

# 유동인구 예측을 위한 Global-Local 구조 기반의 시계열 Deep Learning 모델에 관한 연구

고현모<sup>1,2</sup>, 박상현<sup>2†</sup>

SK 텔레콤 Tech Center (T3K)<sup>1</sup>, 연세대학교 컴퓨터과학과<sup>2</sup>

hm.go@sktelecom.com, sanghyun@yonsei.ac.kr<sup>†</sup>

## A Study on Deep Learning Model Based on Global-Local Structure for Crowd Flow Prediction

Dennis Heounmo Go<sup>1,2</sup>, Sanghyun Park<sup>2,†</sup>

Tech Center(T3K), SK Telecom<sup>1</sup>, Dept. of Computer Science, Yonsei University<sup>2</sup>

### 요 약

유동인구 예측은 상권의 특성에 따른 점포의 입지 선정 및 고객 맞춤형 마케팅 등 민간 분야에서부터 교통망 등 사회 간접 자본 설계를 위한 공공 분야에 이르기까지 다양한 목적으로 연구되어 왔으며, 최근에는 Covid-19의 확산에 따라 그 중요도가 더욱 높아지고 있다. 보다 정교한 예측을 위해서는 전체적인 유동 인구 뿐만 아니라 특성 별로 세분화된 하위 그룹에 대해서도 정확한 예측이 요구되나, 기존의 예측 모델들은 이러한 데이터의 계층 구조를 고려하지 않았다. 본 연구에서는 세분화된 하위 그룹 별 유동인구의 예측 정확도를 높이기 위해 전체 유동인구의 패턴을 동시에 활용하는 Global-Local 구조 기반의 Deep Learning 유동인구 분석 모델을 제안한다. 실험 결과 단일 시계열 데이터만을 사용하는 경우 대비 5.4%~52.6%의 예측 오류 감소 효과가 있음을 확인하였다.

### 1. 서론

스마트폰을 이용한 위치 기반 서비스가 활성화됨에 따라, 이러한 데이터를 활용한 유동인구 예측에 대한 연구 또한 활발히 진행되어 왔다. 민간 분야에서는 상권의 특성에 따른 점포의 입지 선정 및 고객 맞춤형 마케팅 등에 사용해 왔으며, 공공 분야에서는 교통망 등 사회 간접 자본의 추가 건설을 위한 수요 산정 등에 활용하여 왔다. 또한 최근에는 Covid-19의 확산에 따라 감염병 확산 방지를 위한 인구 이동 패턴 및 밀집도 예측을 위한 목적으로도 중요도가 높아지고 있다.

Deep Learning 을 이용한 유동 인구 예측 모델은 크게 RNN 을 기반으로 한 모델과 CNN 을 기반으로 한 모델로 나눌 수 있다. Periodic-CRN[1] 등 RNN 을 기반으로 한 모델은 연산량이 많고 학습이 느리다는 문제가 있었으며, 이를 극복하기 위해 CNN 을 기반으로 한 STResNet[2]이 제안되었고, 장거리 이동 패턴 및 대상 지역의 POI(Point of Interest) 정보를 추가로 반영한 DeepSTN+[3]이 제안되었다. 또한 대도시에서의 교통 흐름 예측에 특화된 추가적인 모델들이 제안되었다[4][5].

하지만 상기 제안된 모델들은 데이터의 계층 구조를 고려하지 않았다는 한계를 가지고 있다. 유동인구는 많은 경우 세분화된 하위 그룹으로 구분될 수 있다. 예를 들면 인구는 연령 및 성별로 구분되고, 소셜 네트워크 서비스에서는 Food, Shopping 등의 하위 카테고리 나눌 수 있다. 유동인구 예측 결과의 효율적인 활용을 위해서는 이러한 하위 카테고리 별로 예측이 정확하게 이루어져야 하는데, 예를 들면 인구 특성에 맞는 고객 맞춤형 마케팅 목적으로 활용하고자 할 때 전체 인구보다는 해당 상품의 카테고리를 많이 소비하는 연령 및 성별 대의 인구 이동을 예측하여 활용하는 것이 보다 효과적일 것이다.

본 연구에서는 이렇게 세분화된 하위 그룹 별 유동인구의 예측 정확도를 높이기 위해, Global 데이터인 전체 유동인구와 Local 데이터인 하위 그룹 별 유동인구의 패턴을 동시에 활용하는 Global-Local 구조 기반의 Deep Learning 유동인구 분석 모델을 제안한다. 이러한 Global-Local 구조는 고차원 다변량 시계열 데이터 예측[6]을 위해서는 적용된 바 있으나, 유동인구 분석을 위해서 적용된 것은 본 연구가 처음으로 볼 수 있다.

† 교신 저자

## 2. 모델

### 2.1 모델 구조 설명

본 연구에서는 상술한 모델 중에 DeepSTN+[3]을 기저 모델로 채택하였다. 이는 격자 구조 상에서의 패턴을 연산 효율적으로 찾아낼 수 있는 CNN 을 기반으로 한 모델이며, 대도시의 교통량 예측에 특화된 모델이 아닌 전체적인 유동 인구를 예측할 수 있는 모델 중에 최신의 연구이기 때문이다. 다만 본 연구의 핵심 아이디어인 Global-Local 구조를 기반으로 한 유동인구 예측은 기저 모델이 바뀌어도 정합 위치 등의 일부 수정을 통해 여전히 적용될 수 있다.

기저 모델을 기반으로 Global-Local 구조를 반영하여 본 연구에서 제안하는 Deep Learning 모델은 그림 1 과 같다. CNN 모듈은 Local 데이터 모델링을 위한 서브 모듈 #1 과 Global 데이터 모델링을 위한 서브 모듈 #2 로 구분된다. 각 서브 모듈은 모델링하고자 하는 시간 상에서의 주기의 길이에 따라 단기 주기성, 중기 주기성, 장기 주기성 모델링을 위한 3 개의 CNN 으로 구성되며, 처리된 CNN 의 결과는 합쳐져서 다음 모듈인 Residual Unit 모듈로 넘어가게 된다. Residual Unit 모듈은 Residual Unit 이 반복되는 구조로 구성되어 있는데, 각 Residual Unit 은 ReLU 활성화 함수 이후에 Convolution 처리가 2 회 반복되는 구조로 되어 있고, 여기서 첫번째 Convolution 은 장거리 공간 패턴을 학습할 수 있도록 인접하지 않은 격자 간의 패턴을 모델링할 수 있는 구조로 고안되었다. 이 결과값은 ReLU 활성화 함수와 Batch 정규화, Dropout 및 CNN, tanh 활성화 함수를 거쳐 최종적으로 예측된 공간상의 유동인구 패턴을 출력하게 된다. 기저 모델

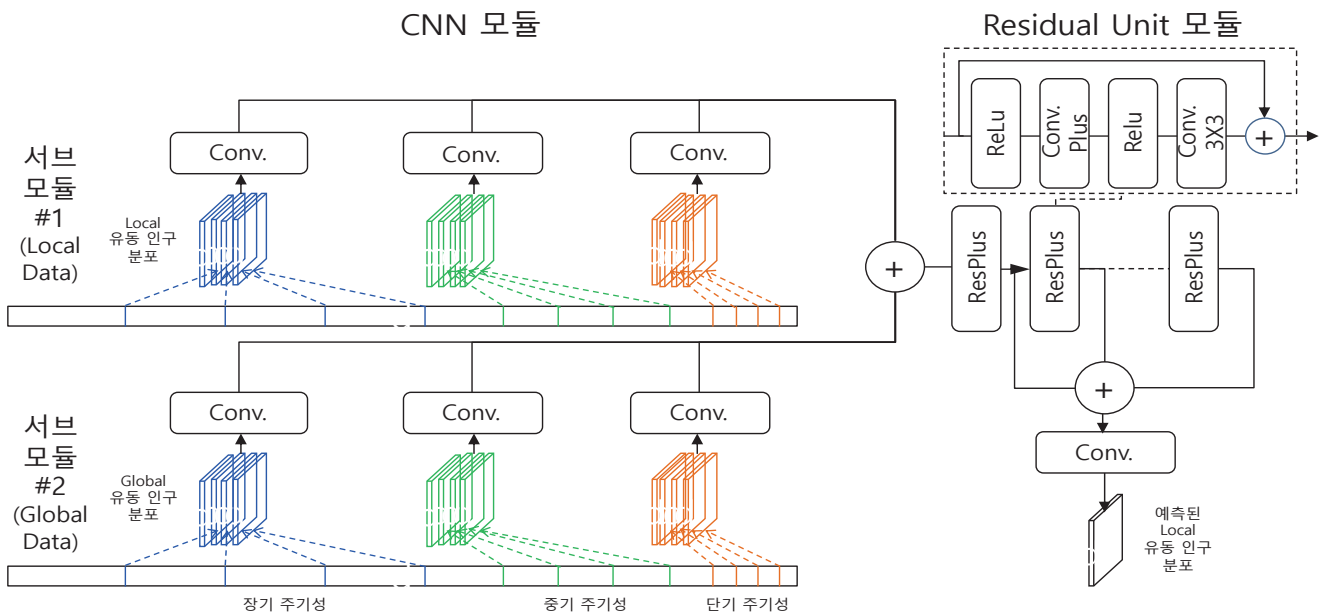
상에 포함되어 있는 POI 모델링 부분은 본 연구의 모델에는 포함시키지 않았는데, 이러한 외부 요인들은 특정 지역에 대한 예측 정확도를 올릴 수는 있으나, 해당 정보가 없는 지역에 대한 모델의 활용도를 떨어뜨리고 넓은 지역으로의 확장에 제약 요인으로 작용하기 때문이다. 실제로 본 연구에서 활용한 Gowalla 데이터도 POI 정보가 존재하지 않았다. 본 연구에서 새롭게 제안하는 부분은 Local - Global 로 이루어진 데이터 계층 구조를 반영하기 위해 CNN 모듈 내에 Global 데이터 모델링을 위한 서브 모듈 #2 를 추가했다는 점이며, 또한 Global 데이터 모델링 결과를 Local 모델링 결과와 병합하기 위한 최적의 포인트를 CNN 모듈의 출력과 Residual Unit 모듈의 입력 사이로 도출하였다는 점이다. 결과적으로 그림 1 과 같은 제안 모델이 가장 우수한 성능을 보여주었다.

### 2.2 훈련 단계

제안 모델은 손실 함수로는 Mean Square Error 를 사용하며, 정확도 평가 metric 으로 RMSE 를 채택하였다. 또한 Adam optimization 알고리즘을 통해 가중치를 업데이트한다. Drop rate 는 0.1 을 적용하였으며, Residual Unit 의 개수는 10 으로 설정하여 실험을 진행하였다. Learning Rate 는  $10^{-4}$ , Epoch 횟수는 400/800 회, Batch Size 는 32 를 적용하였다.

### 2.3 추론 단계

훈련 데이터와 추론 정확도 확인을 위한 Test 데이터의 비율은 약 3:1 정도로 하였고, 훈련된 모델을 10 회 반복 훈련하여 최대/최소 RMSE 를 제외한 나머지 RMSE 를 평균하여 최종 RMSE 를 산출하였다.



(그림 1) 모델 구조

### 3. 실험

#### 3.1 실험 환경

Ubuntu 18.04.5 LTS, 25G Memory, Intel Xeon 2.00GHz 4 core CPU, NVIDIA P100 16GB GPU 에서 수행하였다.

#### 3.2 실험 데이터

본 연구에는 위치 기반 소셜 네트워크인 Foursquare[7]와 Gowalla[8]의 데이터를 사용하였는데, 이는 하위 그룹으로 나뉘어 있는 데이터를 제공하여 Global-Local 구조를 시험하기 적합하며, 또한 Gowalla 데이터는 전 세계에서 수집되어 대상 지역의 범위를 달리 하여 실험이 가능하기 때문이다.

Foursquare 데이터는 뉴욕과 도쿄에서 2012 년 4 월 12 일부터 2013 년 2 월 16 일까지 약 10 개월동안 수집된 데이터로 Check-in 위치 및 시간, check-in 장소의 ID 및 유형을 포함하고 있다. 장소의 유형은 Arts & Entertainment, College & University, Food, Nightlife Spot, Outdoors & Recreation, Professional & Other Places, Residence, Shop & Service, Travel & Transport, Event 의 총 10 가지의 하위 유형으로 구분되며, 뉴욕은 227,428 회, 도쿄는 573,703 회의 check-in 으로 구성되

어 있다. Gowalla 데이터는 2010 년 11 월부터 2011 년 5 월까지 약 7 개월간 수집된 데이터로 전 세계에 걸친 2,844,076 개의 위치에서 319,063 명의 사용자들에 의한 36,001,959 건의 check-in 으로 구성되어 있으며, 장소의 유형은 Community, Entertainment, Food, Nightlife, Outdoors, Shopping, Travel 의 7 가지의 하위 유형으로 구성되어 있다.

#### 3.3 실험 방법

check-in 데이터를 격자 구조 기반의 유동 인구 데이터로 변환하기 위해 각 데이터 셋의 위도 및 경도를 특정 격자의 수로 분할하고, 각 격자에서 발생한 check-in 의 수를 계산하였다. Gowalla 데이터는 전 세계에 걸쳐 있어 지역 범위에 따른 비교 시험을 위해 K-means Clustering 으로 2, 5 개의 군집으로 나누어 추가 시험하였다. 비교 모델은 기저모델인 DeepSTN+에 각 하위 그룹별 Data 만 입력하여 RMSE 를 계산하였고, 제안 모델은 2 절에 기술한 모델에 전체 check-in 수를 Global 데이터, 하위 그룹별 데이터를 Local 로 입력하여 RMSE 를 계산하였다. 추가로 5% 미만의 RMSE 차이는 동등 수준으로 판단하였다.

구. 분	도쿄			뉴욕		
	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ
Arts & Entertainment	0.0406	0.0384	<b>5.4% ↓</b>	0.0147	0.0148	-
College & University	0.0274	0.0269	-	0.0283	0.0283	-
Event	0.0146	0.0146	-	0.0152	0.0152	-
Food	0.0409	0.0384	<b>6.1% ↓</b>	0.0205	0.0192	<b>6.4% ↓</b>
Nightlife Spot	0.0408	0.0409	-	0.0063	0.0063	-
Outdoors & Recreation	0.01	0.01	-	0.0158	0.0149	<b>5.7% ↓</b>
Professional & Other Places	0.036	0.034	<b>5.6% ↓</b>	0.0192	0.0182	<b>5.3% ↓</b>
Residence	0.042	0.042	-	0.0253	0.0252	-
Shop & Service	0.0285	0.0255	<b>10.5% ↓</b>	0.0191	0.0193	-
Travel & Transport	0.0449	0.0418	<b>6.9% ↓</b>	0.0166	0.0164	-

(표 1) Foursquare 데이터 실험 결과

구. 분	Global			2 개 군집화 - 군집 #1			2 개 군집화 - 군집 #2		
	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ
Community	0.0056	0.005	<b>10.7% ↓</b>	0.0177	0.0153	<b>13.6% ↓</b>	0.0078	0.0078	-
Entertainment	0.008	0.0075	<b>6.3% ↓</b>	0.0087	0.0071	<b>18.4% ↓</b>	0.0099	0.0073	<b>26.3% ↓</b>
Food	0.0119	0.0107	<b>10.1% ↓</b>	0.0123	0.0100	<b>18.7% ↓</b>	0.0103	0.0093	<b>9.7% ↓</b>
Nightlife	0.0054	0.005	<b>7.4% ↓</b>	0.0088	0.0072	<b>18.2% ↓</b>	0.0053	0.0051	-
Outdoor	0.0097	0.0095	-	0.0159	0.0146	<b>8.2% ↓</b>	0.0074	0.0040	<b>45.9% ↓</b>
Shopping	0.0077	0.0074	-	0.0128	0.0104	<b>18.8% ↓</b>	0.0080	0.0072	<b>10.0% ↓</b>
Travel	0.0097	0.0066	<b>32% ↓</b>	0.0096	0.0094	-	0.0067	0.0039	<b>41.8% ↓</b>

(표 2) Gowalla 데이터 실험 결과 - Global 전체 및 2 개 군집화

구. 분	군집 #1			군집 #2			군집 #3		
	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ
Community	0.0087	0.0071	18.4% ↓	0.0178	0.0178	-	0.0113	0.0087	23.0% ↓
Entertainment	0.0023	0.0017	26.1% ↓	0.0049	0.0045	8.2% ↓	0.0069	0.0043	37.7% ↓
Food	0.0091	0.0082	9.9% ↓	0.0057	0.0056	-	0.0106	0.0084	20.8% ↓
Nightlife	0.0061	0.0058	-	0.0046	0.0026	43.5% ↓	0.0075	0.0065	13.3% ↓
Outdoor	0.0015	0.0013	13.3% ↓	0.0167	0.0083	50.3% ↓	0.0055	0.0030	45.5% ↓
Shopping	0.0108	0.0102	5.6% ↓	0.0082	0.0073	11.0% ↓	0.0122	0.0105	13.9% ↓
Travel	0.0076	0.0069	9.2% ↓	0.0039	0.0039	-	0.0054	0.0054	-

구. 분	군집 #4			군집 #5		
	비교모델	제안모델	RMSE Δ	비교모델	제안모델	RMSE Δ
Community	0.0053	0.0044	17.0% ↓	0.0073	0.006	17.8% ↓
Entertainment	0.0055	0.0051	7.3% ↓	0.0068	0.0042	38.2% ↓
Food	0.0061	0.0054	11.5% ↓	0.006	0.0053	11.7% ↓
Nightlife	0.0035	0.0019	45.7% ↓	0.0043	0.0039	9.3% ↓
Outdoor	0.0017	0.0012	29.4% ↓	0.0078	0.0037	52.6% ↓
Shopping	0.0057	0.0051	10.5% ↓	0.0079	0.0067	15.2% ↓
Travel	0.0025	0.0019	24.0% ↓	0.0042	0.0024	42.9% ↓

(표 3) Gowalla 데이터 실험 결과 - 5 개 군집화

### 3.4 실험 결과

표 1 에서 확인할 수 있는 바와 같이, Foursquare 데이터에서는 비교 모델 대비 5.4~10.5%의 RMSE 감소 효과를 확인할 수 있었다. 넓은 지역을 대상으로 하는 Gowalla 데이터 실험 결과는 표 2 와 표 3 에 기술된 바와 같이, 하위 카테고리에 따라 차이는 있으나 보다 큰 5.6%~52.6%의 RMSE 감소를 확인하였다.

### 4. 결론

본 연구는 유동인구 데이터의 예측을 위해 Global 데이터인 전체 유동인구 데이터와 Local 데이터인 하위 그룹 별 유동 인구 데이터를 같이 활용하는 모델을 제시하였다. 제안된 모델은 최대 52.6%까지 예측 오류 감소 효과를 확인할 수 있었다. 하위 그룹 별로 오류 감소 정도의 차이가 큰 것은 전체 데이터와 하위 데이터의 상관도의 차이로 추정되며, 이를 분석하여 모델에 반영할 경우 추가 개선이 가능한지를 연구하는 것이 다음 과제라 할 수 있다.

#### Acknowledgement

이 논문은 2021 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (IITP-2017-0-00477, (SW starlab) Research

and development of the high performance in-memory distributed DBMS based on flash memory storage in IoT environment)

#### 참고문헌

- [1] Ali Zonoozi et al., Periodic-CRN: A Convolutional Recurrent Model for Crowd Density Prediction with Recurring Periodic Patterns, IJCAI 2018, p 3732-3738.
- [2] Zhang et al., Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction, AAAI 2017
- [3] Lin., DeepSTN+ : Context-Aware Spatial-Temporal Neural Network for Crowd Flow Prediction, AAAI 2019
- [4] C Zheng et al., DeepSTD: Mining Spatio-Temporal Disturbances of Multiple Context Factors for Citywide Traffic Flow Prediction. TITS 2019. Paper
- [5] J Zhang et al., Multi-Graph Convolutional Network for Short-Term Passenger Flow Forecasting in Urban Rail Transit. IET Intelligent Transport Systems 2020. paper
- [6] R Sen, Think Globally, Act Locally: A Deep Neural Network Approach to High-Dimensional Time Series Forecasting, arXiv 2019, Paper
- [7] Dingqi Yang, Modeling User Activity Preference by Leveraging User Spatial Temporal Characteristics in LBSNs. IEEE TSMC, p 129-142, 2015.
- [8] Yong Liu, Exploiting Geographical Neighborhood Characteristics for Location Recommendation, CIKM, p 739-748