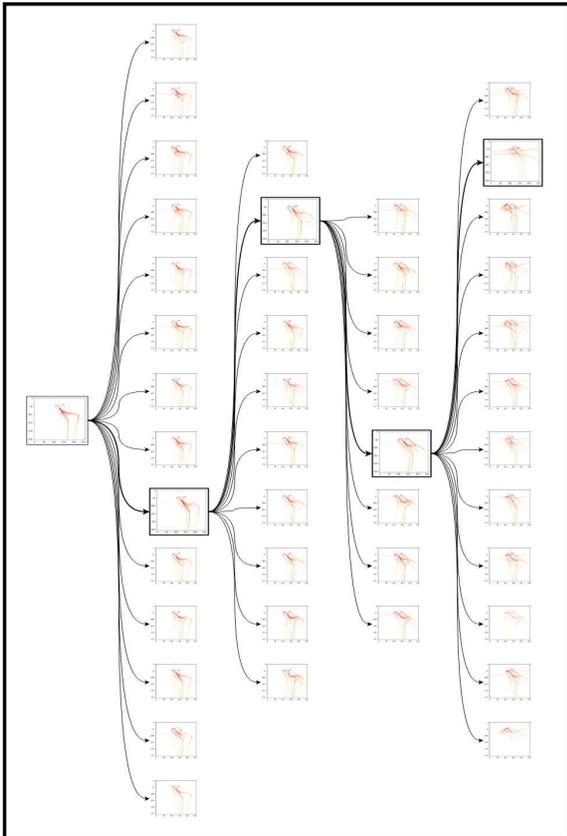


그림 5. Following Highest Probability

VI. 결 론

본 논문에서는 기존의 비행 항적을 기반으로 클러스터링 기법을 적용하여 패턴을 분류하고, 이 패턴들 간의 전이 확률을 구해서 개별 항적이 아닌 특정 시간대의 전체 교통의 모습을 예측하는 연구를 수행하였다. 계층적 클러스터링 알고리즘이 적합한 것으로 판명되었으며, 클러스터링에 사용되지 않은 데이터를 이용하여 예측을 시도한 결과 비교적 유사한 형태로 예측이 가능함을 보여주었다.

추후 데이터 추가, 항적 스냅샷의 시간 간격과 같은 파라미터 조절, 추가적인 클러스터링 알고리즘 평가 등의 연구를 진행할 예정이며, 예측에 있어서 가중 평균을 구하는 방식을 사용해 볼 예정이다.

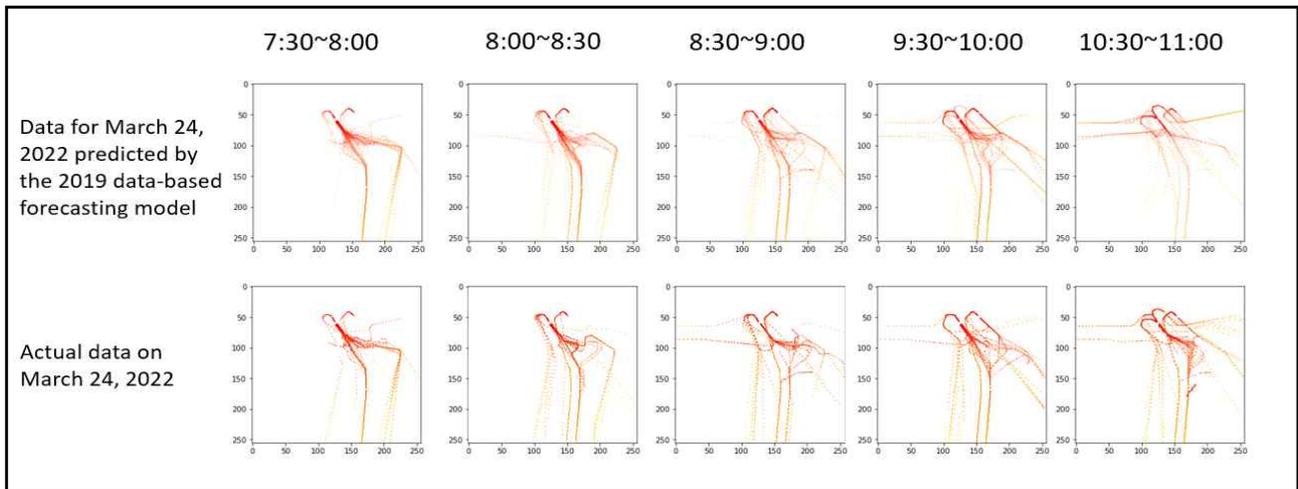


그림 7 Trajectory Pattern Prediction Results

Acknowledgments

본 연구는 국토교통부의 ‘빅데이터 기반 항공안전관리 기술개발 및 플랫폼 구축 (22BDAS-C158275-03)’ 연구의 지원에 의해 수행되었으며, 이에 감사드립니다.

References

- [1] Z. Shi, M. Xu, Q. Pan, B. Yan, and H. Zhang, "LSTM-based Flight Trajectory Prediction," *2018 International Joint Conference on Neural Networks (IJCNN)*, pp. 1-8, 2018.
- [2] X. Zhang, and S. Mahadevan, "Bayesian neural networks for flight trajectory prediction and safety assessment," *Decision Support Systems*, Vol. 131, pp. 113246, 2020.
- [3] S. Banavar, K. S. Sheth, and S. Grabbe, "Airspace complexity and its application in air traffic management," *2nd USA/Europe Air Traffic Management R&D Seminar*. Washington, DC: Federal Aviation Administration, 1998.
- [4] H. C. Choi, D. Chuhao, and I. S. Hwang, "Hybrid Machine learning and estimation-based flight trajectory prediction in terminal airspace," *IEEE Access* 9, pp. 151186-151197, 2021.
- [5] E. Martin, H. P. Kriegel, J. Sander, and X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," *kdd*, Vol. 96, No. 34, 1996.
- [6] S. C. Johnson, "Hierarchical clustering schemes," *Psychometrika*, Vol. 32, No. 3, pp. 241-254, 1967.
- [7] J. A. Hartigan, and M. A. Wong, "Algorithm AS 136: A k-means clustering algorithm," *Journal of the royal statistical society. series c (applied statistics)*, Vol. 28, No. 1, pp. 100-108, 1979.