

공휴일 어텐션 게이트를 활용한 연합학습 기반 항공 여객 수요 예측 (Air Passenger Demand Forecasting via Federated Learning with Holiday-Aware Attention Gate)

서수빈*, 양현성**, 정세훈***, 심춘보****

(Su Bin Seo, Hyun Sung Yang, Se Hoon Jung, Chun Bo Sim)

요약

항공 여객 수요는 공휴일 기간 동안 급격하게 변동하며, 공항별 데이터 통합의 제약으로 인해 연합학습(Federated Learning) 기반 예측 방법이 활용되고 있으나 공휴일 수요 변화를 충분히 반영하지 못하는 한계가 있다. 본 논문에서는 공휴일 수요 패턴을 효과적으로 반영하기 위한 연합학습 프레임워크 HoFeL(Holiday-aware Federated Learning)을 제안한다. 제안 방법은 공휴일 컨텍스트 기반 게이트를 활용하여 공항별 수요 변화를 적응적으로 반영한다. 국내 11개 지방 공항 데이터를 대상으로 실험한 결과, HoFeL은 기존 방법 대비 전체 및 공휴일 데이터에서 가장 낮은 wMAPE(Weighted Mean Absolute Percentage Error)를 기록하였으며, 공휴일과 비공휴일 간 성능 편차를 효과적으로 완화하였다.

■ 중심어 : 공휴일 컨텍스트 ; 연합학습 ; 어텐션 게이트 ; 시계열 예측 ; LSTM

Abstract

Air passenger demand fluctuates significantly during holiday periods, and federated learning-based forecasting methods have been adopted due to limitations in integrating airport data, although they still struggle to effectively capture holiday demand patterns. In this paper, we propose HoFeL(Holiday-aware Federated Learning), a federated learning framework designed to effectively reflect holiday demand patterns. The proposed method adaptively captures airport-specific demand variations using a holiday-context gating mechanism. Experiments conducted on data from 11 regional airports in South Korea demonstrate that HoFeL achieves the lowest wMAPE(Weighted Mean Absolute Percentage Error) on both overall and holiday datasets compared to existing methods, while effectively reducing the performance gap between holiday and non-holiday periods.

■ keywords : Holiday Context ; Federated Learning ; Attention Gate ; Time-series, LSTM

I. 서론

항공 교통은 지역 간 이동과 경제 활동을 연결하는 핵심 인프라로서, 공항의 효율적인 운영은 지역 경제 및 교통 시스템의 성과에 중요한 영향을 미친다[1]. 특히 항공 여객 수요 예측은 공항 운영 계획 수립, 항공사 노선 및 스케줄 조정 등

다양한 의사결정 과정에서 필수적인 기반 정보를 제공한다[2, 3]. 수요 예측 정확도가 높을수록 자원 활용 효율과 서비스 품질을 향상시킬 수 있으며 반대로 예측 오차가 클 경우 운영 비효율이 발생할 수 있다.

국내 항공 시장은 인천공항이나 김포공항과 같

* 준회원, 국립순천대학교 컴퓨터공학과

** 정회원, 국립순천대학교 스마트융합학부 멀티미디어공학전공

*** 정회원, 국립순천대학교 컴퓨터공학과

**** 정회원, 국립순천대학교 인공지능공학부

This paper was supported by Suncheon National University Glocal University Project Fund in 2025

접수일자 : 2026년 05월 20일

게재확정일 : 2026년 06월 08일

수정일자 : 2026년 06월 01일

교신저자 : 심춘보 e-mail : cbsim@scnu.ac.kr

은 대형 허브 공항뿐 아니라 여수, 광주, 울산, 청주 등 다수의 지방 공항으로 구성되어 있다. 이러한 지방 공항은 특정 노선 의존도가 높고 지역적 특성에 따라 수요 변동성이 크게 나타난다[4]. 그림 1은 공휴일을 기준으로 한 상대일에 따른 평균 여객 수요 변화율을 나타낸다. 그림 1에서 공휴일 전후 기간의 평균 여객 수요 변화를 분석한 결과, 공휴일 당일에는 약 15% 이상의 수요 증가가 나타나며 공휴일 이전 구간에서는 점진적인 증가 양상이 관찰된다. 반면 공휴일 이후에는 수요가 빠르게 감소하는 경향을 보이며 전후 구간 변화 양상이 서로 다른 구조를 나타낸다.




그림 1. 공휴일 기준 상대일에 따른 여객 수요 변화율

한편, 공항별 여객 데이터는 서로 다른 기관에 의해 독립적으로 수집 및 관리되며 데이터 공유는 프라이버시 및 보안 문제로 인해 제한된다. 이러한 환경에서는 데이터를 직접 통합하기 어려우며 연합학습(Federated Learning)은 데이터를 공유하지 않고도 협력적으로 모델을 학습할 수 있는 효과적인 대안으로 활용된다[5].

그러나 기존 연합학습 기반 수요 예측 방법들은 클라이언트 간 데이터 분포 차이를 완화하는데 초점을 두고 있고 공휴일 전후와 같이 특정 시점에서 발생하는 급격한 수요 변화는 충분히 반영하지 못하는 한계를 지닌다[7-9]. 특히 공휴일을 단순한 입력 변수로 처리하는 접근은 공휴일 구간의 중요도를 학습 과정에서 명시적으로 반영하지 못하기 때문에 공휴일 구간에서의 수요 예측 오차가 증가하는 문제가 발생한다.

이를 해결하기 위해 본 논문에서는 공휴일 구

간의 구조적 수요 변화를 반영하는 연합학습 기반 모델 HoFeL(Holiday-aware Federated Learning)을 제안한다. 제안 방법은 글로벌 LSTM(Long Short-Term Memory) 기반 백본을 통해 공통적인 시계열 패턴을 학습하고 공항별 Local Head를 통해 지역별 수요 반응 특성을 반영한다. 또한 공휴일 이전과 당일, 이후 구간 정보를 인코딩한 컨텍스트를 어텐션 게이트(Attention Gate)를 통해 시계열 표현에 선택적으로 반영함으로써 공휴일 중심의 수요 변화를 효과적으로 모델링한다.

항공 여객 수요 예측 실험은 2015년부터 2025년까지 수집된 국내 11개 지방 공항의 일별 여객 수요 데이터를 대상으로 수행하였다. 제안 방법은 기존 방법 대비 전체 구간에서 우수한 성능을 보였으며 특히 공휴일 구간에서의 예측 오차를 효과적으로 감소시켰다. 또한 공휴일 구간과 일반 구간 간 성능 차이를 완화하여 보다 안정적인 예측 성능을 달성하였다.

II. 관련 연구

1. 항공 수요 예측

항공 여객 수요 예측은 시계열 분석의 대표적인 응용 분야로, 공항 운영 및 항공 산업 전반의 의사결정에 중요한 역할을 한다. 초기 연구에서는 ARIMA(Autoregressive Integrated Moving Average)와 같은 전통적인 통계 기반 모델이 주로 활용되었으며, 비교적 안정적인 추세와 계절성을 가지는 데이터에서 효과적인 성능을 보였다[10]. 그러나 항공 수요는 계절, 기상, 경제 상황, 공휴일 등 다양한 외부 요인의 영향을 받아 급격한 변동이 발생하는 특성을 가진다. 이에 따라 선형 기반 모델은 복잡한 수요 패턴과 비선형성을 충분히 반영하는 데 한계를 가진다.

최근에는 딥러닝 기반 접근법이 활발히 연구되고 있다[11-13]. 특히 LSTM은 시계열 데이터의 장기 의존성을 효과적으로 학습할 수 있어 항공

수요 예측에 널리 활용되고 있다. 또한 CNN-LSTM, Transformer 기반 모델 등 다양한 확장 구조가 제안되면서 시공간적 특성과 복잡한 패턴을 반영하려는 연구가 진행되고 있다.

그러나 기존 연구의 대부분은 단일 공항 또는 대형 허브 공항을 중심으로 수행되었으며, 데이터 규모가 제한적이고 변동성이 큰 지방 공항에 대한 연구는 상대적으로 부족하다[14, 15]. 지방 공항은 특정 노선 의존도와 지역 행사의 영향을 크게 받아 공항 간 수요 패턴의 이질성이 두드러지게 나타난다. 또한 공휴일과 같은 특정 시점에서는 단기간 내 급격한 수요 변화가 발생한다. 따라서 지방 공항 환경에서는 공항 간 이질성과 특정 이벤트 기반 수요 변화를 동시에 고려할 수 있는 모델링 접근이 필요하다.

2. 연합학습

연합학습은 분산된 데이터 환경에서 원시 데이터를 공유하지 않고 협력 학습을 수행하는 프라이버시 보존 학습 패러다임이다. FedAvg는 각 클라이언트가 로컬 데이터를 이용해 모델을 학습한 후, 서버에서 모델 파라미터를 평균화하여 글로벌 모델을 업데이트하는 방식으로 동작한다[16]. 이러한 구조는 데이터 공유 없이 협력 학습이 가능하다는 장점을 가진다.

그러나 실제 환경에서는 클라이언트 간 데이터 분포 차이로 인해 non-IID(Independent and Identically Distributed) 문제가 발생하며, 모델 수렴 불안정 및 성능 저하로 이어질 수 있다. 이를 완화하기 위해 다양한 개인화 연합학습이 제안되었다. FedProx[17]는 글로벌 모델과 로컬 모델 간 차이를 정규화 항으로 추가하여 학습 안정성을 향상시켰다. FedPer[18]는 글로벌 공유 레이어와 클라이언트별 개인화 레이어를 분리하여 각 클라이언트의 특성을 반영하였다. 또한 Ditto[19]는 글로벌 모델과 로컬 모델을 동시에 최적화하여 일반화 성능과 개인화 성능 간 균형을 유지하고자 하였다. 그럼에도 불구하고 기존 연합학습 연구는 주

로 클라이언트 간 데이터 분포 차이를 완화하거나 개인화 성능 향상에 초점을 두고 있다.

반면 시계열 데이터에서 특정 시점에 발생하는 구조적 변화나 이벤트 기반 패턴 변화에 대한 고려는 상대적으로 제한적이다. 특히 공휴일 이전, 당일, 이후와 같이 짧은 기간 내 발생하는 급격한 수요 변화와 클라이언트 간 이질성을 동시에 반영하는 문제는 충분히 다루어지지 않았다. 따라서 연합학습 기반 시계열 예측에서는 시점 기반 구조 변화와 데이터 이질성을 함께 고려할 수 있는 접근이 필요하다.

3. 공휴일 인식 시계열 예측

공휴일과 같은 이벤트 효과를 시계열 예측에 반영하기 위한 연구가 지속적으로 이루어져 왔다[20, 21]. 대표적으로 Prophet은 공휴일을 별도의 회귀 성분으로 모델링하여 명절 및 특정 이벤트에 따른 수요 변화를 반영한다. 그러나 이러한 방법은 단일 시계열을 대상으로 설계되어 다수의 공항 데이터를 동시에 활용하는 환경이나 분산된 데이터 구조에서는 적용에 제약이 있다.

또한 공휴일 효과를 정교하게 반영하기 위해 공휴일 인접 구간에 더 높은 중요도를 부여하는 가중 손실 함수나 공휴일 정보를 임베딩 벡터로 표현하는 접근이 제안되고 있다[22-24]. 이러한 방법들은 공휴일 구간의 예측 성능 개선에 기여할 수 있으나, 대부분 중앙집중식 학습 환경을 전제로 한다는 한계를 가진다. 특히 연합학습 환경에서는 데이터가 분산되어 있을 뿐만 아니라, 공항별로 공휴일에 대한 수요 반응 패턴이 서로 다르게 나타날 수 있다. 하지만 기존 연구에서는 공휴일 이전, 당일, 이후 구간에서 나타나는 수요 변화와 클라이언트 간 이질성을 동시에 고려하는 접근이 충분히 다루어지지 않았다. 따라서 공휴일 구간에서의 수요 변화를 명시적으로 반영하면서 공항 간 이질성을 유지할 수 있는 연합학습 기반 시계열 예측 프레임워크가 요구된다.

III. 제안 방법

1. 연합학습 기반 HoFeL 프레임워크 구조

본 논문에서는 공항별 데이터 프라이버시를 보호하면서 공휴일 구간의 예측 성능을 향상시키기 위한 프레임워크 HoFeL을 제안한다. 항공 여객 수요는 공휴일과 같은 이벤트에 의해 급격한 변동을 보이며 이러한 변화 양상은 공항별 서로 다르게 나타난다. HoFeL은 글로벌 시계열 패턴과 공항별 수요 특성을 분리하여 학습하는 구조를 가진다. 전체 프레임워크는 모든 클라이언트가 공유하는 글로벌 LSTM 기반 백본과 각 공항이 독립적으로 유지하는 로컬 헤드로 구성된다. 글로벌 백본은 다수 공항의 데이터를 활용하여 공통적인 수요 패턴을 학습하며, 로컬 헤드는 공휴일 정보를 반영하여 공항별 수요 반응을 반영한다. 이러한 구조는 글로벌 지식 공유와 로컬 특성 보존 간의 균형을 유지하면서, 공항 간 데이터 이질성으로 인한 성능 저하를 완화한다.

공휴일 기반 연합학습 구조에서는 글로벌 시계열 표현, 공휴일 컨텍스트, 게이트 벡터 등 다양한 구성 요소가 함께 사용된다. 또한 연합학습 과정에서 클라이언트별 로컬 데이터와 글로벌 모델 간의 상호작용이 반복적으로 수행된다. 제안한 HoFeL 프레임워크에서 사용되는 주요 기호는 표 1에 정리하였다.

표 1. 주요 기호 정의

Notation	Description
X	항공 여객 수요 입력 시계열
z	LSTM 잠재 표현 벡터
c_t	시점 t 의 공휴일 컨텍스트 벡터
\bar{c}	입력 시퀀스 평균 컨텍스트 벡터
g	공휴일 컨텍스트 기반 게이트 벡터
τ	공휴일 구간을 정의하는 윈도우 크기
K	전체 클라이언트 수
R	연합학습 통신 라운드 수

연합학습은 총 R 라운드에 걸쳐 수행된다. 각

라운드 r 에서 서버는 글로벌 백본 파라미터 θ 를 모든 클라이언트에 배포하고, 각 클라이언트는 이를 초기값으로 사용하여 각 클라이언트는 로컬 데이터에 대해 글로벌 백본과 로컬 헤드를 함께 학습한다. 이후 각 클라이언트는 갱신된 백본 파라미터 θ_i 만을 서버로 전송하며, 서버는 이를 평균하여 다음 라운드의 글로벌 모델을 생성한다. 이러한 글로벌 모델 업데이트 과정은 수식 (1)과 같이 표현된다. 수식 (1)에서 K 는 전체 클라이언트 수를 의미하고 로컬 헤드 파라미터는 각 클라이언트에 유지되어 개인화된 수요 반응을 보존한다. 본 연구에서는 모든 클라이언트에 동일한 가중치를 부여하여 글로벌 백본 파라미터를 집계하였다.

$$\theta^{r+1} = \frac{1}{K} \sum_{i=1}^K \theta_i^r \quad (1)$$

전체 연합학습 절차는 표 2에 정리하였다. HoFeL은 공휴일 구간의 구조적 수요 변화를 반영하는 로컬 모델과 공항 간 공통 패턴을 학습하는 글로벌 모델을 결합한 연합학습 프레임워크이다. 이를 통해 데이터 프라이버시를 유지하면서 공항 간 이질성과 시점별 변동성을 동시에 고려할 수 있다.

표 2. 제안하는 HoFeL 알고리즘

Input: Client set $\{1, \dots, K\}$, rounds R , learning rate η
Output: Global backbone θ , local head ϕ_i

1. **Initialize** θ, ϕ_i for all clients
2. **for** $r=1$ to R **do**
3. **for** each client i **do**
4. $\theta_i \leftarrow \theta$
5. **for** each mini-batch $(X, y, d) \in D_i$ **do**
6. update θ_i and ϕ_i using gradient descent
7. **end for**
8. **send** θ_i to server
9. **end for**
10. $\theta \leftarrow \frac{1}{K} \sum_{i=1}^K \theta_i$
11. **end for**

표 3. 제안 모델에서 사용된 입력 특징 구성

Category	Feature	Description	Category	Feature	Description
Basic	pax_dep	출발 여객 수	Extended	is_pre_holiday	공휴일 이전 구간 여부
	pax_arr	도착 여객 수		is_post_holiday	공휴일 이후 구간 여부
	day_of_week	요일 정보		run_len_norm	연속 공휴일 길이
	is_weekend	주말 여부		pos_in_run	공휴일 내 위치
	is_holiday	공휴일 여부		is_long_holiday	장기 연휴 여부
	d_to_holiday	공휴일까지 거리		is_weekend_hol	주말-공휴일 중첩 여부

2. 입력 특징 설계

항공 여객 수요는 요일, 계절성, 공휴일과 같은 다양한 시간적 요인의 영향을 받으며 공휴일 인접 구간에서는 수요가 급격히 변동한다. 이러한 변화는 단순한 공휴일 여부만으로는 설명하기 어렵기 때문에 공휴일과의 상대적 위치 및 연속 공휴일 구조를 반영할 수 있는 입력 특징 설계가 필요하다.

본 연구에서는 기본 시계열 특징과 공휴일 확장 특징을 결합하여 총 12차원의 입력 벡터를 구성하였으며, 전체 구성은 표 3과 같다. 기본 특징은 여객 수요와 시간 정보를 포함한다. 출발 및 도착 여객 수에는 Min-Max 정규화를 적용하였으며, 요일 정보는 수치형 값으로 변환하여 입력에 포함하였다. 또한 주말 여부와 공휴일 여부를 나타내는 이전 변수와 함께 공휴일까지의 상대적 거리 정보를 포함하여 공휴일과의 시간적 관계를 반영하였다. 공휴일 확장 특징은 공휴일 인접 구간에서 나타나는 구조적 수요 변화를 반영하기 위해 설계되었다. 공휴일 이전 및 이후 구간을 구분하는 변수는 수요 집중 시점을 식별하는데 사용되며, 연속 공휴일 길이와 연휴 내 상대적 위치는 단일 공휴일과 장기 연휴 간의 패턴 차이를 반영한다. 또한 장기 연휴 여부와 주말 및 공휴일 중첩 여부를 포함하여 복합적인 이벤트 효과를 모델에 반영하였다. 이러한 입력 특징 설계를 통해 모델은 공휴일 여부뿐만 아니라 공휴일

인접 구간에서의 비대칭적 수요 변화와 연휴 구조에 따른 패턴을 효과적으로 학습할 수 있다.

3. LSTM 백본과 공휴일 인식 로컬 헤드

공휴일 구간에서는 일반적인 시계열 패턴과 구별되는 급격한 수요 변동이 발생하며, 이러한 변동은 공항별로 서로 다른 수요 패턴을 보인다. 이를 반영하기 위해 HoFeL은 글로벌 LSTM 백본과 공휴일 인식 로컬 헤드로 구성된 구조를 기반으로 한다. 글로벌 백본은 공통적인 시계열 패턴을 학습하고, 로컬 헤드는 공휴일 컨텍스트를 반영하여 공항별 수요 반응을 보정한다.

글로벌 백본은 길이 T 의 입력 시퀀스 $X \in \mathbb{R}^{T \times F}$ 를 입력으로 받아 잠재 표현 $z \in \mathbb{R}^H$ 를 생성한다. 이때, H 는 은닉 차원(hidden dimension)을 의미하며, 본 연구에서는 32로 설정하였다. 해당 표현은 시계열의 장기 의존성과 공통 패턴을 반영하는 글로벌 표현으로 활용된다. 식 (2)는 입력 시퀀스 X 로부터 글로벌 시계열 표현 z 를 생성하는 과정을 나타낸다.

$$z = LSTM(X; \theta) \quad (2)$$

이러한 글로벌 표현에 공휴일 효과를 반영하기 위해 각 시점 t 에서 공휴일과의 상대적 거리 d_t 를 기반으로 컨텍스트 벡터 $c_t \in \mathbb{R}^4$ 를 구성한다. 각 시점의 컨텍스트 벡터를 평균하여 시퀀스 전반의 공휴일 영향을 반영하는 대표 컨텍스트 벡터

\bar{c} 를 생성한다. 식 (3)은 각 시점의 공휴일 컨텍스트 벡터를 평균하여 시퀀스 수준의 대표 컨텍스트 벡터를 생성하는 과정을 나타낸다.

$$\bar{c} = \frac{1}{T} \sum_{t=1}^T c_t \quad (3)$$

생성된 컨텍스트 벡터 \bar{c} 는 공휴일 정보를 집약한 표현으로, 이후 로컬 헤드에서 활용된다. 로컬 헤드는 공휴일 컨텍스트를 반영하여 글로벌 표현을 보정한다. 이를 위해 공휴일 컨텍스트에 따라 각 차원의 중요도를 동적으로 조절하는 게이트 벡터 g 를 계산하며, 공휴일 효과가 시계열 표현에 선택적으로 반영되도록 하는 역할을 한다. 게이트 벡터 g 는 식 (4)와 같이 정의된다.

$$g = \sigma(W_{gate} \bar{c}) \quad (4)$$

최종 예측값은 식 (5)와 같이 글로벌 표현과 게이트 벡터를 결합하여 정의된다. 식 (5)에서 $W, V \in \mathbb{R}^{L \times H}$ 는 학습 가능한 파라미터이며, \odot 는 원소별 곱을 의미한다. Wz 는 글로벌 패턴에 기반한 기본 예측을 나타내고, $V(z \odot g)$ 는 공휴일 컨텍스트에 의해 유도되는 추가적인 수요 변화를 반영한다.

$$\hat{y} = Wz + V(z \odot g) \quad (5)$$

식 (5)에서 산출된 예측값은 실제값과의 차이를 최소화하도록 학습되며, 이를 위해 평균 제곱 오차(Mean Squared Error)를 손실 함수로 사용한다. 손실 함수 L 은 식 (6)과 같이 정의된다.

$$L = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (6)$$

이러한 구조를 통해 모델은 일반적인 시계열 패턴과 공휴일 구간에서의 비정상적 수요 변화를 효과적으로 분리하여 학습하며, 공항별로 상이한 공휴일 반응 특성을 반영한다.

IV. 데이터셋 및 실험 설정

1. 데이터셋 및 전처리

본 연구에서는 국토교통부 항공정보포털에서 제공하는 국내 지방 공항의 일별 여객 수요 데이터를 사용하였다. 대상 공항은 대구, 청주, 광주, 여수, 군산, 울산, 사천, 포항, 원주, 무안, 양양을 포함한 총 11개 지방 공항이다. 데이터 수집 기간은 2015년 1월 1일부터 2025년 12월 31일까지이며, 공항별 총 4,018일의 시계열 데이터를 포함한다. 각 시점에서 출발 여객 수와 도착 여객 수를 각각 독립적인 예측 대상으로 설정하였다.

공항별 여객 수요는 계절성과 지역적 특성에 따라 상이한 패턴을 보인다. 이러한 차이를 확인하기 위해 그림 2는 공항별 월별 정규화 여객 수요를 히트맵 형태로 시각화한 결과를 나타낸다. 일부 공항의 경우 연중 비교적 안정적인 수요 분포를 보이는 반면, 특정 지역 공항에서는 계절 및 관광 수요에 따라 뚜렷한 집중 현상이 나타난다. 공항별 데이터가 서로 다른 분포를 가지는 non-IID 특성을 갖고 있음을 시사하며 단일 글로벌 모델만으로는 차이를 충분히 반영하기 어렵다는 점을 보여준다. 또한 항공 여객 수요는 공휴일 기간 동안 평상시와 다른 변동 패턴을 보이기 때문에 공휴일 특성을 반영한 예측 모델이 필요하다.




그림 2. 공항별 월별 정규화 여객 수요 히트맵

한편, 공휴일 구간에서는 일반적인 시계열 패턴과 다른 수요 변화가 나타난다. 그림 3은 연속 비근무일 길이에 따른 공휴일 수요 변화율을 나타낸 것으로, 연휴 길이가 증가할수록 공휴일 수요

증가 폭이 확대되는 경향을 확인할 수 있다. 특히 3일 이상의 연휴에서는 수요 증가가 뚜렷하게 나타나며 4일 이상의 장기 연휴에서는 약 20% 이상의 증가가 관찰된다. 반면, 단일 공휴일에서는 수요 증가 효과가 제한적이거나 감소하는 경우도 나타났다. 이러한 결과는 공휴일 효과가 단순한 이진 변수로 표현되기 어려우며 연휴 구조에 따른 차이를 고려할 필요가 있음을 시사한다.

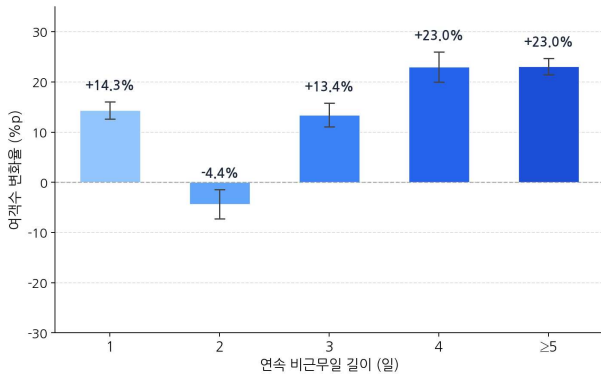


그림 3. 연속 공휴일 길이에 따른 수요 변화율

데이터 전처리는 시계열 특성을 고려하여 시간 순서를 유지한 채 수행하였다. 전체 데이터를 훈련, 검증, 테스트 집합으로 분할하였다. 훈련 집합은 2015년부터 2022년까지, 검증 집합은 2023년, 테스트 집합은 2024년부터 2025년까지로 구성하였다. 코로나19 기간의 데이터는 비정상적인 수요 변동을 포함하므로 구조적 이상치로 간주될 수 있다. 이에 따라 2020년부터 2021년까지의 데이터는 학습 데이터에 포함하되, 손실 함수 계산 시 가중치 0.3을 적용하여 코로나19 기간의 급격한 수요 변화가 모델 학습에 과도한 영향을 미치는 것을 완화하였다. 모든 연속형 변수에 대해 훈련 집합 기준으로 Min-Max 정규화를 수행하고, 검증 및 테스트 집합에는 동일한 스케일을 적용하였다. 모델 출력은 정규화된 값으로 산출되며, 평가 단계에서는 역정규화를 통해 실제 여객 수 단위로 변환하여 성능을 측정하였다.

2. 실험 설정

본 연구에서는 HoFeL의 성능을 평가하기 위해

Local Only, Centralized, FedAvg, FedPer, Ditto와 비교 실험을 수행하였다. Local Only는 각 공항 데이터를 독립적으로 학습하는 방식으로 연합학습을 적용하지 않은 로컬 학습 기준 모델이다. Centralized는 모든 공항 데이터를 단일 서버에 통합하여 학습하는 방식으로, 데이터 공유가 가능한 환경에서의 성능 기준으로 활용하였다. FedAvg는 클라이언트 간 모델 파라미터를 평균하여 글로벌 모델을 갱신하는 대표적인 연합학습 방법이다. FedPer는 글로벌 백본을 공유하면서 클라이언트별 예측 헤드를 유지하는 개인화 연합학습 구조이며, Ditto는 글로벌 모델과 로컬 모델을 동시에 최적화하여 개인화 성능을 향상시키는 방법이다. 제안 방법 HoFeL은 글로벌 백본과 로컬 헤드를 분리한 개인화 연합학습 구조를 기반으로 하며, 로컬 헤드에서 공휴일 컨텍스트 기반 게이트 메커니즘을 활용하여 공항별 시계열 표현을 보정한다.

공정한 비교를 위해 모든 비교 방법은 동일한 LSTM 기반 백본 구조와 12차원 입력 특징을 사용하도록 설정하였다. 입력 특징 차이의 영향을 배제하고, 모델 구조에 따른 성능 차이를 공정하게 비교하기 위함이다. 모든 모델은 과거 14일의 시계열 데이터를 입력으로 향후 7일의 수요를 예측하는 다중 시점 예측 구조로 설정하였다. 실험은 3회 반복 수행하여 평균 성능을 측정하였다.

표 4. 모델 학습에 사용된 하이퍼파라미터 설정

Item	Symbol	Value
클라이언트 수	K	11
라운드	R	100
로컬 에폭	E	1
배치 사이즈	B	16
입력 시퀀스 길이	T	14
예측 기간	L	7
은닉 차원	H	32
학습률	η	0.001
공휴일 윈도우	τ	2
옵티마이저	-	Adam

주요 하이퍼파라미터는 표 4에 정리하였으며 모든 방법에 동일하게 적용하였다. 모든 모델은 Adam 옵티마이저를 사용하여 학습하였으며, 배치 크기는 16, 로컬 에폭 수는 1로 설정하였다. 연합학습은 총 100 라운드 동안 수행하였으며, 각 라운드에서 클라이언트는 로컬 데이터를 이용하여 모델을 학습한 후 백본 파라미터를 서버에 전송하였다. 서버는 각 클라이언트의 파라미터를 동일 가중치로 평균하여 글로벌 모델을 갱신하였다.

3. 평가 지표

모델의 예측 성능 평가는 wMAPE(Weighted Mean Absolute Percentage Error)와 RMSE(Root Mean Squared Error)를 사용하여 수행하였다. 각 지표는 전체 구간과 공휴일 구간에서의 성능을 함께 평가하기 위해 활용하였다.

wMAPE는 실제 값 대비 예측 오차의 비율을 가중 평균 형태로 계산하는 지표이다. 서로 다른 규모의 시계열 간 성능을 공정하게 비교할 수 있다. 특히 공항별 수요 규모 차이가 큰 환경에서 안정적인 평가가 가능하므로 주요 평가 지표로 사용하였다. wMAPE는 식 (7)과 같이 정의된다.

$$wMAPE = \frac{\sum_{t=1}^N |\hat{y}_t - y_t|}{\sum_{t=1}^N y_t} \times 100 \quad (7)$$

RMSE는 제곱 오차를 기반으로 계산되며, 큰 오차에 민감하게 반응하는 특성을 가진다. 따라서 공휴일과 같은 급격한 수요 변동 구간의 예측 안정성을 평가하는 데 유용하다. RMSE는 식 (8)과 같다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{y}_t - y_t)^2} \quad (8)$$

두 가지의 평가 지표에서 y_t 는 시점 t 에서의 실제값, \hat{y}_t 는 예측값, N 은 전체 샘플 수를 의미한다. 공휴일 구간의 성능을 보다 명확하게 분석하기 위해 각 지표를 공휴일 구간과 일반 구간으로 구

분하여 평가하였다. 공휴일 구간은 공휴일 기준 전후 2일을 포함하도록 정의하였다. 모든 실험은 동일한 설정에서 수행하였다.

V. 실험 결과

1. 베이스라인 성능 비교

본 연구에서는 HoFeL의 성능을 평가하기 위해 Local Only, Centralized, FedAvg, FedPer, Ditto와 비교 실험을 수행하였다. 표 5는 11개 공항에 대해 3회 반복 실험한 평균 성능을 나타낸다.

표 5. 모델별 예측 성능 비교

Method	Overall	
	wMAPE (%)	RMSE
Local Only	17.75 ± 0.23	208.2 ± 1.6
Centralized	15.59 ± 0.16	208.3 ± 1.3
FedAvg	15.75 ± 0.25	210.7 ± 3.2
FedPer	15.25 ± 0.36	199.5 ± 0.3
Ditto	15.17 ± 0.16	202.5 ± 0.6
HoFeL	14.94 ± 0.32	199.0 ± 0.5

HoFeL은 전체 구간에서 wMAPE 14.94%를 기록하며 비교 방법 중 가장 낮은 오차를 보였다. RMSE 199.0으로 경쟁 방법 대비 낮은 값을 나타내어 전반적인 예측 성능에서 일관된 개선을 확인할 수 있다. 특히 RMSE 감소는 공휴일과 같은 급격한 수요 변동 구간에서 예측 안정성이 향상되었다.

연합학습을 적용하지 않은 Local Only는 wMAPE 17.75%로 가장 높은 오차를 보였으며, 개별 공항 데이터만으로는 충분한 일반화 성능을 확보하기 어려움을 보여준다. Centralized는 wMAPE 15.59%를 기록하여 성능이 개선되었으나, 공항 간 수요 패턴의 이질성을 단일 모델이 충분히 반영하지 못하는 한계를 보였다.

대표 연합학습 방법인 FedAvg는 wMAPE

15.75%로 Centralized와 유사한 수준의 성능을 보였으며, 단순한 파라미터 평균화 방식만으로는 다양한 공향의 수요 특성을 효과적으로 반영하기 어려움을 확인할 수 있다. 개인화 연합학습 방법인 FedPer과 Ditto는 각각 wMAPE 15.25%와 15.17%를 기록하며 FedAvg 대비 성능 향상을 보였다. 공향별 특성을 반영하는 개인화 구조가 수요 예측 성능 향상에 기여함을 보여준다. 특히 HoFeL은 Ditto 대비 약 0.23%p의 추가 성능 향상을 보였다. 공휴일 컨텍스트 기반 게이트 구조가 공향별 수요 특성을 효과적으로 반영했음을 보여준다.

표 6. Bootstrap 기반 통계적 유의성 검정 결과

Method	wMAPE (%)	Δ (%p)	p-value
Local Only	17.75 \pm 0.23	+ 2.81	< 1e-04
Centralized	15.59 \pm 0.16	+ 0.65	< 1e-04
FedAvg	15.75 \pm 0.25	+ 0.80	1e-04
FedPer	15.25 \pm 0.36	+ 0.30	1e-04
Ditto	15.17 \pm 0.16	+ 0.23	1.56e-02
HoFeL	14.94 \pm 0.32	-	-

HoFeL은 전체 구간에서 Ditto 대비 약 0.23%p의 성능 향상을 보였다. 개선폭은 크지 않지만 이러한 차이가 우연에 의한 것인지 확인하기 위해 10,000회 bootstrap 재표집 기반 통계적 유의성 검정을 수행하였다. 표 6은 HoFeL과 각 비교 방법 간의 전체 구간 wMAPE 차이에 대한 통계적 유의성 검정 결과를 나타낸다. 모든 비교 방법에 대해 p-value가 0.05 미만으로 나타났으며, 특히 가장 우수한 비교 방법인 Ditto와의 비교에서도 p-value가 0.0156으로 확인되었다. HoFeL의 성능 향상이 통계적으로 유의함을 의미하며, 제안한 공휴일 인식 개인화 구조가 예측 성능 향상에 실질적으로 기여함을 보여준다.




그림 4. 통신 라운드별 모델 학습 손실 수렴 비교

그림 4는 통신 라운드에 따른 각 방법론의 학습 손실 수렴 과정을 나타낸다. 모든 방법은 초기 학습 단계에서 손실이 빠르게 감소하였으며, 이후 점진적으로 안정적인 수렴 양상을 보였다. Centralized 방식은 전체적으로 가장 낮은 손실 값을 유지하였고, Local Only는 상대적으로 높은 손실 값에 머물러 데이터 분산 환경에서의 한계를 보였다. FedAvg는 Centralized와 유사한 초기 성능을 보였으나, 후반부에는 손실 감소 폭이 제한적이었다. 반면 개인화 기반 방법인 FedPer와 Ditto는 더 낮은 손실 값으로 수렴하며 지역별 특성을 반영한 학습의 효과를 확인하였다. 특히 제안 방법인 HoFeL은 전 구간에서 안정적인 감소 추세를 유지하면서 최종적으로 가장 낮은 수준의 손실 값에 수렴하였다. HoFeL은 학습 과정에서 비교적 안정적인 최적화 양상을 보였으며, 공향별 수요 특성과 공휴일 정보를 반영한 구조가 손실 감소에 긍정적으로 작용한 것으로 해석할 수 있다.

2. 공휴일 구간과 일반 구간 예측 성능 분석

공휴일 여부에 따른 수요 변동 특성이 예측 성능에 미치는 영향을 분석하기 위해, 데이터를 공휴일 구간과 일반 구간으로 구분하여 각 방법론의 성능을 비교하였다. 공휴일 구간은 일반 구간에 비해 수요 변동성이 크기 때문에 예측 난이도가 높은 구간이다. 표 7에서 보이는 것과 같이, 모든 방법에서 공휴일 구간의 wMAPE는 일반 구간보다 높게 나타났다.

표 7. 공휴일 및 비공휴일 데이터에 대한 모델별 예측 성능 비교

Method	Holiday		non-Holiday	
	wMAPE (%)	RMSE	wMAPE (%)	RMSE
Local Only	17.99 ± 0.52	204.0 ± 2.1	17.71 ± 0.14	210.5 ± 1.0
Centralized	16.56 ± 0.46	207.7 ± 0.9	14.78 ± 0.06	207.0 ± 2.0
FedAvg	16.27 ± 0.19	205.9 ± 3.4	15.34 ± 0.29	213.4 ± 3.0
FedPer	15.76 ± 0.26	193.8 ± 0.3	14.95 ± 0.45	203.2 ± 0.7
Ditto	15.71 ± 0.17	198.2 ± 1.3	14.86 ± 0.20	205.1 ± 0.3
HoFeL	15.51 ± 0.26	193.9 ± 0.9	14.61 ± 0.33	201.8 ± 0.3

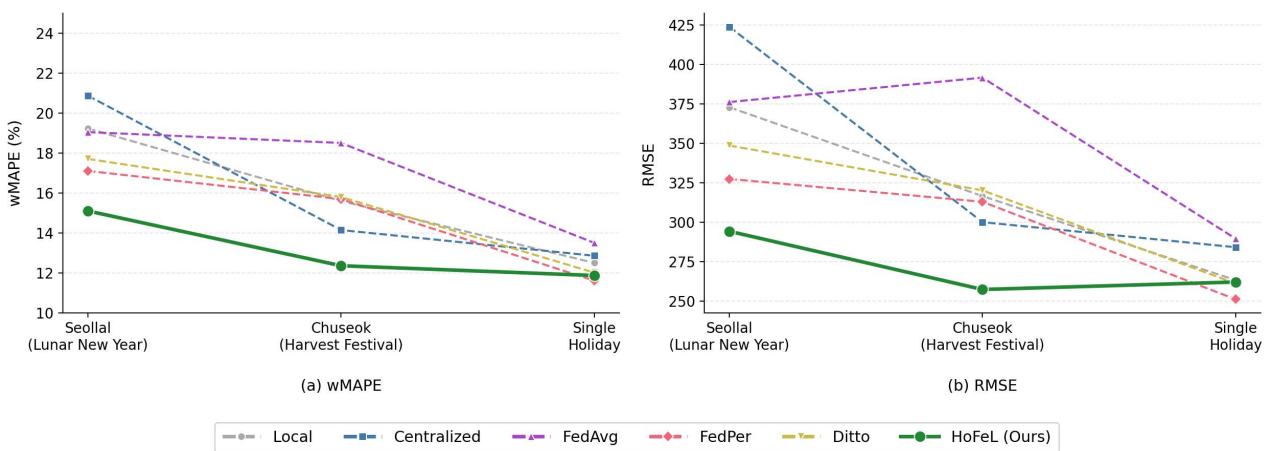


그림 5. 공휴일 유형별 모델 성능 비교

각 방법의 공휴일 구간과 일반 구간 간 성능을 비교한 결과, Centralized는 두 구간 간 차이가 크게 나타나 공휴일 구간에서의 성능 저하가 두드러졌다. 이는 단일 모델 기반 접근이 공휴일과 같은 비정상 구간의 수요 변화를 충분히 반영하지 못함을 의미한다. FedAvg 또한 공휴일 구간에서 높은 오차를 보였으며, 단순한 파라미터 평균화 방식의 한계를 확인할 수 있었다. Local Only 역시 공휴일 구간에서 높은 오차를 나타내어 데이터 분산 환경에서의 일반화 성능이 제한되는 모습을 보였다. 개인화 연합학습 방법인 FedPer과 Ditto는 각각 15.76%와 15.71%의 wMAPE를 기록하며 FedAvg 대비 성능 향상을 보였으나, 여전히 공휴일 구간에서의 오차는 상대적으로 크게 나타났다.

반면 HoFeL은 공휴일 구간에서 wMAPE 15.51%로 비교 방법 중 가장 낮은 오차를 보였으며, 일반 구간에서도 14.61%로 안정적인 성능을 유지하였다. 공휴일 구간뿐만 아니라 전체 시계열에 걸쳐 일관된 예측 성능을 확보했음을 의미한다. HoFeL은 공휴일로 인한 수요 분포 변화에 대해 안정적인 예측 성능을 보였으며, 공휴일 구간과 일반 구간 모두에서 균형 잡힌 성능을 달성하였다. 공휴일 컨텍스트를 반영한 개인화 학습 전략이 비정상적인 시계열 구간에서의 예측 성능 향상에 효과적임을 보여준다.

그림 5는 공휴일 유형에 따른 예측 성능 변화를 나타낸다. 전체적으로 모든 방법에서 설날과 추석 구간의 오차가 단일 공휴일 대비 높게 나타났으며, 이는 장기 연휴에서 여객 수요의 변동성이

크게 증가하기 때문으로 해석된다. 특히 설날 구간에서 가장 높은 오차가 나타났는데, 연휴 전후 이동 수요 집중으로 인해 일반적인 시계열 패턴과 다른 비정형적 변화가 발생하기 때문이다. FedAvg와 Local Only는 공휴일 유형에 따라 성능 변동 폭이 크게 나타나 안정성이 낮은 모습을 보였으며, 일부 장기 연휴 구간에서는 오차가 급격히 증가하였다.

반면 HoFeL은 설날과 추석 구간에서 가장 낮은 wMAPE와 RMSE를 기록하며 장기 연휴 상황에서 우수한 예측 성능을 보였다. 또한 단일 공휴일 구간에서도 경쟁 방법들과 유사하거나 더 낮은 오차를 유지하여 전반적으로 안정적인 성능을 나타냈다. 이는 글로벌 백본이 공통적인 시계열 패턴을 학습하고, 공휴일 인식 로컬 헤드가 공휴일 유형별 수요 변화를 효과적으로 보정함으로써 다양한 공휴일 상황에서도 안정적인 예측이 가능했음을 의미한다.

그림 6은 HoFeL의 공휴일 기간 예측 성능 특성을 대표적으로 보여주는 공항 사례를 비교한 것이다. 청주, 대구, 무안 공항은 각각 상대적으로 우수한 성능, 평균적인 성능, 그리고 오차가 크게 나타난 사례에 해당하며, 이를 통해 공항별 수요 규모와 변동성 차이에 따른 예측 특성을 함께 분석하고자 하였다. 특히 추석 연휴 기간에는 공항별 수요 패턴과 변동 폭이 크게 달라지는 경향이 나타났으며, 일부 방법은 실제 수요 변화를

충분히 반영하지 못하였다. 반면 HoFeL은 청주 공항에서 실제 수요 추세를 안정적으로 반영하였고, 대구 공항에서도 큰 변동 상황에서 전반적으로 안정적인 성능을 유지하였다. 또한 여객 수가 매우 적고 일부 날짜에는 수요가 발생하지 않은 무안 공항에서도 다른 방법 대비 상대적으로 낮은 오차를 보였다. 이러한 결과는 HoFeL이 공항별 수요 특성과 공휴일 정보를 함께 반영함으로써 다양한 규모의 공항에서 비교적 일관된 예측 성능을 유지할 가능성을 보여준다.

3. Ablation Study

제안 방법 HoFeL의 각 구성 요소가 성능에 미치는 영향을 분석하기 위해 절제 실험을 수행하였다. 전체 모델을 기준으로 세 가지 변형 모델을 구성하여 비교하였다. A1은 공휴일 인식 게이트를 제거한 변형으로 로컬 헤드가 공휴일 컨텍스트 없이 백본 출력만을 기반으로 예측을 수행한다. A2는 로컬 헤드를 제거하고 글로벌 백본 출력에 단일 공유 선형 레이어를 적용하는 구조로 모든 공항이 동일한 예측 함수를 사용한다. A3는 공휴일 확장 특징을 제거하고 기본 입력만을 사용하는 변형으로 공휴일 구조 정보가 입력에서 배제된다. 표 8은 각 변형 모델의 성능 비교 결과를 나타낸다. 각 변형 모델은 공휴일 인식 게이트, 공항별 로컬 헤드, 공휴일 확장 특징의 기여도를 개별적으로 분석하기 위해 설계되었다.




그림 6. 공항별 실제값과 예측값 비교

표 8. HoFeL 구성 요소 제거에 따른 성능 비교

Model		Overall		Holiday		non-Holiday	
		wMAPE (%)	RMSE	wMAPE (%)	RMSE	wMAPE (%)	RMSE
A1	w/o Gate	15.31 ± 0.04	201.6 ± 1.3	15.83 ± 0.10	208.1 ± 1.5	15.01 ± 0.15	196.7±1.5
A2	w/o Local Head	15.50 ± 0.19	207.5 ± 1.5	16.29 ± 0.25	212.8 ± 1.8	14.89 ± 0.19	203.4 ± 1.5
A3	w/o Exp. Feats	15.34 ± 0.14	203.3 ± 1.7	16.07 ± 0.05	209.5 ± 2.6	14.87 ± 0.22	198.7 ± 1.3
HoFeL		14.94±0.32	199.0±0.5	15.51±0.26	205.3±2.6	14.61±0.33	196.8 ± 2.3

전체 모델 HoFeL은 모든 지표에서 가장 우수한 성능을 나타낸다. 각 구성 요소의 기여를 확인할 수 있다. 게이트를 제거한 A1은 전체 wMAPE가 14.94%에서 15.31%로 증가하였으며, 공휴일 구간에서도 15.51%에서 15.83%로 오차가 상승하였다. 이에 따라 공휴일 컨텍스트를 반영하는 게이트 구조가 공휴일 구간의 수요 변동을 효과적으로 보정함을 보여준다.

로컬 헤드를 제거한 A2는 공휴일 구간 wMAPE가 16.29%로 가장 크게 증가하였다. 따라서 공휴일 개인화 구조가 공휴일 구간 수요 이질성을 반영하는 데 핵심적인 역할을 함을 의미한다.

공휴일 확장 특징을 제거한 A3는 일반 구간 성능은 비교적 유지되었으나 공휴일 구간 wMAPE가 16.07%로 증가하였다. 이러한 결과는 공휴일 구조를 명시적으로 반영하는 입력 특징이 공휴일 구간 예측 성능 향상에 중요한 역할을 함을 보여준다. 종합적으로 HoFeL의 세 구성 요소는 각각 독립적으로 성능 향상에 기여하며, 이들의 결합을 통해 공휴일 구간과 일반 구간 모두에서 가장 안정적인 예측 성능을 달성하였다.

이와 같은 결과는 모델 구조뿐만 아니라 공휴일 컨텍스트를 정의하는 하이퍼파라미터 설정 또한 성능에 중요한 영향을 미칠 수 있음을 시사한다. 특히 공휴일 인접 구간의 범위를 결정하는

윈도우 크기 τ 는 공휴일 구간과 일반 구간을 구분하는 기준으로 작용하며, 모델이 공휴일 수요 변동을 학습하는 범위를 결정한다. 이에 따라 윈도우 크기 τ 에 따른 성능 변화를 추가적으로 분석하였다.




그림 7. 윈도우 크기에 따른 모델 성능 비교

그림 7은 윈도우 크기 τ 에 따른 성능 변화를 나타낸다. 전반적으로 작은 윈도우에서는 공휴일 인접 구간의 정보가 제한되어 공휴일 구간의 변동을 충분히 반영하지 못하는 경향이 나타났으며, 윈도우 크기가 증가할수록 공휴일 구간의 범위가 확장되면서 성능 변화가 관찰되었다.

실험 결과, $\tau=2$ 는 전체 성능과 공휴일 구간 성

능 간의 균형 측면에서 가장 안정적인 결과를 보였다. 특히 공휴일 구간 wMAPE에서 낮은 오차를 유지하면서도 전체 성능의 변동성이 작아, 공휴일 전후의 수요 변화를 효과적으로 포착하는 것으로 확인되었다.

반면 $\tau=5$ 이상의 경우 성능이 전반적으로 저하되는 경향이 나타났다. 공휴일 윈도우가 과도하게 확장될 경우 공휴일 구간과 일반 구간 간의 경계가 모호해져 모델이 두 구간의 특성을 명확히 구분하지 못하기 때문으로 해석된다.

$\tau=7$ 은 전체 wMAPE 기준으로 가장 낮은 값을 보였으나, 공휴일 구간 성능에서는 $\tau=2$ 대비 유의미한 개선이 나타나지 않았다. 윈도우 범위가 과도하게 넓어질 경우 공휴일 특화 패턴보다는 전체 시계열의 평균적인 경향을 반영하게 되어, 공휴일 구간의 특수성을 충분히 반영하지 못하기 때문으로 볼 수 있다.

종합적으로 $\tau=2$ 는 공휴일 전후의 핵심 변동 구간을 효과적으로 포함하면서도 일반 구간과의 혼재를 최소화하는 균형적인 설정으로 판단되며, 본 연구에서는 이를 최종 하이퍼파라미터로 선택하였다.

VI. 결 론

본 논문에서는 공항별 데이터 프라이버시를 보존하면서 공휴일 구간의 항공 여객 수요 예측 성능을 향상시키기 위한 연합학습 기반 프레임워크 HoFeL을 제안하였다. 제안 방법은 글로벌 LSTM 백본과 공항별 로컬 헤드를 결합한 구조를 기반으로, 공휴일 컨텍스트를 반영한 게이트 메커니즘을 통해 공휴일 구간에서의 수요 변화를 효과적으로 모델링한다. 또한 공휴일 전후 구간과 연속 공휴일 구조를 반영한 입력 특징을 설계하여, 공휴일 구간에서 나타나는 비대칭적 수요 패턴을 명시적으로 학습하도록 하였다.

국내 11개 지방 공항의 일별 여객 수요 데이터를 활용한 실험 결과, HoFeL은 기존 방법 대비

전체 및 공휴일 구간에서 가장 낮은 예측 오차를 달성하였다. 또한 절제 실험을 통해 각 구성 요소가 성능 향상에 기여함을 확인하였으며, 윈도우 크기 τ 에 대한 분석을 통해 공휴일 컨텍스트 정의의 중요성을 검증하였다. 이러한 결과는 공휴일과 같이 특정 시점에서 발생하는 구조적 수요 변화를 고려하는 개인화 연합학습 접근이 시계열 예측 성능 향상에 효과적임을 보여준다.

향후 연구에서는 공항 간 유사도를 반영한 클러스터링 기반 연합학습 구조를 도입하여 이질성을 보다 정교하게 반영하는 방향을 고려할 수 있다. 또한 데이터가 제한적인 소규모 공항에 대한 성능 개선 및 다양한 이벤트 기반 수요 예측으로의 확장이 필요하다.

REFERENCES

- [1] J. Liang, B. Lin, and J. Tang, "Research on the Measurement and Improvement Path of Airport Economic Development Efficiency," *The Development of Humanities and Social Sciences*, vol. 1, no. 5, 2025, pp. 102-118.
- [2] R. A. Zachariah, S. Sharma, and V. Kumar, "Systematic Review of Passenger Demand Forecasting in Aviation Industry," *Multimedia Tools and Applications*, vol. 82, 2023, pp. 46483-46519.
- [3] O. A. C. Dewi, N. A. Masruroh, and B. S. Wibowo, "Trends and Challenges of Forecasting in the Airline Industry Research," *Engineering Management in Production and Services*, vol. 17, no. 2, July 2025.
- [4] Air Transport Information Portal System, "Live Airplane Transport Statistics," Ministry of Land, Infrastructure and Transport. Available: <https://www.airportal.go.kr/stats/transport/liveAirplane.do> (accessed May., 13, 2026).
- [5] S. Chen and Y. Huang, "A Privacy-Preserving Federated Learning Approach for Airline Upgrade Optimization," *J. of Air Transport Management*, vol. 122, Jan. 2025.
- [6] G. Dai, J. Tang, J. Zeng, and Y. Jiang, "Short-Term Passenger Flow Prediction Based on Federated Learning on the Urban Metro System," *J. of Advanced Transportation*, 2025.
- [7] M. Yaqub, S. Ahmad, M. A. Manan, M. S. Pathan, and L. He, "Predicting Traffic Flow with

- Federated Learning and Graph Neural with Asynchronous Computations Network,” *Array*, vol. 26, Jul. 2025.
- [8] H. Wang, M. Yurochkin, Y. Sun, D. Papailiopoulos, and Y. Khazaeni, “Federated Learning with Matched Averaging,” arXiv preprint arXiv:2002.06440, 2020.
- [9] Y. Liu, S. Zhang, C. Zhang, and J. J. Q. Yu, “FedGRU: Privacy-Preserving Traffic Flow Prediction via Federated Learning,” 2020 IEEE 23rd Int. Conf. on Intelligent Transportation Systems, Rhodes, Greece, 2020, pp. 1-6.
- [10] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, Wiley, 2015.
- [11] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Computation*, vol. 9, no. 8, Nov. 1997, pp. 1735-1780.
- [12] S. Mehtab, J. Sen, and S. Dasgupta, “Robust Analysis of Stock Price Time Series Using CNN and LSTM-Based Deep Learning Models,” arXiv preprint arXiv:2011.08011, 2020.
- [13] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, “Attention Is All You Need,” *Advances in Neural Information Processing Systems*, 2017, pp. 5998-6008.
- [14] J. Zhou and Y. Zhang, “A Short-Term Passenger Flow Forecasting Algorithm for Airports Based on Improved Back Propagation Neural Network,” 2025 Int. Conf. on Culture-Oriented Science & Technology, Dunhuang, China, 2025, pp. 409-413.
- [15] J. Lee, H. Han, and S. Yoon, “Air Passenger Demand Forecasting for the Incheon Airport Using Time Series Models,” *J. of Digital Convergence*, vol. 18, no. 12, Dec. 2020, pp. 87-95.
- [16] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, “Communication-Efficient Learning of Deep Networks from Decentralized Data,” In Proc. of Artificial Intelligence and Statistics, Apr. 2017, pp. 1273-1282.
- [17] T. Li, A. K. Sahu, M. Zaheer, M. Sanjabi, A. Talwalkar, and V. Smith, “Federated Optimization in Heterogeneous Networks,” *Proceedings of Machine Learning and Systems*, vol. 2, 2020, pp. 429-450.
- [18] M. G. Arivazhagan, V. Aggarwal, A. K. Singh, and S. Choudhary, “Federated Learning with Personalization Layers,” arXiv preprint arXiv:1912.00818, 2019.
- [19] T. Li, S. Hu, A. Beirami, and V. Smith, “Ditto: Fair and Robust Federated Learning Through Personalization,” In Proc. of Int. Conf. on Machine Learning, Jul. 2021, pp. 6357-6368.
- [20] S. J. Taylor and B. Letham, “Forecasting at Scale,” *The American Statistician*, vol. 72, no. 1, 2018, pp. 37-45.
- [21] S. L. Scott and H. R. Varian, “Predicting the Present with Bayesian Structural Time Series,” *Int. J. of Mathematical Modelling and Numerical Optimisation*, vol. 5, no. 1-2, 2014, pp. 4-23.
- [22] Y. Qin, D. Song, H. Chen, W. Cheng, G. Jiang, and G. Cottrell, “A Dual-Stage Attention-Based Recurrent Neural Network for Time Series Prediction,” arXiv preprint arXiv:1704.02971, 2017.
- [23] H. Zhou, S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, and W. Zhang, “Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting,” In Proc. of AAAI Conf. on Artificial Intelligence, vol. 35, no. 12, May 2021, pp. 11106-11115.
- [24] B. Lim, S. Ö. Anık, N. Loeff, and T. Pfister, “Temporal Fusion Transformers for Interpretable Multi-Horizon Time Series Forecasting,” *Int. J. of Forecasting*, vol. 37, no. 4, 2021, pp. 1748-1764.
- [25] P. Kairouz and H. B. McMahan, “Advances and Open Problems in Federated Learning,” *Foundations and Trends in Machine Learning*, vol. 14, no. 1-2, 2021, pp. 1-210.

 저 자 소 개



서수빈(준회원)

2025년 국립순천대학교 컴퓨터공학과 졸업(공학사)

2025년 ~현재 국립순천대학교 컴퓨터공학과 석사과정 재학

<주관심분야 : 딥러닝, 연합학습, 빅데이터 분석>



양현성(정회원)

2022년 국립순천대학교 멀티미디어공학과 졸업(공학사)

2026년 ~현재 국립순천대학교 스마트융합학부 멀티미디어공학 전공 석·박사 통합과정 수료

<주관심분야 : 컴퓨터 비전, 딥러닝, 객체 추적>



정세훈(정회원)

2012년 국립순천대학교 멀티미디어공학과 졸업(공학석사)

2017년 국립순천대학교 멀티미디어공학과 졸업(공학박사)

2018년 영산대학교 빅데이터융합전공 조교수

2020년 국립안동대학교 창의융합학부 조교수

2022년 국립순천대학교 컴퓨터공학과 조교수

2024년~현재 국립순천대학교 컴퓨터공학과 부교수

<주관심분야 : 블록체인, 딥러닝, 생성모델, 빅데이터 분석 및 예측>



심춘보(정회원)

1996년 전북대학교 컴퓨터공학과 졸업(공학사)

1998년 전북대학교 컴퓨터공학과 졸업(공학석사)

2003년 전북대학교 컴퓨터공학과 졸업(공학박사)

2005년 ~현재 국립순천대학교 인공지능공학부 교수

<주관심분야 : 컴퓨터 비전, 딥러닝, 객체 추적>