

Original Article

<https://doi.org/10.12985/ksaa.2026.34.3.222>
ISSN 1225-9705(print) ISSN 2466-1791(online)

오토인코더 복원오차에 기반한 경착륙의 운항 메커니즘 특성 분석

이준민*, 최대영**

Characterizing Operational-Mechanism Signatures of Hard Landings using Autoencoder Reconstruction Errors

Joon Min Lee*, Daeyoung Choi**

ABSTRACT

Hard landings can damage aircraft structures and threaten operational safety. This study proposes an explainable, mechanism-based approach that uses an unsupervised autoencoder, trained only on normal landings, to characterize operational-mechanism signatures of hard landings from reconstruction-error patterns. Each final-approach segment in the NASA DASHlink dataset was represented by 20 features grouped into five mechanisms (H1-H5); vertical acceleration was excluded from the inputs to avoid circular reasoning. In six of the seven Hard cases, thrust-related features (H1) showed the largest reconstruction-error share, with a mean of 51.9%. Touchdown N1 increased and flare duration decreased from the Normal to Firm and Hard categories, and the combined high-N1/short-flare condition occurred in 85.7% of Hard versus 10.5% of Normal cases. These observations indicate that thrust-related deviations were concentrated in hard landings but do not establish causation. Given only seven Hard cases, the findings are exploratory, and the method may support post-flight review and evidence-based training (EBT).

Key Words : Anomaly Detection(이상 탐지), Autoencoder(오토인코더), Evidence-Based Training(근거 기반 훈련), Explainable Artificial Intelligence(설명 가능한 인공지능), Flight Data Analysis(비행 자료 분석), Hard Landing(경착륙)

1. 서 론

착륙은 전체 비행에서 몇 분에 지나지 않는 짧은 구간이지만 항공 사고와 준사고가 가장 빈번하게 발생하는 단계다. 이처럼 위험이 응축된 국면에서 경착륙

(hard landing)은 접지 순간의 큰 충격으로 기체 구조에 손상을 남기는 대표적 사건이며 기체 점검과 정비를 요구하여 운항 효율을 저하시키고 반복될 경우 안전 위험을 누적시킨다(Jeon and Kim, 2024). 따라서 경착륙의 발생을 분석하고 관련 운항 특성을 파악하는 일은 운항 안전 관리의 핵심 과제 중 하나이다.

운항품질보증프로그램(flight operational quality assurance, FOQA)이 보급되면서 비행 기록을 활용한 경착륙 분석이 가능해졌고(FAA, 2004), 최근에는 기계 학습을 적용한 분석 연구가 활발하게 이뤄지고 있다. 다만 이러한 연구는 두 가지 측면에서 추가적인 논의

Received: 6. Aug. 2026, Revised: 31. Aug. 2026,

Accepted: 11. Sep. 2026

* 고려사이버대학교 일반대학원 석사과정

** 고려사이버대학교 일반대학원 교수

연락처자 E-mail : choidy@koreacu.ac.kr

연락처자 주소 : 서울특별시 종로구 북촌로 106

가 필요하다(Kong et al., 2022; Dang et al., 2025). 첫째, 기존 연구는 대체로 경착륙의 발생 여부를 맞히는 분류(classification)에 초점을 맞추어 왔다(Kong et al., 2022; Dang et al., 2025). 그러나 이를 지도 학습(supervised learning) 문제로 정식화하려면 다수의 경착륙 사례가 필요한데, 경착륙은 매우 드물게 일어나는 사건이어서 학습에 충분한 데이터를 수집하기 어렵다. 둘째, 기계학습을 적용하더라도 경착륙과 관련된 운항 특성을 설명하고 분석하려는 시도는 상대적으로 드물다(Jeon and Kim, 2024).

기계학습을 활용해 경착륙과 관련된 운항 특성을 객관적으로 분석하는 일은 실비행과 시뮬레이터 훈련 현장에서 특히 중요하다. FOQA는 경착륙의 발생 자체는 데이터로 탐지하지만 관련 운항 특성의 해석은 대체로 교관의 경험과 직관에 의존한다. 이로 인해 동일한 비행 상황에 대해서도 교관과 훈련생의 판단이 달라질 수 있으며, FOQA 자료만으로 이러한 판단 차이의 근거를 객관적으로 설명하는 데에는 한계가 있다. (이하에서는 실비행과 시뮬레이터를 아울러, 비행 데이터를 분석하고 지도하는 측을 ‘교관’으로, 그 분석 및 지도의 대상이 되는 측을 ‘훈련생’으로 통칭한다.) 데이터에 기반하여 경착륙과 관련된 운항 특성을 제시할 수 있다면 교관의 판단을 보조함과 동시에 훈련생이 수용 가능한 근거 기반 훈련을 지원할 수 있을 것이다.

본 연구는 앞서 지적한 데이터 부족과 경착륙 관련 운항 특성의 설명 한계를 함께 보완하기 위해, 정상 착륙만으로 학습한 비지도 오토인코더(autoencoder)로 경착륙의 운항 메커니즘별 정상 패턴 이탈 양상을 복원오차를 통해 분석하는 방법을 제안한다. 접근의 특징은 두 가지다. 첫째, 다수의 정상 착륙으로부터 정상 패턴을 학습하고 이로부터의 이탈 정도를 평가함으로써 드문 경착륙 사례에 대한 라벨 의존성을 완화한다. 둘째, 착륙의 최종 진입 구간을 운항 논리에 따라 다섯 가지 메커니즘으로 나누고 정상 착륙 패턴으로부터의 이상 편차를 운항 메커니즘 단위로 제시한다. 본 연구에서 Hard는 접지 시 수직가속도 정점값이 1.70 G 이상인 사례를 가리키는 연구 한정의 조작적 범주이며 특정 기종의 공식적인 경착륙 판정을 의미하지 않는다.

제안한 방법은 NASA가 공개한 DASHlink 비행자료로 검토하였다. 세 가지 보완적 분석에서 접지 시점의 추력 관련 특징에서 정상 착륙으로부터의 이탈이 두드러지는 패턴이 공통적으로 관찰되었다. 이 논문의

구성은 다음과 같다. II장에서 관련 연구를 검토하고 III장에서 데이터와 분석 방법을 기술하며 IV장에서 분석 결과를 제시하고 V장에서 운항적 의미와 한계를 논의하며 VI장에서 결론을 맺는다.

II. 선행연구

2.1 비행자료 기반 경착륙 분석 및 예측

기존 연구는 통계적 분석과 기계학습을 활용하여 비행자료 기반의 경착륙 분석을 수행해 왔다. Kong et al.(2022)은 본 연구와 동일한 NASA DASHlink 자료를 사용하여 베이지안 심층학습 기반의 경착륙 안전성 평가 모델을 제안하고 접지 수직속도를 회귀 예측하였다. 이 연구는 경착륙의 정도를 정량적으로 예측하였으나, 그 원인을 운항 메커니즘 단위로 분해하여 분석하지는 않았다. Dang et al.(2025)은 신속 접근 기록장치(quick access recorder, QAR) 자료를 XGBoost(Chen and Guestrin, 2016)로 모델링하고 SHAP(SHapley Additive exPlanations; Lundberg and Lee, 2017)을 적용하여 이상 비행의 원인을 분석하였다. Jeon & Kim(2024)은 단일 항공사의 A320 기종 운항자료(약 34만 착륙)를 대상으로 수직가속도 초과 이벤트를 분산분석, 상관분석, 회귀분석으로 검토하여 낮은 플레어와 낮은 수직경로, 강하율 및 에너지 관리가 경착륙 전조의 핵심 요인임을 통계적으로 규명하였다. Lee & Jeon(2026)은 미국 교통안전위원회(National Transportation Safety Board, NTSB) 사고자료에 XGBoost와 SHAP을 적용하여 기체 손상 심각도의 영향 요인을 정량적으로 분석함으로써 설명 가능한 인공지능이 항공안전 분야의 요인 분석에 유효함을 보였다.

2.2 오토인코더 기반 비행자료 이상 탐지

비지도 학습 기반 이상 탐지는 정상 비행자료만으로 학습하여 그로부터의 이탈을 탐지하는 접근이다. Das et al.(2010)은 다중 커널 학습에 기반한 다중 커널 이상 탐지(multiple kernel anomaly detection, MKAD)를 제안하여 라벨 없이 비행자료의 이상을 탐지하였고 Li et al.(2015)은 군집화 기반의 ClusterAD를 통해 표준 운항 패턴에서 벗어난 비행을 식별하였다. 이후 오토인코더 계열의 방법이 도입되면서

Memarzadeh et al.(2020)은 합성곱 변분 오토인코더(convolutional variational auto-encoder)로 비행자료의 이상을 비지도 방식으로 탐지하였으며 Memarzadeh et al.(2022)은 착륙 단계의 비행자료에 준지도(semi-supervised) 설명 가능 심층학습 모델을 적용하여 다중 클래스 이상을 탐지하였다.

2.3 본 연구의 차별점

앞서 검토한 연구들은 경착륙을 예측하거나 비행자료의 이상을 탐지하는 데 기여하였다. 다만 탐지된 이상을 운항 메커니즘 단위로 해석하는 데에는 이르지 못하였다. 본 연구는 선행연구와 두 가지 지점에서 구별된다. 첫째, 라벨 의존성의 완화이다. Kong et al.(2022)과 Dang et al.(2025)은 라벨이 부여된 자료로 경착륙의 심각도나 이상 원인을 학습하였고 Jeon & Kim(2024)의 통계적 접근 역시 심각도 등급이 부여된 이벤트 집단을 전제한다. 이러한 접근은 공통적으로 드문 경착륙 사례에 대한 라벨을 요구한다. 반면 본 연구는 정상 착륙만으로 학습하는 비지도 오토인코더를 사용하여 이러한 라벨 의존성을 완화한다. 둘째, 이상 편차의 운항 메커니즘 단위 분석이다. Jeon & Kim(2024)은 경착륙 관련 요인을 개별 변수 수준에서 제시하였고 Das et al.(2010), Li et al.(2015), Memarzadeh et al.(2020, 2022)의 비지도 이상 탐지는 정상 자료 기반의 탐지와 설명 가능성을 지향하였으나 탐지된 이상을 운항 메커니즘으로 분해하는 데에는 이르지 못하였다. 본 연구는 착륙의 최종 진입 구간을 다섯 가지 운항 메커니즘(H1 - H5)에 대응하는 특징 구조로 설계하고 복원오차가 어느 메커니즘에서 크게 나타나는지를 분석함으로써 정상 착륙 패턴으로부터의 이상 편차를 운항 관점에서 제시한다.

III. 연구 방법

본 장에서는 제안하는 분석 방법을 착륙 심각도의 정의(3.1), 분석 자료(3.2), 특징 추출(3.3), 오토인코더 모델(3.4), 메커니즘별 복원오차 분석 방법(3.5)의 순서로 기술한다.

3.1 경착륙과 문제의 정의

착륙 심각도를 규정하는 국제적으로 합의된 단일 기

준은 존재하지 않는다. 항공기 제작사는 기종별 구조 설계와 착륙장치 완충 성능을 반영하여 자체적인 경착륙(hard landing) 판정 기준을 항공기 정비 매뉴얼(aircraft maintenance manual, AMM)에 규정하고 있으며 이 기준은 제작사와 기종에 따라 상이하다. 예를 들어 Boeing은 최대 착륙중량 이하에서 주착륙장치 수직가속도 정점값이 1.7 - 1.8 G를 초과하는 경우를 경착륙 지표로 제시한다. 본 연구는 착륙의 심각도를 접지 시 수직가속도(vertical acceleration, VRTG)의 정점값으로 정의한다. VRTG는 착륙 충격의 크기를 직접 반영하는 지표로, 비행자료 분석 및 운항 안전 분야에서 경착륙 판정의 주요 지표로 사용된다(Jeon and Kim, 2024). 본 연구에서는 분석을 위해 VRTG 정점값을 기준으로 1.20 G 미만을 normal, 1.50 G 이상 1.70 G 미만을 firm, 1.70 G 이상 2.10 G 이하를 Hard 범주로 구분하였다. 이 분류는 기종을 특정할 수 없는 연구 자료에 적용한 조작적 정의이며 특정 제작사 또는 기종의 공식적인 정비 판정 기준을 의미하지 않는다. 이하 분석 결과에서는 두 분석 대상 범주를 각각 firm과 hard로 구분하여 기술한다.

본 연구는 이러한 착륙 심각도 분류를 이상 탐지(anomaly detection) 문제로 정식화한다. 즉, 정상 착륙 데이터로부터 정상 분포를 학습한 모델에 firm 및 hard 착륙 데이터를 입력하여 정상 착륙 패턴으로부터 크게 이탈한 특징과 운항 메커니즘을 탐색하는 것을 연구 문제로 정의한다. 이를 위하여 1.20 G 미만의 정상 착륙만으로 기준 분포를 학습하고 1.20 - 1.50 G 구간은 normal과 firm의 경계가 불분명한 완충구간(buffer zone)으로 간주하여 학습과 분석 양쪽에서 의도적으로 배제하였다.

3.2 DASHlink 데이터 및 표본 구성

본 연구는 미국 항공우주국(NASA)이 공개한 DASHlink 비행기록 자료를 사용한다(NASA, 2012). 해당 자료는 4발 엔진을 갖춘 운송용 항공기의 신속 접근 기록장치(quick access recorder, QAR)에서 수집된 실제 운항 비행자료로, 비행당 186개의 파라미터가 기록되어 있다. 표본 주파수는 파라미터에 따라 1-16 Hz로 상이하며 본 연구가 사용한 파라미터는 1-8 Hz 범위에 속한다(수직가속도·전파고도·피치각·롤각 8 Hz, 대기속도·엔진 N1·추력레버각·횡방향 가속도·풍향·풍속·기수방위 4 Hz, 접지 하중 신호 및 글라이드슬

로프 편차 1 Hz). 자료는 기종을 특정하지 않은 여섯 개의 기체 단위 폴더로 제공되며 본 연구는 이로부터 착륙 구간의 기동을 요약하는 20개의 특징(3.3절)을 추출하여 분석에 사용하였다. 6개 기체는 각각 약 5,100 - 5,600개의 비행기록을 포함하여 총 32,339개의 비행기록을 구성하였다. 다만 모든 파일이 착륙을 포함하는 것은 아니어서, 지상 감지 신호(weight-on-wheels, WOW)의 전환이 발생하지 않는 지상 이동 등의 비행 조각이 일부 섞여 있었다. 이러한 파일은 특징 추출 단계에서 접지 시점이 검출되지 않아 자연히 분석 대상에서 제외되므로 본 연구는 6개 기체의 전체 자료를 입력으로 사용하되 접지가 실제로 검출된 착륙만을 최종 분석 대상으로 삼았다. 한편 기체 간 접지 시 수직 가속도의 평균값에는 다소 차이가 있었고 일부 착륙에서는 물리적으로 성립하기 어려운 1.0 G 미만의 정점값도 확인되었다. 본 연구는 6개 기체의 자료를 모두 분석 대상으로 포함하되 이러한 사례는 정상 착륙 학습 세트를 구성하는 단계에서 제외하였다.

접지 시점은 지상 감지 신호(WOW)와 전파고도(Radio Altitude, RALT)를 교차 검증하여 확정하였으며 접지가 검출되지 않은 5,048건(착륙을 포함하지 않는 비행 조각 등)을 제외하여 총 27,291건의 착륙을 확보하였다. VRTG 정점값에 따라 정상(1.20 G 미만) 21,512건, 학습·분석에서 배제한 완충구간(1.20 - 1.50 G) 5,703건, firm(1.50 - 1.69 G) 69건, Hard(1.70 - 2.10 G) 7건으로 분류되었으며(검산 합계 27,291건) VRTG 정점이 2.10 G를 초과하는 착륙은 존재하지 않아 Hard 범주의 상한은 자료에 의해 자연적으로 결정되었다. 정상 착륙 중 특징 결측 및 물리적으로 성립할 수 없는 1.0 G 미만의 값을 갖는 사례를 제외한 결과, 최종 학습에는 19,963건이 사용되었다. 이에 따라 최종 분석 대상은 정상 19,963건, firm 69건, hard 7건이다(Table 1).

정상 착륙 19,963건은 오토인코더 학습에 사용되며 훈련 80%(15,970건)와 검증 20%(3,993건)로 무작위

분할하였다. Firm 69건과 hard 7건은 학습된 모델을 통해 분석되는 대상이다. Hard 착륙의 표본 수가 적은 것은 실제 운항에서 1.70 G 이상의 경착륙이 드물게 발생하는 자료 자체의 본질적 특성에 기인하며(27,291건 중 7건, 약 0.03%) 본 연구는 이러한 극소표본의 한계를 고려하여 hard 착륙에 대한 분석을 확증적 검증이 아닌 탐색적 분석(exploratory analysis)으로 다룬다.

3.3 특징 추출 및 정의

본 연구는 착륙의 최종 진입 구간을 운항 논리에 근거하여 정의하고 각 비행을 그 구간의 기동을 요약하는 20개의 특징으로 변환하여 오토인코더의 입력으로 사용한다. 이는 원시 시계열을 그대로 입력할 경우 착륙이라는 짧은 사건의 핵심 정보가 방대한 순항 구간에 희석되고 비행마다 시계열 길이가 달라 고정 차원의 입력을 구성하기 어렵다는 두 가지 한계를 해소하기 위함이다.

DASHlink 자료는 비행당 186개의 파라미터를 기록하고 있으나, 본 연구는 이 중 착륙 단계의 기동을 설명하는 데 직접적으로 관련된 일부 파라미터만을 특징 산출에 사용하였다. 사용된 원시 파라미터는 교정대 기속도(calibrated airspeed, CAS), 피치각(pitch attitude, PTCH), 엔진 회전수(engine fan speed, N1), 추력레버각(power lever angle, PLA), 활공각(glideslope, GLS) 편차, 롤각(roll attitude), 횡방향 가속도(lateral acceleration, LATG), 기수방위(true heading, TH), 풍향(wind direction, WD) 및 풍속(wind speed, WS)과, 시점 판정에 사용된 전파고도(RALT) 및 지상 감지 신호(WOW)이다. 특징 추출은 두 기준 시점 사이의 구간을 중심으로 이루어진다. 접지 시점(t_{TD})은 지상 감지 신호(WOW)가 공중에서 지상 상태로 전환되는 표본으로 식별하고 RALT가 0 ft에 도달하는 시점과 교차 검증하여 확정한다. 50 ft 통과 시점(t_{50})은 접지 직전 구간에서 RALT가 50 ft 이하로 처음 내려가는 시점으로 정의한다. 이 두 시점

Table 1. Composition of the analysis dataset

구분	VRTG 기준	건수	용도
정상(Normal)	<1.20 G	19,963	학습 (훈련 15,970/검증 3,993)
Firm	1.50 - 1.69 G	69	분석
Hard	1.70 - 2.10 G	7	분석

사이클 플레어 구간으로 정의하며 본 연구의 주요 특징은 이 구간 및 두 기준 시점에서 산출된다.

20개의 특징은 착륙 최종 단계와 관련된 다섯 가지 운항 가설(H1 - H5)로 분류되며 각 가설은 운송용 항공기 비행교범(flight crew training manual, FCTM)에 기술된 착륙 단계의 표준 운항 원리에 근거한다(Boeing, 2025). H1은 추력·동력 상태, H2는 플레어 자세·시점, H3은 속도·에너지 상태, H4는 최종 비행 경로, H5는 바람·횡방향 정렬에 관한 가설이다. 각 그룹과 특징은 Table 2와 같다.

H1(추력)은 개별 엔진이 아닌 항공기 전체의 추력 상태를 반영하기 위해 4개 엔진의 평균값(N1)으로 산출하였으며 $n1_delta$ 는 $N1(t_TD) - N1(t_50)$ 로 두 기준 시점 간의 변화량을 나타낸다. H2(플레어)의 $ptch_delta$ 역시 $PTCH(t_TD) - PTCH(t_50)$ 로 동일한 방식으로 산출하며 $flare_dur_sec$ 은 두 기준 시

점 사이의 표본 수를 해당 파라미터의 표본 주파수(f_s)로 나누어 초 단위로 환산한 값이다. H3(속도)의 cas_delta 는 $CAS(t_TD) - CAS(t_50)$ 로, 50 ft 통과 시점 대비 접지 시점의 속도 변화를 나타낸다. H4(경로)의 강하율 특징은 전파고도의 평균 변화율로 산출하며 50→20 ft 구간($approach_sr_fpm$)과 20→5 ft 구간($sink_rate_fpm$)으로 분해하여 플레어 진입 직전과 접지 직전의 강하율 변화를 구분한다.

H4(경로)의 gls_at_50ft 는 50 ft 통과 시점의 활공각($glideslope$) 편차로, 계기착륙장치($instrument\ landing\ system$, ILS)의 활공각 신호로부터 산출되며 단위는 DDM($difference\ in\ depth\ of\ modulation$)이다. 부호 규약은 항공기가 표준 활공각보다 위에 있는 상방 편차를 양(+), 아래에 있는 하방 편차를 음(-)으로 정의한다.

H5(바람)의 특징은 모두 50 ft 통과 시점을 기준으

Table 2. Feature definitions by operational mechanism

그룹	특징	정의 / 산출식	단위
H1(추력·동력 상태)	$n1_at_50ft$	50 ft 통과 시 4엔진 평균 N1	%RPM
	$n1_avg_flare$	플레어 구간 4엔진 평균 N1	%RPM
	$n1_at_td$	접지 시 4엔진 평균 N1	%RPM
	$n1_delta$	$N1(t_TD) - N1(t_50)$	%RPM
	pla_at_td	접지 시 추력레버각	deg
H2(플레어 자세·시점)	$ptch_at_50ft$	50 ft 통과 시 피치	deg
	$ptch_at_td$	접지 시 피치	deg
	$ptch_delta$	$PTCH(t_TD) - PTCH(t_50)$	deg
	$flare_dur_sec$	$(i_TD - i_50)/f_s$	sec
H3(속도·에너지 상태)	cas_at_50ft	50 ft 통과 시 교정대기속도	kt
	cas_at_td	접지 시 교정대기속도	kt
	cas_delta	$CAS(t_TD) - CAS(t_50)$	kt
H4(최종 비행경로)	$approach_sr_fpm$	50→20 ft 평균 강하율	fpm
	$sink_rate_fpm$	20→5 ft 평균 강하율	fpm
	gls_at_50ft	50 ft 글라이드슬로프 편차	DDM
H5(바람·횡방향 정렬)	$xwind_at_50ft$	$WS \cdot \sin(WD - TH) $	kt
	$hwind_at_50ft$	$WS \cdot \cos(WD - TH)$	kt
	ws_at_50ft	50 ft 총 풍속	kt
	$roll_at_td$	접지 시 롤	deg
	$latg_at_td$	접지 시 횡방향 가속도	G

로 산출한다. ws_at_50ft는 해당 시점의 총 풍속(wind speed, WS)이며 횡풍 성분 xwind_at_50ft와 배풍·정풍 성분 hwind_at_50ft는 풍속(WS), 풍향(wind direction, WD), 기수방위(true heading, TH)로부터 각각 $WS \cdot |\sin(WD - TH)|$ 와 $WS \cdot \cos(WD - TH)$ 로 산출한다. xwind_at_50ft는 절댓값을 취하여 좌우 방향을 구분하지 않는 횡풍의 크기를 나타내며, hwind_at_50ft는 정풍을 양(+), 배풍을 음(-)으로 정의한다. roll_at_td와 latg_at_td는 접지 시점의 롤각(Roll)과 횡방향 가속도(lateral acceleration, LATG)로, 접지 순간의 횡방향 정렬 상태를 나타낸다. 이에 따라 원시 파라미터로 기수방위(TH), 롤각, 횡방향 가속도(LATG)를 추가로 사용하였다.

20개 특징은 척도가 상이하므로 각 특징을 0 - 1 범위로 변환하는 최소 - 최대 정규화를 적용하였다. 정규화 모수는 훈련 데이터에만 적합하여 검증 단계로의 정보 누수를 방지하였다.

3.4 오토인코더 모델

오토인코더(autoencoder)는 입력을 저차원 잠재 공간으로 압축하는 부호화기(encoder)와, 이를 원래 차원으로 복원하는 복호화기(decoder)로 구성된다. 정상 데이터만으로 학습할 경우 정상 차량은 낮은 복원오차로, 정상에서 이탈한 기동은 높은 복원오차로 나타난다(Sakurada and Yairi, 2014). 모델 구조는 입력 20차원으로부터 잠재 6차원까지 대칭적으로 축소·복원하는 형태(20 - 16 - 12 - 6 - 12 - 16 - 20)로 설계하였다. 각 은닉층에는 배치 정규화(batch normalization)와 ELU 활성화 함수, 드롭아웃(dropout, 0.1)을 적용하였으며 출력층에는 시그모이드 활성화 함수를 사용하였다.

손실함수는 평균 제곱 오차(mean squared error, MSE)를, 최적화기로는 adam(초기 학습률 1×10^{-3})을 사용하였으며 검증 손실이 개선되지 않을 때 학습률을 감소시키는 스케줄러를 적용하였다. 배치 크기(batch size)는 256, 최대 200 epoch으로 설정하였고 검증 손실이 20 epoch 동안 개선되지 않으면 학습을 중단하는 조기 종료(early stopping)를 적용하였다. 학습 결과 검증 손실은 약 0.0027로 수렴하였다. 잠재 차원(latent dimension)은 4 - 8 범위에서 동일한 조건으로 재학습하여 비교하였으며 검증 성능이 가장 우수한 잠재 차원 6을 최종 모델로 선택하였다.

3.5 메커니즘별 복원오차 분석 방법

학습된 오토인코더에 한 차량의 정규화된 특징 벡터를 입력하면 복원된 벡터가 산출된다. 각 특징의 복원 오차(reconstruction error)는 입력값과 복원값 간의 제곱오차로 정의한다.

$$e_i = (x_i - \hat{x}_i)^2. \quad (1)$$

정상 차량에서 벗어난 특징일수록 복원오차가 크게 나타나므로 특징별 복원오차는 해당 차량이 어느 측면에서 비정상적이었는지를 나타내는 지표로 사용할 수 있다.

각 특징은 3.3절에서 정의한 다섯 가지 운항 가설(H1 - H5) 중 하나에 속한다. 메커니즘 $k(k \in \{H1, \dots, H5\})$ 에 속한 특징들의 집합을 G_k , 그 특징 수를 $|G_k|$ 라 할 때, 메커니즘별 복원오차 점수 S_k 는 해당 그룹에 속한 특징들의 복원오차 평균으로 산출한다.

$$S_k = \frac{1}{|G_k|} \sum_{i \in G_k} e_i. \quad (1)$$

S_k 값이 클수록 해당 메커니즘에 속한 특징들이 정상 차량 분포로부터 크게 이탈했음을 의미한다. 차량별 메커니즘 복원오차 비중은 각 S_k 를 다섯 메커니즘 점수의 합으로 나누어 백분율로 환산하였으며 가장 높은 비중을 보이는 메커니즘을 해당 차량에서 복원오차가 가장 크게 배분된 메커니즘으로 구분하였다. 메커니즘별 복원오차 비중은 정상 차량 패턴으로부터의 이상 편차가 어느 특징군에 상대적으로 집중되었는지를 나타내는 기술적 지표이다. 이는 해당 메커니즘이 Hard 차량을 유발하였다는 인과적 기여도 또는 물리적 원인 비율을 의미하지 않는다. 따라서 본 연구에서 보고하는 메커니즘별 값은 Hard 차량 결과에 대한 인과적 기여율이 아니라, 전체 복원오차 중 해당 특징군에 배분된 상대적 비중으로 해석한다.

IV. 결 과

4.1 복원오차의 분포

Fig. 1은 학습된 오토인코더에 정상 차량과 경차량을 입력하여 산출한 복원오차의 분포를 나타낸다. 정상 차량의 복원오차는 낮은 값에 집중되어 분포하는 반면, 경차량의 복원오차는 평균적으로 정상 차량보다 높은




Fig. 1. Distribution of reconstruction errors: histogram for normal landings and individual markers for Firm (n=69) and Hard (n=7) landings

값에 분포하였다. Hard 착륙의 평균 복원오차는 정상 착륙의 약 5.7배였으며 특히 상위 몇 건은 정상 착륙 분포에서 뚜렷이 분리되었다. 다만 Hard 착륙의 일부는 정상 분포의 상단 꼬리와 겹쳐, 표본 수가 7건으로 적은 본 자료의 특성상 평균값이 상위 소수 사례에 민감함을 보여준다. VRTG를 학습에 사용하지 않았음에도 모델은 정상 착륙으로부터의 이탈만으로 범주 분류 성능을 검증한 결과가 아니다. 다만 표본이 적으므로 분석 결과는 탐색적으로 해석해야 한다.

4.2 메커니즘별 복원오차 분포

각 firm 및 hard 착륙에 대하여 특징별 복원오차를

다섯 가지 운항 메커니즘으로 배분하고 메커니즘별 평균 복원오차 비중을 산출하였다(Table 3). Hard 7건 중 6건에서는 H1 관련 복원오차가 가장 크게 나타났고, 나머지 1건에서는 H3 관련 복원오차가 가장 크게 나타났다. Hard 그룹에서 H1에 배분된 평균 복원오차 비중은 51.9%로, H4의 16.3%보다 약 3.2배 높았다. 반면 Firm 69건에서 최대 복원오차 메커니즘은 H4 27건, H3 15건, H1 14건, H5 10건, H2 3건으로 분산되었다. 이러한 결과는 본 자료의 Hard 사례에서 정상 착륙 패턴으로부터의 이상 편차가 H1 관련 특징에 집중되는 경향을 보여준다. 다만 복원오차의 크기는 인과적 기여도를 의미하지 않으므로 H1이 hard 착륙을 발생시킨 원인이라고 해석할 수는 없다.

Table 3. Mean proportions and ranks of reconstruction error by operational mechanism and landing category

메커니즘	Hard (n=7)		Firm (n=69)	
	복원오차 비중 (%)	순위	복원오차 비중 (%)	순위
H1	51.9	1	21.0	2
H2	9.5	4	13.0	5
H3	15.6	3	19.6	3
H4	16.3	2	29.2	1
H5	6.7	5	17.2	4

4.3 접지 추력과 플레어 시간의 단조 관계

오토인코더의 산출 결과는 20개 특징을 결합한 잠재 공간 표현에 근거한다. 따라서 4.2절에서 복원오차 비중이 가장 크게 나타난 H1(추력·동력 상태)의 패턴이 원시 변수에서도 관찰되는지를 별도로 검토하였다. 이에 H1과 직접 관련된 두 핵심 특징, 즉 접지 시 4엔진 평균 N1과 플레어 지속 시간을 심각도 그룹별로 비교하였다(Table 4).

접지 시 N1은 정상 30.1 ± 1.9 % RPM, firm 33.6 ± 4.3 %RPM, hard 43.5 ± 5.1 % RPM으로 심각도에 따라 단조 증가하였다. 플레어 지속 시간은

Table 4. Touchdown N1 and flare duration by severity group (mean $\pm$ SD)

그룹	접지 N1 (%RPM)	플레어 시간 (sec)
정상 (n=19,963)	30.1 ± 1.9	12.0 ± 1.6
Firm (n=69)	33.6 ± 4.3	11.4 ± 1.6
Hard (n=7)	43.5 ± 5.1	9.1 ± 2.2

정상 12.0 ± 1.6 초, firm 11.4 ± 1.6 초, hard 9.1 ± 2.2 초로 심각도에 따라 단조 감소하였다. Hard 그룹의 개별 값 범위는 접지 N1 34.8 - 49.4 % RPM, 플레어 시간 6.0 - 12.5초였다.

4.4 추력과 플레어의 상호작용 효과

두 특징을 각각 단변량으로 비교하는 것만으로는 두 조건이 동시에 나타나는 착륙의 분포 특성을 확인하는데 제한이 있다. 이에 4.3절의 단변량 비교를 넘어 두 특징이 결합된 조건의 관찰 비율을 검증하였다. 임계값의 사후 선택에 따른 자의성을 줄이기 위해 두 임계값은 정상 착륙 분포의 사분위수로 정의하였다. 즉, 접지 N1이 정상 분포의 75백분위수(약 30.5 % RPM) 이상 이면서 플레어 시간이 25백분위수(약 10.9초) 미만인 조합의 관찰 비율을 Normal과 Hard 그룹에서 비교하였다(Fig. 2).

해당 조합은 normal에서는 10.5%(19,963건 중 2,088건), firm에서는 36.2%(69건 중 25건), hard에서는 85.7%(7건 중 6건)에서 관찰되어 착륙 범주에 따라 단조적인 경향을 보였다. Fisher 정확검정 결과




Fig. 2. Touchdown N1 versus flare duration for Normal, Firm, and Hard landings, with quartile-based thresholds (30.5 %RPM and 10.9 s)

Table 5. Occurrence rate of the thrust-flare interaction combination

	조합 발생	전체	비율 (%)
Normal	2,088	19,963	10.5
Firm	25	69	36.2%
Hard	6	7	85.7%

normal과 hard 두 집단 간 조합 관찰 비율의 차이는 통계적으로 유의하였다($p=8.42 \times 10^{-6}$). 오즈비는 51.4, 정확 95% 신뢰구간은 6.2 - 2362.8이었다 (Table 5). 다만 Hard 표본이 7건에 불과하여 오즈비의 신뢰구간이 매우 넓었으므로 효과 크기의 정확한 추정에는 상당한 불확실성이 존재한다. 이 결과는 접지 N1 30.5 %RPM 이상과 플레어 시간 10.9초 미만의 조합이 Hard 그룹에서 상대적으로 높은 비율로 관찰되었음을 보여준다. 오토인코더의 복원오차 분석과 별도로 원시 변수의 관찰값을 사용한 보조 분석에서도 같은 방향의 패턴이 관찰되었다. 이는 완전히 독립적인 외부 검증은 아니지만 모델 산출 결과를 원자료 수준에서 보조적으로 검토한 결과이다.

V. 논 의

5.1 결과의 운항적 해석

착륙 최종 단계의 수직가속도는 속도, 강하율, 플레어 및 추력 상태가 복합적으로 작용한 결과로 해석할 필요가 있다. 본 연구는 이들 운항 특성 중 정상 착륙 패턴으로부터 상대적으로 크게 이탈한 특징을 복원오차를 통해 검토하였다. 메커니즘별 복원오차 분석, 원시 변수의 단변량 비교 및 추력-플레어 상호작용 분석에서 접지 시점의 추력 관련 특징이 정상 착륙 패턴으로부터 두드러지게 이탈하는 경향이 공통적으로 관찰되었다. 다만 hard 착륙 표본이 7건이므로 이 결과는 탐색적 분석에 해당하며 확정적 결론으로 제시하지 않는다. 이러한 패턴은 운송용 항공기 비행교범(FCTM)에 기술된 착륙 기술의 표준 원리와 비교하여 해석할 수 있다(Boeing, 2025). 교범은 최종 진입에서 기준속도를 유지하도록 추력을 조절하되, 플레어 단계에서는 추력을 idle로 감소시키도록 기술한다. 본 자료의 Hard 착륙에서 접지 시점의 평균 N1이 43.5 %RPM으로 관찰된 것은 해당 표준 절차와 비교할 때

주목할 만한 편차이다.

4.4절의 상호작용 결과는 착륙 단계의 에너지 관리(energy management) 관점에서 해석할 수 있다. 접지 시점에 추력이 남아 있으면 지상속도 감속이 제한될 수 있고, 여기에 플레어 시간까지 짧으면 남은 에너지를 소산시킬 시간이 부족할 수 있다. 본 연구는 접지 시 N1 30.5 %RPM 이상과 플레어 시간 10.9초 미만의 조합이 착륙 범주별로 관찰되는 정도를 19,963건의 정상 착륙을 기준으로 산출하였다(오즈비 51.4). 다만 이 결합이 경착륙의 원인 기전으로 확립된 것은 아니며, 본 연구는 이를 본 자료에서 관찰된 연관으로 보고한다.

본 연구의 자료는 관측 자료이므로, 접지 시 잔존 추력이 hard 착륙의 원인인지 결과적 징후인지의 인과 방향은 자료만으로 확정할 수 없다. 운항적으로 접지 직전의 높은 N1은 플레어 단계에서 추력을 idle로 감소시키지 못한 추력 관리의 문제일 수도 있고, 반대로 과도한 강하율을 뒤늦게 인지한 조종사가 이를 저지하기 위해 투입한 보정 추력일 수도 있다. 본 방법이 식별하는 것은 hard 착륙에 동반된 이상 편차의 특성이다. 따라서 개별 사례의 인과 방향 판단은 플레어 구간의 시계열 분석과 교관의 운항적 판단으로 보완될 필요가 있다.

결과 내부에도 부연이 필요한 부분이 있다. 플레어 시간의 단축이 4.3절에서 뚜렷한 단변량 경향으로 나타났다으나, 4.2절의 메커니즘별 복원오차 분석에서는 H2(플레어)의 비중이 낮게 산출되었다. 메커니즘별 비중은 원값의 편차가 아니라 복원오차에 기반한다. Hard 착륙의 짧은 플레어 시간은 정상 분포의 하단과 연속적이어서 오토인코더가 비교적 낮은 오차로 복원한 반면, H2 그룹의 나머지 피치 특징들 역시 복원오차가 낮아 그룹의 평균 비중을 낮추었다. 이에 비해 H1 그룹에서는 다섯 특징이 함께 이탈하여 복원오차 비중이 높게 나타났다. 단변량 비교와 복원오차 비중은 서로 다른 정보를 제공하며 본 연구는 이를 보완적으로 제시하였다.

이러한 해석은 국내 비행자료 연구의 결과와도 비교할 수 있다. Jeon & Kim(2024)은 단일 항공사 A320 자료에 대한 회귀분석을 통해 강하 속도와 추력레버각이 수직가속도 초과 이벤트 발생 확률을 높이는 양(+)의 요인이며 낮은 플레어가 주요 원인임을 보고하였다. 본 연구에서도 다른 방법과 다른 자료를 사용하여 유

사한 방향의 관찰 패턴이 나타났다.

5.2 전문가 자문을 통한 타당성 예비 검토

본 연구에서 관찰된 복원오차 패턴이 운항 실무의 관점에서도 해석 가능한지 예비적으로 검토하기 위하여 FOQA 이벤트 분석 경험이 있는 현직 B747 및 A330 라인검열관 각 1인에게 자문을 구하였다. 자문자들에게 본 연구의 분석 절차와 주요 결과를 설명하고 Hard 사례에서 H1 관련 복원오차가 크게 나타난 현상과 접지 시 N1 및 플레어 시간의 관계에 대한 운항적 해석을 요청하였다.

두 자문자는 접지 시 잔존 추력과 큰 수직가속도가 함께 관찰될 수 있다는 점에 동의하였으나, 경착륙을 추력이라는 단일 요인으로 설명하기는 어렵고 플레어 과정에서 강하율이 충분히 해소되었는지를 함께 고려해야 한다고 보았다. 강하율이 적절히 해소된 경우에는 추력이 남아 있더라도 Hard 착륙으로 이어지지 않을 수 있지만 강하율이 충분히 해소되지 않은 상태에서 추력까지 남아 있으면 접지 시 에너지가 증가하여 수직가속도가 더 크게 나타날 가능성이 있다는 의견이었다. 따라서 본 연구에서 관찰된 H1 관련 복원오차는 경착륙의 직접적인 원인이라기보다, 높은 VRTG 착륙에 동반된 운항 특성으로 해석하는 것이 적절하다.

이러한 자문 결과는 본 연구에서 관찰된 패턴이 운항 실무의 관점에서도 해석될 수 있음을 예비적으로 보여준다. 다만 자문자가 2인에 불과하고 정량적인 전문가 조사도 수행하지 않았으므로, 이를 분석 결과에 대한 독립적인 검증으로 간주할 수는 없다. 향후에는 더 많은 조종사와 다양한 기종을 대상으로 한 정량적 검토와 플레어 구간의 시계열 분석을 통해 관찰된 추력 패턴의 의미를 추가로 확인할 필요가 있다.

5.3 교관 보조와 근거 기반 훈련을 위한 실무적 활용

본 연구의 분석 방법은 비행교관의 전문적 판단을 대체하기 위한 것이 아니라, 교관의 판단을 데이터 기반 정보로 보조하기 위한 것이다. 통상 경착륙에 대한 디브리핑은 교관의 경험과 직관에 의존하는데, 이 경우 교관과 훈련생 사이에 운항 특성에 대한 해석이 일치하지 않을 수 있다. 본 방법은 특정 착륙에서 정상 패턴

으로부터의 이상 편차가 어느 운항 메커니즘에 집중되었는지를 제시하여 교관과 훈련생이 함께 검토할 수 있는 자료를 제공한다.

이러한 특성은 근거 기반 훈련(evidence-based training, EBT)의 취지와 부합한다(ICA0, 2013). 통상 교관은 경험에 근거하여 훈련생의 수행을 지적하나, 훈련생이 그 지적에 동의하지 않는 경우가 발생할 수 있다. 본 방법이 제공하는 데이터 기반 근거를 보조 자료로 공유하면 훈련생이 수긍할 수 있는 훈련이 이루어질 수 있다. 본 방법은 실비행 자료의 사후 디브리핑과 시뮬레이터 훈련 세션 양쪽에 적용할 수 있다.

나아가 본 방법은 초과 이벤트 중심의 현행 운항품질보증프로그램이 갖는 한계를 보완할 수 있다. 현행 FOQA 체계는 수직가속도 등 소수 지표가 임계값을 초과한 사례를 주된 검토 대상으로 삼으므로, 임계값에 도달하지 않았으나 정상 운항 패턴으로부터 이탈한 일부 착륙은 관리의 사각지대에 남을 수 있다. 본 방법은 모든 착륙에 대해 정상으로부터의 이탈 정도와 메커니즘별 복원오차 비중을 산출할 수 있다. 따라서 임계값 미만(sub-threshold)의 착륙을 포함한 전수 검토와 이상 편차의 추세 관리에 활용될 가능성이 있다. 이는 초과 이벤트 발생 이후의 사후 분석을 보완하는 예방적 안전 관리 자료로 활용될 수 있다.

5.4 한계

본 연구는 다음과 같은 한계를 가진다. 첫째, Hard 착륙의 표본 수가 7건으로 적어 H1 관련 복원오차가 집중된 패턴은 탐색적 성격을 가진다. 이는 실제 운항에서 본 연구가 조작적으로 정의한 1.70 G 이상의 Hard 사례가 드물게 발생하기 때문이며 향후 더 많은 사례를 통한 검토가 필요하다. 둘째, 본 연구는 기종 정보가 공개되지 않은 단일 공개 데이터셋을 사용하였으므로, 결과의 일반화를 위해서는 기종이 확인된 다양한 항공기 자료에 대한 추가 적용이 필요하다. 셋째, 본 연구의 특징은 두 기준 시점의 스칼라 값과 그 변화량으로 구성된 정적 특징이다. 따라서 플레어 구간에서 추력 변화와 강하율 변화의 시간적 선후관계를 분석하지 못했으며 인과 방향을 구분할 수 없다. 플레어 구간의 시간적 동역학을 포착하는 시계열 기반 분석은 향후 과제로 남는다.

VI. 결 론

본 연구는 정상 착륙만으로 학습한 비지도 오토인코더를 이용하여 경착륙의 운항 메커니즘별 이상 특성을 복원오차 패턴으로 분석하는 방법을 제안하고 이를 NASA DASHlink 비행자료로 검토하였다. 자료의 무결성을 확인해 신뢰할 수 있는 자료를 선별하고 착륙의 최종 진입 구간을 다섯 가지 운항 메커니즘에 대응하는 20개의 특징으로 변환하였다.

분석 결과, 세 가지 보완적 분석에서 일관된 방향의 패턴이 관찰되었다. Hard 7건 중 6건에서 H1 관련 복원오차가 가장 크게 나타났으며 Hard 그룹에서 H1에 배분된 평균 복원오차 비중은 51.9%였다. 또한 접지 시 N1은 normal, firm, hard 순으로 증가하고 플레어 시간은 같은 순서로 감소하였다. 접지 시 N1 30.5 %RPM 이상과 플레어 시간 10.9초 미만의 조합은 normal의 10.5%와 hard의 85.7%에서 관찰되었다. 이러한 결과는 높은 VRTG 착륙에서 추력 관련 특징의 이상 편차가 집중되고 높은 접지 N1과 짧은 플레어 시간이 함께 관찰되는 경향을 보여준다. 다만 본 분석은 추력 상태가 hard 착륙의 원인이었는지, 높은 강하율을 완화하기 위한 보정행동의 결과였는지를 구분하지 못한다.

본 연구의 의의는 두 가지이다. 방법론적으로는 정상 자료만으로 학습한 오토인코더의 복원오차를 운항 메커니즘 단위로 배분함으로써 드문 hard 사례에 대한 학습 라벨 없이 정상 착륙 패턴으로부터의 이상 편차를 제시하였다. 실무적으로는 본 방법이 비행교관의 판단을 데이터 기반 자료로 보조하여 교관과 훈련생이 함께 검토할 수 있는 정보를 제공하고 근거 기반 훈련(EBT)의 보조 자료로 활용될 가능성을 제시하였다.

다만 본 연구는 Hard 착륙의 표본이 7건으로 적어 탐색적 성격을 가지며 기종 정보가 공개되지 않은 단일 공개 데이터셋을 사용하였고 정적 특징을 사용하였다는 한계를 가진다. 향후 연구에서는 더 많은 Hard 사례와 다양한 기종으로 분석 범위를 확장하고 플레어 구간의 시간적 변화를 포착하는 시계열 분석을 통해 관찰된 추력 패턴의 선후관계와 인과 방향을 검토할 필요가 있다.

References

1. Boeing, "Flight Crew Training Manual (FCTM)", Revision 11, Boeing, 2025.
2. Chen, T., and Guestrin, C., "XGBoost: a scalable tree boosting system", Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016, pp.785-794.
3. Dang, X., Hua, C., and Rong, C., "Automated anomaly detection and causal analysis for civil aviation using QAR data", Applied Sciences, 15(5), 2025, Article 2250.
4. Das, S., Matthews, B. L., Srivastava, A. N., and Oza, N. C., "Multiple kernel learning for heterogeneous anomaly detection: Algorithm and aviation safety case study", Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2010, pp.47-56.
5. FAA, "Flight Operational Quality Assurance", Advisory Circular 120-82, Federal Aviation Administration, 2004.
6. ICAO, "Manual of Evidence-Based Training", Doc 9995, AN/497, 1st ed., International Civil Aviation Organization, 2013.
7. Jeon, J. H., and Kim, H. D., "Research on statistical analysis of vertical acceleration events during aircraft landing", Journal of the Korean Society for Aviation and Aeronautics, 32(2), 2024, pp.135-141.
8. Kong, Y., Zhang, X., and Mahadevan, S., "Bayesian deep learning for aircraft hard landing safety assessment", IEEE Transactions on Intelligent Transportation Systems, 23(10), 2022, pp.17062-17076.
9. Lee, J., and Jeon, J., "Analysis of factors affecting aircraft damage severity in aircraft accidents based on machine learning", Journal of the Korean Society for Aviation and Aeronautics, 34(1), 2026, pp.66-79.
10. Li, L., Das, S., Hansman, R. J., Palacios, R.,

- and Srivastava, A. N., "Analysis of flight data using clustering techniques for detecting abnormal operations", *Journal of Aerospace Information Systems*, 12(9), 2015, pp.587-598.
11. Lundberg, S. M., and Lee, S. I., "A unified approach to interpreting model predictions", *Advances in Neural Information Processing Systems*, 30, 2017, pp.4765-4777
 12. Memarzadeh, M., Matthews, B., and Avrekh, I., "Unsupervised anomaly detection in flight data using convolutional variational auto-encoder", *Aerospace*, 7(8), 2020, Article 115.
 13. Memarzadeh, M., Matthews, B., and Templein, T., "Multiclass anomaly detection in flight data using semi-supervised explainable deep learning model", *Journal of Aerospace Information Systems*, 19(2), 2022, pp.83-97.
 14. NASA, "DASHlink - sample flight data", NASA Ames Research Center, 2012, Available from: <https://c3.ndc.nasa.gov/dashlink/projects/85/> (accessed 11 July 2026).
 15. Sakurada, M., and Yairi, T., "Anomaly detection using autoencoders with nonlinear dimensionality reduction", *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*, 2014, pp.4-11.