

공학석사학위 논문

빅데이터를 이용한 최종접근경로 과이탈 예측 연구

Data-Driven Final Approach Overshoot Prediction

2024년 2월

인하대학교 대학원

항공우주공학과(항공우주공학전공)

한성민

공학석사학위 논문

빅데이터를 이용한 최종접근경로 과이탈 예측 연구

Data-Driven Final Approach Overshoot Prediction

2024년 2월

지도교수 이 학 태

이 논문을 석사학위 논문으로 제출함

이 논문을 한성민의 석사학위논문으로 인정함.

2024년 2월 16일

주심 김 중 한 (인)

부심 이 학 태 (인)

위원 목 성 훈 (인)

초록

항공기는 여러 비행단계를 거쳐 운항을 시작하고 종료한다. 운항 중 안전사고는 주로 착륙 단계에서 발생하며, 이는 이전 접근 단계에서의 영향을 받을 수 있다. 따라서 접근 단계 중 발생할 수 있는 최종접근경로 과이탈 현상에 대한 연구를 진행하였다. 최종접근경로 과이탈이 발생하면 Glideslope 편차나 Localizer 편차와 같은 불안전 접근을 유래할 수 있고, 나아가 복행이나 경착륙 같은 심각한 안전문제로 이어질 수 있다. 본 논문에서는 최종접근경로 과이탈에 대해 분석하고, 이를 이용하여 과이탈을 예측하고자 한다.

최종접근경로 과이탈을 분석하기 위해 ADS-B 항적 데이터를 사용하는 과이탈 산출 알고리즘을 개발하였고 이를 이용하여 과이탈을 산출하였다. 산출된 결과는 지상속도, 바람 성분, 클러스터링을 활용하여 분석하였다. 항적 데이터에는 바람에 관한 정보가 포함되어 있지 않기 때문에 기상청에서 제공하는 KLAPS 기상데이터를 활용하였으며, 바람 정보를 추출하기 위해 기상 데이터를 전처리하고 항적데이터와 결합하는 과정을 진행하였다. 클러스터링을 활용한 분석은 이전 김해공항을 대상으로 실행한 연구결과와 과이탈을 비교하여 분석을 진행하였다. 분석 결과 접근 구간에서 과이탈이 발생한 항공기의 지상속도가 더 큰 것을 확인했으며, 측풍 성분과 배풍 성분의 속도가 증가함에 따라 과이탈이 증가하는 경향을 확인였고, 특정 군집에서 과이탈 비율이 매우 큰 것을 확인하였다.

최종접근경로 과이탈을 예측하기 위해 머신러닝 기법 중 심층 신경망 기법을 사용하였다. 심층 신경망의 입력 값으로는 과이탈에 영향을 미치는 지상속도, 측풍 속도, 배풍 속도, 클러스터링 결과가 사용되었으며, 과이탈 발생 비율이 출력되도록 모델을 구성하였다. 2019년 김해공항에서 과이탈이 발생하지 않은 항공기와 과이탈이 발생한 항공기 중 각각 무작위 90%를 선택하여 학습을 수행하였고, 나머지 10% 항적의 예측을 시도하였다. 예측 결과와 실제 결과를 비교한 결과 경향성을 따라가긴 하지만 두 값의 차이가 커, 모델을 보완할 필요가 있다.

핵심어: ADS-B 항적 데이터, KLAPS 기상 데이터, 최종접근경로 과이탈, 심층 신경망

Abstract

Aircraft begin and end their operations through several phases of flight. The highest number of safety incidents in flight occurs during the landing phase, which can be influenced by the previous approach phase. We have therefore investigated the phenomenon of Final Approach Overshoot that can occur during the approach phase. Final approach Overshoot can result in unsafe approaches, such as glideslope deviations and localizer deviations, and can lead to serious safety problems, such as go around and hard landings. In this paper we analyze final approach path deviations and use them to predict deviations.

To analyze Final Approach Overshoot, an algorithm for calculating Overshoot using ADS-B trajectory data was developed and used to calculate Overshoot. The results were analyzed using ground speed, wind component and clustering. Since the trajectory data does not contain wind information, KLAPS weather data provided by the Korea Meteorological Administration was used, and the weather data was pre-processed and combined with the navigation data to extract wind information. The analysis using clustering was performed by comparing the Overshoot with the previous results of Gimhae Airport. As a result of the analysis, it was found that the ground speed of the aircraft Overshoot in the approach section was larger, the probability of Overshoot increased as the speed of the crosswind component and the tailwind component increased, and the probability of Overshoot in certain clusters was very large.

A deep neural network was used as a machine learning technique to predict Final Approach Overshoot. The input values of the deep neural network were ground speed, crosswind speed, exhaust wind speed, and clustering results, which affect Overshoot, and the model was configured to output the probability of Overshoot. For training, we randomly selected 90% of the non-Overshoot flights and 90% of the Overshoot flights at Gimhae Airport in 2019, and attempted to predict the remaining 10% of the flights. Comparing the predicted results with the actual results, it follows the trend, but the difference between the two values is large and the model needs to be supplemented.

Keywords: ADS-B Trajectory Data, KLAPS Weather Data, Final Approach Overshoot,
Deep Neural Network

제 1 장. 서론	1
1.1 연구 배경	1
1.2 연구 목표	2
1.3 연구 방향	2
제 2 장. 최종접근경로 과이탈	4
2.1 ADS-B 항적 데이터	4
2.2 최종접근경로 과이탈	5
2.3 최종접근경로 과이탈 산출 과정	5
2.3.1 과이탈 거리 산출 방법	5
2.3.2 착륙 활주로 판별	6
2.3.1 과이탈 판별 조건	7
2.4 최종접근경로 과이탈 산출 결과	9
2.4.1 김해공항	9
2.4.2 인천공항	9
2.4.3 김포공항	10
2.4.4 제주공항	11
제 3 장. 최종접근경로 과이탈 분석	13
3.1 속도 분석	13
3.1 바람 분석	16
3.2.1 바람 성분 추출 지점	16
3.2.2 바람 성분 추출	19

3.2.2.1 KLAPS 기상 데이터	19
3.2.2.1 데이터 변환 및 바람 성분 추출	19
3.2.3 바람 장미	20
3.2.4 공항 별 바람 분석 결과	23
3.2.4.1 김해공항	23
3.2.4.2 인천공항	25
3.2.4.3 제주공항	30
3.2.4.4 김포공항	33
3.3 클러스터링 분석	39
3.3.1 클러스터링 결과 재 군집	39
3.3.1 클러스터링 분석	41
제 4 장. 심층 신경망을 이용한 과이탈 예측	48
4.1 심층 신경망	48
4.2 과이탈 예측 결과	49
제 5 장. 결론	51
제 6 장. 참고문헌	52

그림 차례

그림 1 비행 단계 별 안전사고 분포	1
그림 2 연구 방향	3
그림 3 최종접근경로 과이탈 개념도	5
그림 4 과이탈 발생 항공기의 투영 궤적	6
그림 5 활주로 판별 알고리즘	7
그림 6 착륙 활주로 및 과이탈 지점 판별 결과	8
그림 7 김해공항의 과이탈 결과	9
그림 8 인천공항 과이탈 결과	10
그림 9 김포공항 과이탈 결과	11
그림 10 제주공항 과이탈 결과	12
그림 11 김해공항 36L 활주로 접근구간 속도분포	13
그림 12 김해공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교	13
그림 13 인천공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교	14
그림 14 제주공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교	15
그림 15 김포공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교	15
그림 16 김해공항 36L 활주로의 과이탈 히트맵	16
그림 17 인천공항 과이탈 히트맵	17
그림 18 제주공항 과이탈 히트맵	18
그림 19 김포공항 과이탈 히트맵	18
그림 20 등압면에서 고도면으로 기상 데이터 변환 과정	19
그림 21 기상 데이터와 항적데이터 결합 과정	20
그림 22 김해공항 36L 활주로의 바람 장미	21

그림 23	과이탈 유무와 과이탈 방향에 기반한 바람 장미 분류 과정	22
그림 24	36L 활주로의 측풍 성분에 따른 과이탈 비율	24
그림 25	36L 활주로의 배풍 성분에 따른 과이탈 비율	24
그림 26	15L 활주로와 16 활주로의 바람 장미	25
그림 27	15L 활주로와 16 활주로의 바람 성분에 따른 과이탈 비율	26
그림 28	33R 활주로 바람 장미	27
그림 29	33R 활주로의 바람 성분에 따른 과이탈 비율	28
그림 30	34 활주로 바람 장미	29
그림 31	34 활주로의 바람 성분에 따른 과이탈 비율	29
그림 32	07 활주로 바람 장미	30
그림 33	07 활주로의 바람 성분에 따른 과이탈 비율	31
그림 34	25 활주로 바람 장미	32
그림 35	25 활주로의 바람 성분에 따른 과이탈 비율	33
그림 36	14R 활주로 바람 장미	34
그림 37	14R 활주로의 바람 성분에 따른 과이탈 비율	34
그림 38	32L 활주로 바람 장미	35
그림 39	32L 활주로의 바람 성분에 따른 과이탈 비율	36
그림 40	32R 활주로 바람 장미	37
그림 41	32R 활주로의 바람 성분에 따른 과이탈 비율	38
그림 42	김해공항의 STAR 지점	39
그림 43	86개의 군집 재 군집화	40
그림 44	MASTA-1의 19개 군집	43
그림 45	과이탈 비율이 큰 MASTA-1 군집	44
그림 46	KALEK-1의 8개 군집	46

그림 47 과이탈 비율이 큰 KALEK-1 군집 47
그림 48 심층 신경망 구조 48

표 차례

표 1 ADS-B 항적 데이터 예시	4
표 2 국내 공항 과이탈 요약	17
표 3 대군집별 과이탈 비율	41
표 4 MASTA-1의 군집 별 과이탈	42
표 5 KALEK-1의 군집 별 과이탈	45
표 6 심층 신경망 파라미터	49
표 7 Layer node	49
표 8 과이탈 예측 결과 및 비교	50

제 1 장. 서론

1.1 연구 배경

항공기의 운항은 다양한 비행 단계를 거쳐 이뤄지며, 이러한 단계들은 비행 계획, 이륙, 상승, 순항 등 다양한 단계를 포함한다. 그림 1 은 국제 항공 운송 협회 (International Air Transport Association, IATA) 안전 보고서에 기재된, 각 비행 단계에서의 안전 사고 비율이다[1]. 2017년부터 2021년까지의 통계에 따르면, 안전 사고가 가장 많이 발생하는 단계는 착륙 단계이다.




그림 1 비행 단계 별 안전사고 분포

항공기의 비행 단계는 연속적으로 이루어진다. 이는 현재 단계의 비행이 다음 단계의 비행에 영향을 미칠 수 있음을 의미한다. 특히, 본 연구에서는 착륙 단계 직전 인 접근 단계에서 발생하는 최종접근경로 과이탈에 주목하여 연구가 진행된다.

1.2 연구 목표

항공 교통과 관련된 연구에서 운항 중 안전은 가장 중요한 요소로 간주된다. 최근에는 안전 및 위험도를 분석하는 데이터 기반으로 분석하는 연구가 활발하게 수행되고 있으며, 특히 AI 기법을 활용한 비행 중 위험도를 예측하는 연구도 두드러지게 수행되고 있다[2-4].

본 연구는 ADS-B 항적 데이터를 활용하여 최종접근경로 과이탈을 산출하고, 이 과이탈에 영향을 미치는 요인들을 분석하는 것을 목표로 한다. 특히 최종접근경로 과이탈이 발생했을 경우, Glideslope 편차나 Localizer 편차와 같은 불안정한 접근을 초래할 수 있으며, 이는 복행 또는 경착륙과 같은 더 심각한 안전 문제로 이어질 수 있다. 따라서 본 연구는 안전한 비행을 유지하기 위해 최종접근경로 과이탈을 예측하는 데에 중점을 두고 진행된다.

1.3 연구 방향

본 연구의 진행 방향을 그림 2에 나타내었다. 2019년도 국내 주요 공항인 인천공항, 김포공항, 김해공항, 제주공항에 착륙하는 항공기의 ADS-B 항적 데이터를 사용하여 과이탈을 산출하였으며, 과이탈 산출을 위해 알고리즘을 개발 및 구현하였다. 이를 통해 산출된 결과를 지상속도, 바람 성분, 클러스터링을 이용하여 분석을 진행하였다. 기상 데이터를 활용하여, 항적 데이터에는 존재하지 않은 바람 성분을 추출하였으며, 바람 성분을 추출하기 위해 기상 데이터 전처리 과정과, 처리된 기상 데이터와 항적 데이터를 결합하는 과정을 진행하였다. 이후 과이탈 거리와 비행 거리의 관계를 히트맵으로 나타내어 바람 성분을 추출할 지점을 확인하였고, 추출 지점에서의 측풍 성분과 배풍 성분을 바람 장미를 이용하여 분석을 진행하였다. 지상속도 분석과 바람 성분 분석은 공항의 활주로 별로 세분화하여 진행하였다. 클러스터링 분석은 선행 연구에서 김해공항을 대상으로 수행된 클러스터링 결과와 과

이탈 산출을 비교하여 진행하였다. 앞서 분석된 지상속도, 바람 성분, 클러스터링 결과와 머신러닝 기법을 활용하여 최종접근경로 과이탈을 예측하고, 실제 결과와 비교 분석하였다.

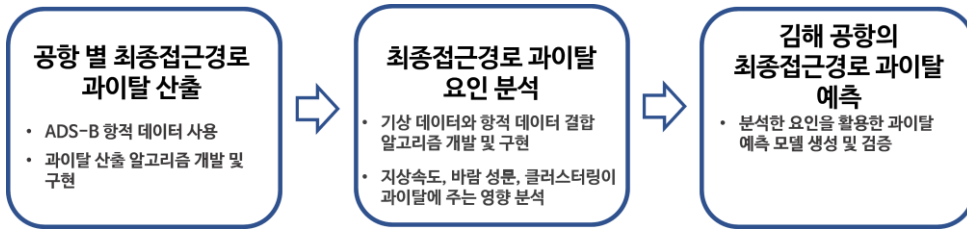


그림 2 연구 방향

제 2 장. 최종접근경로 과이탈

2.1 ADS-B 항적 데이터

본 연구에서 최종접근경로 과이탈을 산출하기 위해 사용한 항적 데이터는 ‘방송형-자동 종속 감시 (Automatic Dependent Surveillance-Broadcast, ADS-B)’이다. ADS-B 항적 데이터에는 항공기의 고유 식별코드, 출발 공항, 도착 공항, 콜사인, 항적의 위치정보, 수신 시간, 속도, 방향 등이 포함되어 있다. 본 연구에서는 항공 교통량이 가장 많은 국내의 4개 공항인 인천국제공항, 김포국제공항, 김해국제공항, 제주국제공항을 기준 공항으로 설정하였다. 2019년 1년동안 해당 공항에 착륙하는 항공기의 ADS-B 데이터를 FlightAware 사에서 구매하여 최종 접근경로 과이탈을 산출하는데 사용하였다. 표 1은 단일 항공기의 ADS-B 데이터의 예시를 나타낸다. 해당 데이터에서 알 수 있듯이 데이터가 시간에 대해 연속적이지 않으므로, 1초를 기준으로 위치정보(위도, 경도, 고도)를 선형 보간하여 사용하였다.

표 1 ADS-B 항적 데이터 예시

Callsign		Type			Origin		Destination	
AAR8001		A320			RKPK		RKPC	
Time	Lat(deg)	Lon(deg)	Alt(ft)	GS(knot)	VR(fpm)	Crs(deg)		
2019-01-06 04:25:56	34.9395	128.3068	20575	393	1600	226		
2019-01-06 04:26:27	34.8964	128.2618	21700	395	2177	226		
2019-01-06 04:26:57	34.8557	128.2198	21975	385	550	226		

2.2 최종접근경로 과이탈

항공기가 활주로에 정렬하는 과정에서, 항공기의 궤적을 평면에 투영한 결과, 궤적이 활주로 중심선을 침범하고 일정 범위 이상 이탈할 경우 최종 접근 경로 과이탈(Final Approach Overshoot)이 발생한다. 그림 3은 최종 접근 경로 과이탈을 시각적으로 나타낸다. 본 연구에서는 과이탈 거리가 100m부터 1000m까지의 범위에 해당할 때 최종 접근 경로 과이탈로 정의한다. 여기서 비행 거리(Travel Distance)는 현재 위치부터 도착 시점까지 남은 비행 거리를 의미하며, 과이탈 거리(Overshoot Distance)는 과이탈이 발생할 때 활주로 중심선과 항적 사이의 최대 수직 거리를 의미한다.

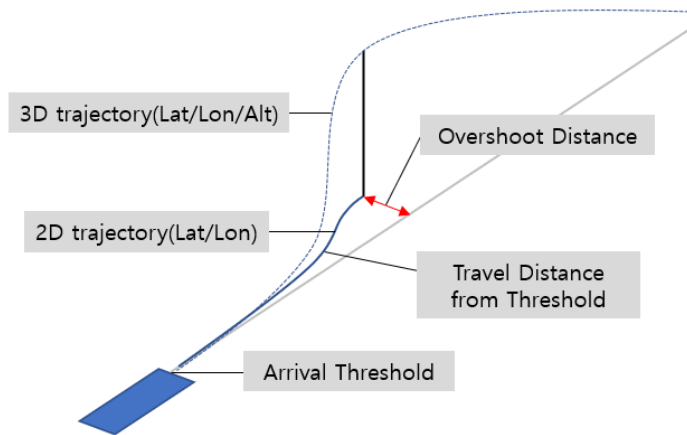


그림 3 최종접근경로 과이탈 개념도

2.3 최종접근경로 과이탈 산출 과정

2.3.1 과이탈 거리 산출 방법

최종접근경로 과이탈을 산출하기 위해서는 항적 데이터의 위치 정보(위도, 경도)를 2D 평면에 투영해야 한다. 이를 위해 람베르트 정각 원추 도법을 활용하였으며, 투영 오차 최소화를 위해 공향에 따라 투영 범위를 다르게 설정하였다. 그림 4은

최종접근경로 과이탈이 발생한 항공기 궤적을 2D 평면에 투영한 결과를 나타낸다. 각 위치에서 식 (2-1, 2-2)를 활용하여 활주로 중심선과 항공기 사이의 거리를 계산하였다. 과이탈이 발생한 항공기를 기준으로, 만일 활주로는 좌측에 위치한다면 거리는 음수(-)로 정의되며, 우측에 위치한다면 양수(+)로 정의된다. 거리의 부호가 바뀌면 활주로를 침범한 것으로 간주한다.

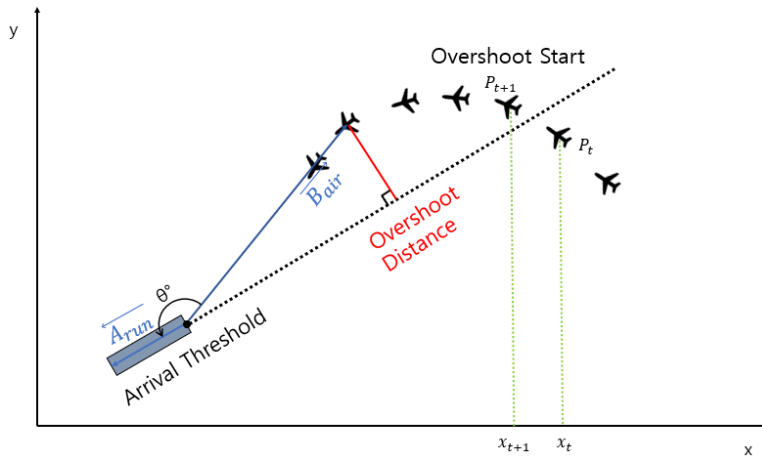


그림 4 과이탈 발생 항공기의 투영 궤적

$$\sin \theta^\circ = \frac{\vec{B}_{air} \times \vec{A}_{run}}{|\vec{A}_{run}| |\vec{B}_{air}|} \quad (2-1)$$

$$Distance = -|\vec{B}_{air}| \sin \theta^\circ \quad (2-2)$$

2.3.2 착륙 활주로 판별

ADS-B 항적 데이터에는 위치, 속도, 방향 데이터는 존재하지만 착륙 활주로 정보는 존재하지 않는다. 접근 단계에서 활주로의 방향과 항적 데이터의 방향을 비교하면 어떤 활주로는 착륙하는지 판별이 가능하다. 하지만 공항에 다수의 평행 활주로는 존재한다면 방향 데이터만으로 판별이 불가하며, 잘못된 활주로 판별을 활주로 사이 간격만큼 과이탈 오차가 발생한다. 정확한 활주로 판별을 위해 그림 [4]의 방법을 사용하였다.




그림 5 활주로 판별 알고리즘

평행 활주로를 갖는 공항에서의 항공기 착륙에 대한 예시를 나타내는 그림 [4]에서, 각 활주로 중심선과 항적 사이의 거리를 계산하기 위해 식 (2-1, 2-2)를 적용하였다. 이를 통해 거리가 100m 이내인 시간을 확인하고, 항적이 교차하는 활주로 중 가장 오랜 시간을 소비한 활주로를 찾아내어 착륙 활주로로 판별한다. 그림 5의 예시에서 단일 항적은 Runway1과 3초, Runway2와 7초 동안 정렬하였으므로, Runway2가 착륙 활주로로 판별된다.

2.3.3 파이탈 판별 조건

파이탈 산출 결과를 향상시키기 위해 다음과 같은 추가 조건을 도입하였다. 먼저, 접근 구간에서 활주로와 항적이 교차하는 지점을 찾기 위해 도착 공항을 기준으로 투영 거리가 15nmi 이내인 항적 데이터만을 활용하였다. 이때, 공항의 기준 위치(위도, 경도)는 항공정보포털시스템에 기재된 위치 정보를 활용하였다[5]. 만약 15nmi 이내에서 항적이 반대편 활주로 중심선과 교차할 경우, 잘못된 파이탈이 산출될 가능성이 있다. 따라서 교차할 때 항적의 방위각과 도착 활주로의 방향을 비교하고, 이 각이 45° 이내일 때를 파이탈로 판단한다. 그림 6은 파이탈이 발생했다

고 판단된 일부 항공기의 궤적을 보여준다. 다수의 평행 활주로가 존재하는 공항에서 착륙 활주로와 파이탈 지점이 판별된 것을 확인할 수 있다.

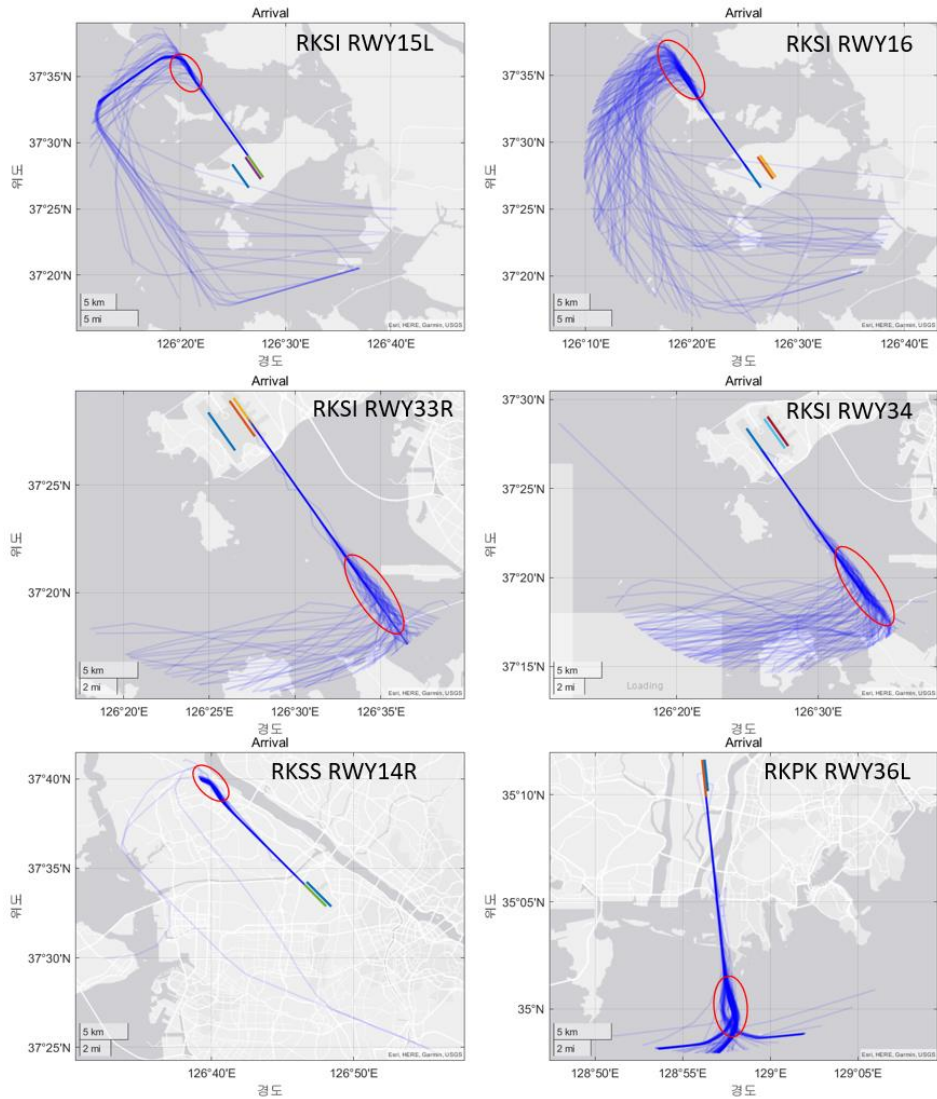


그림 6 착륙 활주로 및 파이탈 지점 판별 결과

2.4 최종접근경로 파이탈 산출 결과

다음은 앞서 개발한 알고리즘을 사용하여 산출된 파이탈 결과이다. 공항 및 착륙 활주로에 대해 분리하여 항공기의 파이탈 거리 분포를 시각적으로 나타내었다.

2.4.1 김해공항

2019년 김해공항에 착륙하는 항공기 대부분은 주로 36L 활주로를 이용했다. 해당 년도에는 총 51,016대의 항공기가 착륙하였으며, 이 중 3,378대의 파이탈이 발생했다. 김해공항에서의 파이탈 분포는 파이탈 거리가 증가함에 따라 항공기의 비율이 감소하는 평균적인 양상을 보여주고 있다.




그림 7 김해공항의 파이탈 결과

2.4.2 인천공항

2019년 인천공항에 착륙하는 항공기는 주로 15L, 16, 33R, 34 활주로를 이용했다. 각각 33,739대, 13,201대, 107,172대, 32,722대의 항공기가 착륙하였으며 이 중 1,603대, 554대, 904대, 736대의 파이탈이 발생했다. 인천공항에서는 15L, 16 활주로에 착륙하는 항공기의 파이탈의 발생 확률이 33R, 34 활주로에 착륙하는 항공기보다 높은 것을 그림 8에서 확인할 수 있다.

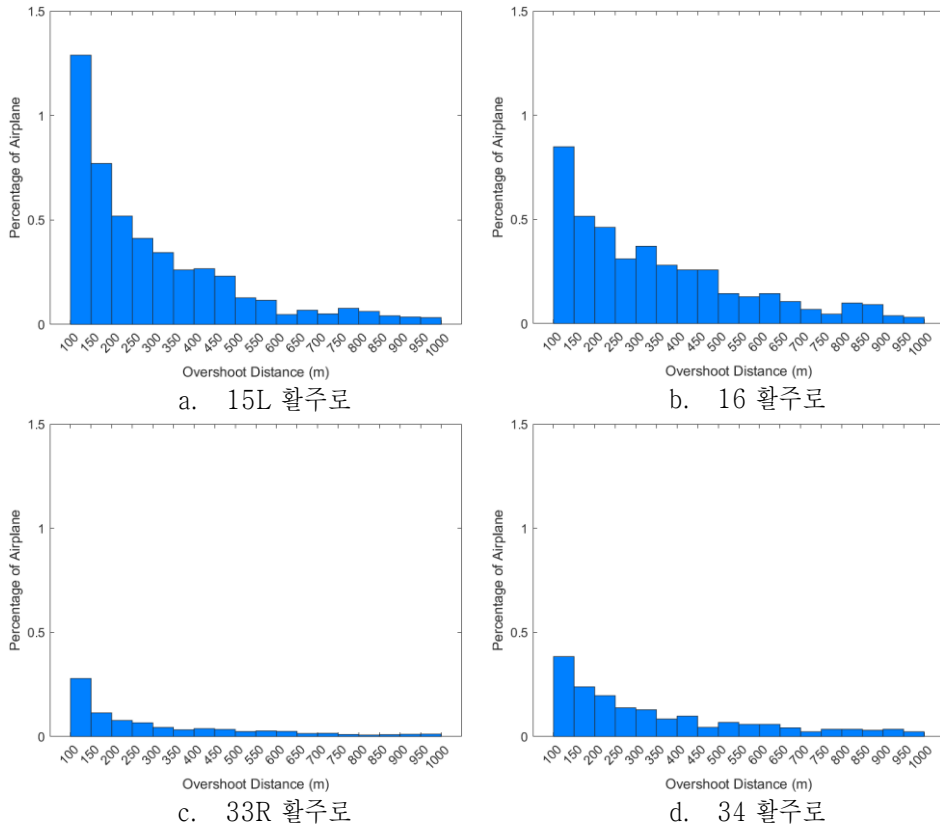




그림 8 인천공항 파이탈 결과

2.4.3 김포공항

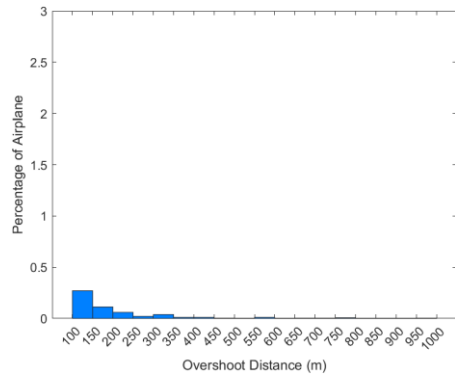
2019년 김포공항에 착륙하는 항공기는 주로 14R, 32L, 32R 활주로를 이용했다. 각각 18,193대, 24,964대, 28,469대의 항공기가 착륙하였으며, 이중 1,751대, 114대, 158대의 파이탈이 발생했다. 김포공항의 14R 활주로에 착륙하는 항공기 수는 32L과 32R 활주로에 착륙하는 항공기수보다 적지만 파이탈이 발생한 항공기는 훨씬 많은 것을 확인할 수 있다.



a. 14R 활주로



b. 32L 활주로




c. 32R 활주로


그림 9 김포공항 파이탈 결과

2.4.4 제주공항

제주공항에는 07, 25활주위에 각각 51422대, 36187대의 항공기가 착륙하고 3906대, 1551대의 파이탈이 발생했다. 그림 10에서 25활주로의 파이탈은 평균적인 양상을 갖는 반면에, 07활주로의 파이탈 거리 200m 이상에서 평균 이상으로 분포되어 있음을 확인할 수 있다.



a. 07 활주로



b. 25 활주로

그림 10 제주공항 과이탈 결과

제 3 장. 최종접근경로 파이탈 분석

3.1 속도 분석

최종접근경로 파이탈에 접근구간의 속도가 주는 영향을 확인하기 위해 활주로별로 1년동안 착륙 항공기의 속도분포를 중첩하여 분석하였다. 비행거리 6 - 14nmi 지점에서 파이탈 항공기와 정상 항공기의 속도분포를 각각 중첩하였으며 속도 분포의 ± 1 표준편차 부분을 표시하였다.

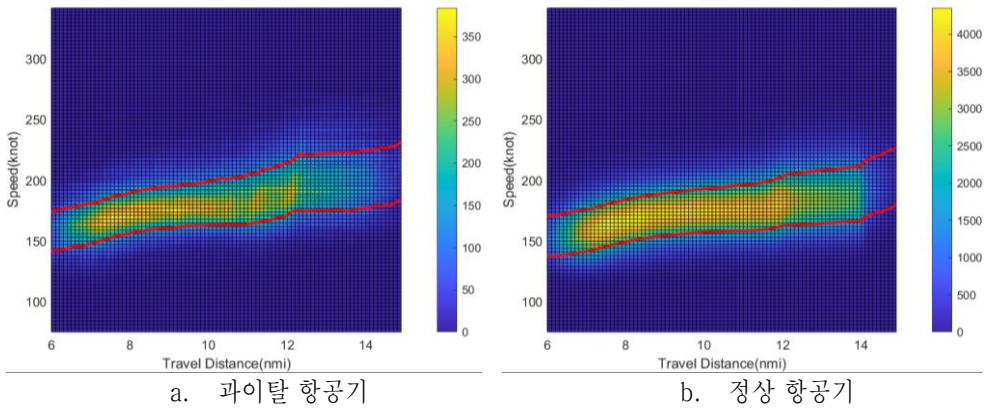


그림 11 김해공항 36L 활주로 접근구간 속도분포




그림 12 김해공항 파이탈(Over) 및 정상(Normal) 항공기 속도 비교

그림 11은 김해공항 36L 활주로에 착륙하는 과이탈 항공기와 정상 항공기의 속도 분포를 보여주며, 그림 12는 두 속도분포의 표준편차를 비교하였다. 김해공항의 접근 구간에서 과이탈 항공기가 정상 항공기보다 더 큰 속도로 분포되어 있음을 확인할 수 있다. 또한, 이어지는 그림들은 타 공항들의 속도분포를 비교한 것이며, 대부분의 공항에서도 접근구간에서 김해공항과 같은 경향을 보인다. 이러한 속도 분포의 차이는 최종접근경로 과이탈 발생 시 항공기의 비행 속도가 접근구간에서 특히 높게 나타날 수 있음을 시사한다. 김포공항의 32L 활주로나 32R 활주로에 착륙하는 경우에는 다른 경향이 나타나는데, 이는 과이탈 항공기의 비율과 수가 적어 경향성을 확인하기 어렵다는 점을 고려한다.


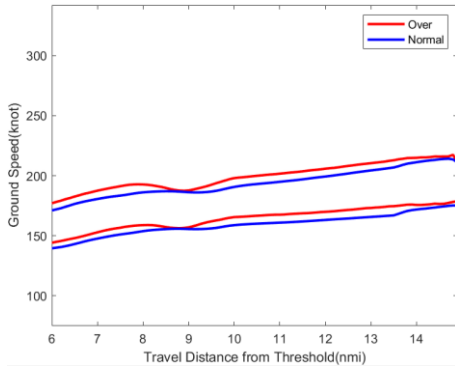



그림 13 인천공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교




a. 07 활주로




b. 25 활주로

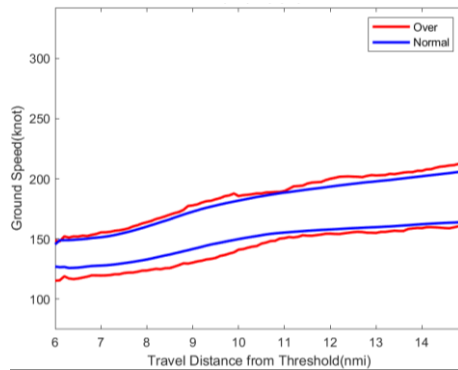
그림 14 제주공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교



a. 14R 활주로



b. 32L 활주로



c. 32R 활주로

그림 15 김포공항 과이탈(Over) 및 정상(Normal) 항공기 속도 비교

3.2 바람 분석

3.2.1 바람 성분 추출 지점

최종접근경로 과이탈에 바람의 영향이 있다고 가정된 후 하고 바람 성분을 추출하였다. 바람 성분을 추출할 지점을 선택하기 위해 과이탈 거리와 비행거리의 히트맵을 이용하였다. 그림 16은 김해공항 36L 활주로의 히트맵으로, 주로 음의 방향 과이탈이 발생했고, 비행거리 8-11nmi 범위에서 과이탈 최대 지점이 집중되어 있음을 확인할 수 있다. 이러한 관찰을 토대로, 과이탈 발생 범위의 최대값에 1nmi를 더한 비행거리 12nmi 지점을 기준으로 바람을 추출하였다.

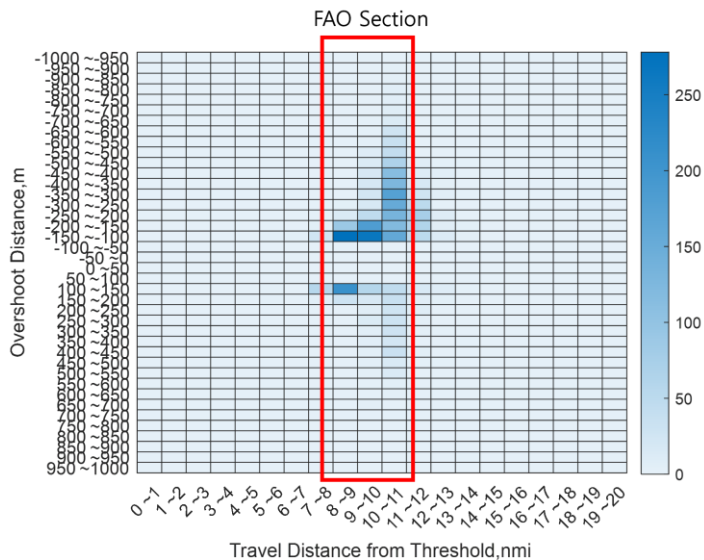



그림 16 김해공항 36L 활주로의 과이탈 히트맵

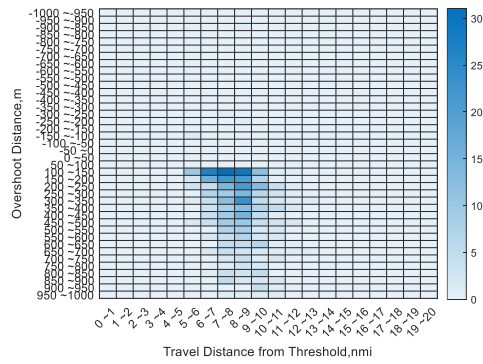
표 2는 앞서 산출한 각 공항의 과이탈과 바람 성분 추출 지점을 요약하여 보여주고 있으며, 이어지는 그림들은 타 공항의 활주로별 히트맵들을 나타내고 있다.

표 2 국내 공항 과이탈 요약

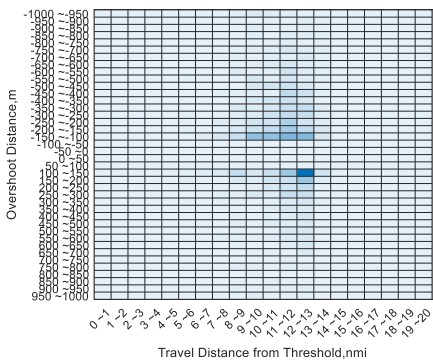
공항	활주로	착륙 항공기	과이탈 항공기	과이탈 비율 (%)	바람 추출 지점 (nmi)
김해	36L	51,016	3,378	6.6	12
인천	15L	33,739	1,603	4.8	9
	16	13,201	554	4.2	10
	33R	107,172	904	0.84	13
	34	32,722	736	2.3	14
김포	14R	18,193	1,751	9.6	9
	32L	24,964	114	0.46	12
	32R	28,469	158	0.55	13
제주	07	51,422	3,905	7.6	10
	25	36,187	1,551	4.3	12



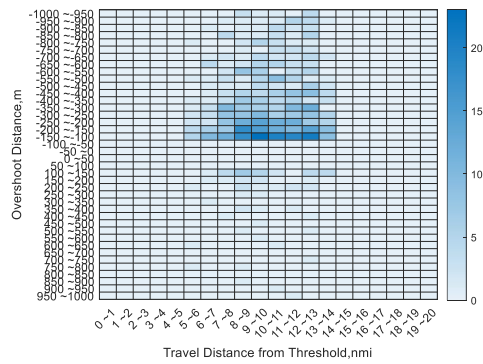
a. 15L 활주로



b. 16 활주로



c. 33R 활주로



d. 34 활주로

그림 17 인천공항 과이탈 히트맵

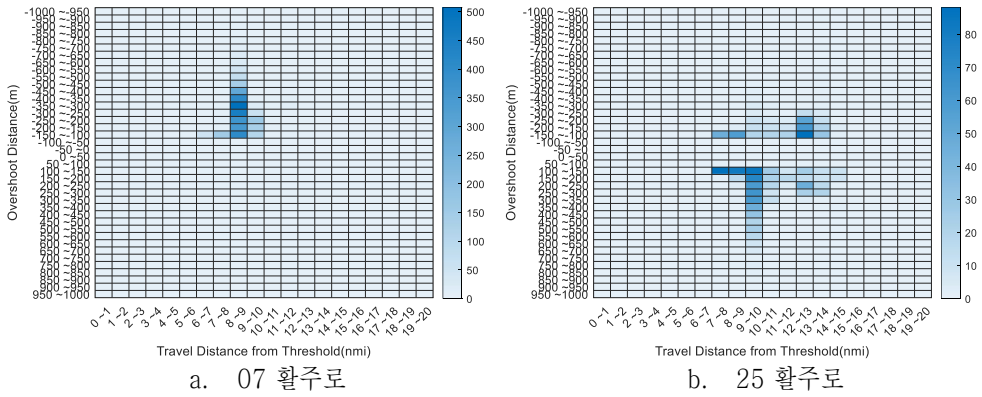


그림 18 제주공항 파이탈 히트맵

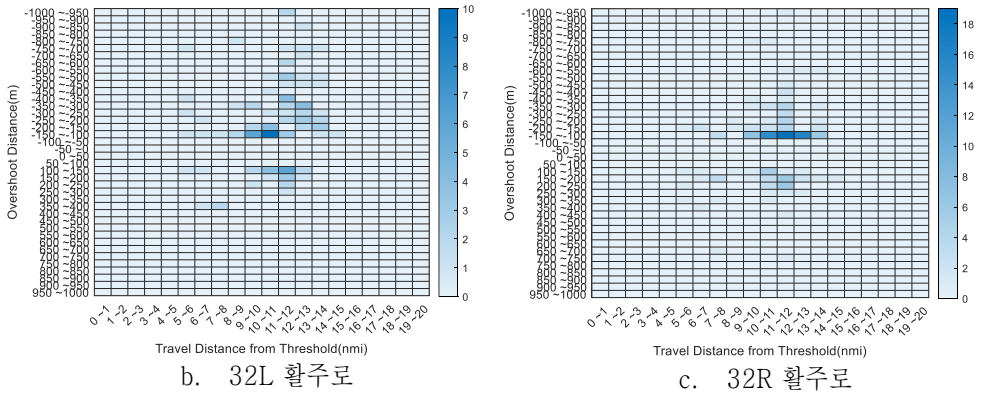
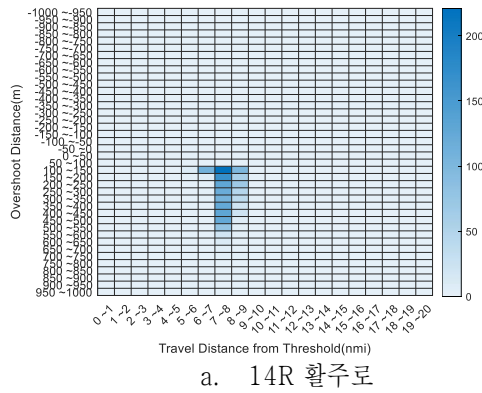


그림 19 김포공항 파이탈 히트맵

3.2.2 바람 성분 추출

3.2.2.1 KLAPS 기상 데이터

초단기예보모델(Korean Local Analysis and Prediction System, KLAPS)은 한반도의 기상예측을 위해 수행하는 수치예보시스템을 의미하며, 주로 한반도 영역의 3차원 분석 예측에 활용된다[6]. 기상청에서 제공하는 KLAPS 기상 데이터는 수평방향으로 5km 간격의 235×283개의 격자점과 수직방향으로 50hPa 간격의 23개의 등압면으로 이루어진 대형 격자 데이터이다[7]. 등압면은 지표면과 50hPa - 1100hPa의 22개의 등압면으로 이루어져 있으며, 1시간 간격으로 제공된다. 각 격자점에는 기압, 온도, 지위 고도, 풍향, 풍속 등 다양한 정보가 포함되어 있다.

3.2.2.2 데이터 변환 및 바람 성분 추출

KLAPS 기상 데이터의 수직 방향 격자점은 등압면을 기준으로 하기 때문에 ADS-B 항적 데이터와 결합하기 위해서는 고도면으로 변환하는 전처리과정이 필요하다. 그러나 등압 고도를 사용하여 변환하는 경우에는 그림 20과 같이 고도면이 평평하지 않게 된다. 따라서 각 격자점의 위치와 기상 정보를 지위 고도를 이용하여 500m 간격으로 선형 보간하여 새로운 격자 형태로 변환하였다[8].




그림 20 등압면에서 고도면으로 기상 데이터 변환 과정

주어진 시간에 항적이 위치하는 지점의 바람 성분을 추출하기 위해서는 16개의 격자점을 기상 데이터에서 가져와야 한다. 기상 데이터는 1시간 간격으로 제공되므로 주어진 시간을 포함하는 가장 가까운 2개의 시간대에서 항적의 위치를 포함하는 8개의 격자점을 선택해야 한다. 한 시간대에서 큐브 형태의 8개 격자점의 바람 성분을 3차 선형 보간을 통해 항적이 위치하는 지점의 바람 성분을 추출하게 된다. 이후, 다른 시간대에서 추출된 바람성분과 1차 선형 보간을 통해 주어진 시간과 위치에서의 바람성분을 정확히 추정할 수 있다. 그림 21은 바람 성분을 추출하는 과정을 시각적으로 나타내고 있다.

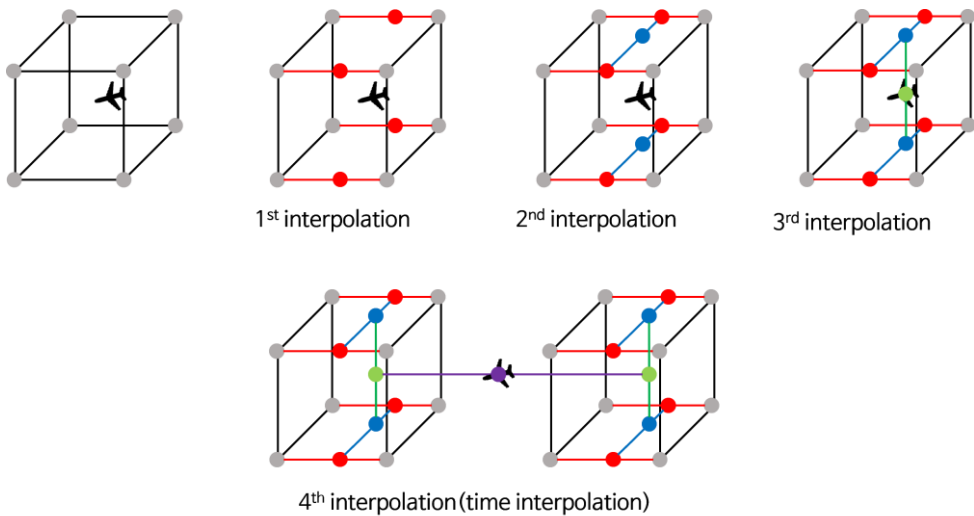


그림 21 기상 데이터와 항적데이터 결합 과정

3.2.3 바람 장미

바람의 영향을 분석하기 위해, 바람 장미를 이용하여 바람 성분을 시각적으로 표현하였다. 바람 장미는 기본적으로 원형의 히스토그램으로 나타내며, 앞서 활주로 별로 지정한 추출지점에서의 바람 성분을 기반으로 한다. 이러한 바람 장미에서 바

람의 방향은 중앙에서 바깥 방향을 향하고 있다. 또한, 바람의 속도는 파란색에서 노란색까지 색상으로 구분되며, 부채꼴의 길이는 빈도를 나타낸다.

그림 22는 바람 장미의 예시로, 김해공항 36L 활주로에 착륙하는 항공기의 바람의 방향, 속도, 빈도를 나타낸다. 분석을 위해 활주로 방향이 표시되어 있으며, 자기 방향에 대한 보정으로 정북 방향을 향하지 않도록 조정되었다.

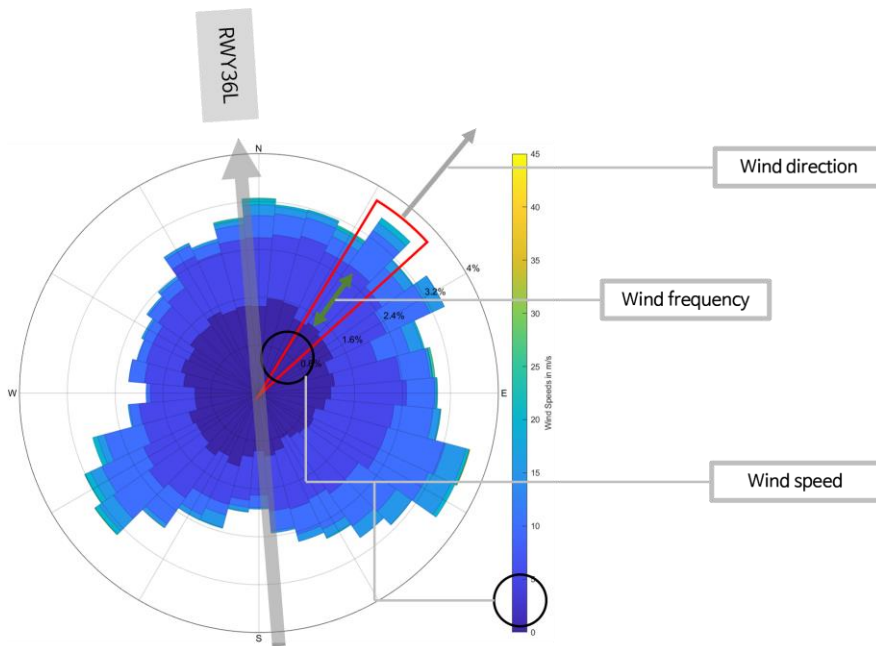


그림 22 김해공항 36L 활주로의 바람 장미

더 자세한 분석을 위해 전체 항공기의 바람 장미를 과이탈 항공기와 과이탈이 발생하지 않은 항공기로 분류하였다. 양의 방향 과이탈과 음의 방향 과이탈이 모두 발생했을 경우, 과이탈 항공기의 바람 장미를 해당 과이탈의 발생 방향으로 한 번 더 세분화하였다. 그림그림 23은 바람 장미 분류 과정을 시각적으로 보여주며, 김해공항의 36L 활주로에 착륙하는 항공기에 대한 바람 장미를 분류한 결과를 나타낸다.

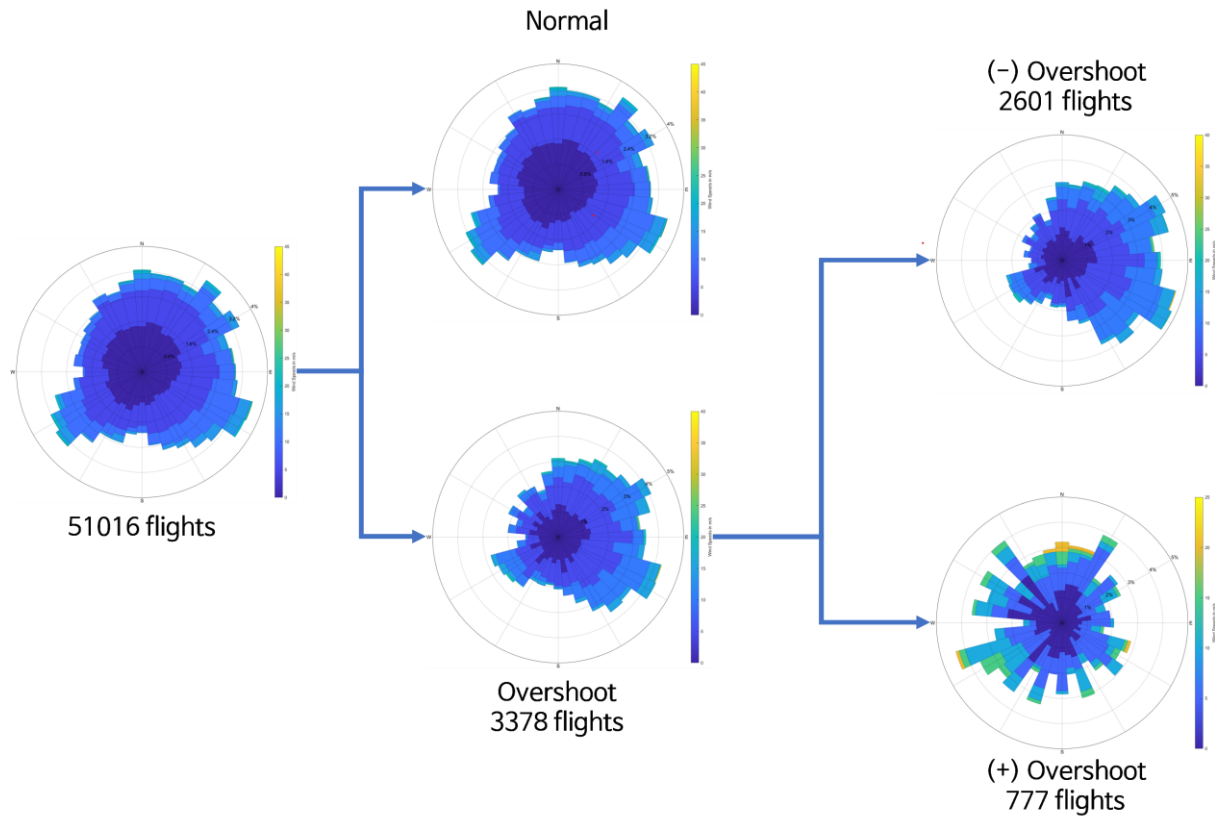


그림 23 파이탈 유무와 파이탈 방향에 기반한 바람 장미 분류 과정


그림 24는 과이탈이 발생한 방향을 기준으로 분류한 바람 장미에서 측풍 성분과 배풍 성분에 따른 과이탈 비율을 계산하고 이를 히스토그램으로 표현하였다. 여기서 측풍 성분은 활주로에 수직인 바람 성분을 나타내며, 배풍 성분은 활주로 방향의 바람 성분을 나타낸다. 그림 24의 b에서 음의 방향으로 과이탈이 발생했을 때, 측풍 성분이 10 - 15m/s인 경우, 과이탈 확률은 약 12%로 나타난다. 이는 해당 활주로의 바람 추출 지점에서 동일한 측풍 성분을 가진 모든 착륙 항공기 중 약 12%가 최종접근경로 과이탈이 발생한다는 것을 의미한다.

3.2.4 공항 별 바람 분석 결과

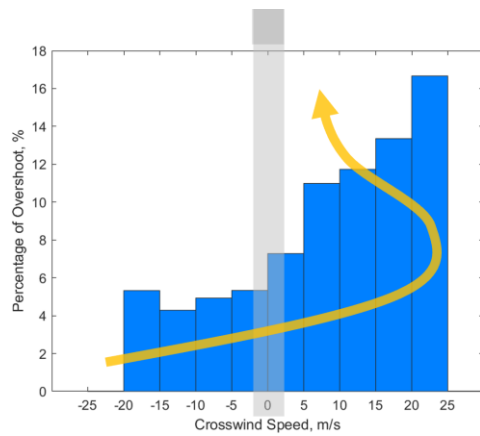
앞서 설명한 바람 분석 과정을 4개 공항에 대하여 진행하였으며, 분석 결과는 다음과 같다. 과이탈 발생 방향은 활주로별 과이탈 히트맵을 통해 확인할 수 있다.

3.2.4.1 김해공항

김해공항의 36L 활주로에 착륙하는 항공기의 경우, 양의 방향으로 과이탈이 발생한 항공기는 2,601대이며, 음의 방향으로 과이탈이 발생한 항공기는 777대이다. 그림 24는 측풍 성분과 과이탈 비율 간의 관계를 시각적으로 나타내고 있으며, 그림 25는 배풍 성분과 과이탈 비율 간의 관계를 보여준다. 붉은색으로 표시된 부분이 배풍 부분이며 반대 부분은 정풍 부분이다. 그림 23의 분류된 바람 장미에서 바람 성분이 균일하게 분포되어 있는 것으로 보이지만, 그림 24에서는 과이탈이 발생하는 방향으로 측풍 성분의 속도가 증가함에 따라 과이탈 발생 비율이 더 높아짐을 확인할 수 있다. 더불어, 그림 25에서 정풍 성분 대비 배풍 성분에서 과이탈 비율이 더 높은 것을 관찰할 수 있다. 이는 김해공항에 착륙하는 항공기의 최종 접근 경로 과이탈이 측풍과 배풍의 영향을 받으며, 특히 측풍에 의해 과이탈이 증가할 수 있음을 시사한다.




a. 양의 방향 과이탈




b. 음의 방향 과이탈

그림 24 36L 활주로의 측풍 성분에 따른 과이탈 비율



a. 양의 방향 과이탈



b. 음의 방향 과이탈

그림 25 36L 활주로의 배풍 성분에 따른 과이탈 비율

3.2.4.2 인천공항

인천공항의 15L 활주로에 착륙하는 항공기는 대부분 양의 방향 과이탈이 발생한다. 그림 26의 바람 장미에서 과이탈이 발생하지 않은 항공기에 비해 과이탈이 발생한 항공기의 측풍 성분이 과이탈 방향으로 더 우세하게 분포되어 있다. 이 경향은 16 활주로의 바람 장미에서도 유사하게 나타난다.

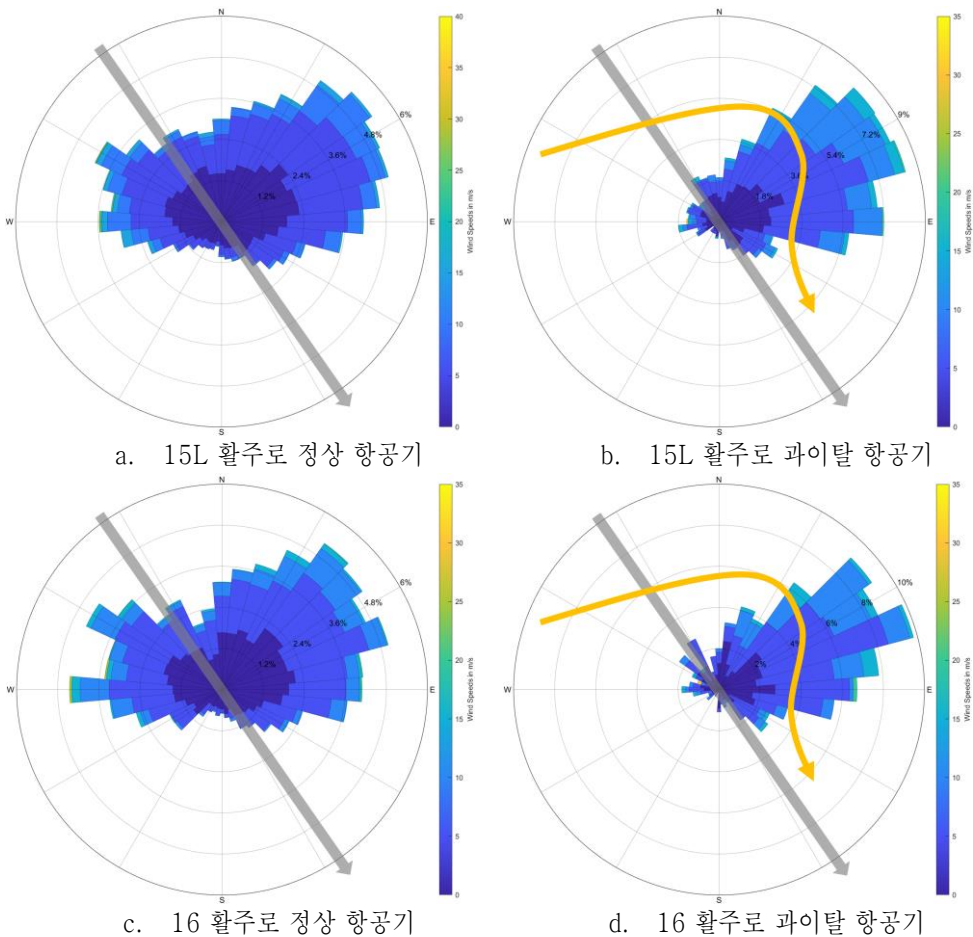


그림 26 15L 활주로의와 16 활주로의 바람 장미

그림 27에서 배풍 성분이 15 - 20m/s인 경우, 과이탈 비율이 급증한 것을 확인

할 수 있다. 이는 착륙 항공기 수와 파이탈 항공기 수가 적어 정확한 결과로 보기는 어렵지만 해당 부분을 제외하더라도 배풍 성분일 때, 파이탈 비율이 증가하는 경향을 확인할 수 있다. 또한, 15L 활주로와 16 활주로 모두 측풍 성분의 속도가 증가함에 따라 파이탈 발생 비율이 더 높아진다.

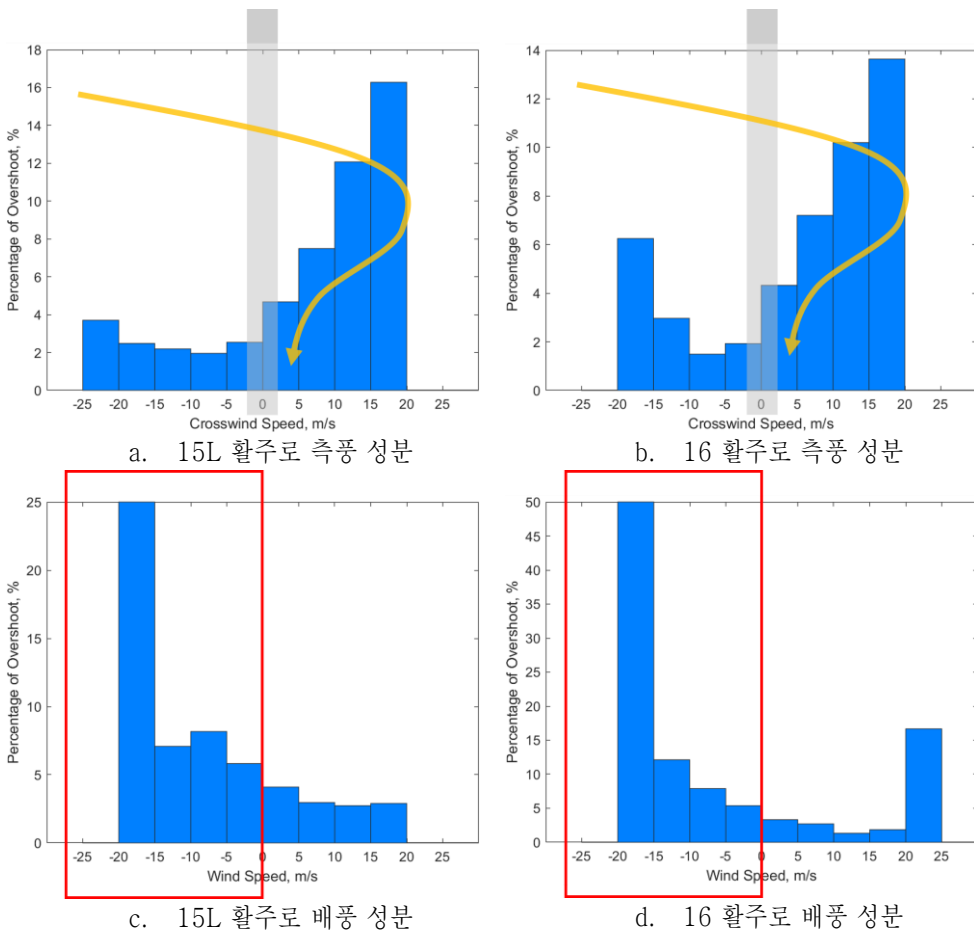


그림 27 15L 활주로의와 16 활주로의 바람 성분에 따른 파이탈 비율

33R 활주로는 370대의 양 방향 파이탈과 534대의 음 방향 파이탈이 발생한다. 파이탈이 발생하지 않은 항공기의 바람 장미는 정풍 성분이 두드러지게 분포되어

있지만, 과이탈 항공기의 바람 장미는 바람 성분이 여러 방향으로 분포되어 있다. 그림 29에서 양 방향 과이탈은 측풍과 배풍의 영향을 받아 바람 성분의 속도가 커질수록 과이탈 비율이 증가하는 경향을 보이지만 음 방향 과이탈은 측풍과 배풍의 영향을 상대적으로 덜 받음을 확인할 수 있다.

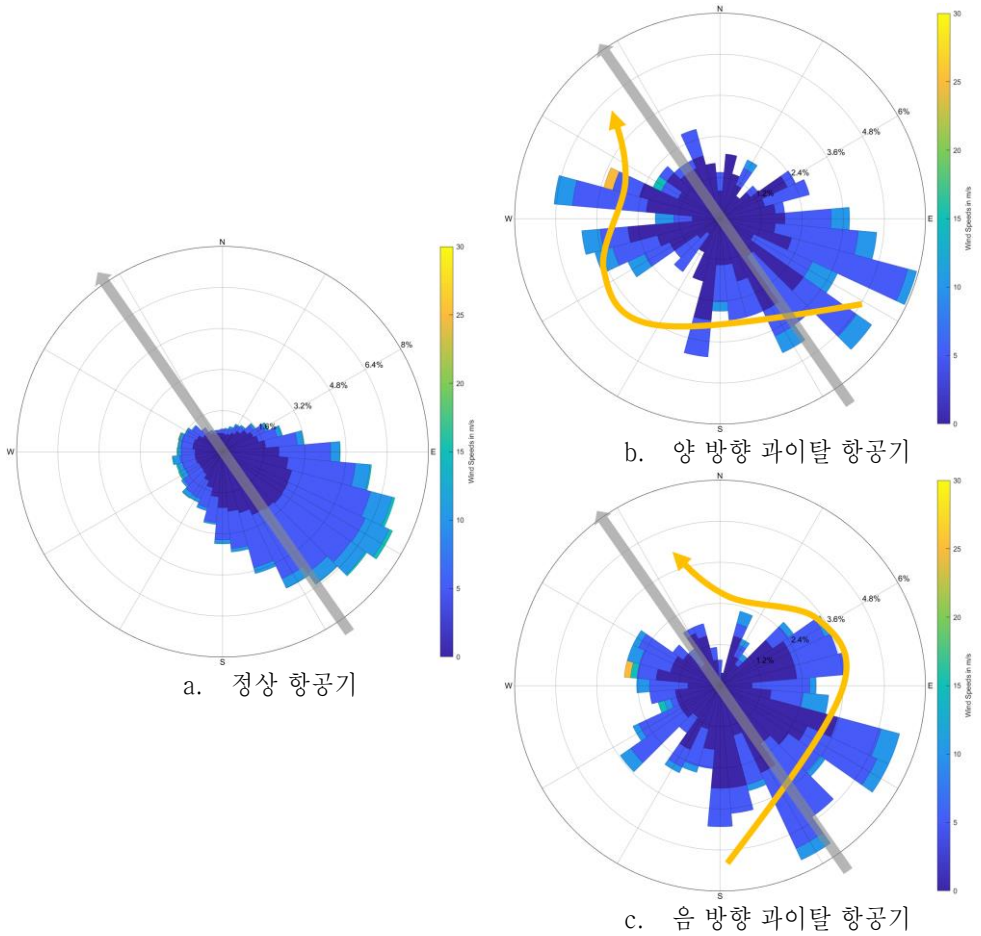





그림 28 33R 활주로 바람 장미




a. 양 방향 과이탈의 측풍 성분



b. 음 방향 과이탈의 측풍 성분



c. 양 방향 과이탈의 배풍 성분



d. 음 방향 과이탈의 배풍 성분

그림 29 33R 활주로의 바람 성분에 따른 과이탈 비율

34 활주로는 대부분 음 방향 과이탈이 발생하며, 671대의 음 방향 과이탈이 발생한다. 과이탈이 발생하지 않은 항공기의 바람장미는 33R 활주로와 유사하게 정풍 성분이주를 이루고 있다. 반면, 과이탈 항공기의 바람장미는 33R 활주로에 비해 정풍 성분이 우세하게 나타난다. 그림 31에서 과이탈이 발생하는 방향으로 측풍 성분과 배풍 성분의 속도가 커질수록 과이탈이 증가하는 것을 확인할 수 있다.

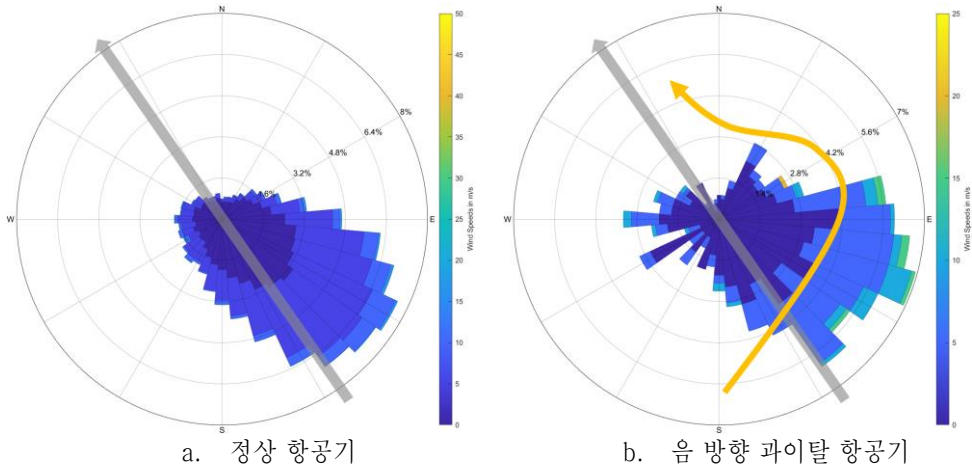


그림 30 34 활주로 바람 장미

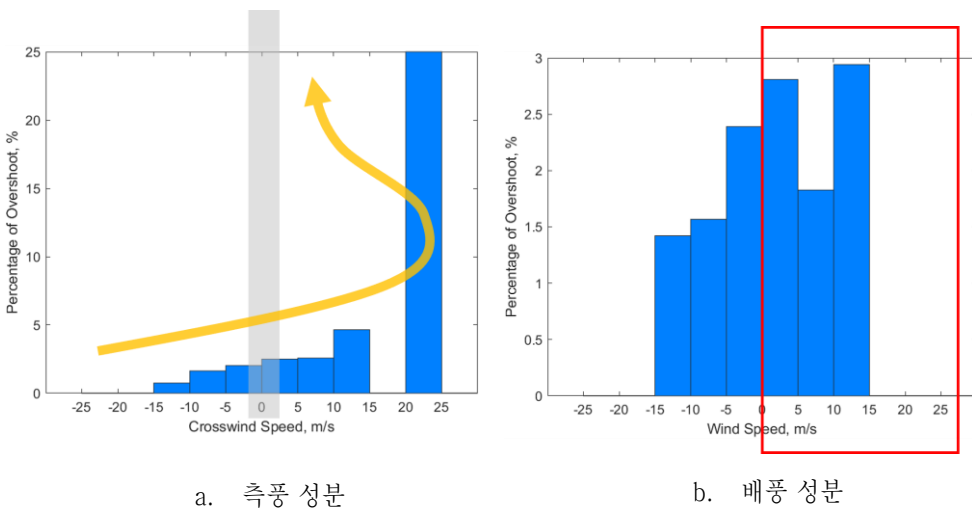


그림 31 34 활주로의 바람 성분에 따른 과이탈 비율

앞서 산출한 인천공항의 과이탈 결과에서 15L 활주로의 16 활주로의 착륙하는 항공기 보다 33R 활주로의 34 활주로의 착륙하는 항공기의 과이탈 비율이 높은 것을 확인할 수 있다. 각 활주로의 바람 장미를 살펴보면, 전반적으로 33R 방향으

로 착륙하는 항공기의 바람 분포는 정풍 성분이 많이 분포되어있다, 반면에 15L 방향으로 착륙하는 항공기의 바람 분포는 측풍 성분의 분포가 더 많음을 확인할 수 있다. 이는 같은 공향에 착륙하더라도, 활주로 방향에 따라 바람의 영향을 받아 과이탈 발생이 증가할 수 있음을 시사한다.

3.2.4.3 제주공항

제주공항의 07 활주로에 착륙하는 항공기는 주로 음의 방향 과이탈이 발생한다. 그림 32는 07 활주로의 바람 장미를 나타내며, 과이탈이 발생하지 않은 항공기와 과이탈이 발생한 항공기의 바람 장미의 형상이 매우 유사하다. 그림 33은 07 활주로의 바람 성분에 따른 과이탈 비율을 나타낸다. 타 공향과는 다르게 과이탈 방향으로 측풍의 속도가 증가하더라도 과이탈 비율이 증가하지 않는다. 대신에 배풍 성분의 속도가 증가함에 따라 과이탈 비율이 증가함을 확인할 수 있다.

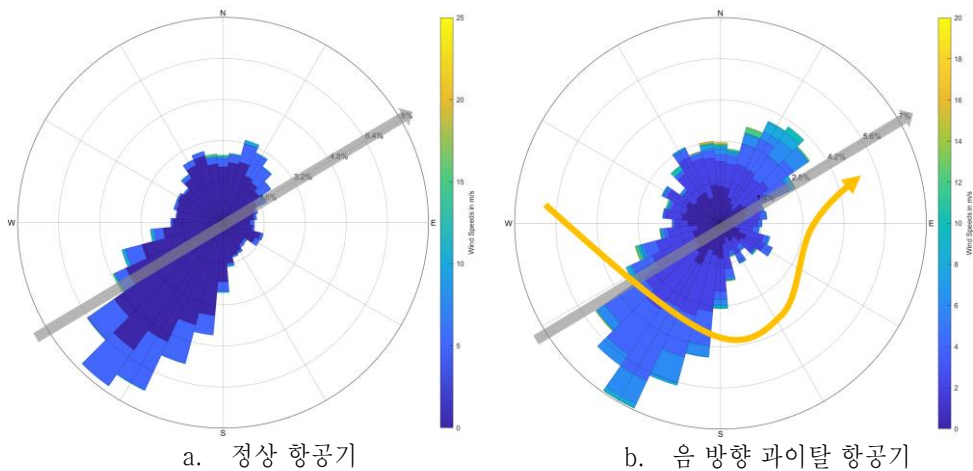



그림 32 07 활주로 바람 장미



a. 측풍 성분

b. 배풍 성분

그림 33 07 활주로의 바람 성분에 따른 과이탈 비율

25 활주로에 착륙하는 항공기는 1,012대의 양 방향 과이탈과 539대의 음 방향 과이탈이 모두 발생한다. 그림 34에서 25 활주로의 바람장미를 비교해보면, 과이탈이 발생하지 않은 항공기와 과이탈이 발생한 항공기의 바람 장미 모두 유사한 형상을 가지고 있다. 그림 35은 25 활주로의 바람 성분에 따른 과이탈 비율을 나타낸다. 양 방향 과이탈이 발생한 경우, 과이탈 발생 방향으로 측풍 성분의 속도가 증가할수록 과이탈 비율이 증가하는 반면, 음 방향 과이탈이 발생한 경우 측풍 성분의 영향을 받지 않는 것으로 보인다. 그러나 음 방향 과이탈의 발생 비율이 양 방향 과이탈에 비해 매우 적은 고려하면 음 방향 과이탈 역시 측풍 성분의 영향을 받는 것으로 판단된다. 배풍 성분의 경우, 양 방향 과이탈이 발생한 경우 배풍 성분의 속도가 증가할수록 과이탈 비율이 증가하는 경향이 확인되지만, 음 방향 과이탈이 발생한 경우에는 배풍 성분의 속도에 따른 명확한 경향이 나타나지 않는다.

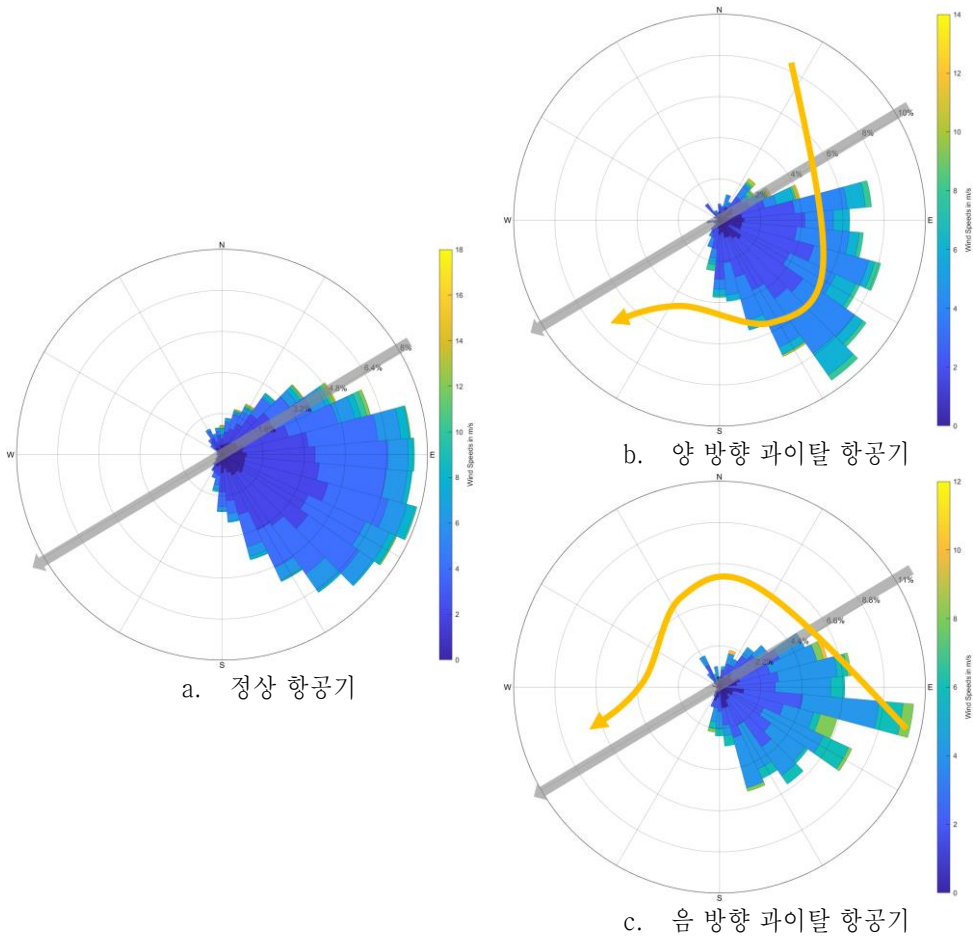


그림 34 25 활주로 바람 장미

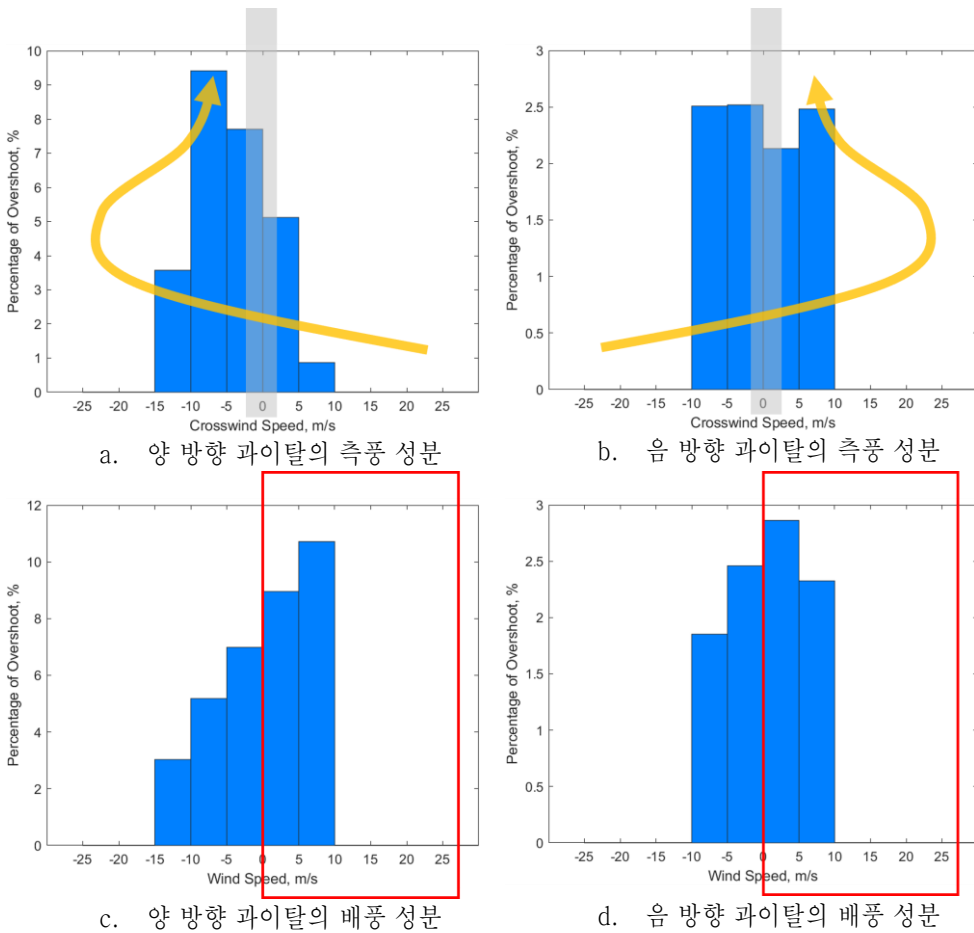


그림 35 25 활주로의 바람 성분에 따른 과이탈 비율

3.2.4.4 김포공항

김포공항 14R 활주로에 착륙하는 항공기는 대부분 음 방향 과이탈이 발생한다. 그림 36은 14R 활주로에 착륙하는 항공기의 바람 장미이다. 14R 활주로의 바람 장미에서 과이탈이 발생하지 않은 항공기의 바람 장미에 비해 과이탈이 발생한 항공기의 바람 장미에서 측풍 성분이 매우 우세하게 분포되어 있음을 확인할 수 있다. 그림 37의 바람 성분과 과이탈 비율의 관계에서 측풍 성분과 배풍 성분의 속도가

증가할수록 과이탈 비율이 증가하는 경향을 확인할 수 있다.

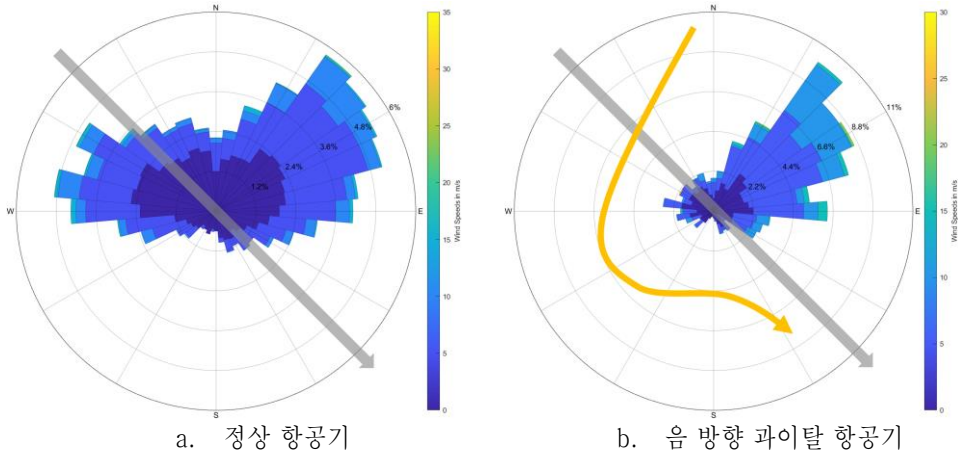


그림 36 14R 활주로 바람 장미

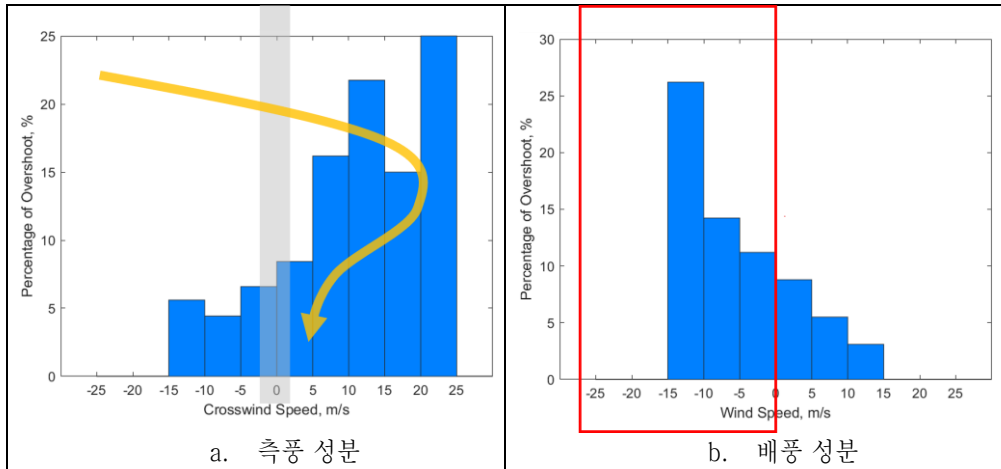


그림 37 14R 활주로의 바람 성분에 따른 과이탈 비율

32L 활주로는 28대의 양 방향 과이탈과 86대의 음 방향 과이탈이 발생하며, 그 비율은 매우 낮다. 그림 38의 바람 장미에서 정풍의 분포가 우세한 것을 확인할 수

있다. 바람 성분에 따른 과이탈 비율을 살펴보면, 측풍 성분은 다른 공항의 활주로와는 다른 경향이 나타나는 반면 배풍 성분에 의해서는 과이탈 비율이 증가하는 것을 확인할 수 있다.

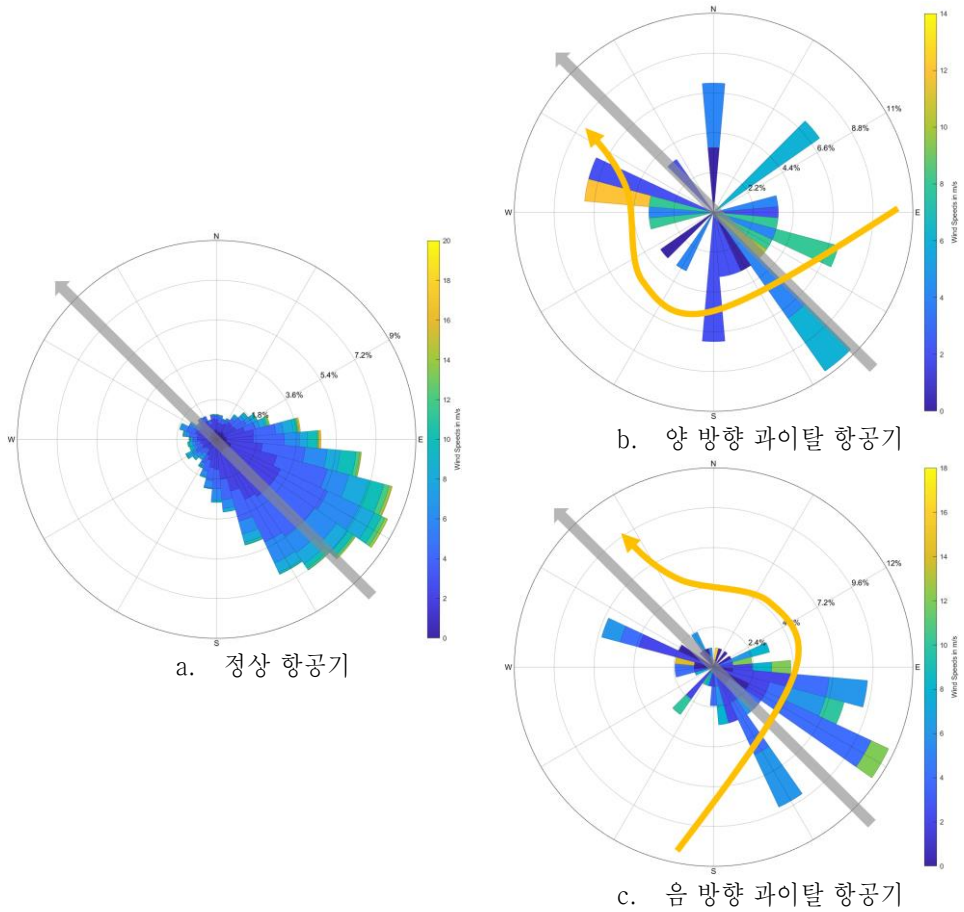


그림 38 32L 활주로 바람 장미

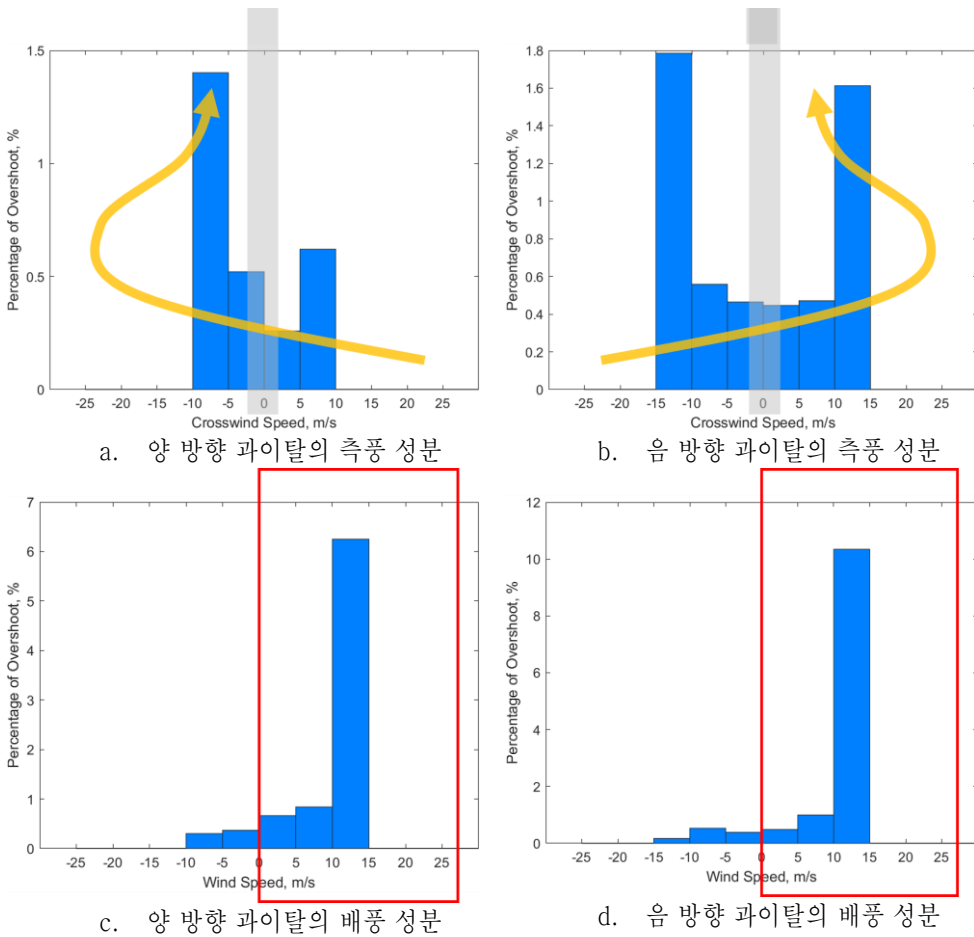


그림 39 32L 활주로의 바람 성분에 따른 과이탈 비율

32R 활주로는 49대의 양 방향 과이탈과 109대의 음 방향 과이탈이 발생하며, 32L 활주로와 여러 유사한 특성을 나타낸다. 과이탈 비율은 매우 낮으며, 바람 장미에서는 정풍의 분포가 우세함을 확인할 수 있다. 바람 성분 또한, 측풍 성분은 다른 공항의 활주로와는 다른 경향이 나타나며, 배풍 성분에 의해서는 과이탈 비율이 증가하는 경향을 확인할 수 있다.




그림 40 32R 활주로 바람 장미

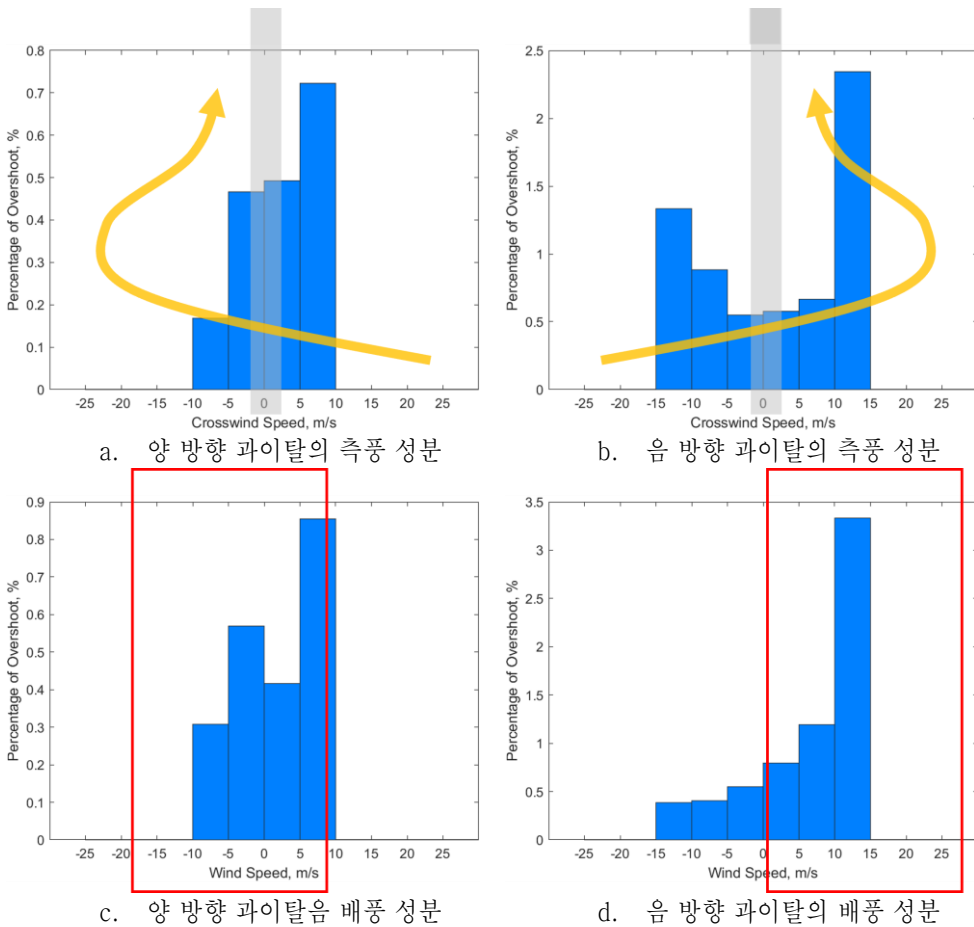


그림 41 32R 활주로의 바람 성분에 따른 과이탈 비율

김포공항의 과이탈 결과에서 14R 활주로의 과이탈 비율이 32L 활주로와 32R 활주로의 과이탈 비율보다 높은 것을 확인할 수 있다. 이는 바람 장미의 형상에서 14R 활주로에 착륙하는 경우, 32L 활주로와 32R 활주로에 착륙하는 경우보다 측풍 성분의 분포가 우세하게 나타나기 때문이라 판단된다. 이러한 현상은 앞서 인천공항의 바람 성분과 매우 유사하며, 이는 두 공항의 지리적 위치가 가까우며, 활주로 방향 또한 비슷하기 때문이라 판단된다.

3.3 클러스터링 분석

클러스터링 과정과 결과는 Ryu 등의 연구에서 얻은 것으로, Agglomerative Clustering 알고리즘을 사용하여 군집의 개수를 정하고 GMM Clustering 알고리즘을 사용하여 데이터를 그룹화하였다[9]. 2019년 김해공항에 착륙하는 항공기를 대상으로, 김해공항의 각 STAR 지점부터 3nmi 내에 들어오는 시점부터 데이터 셋을 구성하였다. 그림 42은 김해공항의 STAR 지점을 도식한 것이다.




그림 42 김해공항의 STAR 지점

3.3.1 클러스터링 결과 재 군집

이전 연구에서 김해공항의 클러스터링 결과, 86개의 군집이 생성되었다. 이러한 군집을 기반으로 시작 STAR와 진행 궤적을 기준으로 재 군집화를 진행하였고, 이 과정에서 17개의 새로운 군집이 형성되었다. 이 새로운 군집은 대군집으로 명명하며, 그림 43은 재 군집화 과정을 시각적으로 나타내고 있다.

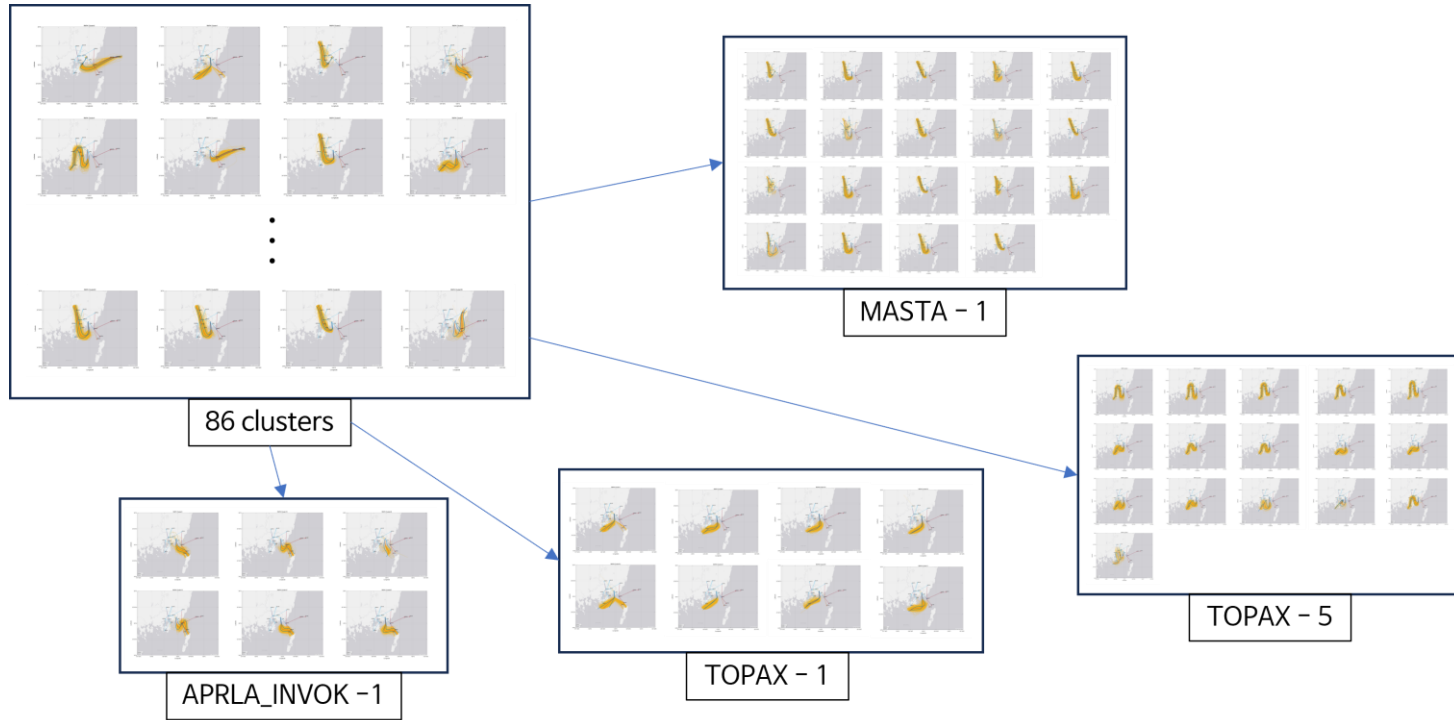


그림 43 86개의 군집 재 군집화

3.3.2 클러스터링 분석

17개의 대군집 각각에 대해 과이탈 비율을 계산하였다. 표 3은 계산된 결과를 보여주며, 해당 결과에서 김해공항의 과이탈 비율인 6.6% 보다 큰 대군집을 확인할 수 있다. MASTA-1 과 KALEK-1 군집은 각각 9.4%와 10.8%로 다른 군집에 비해 과이탈 비율이 높은 것을 확인할 수 있다. NOISE-1의 경우 항공기가 1대만 포함되어 있어 정확한 비율을 계산하기 어려우므로 무시할 수 있다.

표 3 대군집별 과이탈 비율

Cluster	TOPAX -1	TOPAX -2	TOPAX -3	TOPAX -4	TOPAX -5	MASTA -1	MASTA -2	APELA -1
Ratio	6.8	1.1	6.7	2.9	0.8	9.4	3.5	2.9
APELA -2	APELA -3	KALEK -1	KALEK -2	KALEK -3	APARU -1	APARU -2	SARAM -1	NOISE -1
2.3	5.9	10.8	2.7	5.6	4.0	0	6.5	100

MASTA-1 대군집에 해당하는 항공기는 총 13,820대이며, 이중 1,294대의 항공기에서 과이탈이 발생하였다. 표 4는 MASTA-1 대군집 내 19개의 개별 군집에 대한 전체 항공기 수와 과이탈 항공기 수를 제시한다. 이 중 6개의 군집이 과이탈 비율이 상대적으로 높은 것을 확인할 수 있다. 또한, 그림 44는 MASTA-1 대군집에 해당하는 군집들을 시각적으로 나타내고 있으며, 그림 45는 이 중 과이탈 비율이 높은 6개의 군집들을 강조하고 있다. MASTA-1에 해당하는 군집과 과이탈 비율이 높은 군집들의 궤적을 비교하면 ZULBI 경로점에서 선회 반경이 감소함에 따라 과이탈 비율이 증가하는 경향을 확인할 수 있다.

표 4 MASTA-1의 군집 별 과이탈

Cluster	착륙 항공기	과이탈 항공기	과이탈 비율 (%)
2	2	0	0
6	737	43	5.8
8	1465	193	13.2
14	71	2	2.8
68	1059	43	4.1
17	1139	100	8.8
22	69	1	1.5
36	1547	121	7.8
39	46	1	2.2
69	1556	252	16.2
40	34	2	5.9
46	442	4	0.9
51	2215	349	15.7
64	4	0	0
75	280	3	1.1
78	79	1	1.3
82	704	3	0.4
83	624	8	1.3
84	1747	168	9.6

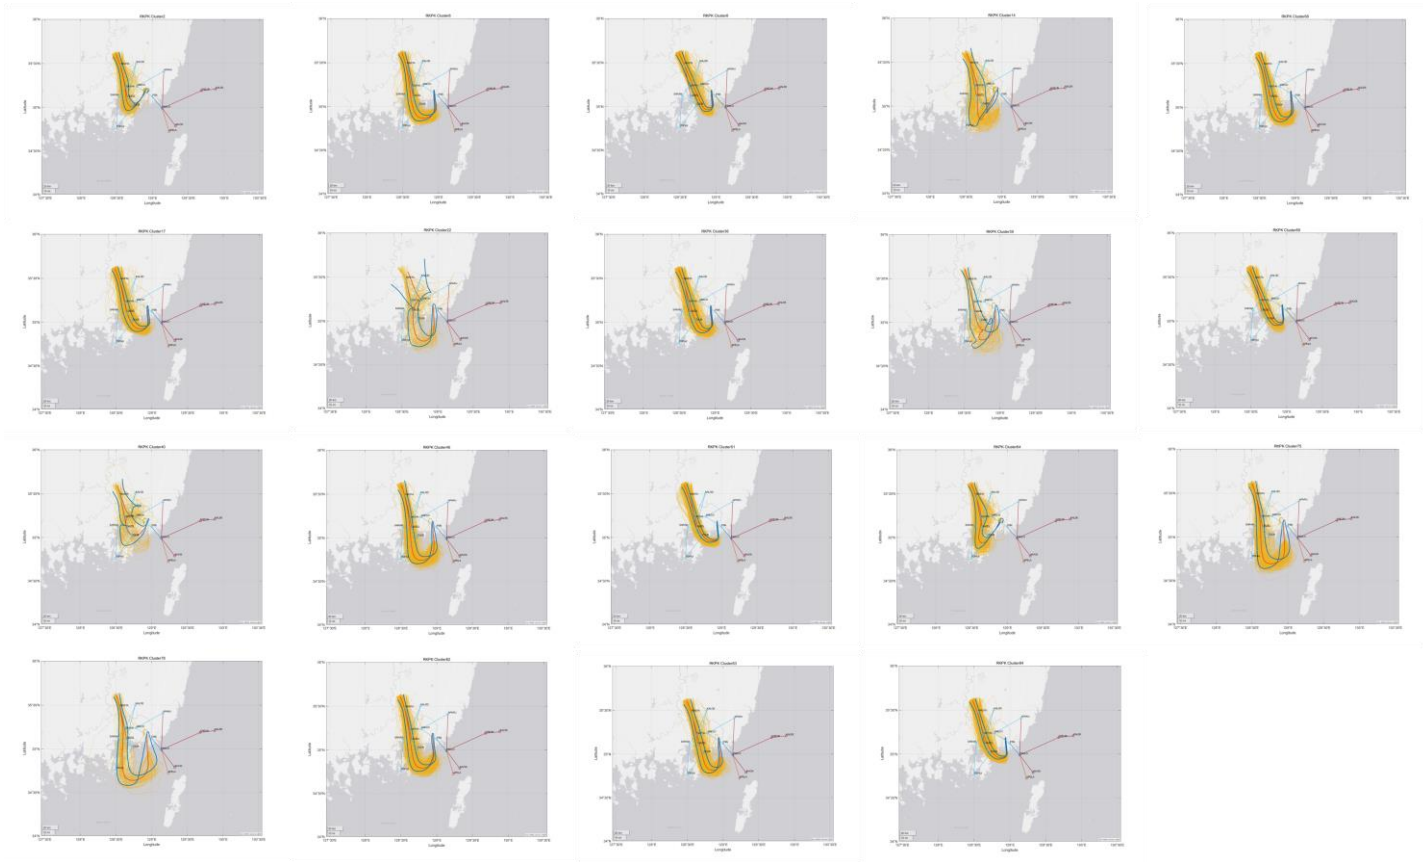





그림 44 MASTA-1의 19개 군집




a. Cluster 8




b. Cluster 17



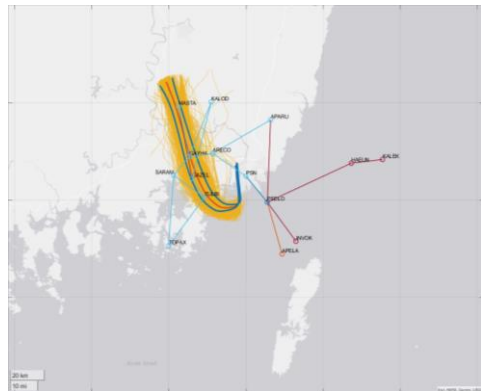
c. Cluster 36



d. Cluster 69



e. Cluster 51



f. Cluster 84

그림 45 파이탈 비율이 큰 MASTA-1 군집

KALEK-1 대군집에 해당하는 항공기는 총 5,611대이며, 이중 606대의 항공기에서 과이탈이 발생하였다. 표 5은 KALEK-1 대군집 내 8개의 각 군집에 대한 전체 항공기 수와 과이탈 항공기 수가 나와있다. 이 중 3개의 군집에서는 상대적으로 높은 과이탈 비율을 확인할 수 있다. 그림 46은 KALEK-1 대군집에 해당하는 군집들을 시각적으로 나타내고 있으며, 그림 47은 이 중 과이탈 비율이 높은 3개의 군집들을 강조하고 있다. KALEK-1에 해당하는 군집과 과이탈 비율이 높은 군집들의 궤적을 비교하면 접근구간에서 선회 반경이 감소함에 따라 과이탈 비율이 증가하는 경향을 확인할 수 있다. 이는 MASTA-1과 유사한 양상을 나타낸다.

표 5 KALEK-1의 군집 별 과이탈

Cluster	착륙 항공기	과이탈 항공기	과이탈 비율 (%)
5	866	88	10.2
13	64	3	4.7
26	1434	220	15.3
30	662	18	2.7
15	725	15	2.1
57	1052	258	24.5
65	372	4	1.1
77	436	0	0

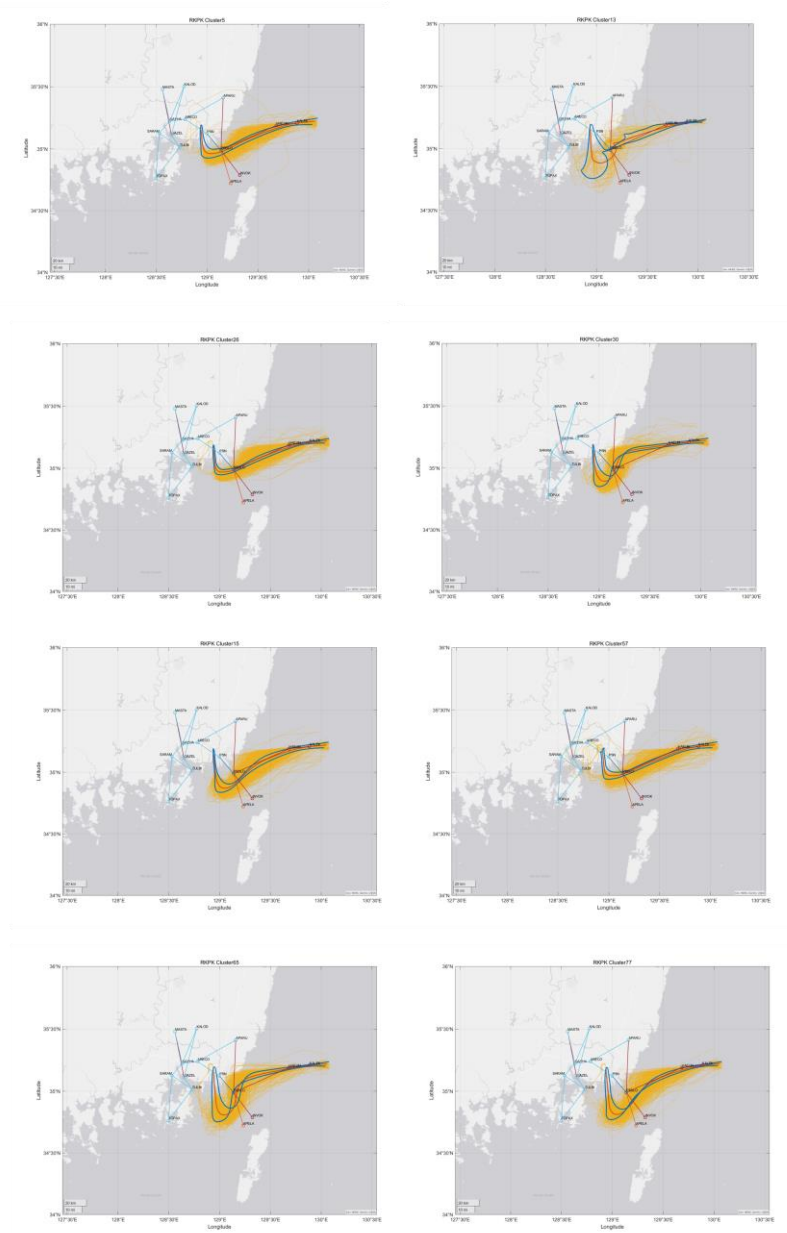
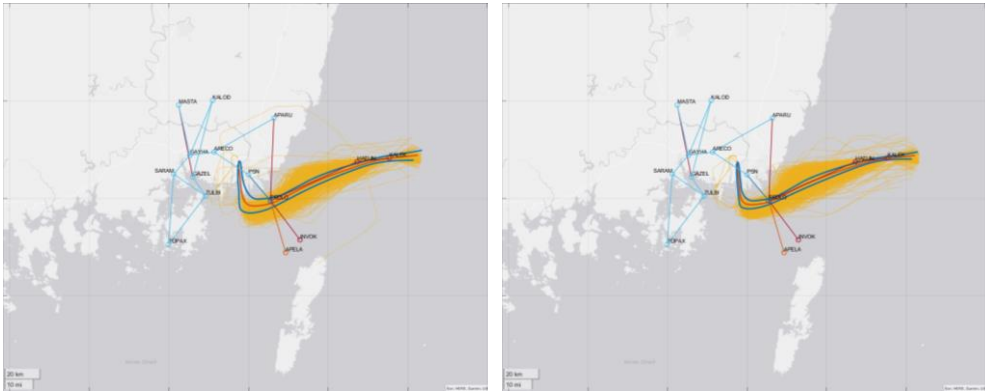



그림 46 KALEK-1의 8개 군집



a. Cluster 5

b. Cluster 26



c. Cluster 57

그림 47 과이탈 비율이 큰 KALEK-1 군집

제 4 장. 심층 신경망을 이용한 과이탈 예측

최종접근경로 과이탈을 예측하기 위해 머신러닝 기법 중 심층 신경망 기법을 사용하였다. 앞서 분석한 결과 접근구간의 속도, 바람 성분, 클러스터링이 과이탈에 영향을 주는 것을 확인하였다. 본 논문에서는 위 요인들을 이용하여 과이탈을 예측하고자 한다.

4.1 심층 신경망[10, 11]

심층 신경망은 데이터를 입력 받는 입력층과 학습을 수행하는 은닉층, 결과를 출력하는 출력층으로 이루어진 구조를 가지고 있다. 각 층은 여러 노드로 구성되어 있으며, 활성화 함수(Activation Function)를 통해 다음 층의 노드로 신호가 전달된다. 그림 48은 심층 신경망의 구조를 시각적으로 나타낸 것이다. 활성화 함수는 주로 비선형 함수를 사용하는데, 선형 함수만 사용할 경우 단순한 선형 계산의 반복이므로 과이탈에 영향을 주는 요인들을 학습하기 어렵다. 본 논문에서는 활성화 함수로 비선형 함수인 ReLU 함수를 선택하였으며, 마지막 층에서는 Softmax 함수를 사용하여 과이탈의 확률을 계산할 수 있도록 구성하였다. 식 (4-1)은 ReLU 함수를, 식 (4-2)는 Softmax 함수를 나타낸다.




그림 48 심층 신경망 구조

$$ReLU(x) = \begin{cases} x & \text{for } x \geq 0 \\ 0 & \text{for } x < 0 \end{cases} \quad (4-1)$$

$$Softmax_k(x) = \frac{e^{x_k}}{\sum_{j=1}^n e^{x_j}} \quad (4-2)$$

본 논문에서 구성하는 심층 신경망은 과이탈이 발생 여부를 예측하는 모델이다. 평균적으로 사용되는 평균 제곱 오차(MSE) 손실 대신에 이진 교차 엔트로피(Binary Cross Entropy) 손실 함수를 사용하였으며, 이에 모멘텀과 RMS Prop 기법을 합친 ADAM(Adaptive Moment Estimation) 최적화를 적용하였다[12]. 표 6은 구성된 신경망의 Learning rate, Epoch, beta, Batch size를 나타낸다.

표 6 심층 신경망 파라미터

Learning rate	Epoch	beta	Batch size
10^{-5}	2000	0.9, 0.99	16

신경망의 입력층 노드에는 접근 구간의 속도, 측풍 성분, 배풍 성분, 클러스터링으로 4개의 입력이 들어가 있다. 그 이후의 층들은 다음 표 7과 같은 노드의 개수를 가지고 있다.

표 7 Layer node

Input	Hidden1	Hidden2	Hidden3	Hidden4	Output
4	128	64	32	16	2

4.2 과이탈 예측 결과

앞서 구성한 심층 신경망은 2019년 김해공항에 착륙하는 항공기를 이용하여 학습하였다. 학습 데이터는 정상 항공기와 과이탈 항공기 각각의 90% 무작위 항공

기로 구성되었으며, 나머지 10%의 항공기로 예측을 시도하였다. 표 8은 예측 결과를 비율별로 나누어 실제 과이탈 비율과 비교한 결과를 보여준다. 과이탈 예측 비율이 10 - 20%인 항공기수는 625대이며, 해당 항공기 중에서 실제로 과이탈이 발생한 항공기 수는 76대이다.

표 8 과이탈 예측 결과 및 비교

과이탈 예측 비율(%)	과이탈 항공기	전체 항공기	실제 과이탈 비율(%)
0 - 10	202	4147	4.87
10 - 20	76	625	12.16
20 - 30	31	181	17.13
30 - 40	10	62	16.13
40 - 50	8	21	38.09
50 - 60	2	15	13.33
60 - 70	0	14	0.00
70 - 80	2	9	22.22
80 - 90	3	12	25.00
90 - 100	4	14	28.57

과이탈 예측 비율이 높다면 실제 과이탈 비율도 높은 경향을 확인할 수 있다. 그러나 현재로서는 예측 값과 실제 값 사이에 아직 상당한 차이가 나타나고 있다. 특히 예측 값이 증가할수록 실제 값과의 차이가 더 커지는 것을 확인할 수 있다.

제 5 장. 결론

본 연구에서는 항공기가 착륙을 준비하는 접근 단계에서 발생할 수 있는 최종접근경로 과이탈을 산출하고 이를 분석하여 예측을 시도하였다. 최종접근경로 과이탈을 산출하기 위해 인천공항, 김포공항, 제주공항, 김해공항에 착륙하는 2019년도 ADS-B 항적 데이터를 이용하였다. 최종접근경로 과이탈을 산출하기 위해 산출 알고리즘을 개발하였으며, 활주로 판별 알고리즘이 개발하여 산출 결과의 정확도를 확보하였다.

산출된 결과를 기반으로 지상 속도, 바람 성분, 클러스터링을 활용하여 분석을 수행하였다. 바람 성분을 분석에는 KLASP 기상 데이터와 ADS-B 항적 데이터를 결합하여 바람의 영향을 확인하였고, 과이탈 거리와 비행 거리의 관계를 히트맵을 이용하여 바람 성분 추출 지점을 제시하였다. 지상 속도와 바람 성분 분석은 공항의 활주로 별로 세분화하여 진행하였다. 클러스터링은 김해공항을 대상으로 수행되었으며, 2019년도 김해공항의 각 STAR 지점부터 착륙 활주로까지 궤적을 분류하였다. 이후 분류된 군집을 대군집으로 재 군집화 하였고, 군집 별 과이탈 비율을 확인하였다. 분석 결과 위 요인들이 과이탈에 영향을 주는 것을 확인할 수 있다.

이후, 위 분석에서 도출한 요인들을 입력으로 하여 예측 과이탈 비율을 출력하는 심층 신경망 모델을 구성하였다. 학습 데이터는 2019년 김해공항의 정상 항공기와 과이탈 항공기 각각의 90%의 무작위 항공기로 구성되어 있으며, 나머지 10% 항공기로 예측을 시도하였다. 예측 값이 증가할수록 실제 값도 증가하는 경향을 확인할 수 있지만, 아직 두 값 사이에 상당한 차이가 나타난다.

추후, 항공기의 성능, 관제사의 관제명령 등, 과이탈에 영향을 줄 수 있는 다른 요인들을 추가 분석 후, 신경 심층망을 보완하여 과이탈 예측 모델의 성능을 향상시킬 계획이다.

제 6 장. 참고 문헌

- [1] IATA, "2021 Safety Report," Ed. 58, 2022, pp. 50.
- [2] Kim, H. D., "Unstable Approach Mitigation Based on Flight Data Analysis", The Journal of Korea Navigation Institute, 25(1), 2021, pp. 52-59.
- [3] Lee, H. Y., and Lee. H. T., "Risk Analysis of Flight Procedures at Incheon International Airport and Gimpo International Airport." The Journal of Korea Navigation Institute, vol. 24, no. 6, pp. 500-507, 2020.
- [4] You, K.K., Lee, Y. G., and Jeong, S.K., "Prediction of Multicopter Deviation Distance in Urban Environment using Deep Learning." Proceeding of the 2019 Computational Fluids Engineering Conference, 2021, pp. 18.
- [5] 항공정보포털시스템, "공항 정보," Airportal, URL:<https://www.airportal.go.kr/knowledge/airports/KfAirport01.jsp?area=name>.
- [6] 기상자료개방포털, "초단기예보모델," 기상청, URL:<https://data.kma.go.kr/data/rmt/rmtList.do?code=320&pgmNo=66>.
- [7] Kim, J., "ANNUAL REPORT 2017," Korea Meteorological Administration on 11-1360000-000999-01, 2017.
- [8] Park, B. S., and Lee, H. T., "Master Data Set for Aviation Safety Analysis," Asia-Pacific International Symposium on Aerospace Technology 2022, 2022.
- [9] Ryu, J. Y., Han, S. M., and Lee, H. T., "Extracting Patterns of Airport Approach Using Gaussian Mixture Models and Analyzing the Overshoot Probabilities," The Journal of Korea Navigation Institute, Undergoing revision.
- [10] 류재영, "머신러닝을 이용한 충돌 회피 알고리즘 개발 및 충돌 회피 알고리즘 평가 방법 연구," 인하대학교 대학원, 2022.
- [11] 이재성, "심층 신경망의 발전 과정과 이해," The Journal of The Korean Institute of Communication Sciences, Vol. 33, No. 10, 2016, pp. 40-48.
- [12] Kingma, D., and Ba, J., 2014, Adam: A method for stochastic optimization, arXiv preprint, arXiv:1412.6980.