

에이콘아카데미(강남) \_ 최종 프로젝트

# Acorn Academy Final Project

## Gguldangi프로젝트 (주식 및 금융 데이터 분석)

TEAM 1팀 (Gguldangi)

# 목차

01. 프로젝트 개요

02. 프로젝트 팀 구성 및 역할

03. 프로젝트 환경

04. 프로젝트 수행 과정 및 결과

05. 자체 평가 의견

# 01 프로젝트 개요



## 주제 및 프로젝트 주제 구체화

- 주제 - 금융 데이터를 분석
- 주제 구체화 - 거래량이 많은 서울 노원구 단지 커뮤니티 및 가격 예측



## | 문제접근

- 2017.01 ~ 2022.08 기간 내 서울 노원구 아파트 매매 가격, 거래량을 데이터로
- 선정하여 8개의 모델로 테스트, 가장 성능 좋은 모델을 선정하여 향후 집값 예측



## | 프로젝트 결과

## 02 프로젝트 팀 구성 및 역할 – 데이터 분석

훈련생	역할	담당 업무
강현*	팀장	▶ 데이터 수집, Prophet으로 시계열 예측
김혁*	팀원(Analysis)	▶ ppt 제작, 데이터 수집, 데이터 전처리 및 데이터 정규화 RMSLE값 분석 후 모델선정 사용 및 분석
노태*	팀원(Analysis)	▶ 데이터 수집, 데이터 전처리 및 데이터 정규화 RMSLE값 분석 후 모델선정 사용 및 분석
안정*	팀원(Analysis)	▶ 데이터 수집, 데이터 전처리 및 데이터 정규화 RMSLE값 분석 후 모델선정 사용 및 분석


## 02 프로젝트 팀 구성 및 역할 - 백엔드



훈련생	역할	담당 업무
강현*	팀장	▶ 장고 어드민 사용자 구현 프론트
전해*	팀원(Web)	▶ 아파트 단지 정보, 단지특
최광*	팀원(Web)	▶ 아파트 실거래 구현 북마크

# 03 프로젝트 환경

종류	환경
운영체제	Windows 11 / Ubuntu 20.04
백엔드	Django, Spring
데이터 분석	Python, Colab Jupyter
협업툴	Git, Github, Discord



## 03 프로젝트 환경

---

1. 각 Local 환경에서 개발 후 Remote Repository의 해당 기능 Branch에 올림
2. 해당 기능 구현이 완료되면 PR(Pull Request) 작성
3. Github Actions 수행
  - test
  - formatting
4. 코드 리뷰 및 확인
5. Merge 조건에 부합하면 Main(Master) Branch에 병합
6. Github Actions 수행
  - test
  - build
  - push docker images to Dockerhub
  - connect to IaaS(GCP or EC2) using ssh
  - execute
7. Deploy

## 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (DATA 수집)

---



- 서울 아파트 매매 실거래 데이터.csv - 서울시 아파트(201701 ~ 202208)

**부동산 매매 총 거래량**

(출처 :열린데이터광장 <http://data.seoul.go.kr/dataList/OA-15818/S/1/datasetView.do> )

- 노원구5년거래량.csv – 서울 아파트 매매 실거래 데이터.csv 에서 노원구 아파트  
거래량만 정제



# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (DATA 수집)

▶ 서울시5년거래량.csv 의 노원구 데이터만 추출, 노원구5년거래량.csv 저장

Microsoft Excel - 노원구5년거래량.csv:1

1	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
	지역코드	도로명	법정동	지번	아파트	건축년도	층	전용면적	년	월	일	거래금액	도로명건물	도로명건물	도로명시군	도로명일련	도로명지상도		
2	0	11350	초안산로1	월계동	556	주공2	1992	3	84.815	2017	1	2	32000	18	0	11350	1	0	4
3	1	11350	초안산로2	월계동	946	우남푸르미	2006	9	59.92	2017	1	2	29000	91	0	11350	1	0	4
4	2	11350	석계로18길	월계동	380-1	삼능스페이스	2006	4	84.81	2017	1	2	34000	23	0	11350	1	0	4
5	3	11350	월계로53길	월계동	940	동원베네스	2005	4	84.627	2017	1	2	35700	21	0	11350	1	0	4
6	4	11350	석계로	월계동	929	현대	2000	11	84.98	2017	1	2	41000	49	0	11350	1	0	3
7	5	11350	석계로	월계동	929	현대	2000	22	59.95	2017	1	2	30500	49	0	11350	1	0	3
8	6	11350	석계로13길	월계동	927	한일2	2000	4	114.816	2017	1	2	42700	6	10	11350	1	0	4
9	7	11350	마들로	월계동	18	한진한화2	2002	17	84.97	2017	1	3	42300	31	0	11350	1	0	3
10	8	11350	마들로	월계동	13	미성	1986	5	50.14	2017	1	4	28800	59	0	11350	1	0	3
11	9	11350	마들로	월계동	13	미릉	1986	6	51.48	2017	1	5	29100	111	0	11350	1	0	3
12	10	11350	덕릉로60길	월계동	923	초안1	1998	5	59.85	2017	1	5	24300	185	0	11350	1	0	4
13	11	11350	초안산로1	월계동	556	주공2	1992	10	44.52	2017	1	6	18750	18	0	11350	1	0	4
14	12	11350	마들로	월계동	18	한진한화2	2002	18	59.94	2017	1	7	37800	31	0	11350	1	0	3
15	13	11350	월계로45길	월계동	780	청백3	1998	2	49.77	2017	1	7	21600	89	0	11350	1	0	4
16	14	11350	초안산로1	월계동	556	주공2	1992	2	38.64	2017	1	7	16950	18	0	11350	1	0	4
17	15	11350	마들로	월계동	13	미성	1986	6	50.14	2017	1	7	28500	59	0	11350	1	0	3
18	16	11350	초안산로1	월계동	556	주공2	1992	8	38.64	2017	1	9	17400	18	0	11350	1	0	4
19	17	11350	초안산로1	월계동	556	주공2	1992	4	44.52	2017	1	10	19000	18	0	11350	1	0	4
20	18	11350	우이천로2	월계동	939	월계흥화브	2004	4	70.94	2017	1	10	31500	14	0	11350	1	0	4
21	19	11350	마들로	월계동	13	삼호3	1986	1	59.22	2017	1	10	32000	111	0	11350	1	0	3
22	20	11350	월계로45길	월계동	781	청백4	1998	14	39.84	2017	1	10	17300	94	0	11350	1	0	4
23	21	11350	우이천로2	월계동	939	월계흥화브	2004	6	84.91	2017	1	11	35000	14	0	11350	1	0	4
24	22	11350	광운로2나	월계동	436	동신	1983	4	70.81	2017	1	12	27000	30	0	11350	1	0	4
25	23	11350	월계로55길	월계동	320-11	사슴3	1995	10	39.6	2017	1	13	19800	15	0	11350	1	0	4
26	24	11350	광운로	월계동	925	대동	1997	9	59.76	2017	1	14	27000	46	0	11350	1	0	3
27	25	11350	석계로15길	월계동	926	한일1	1999	7	84.942	2017	1	14	37000	25	0	11350	1	0	4
28	26	11350	마들로	월계동	12	삼호4	1987	9	59.49	2017	1	14	31000	127	0	11350	1	0	3
29	27	11350	마들로	월계동	13	미릉	1986	14	51.48	2017	1	14	28500	111	0	11350	1	0	3
30	28	11350	마들로	월계동	13	삼호3	1986	12	59.22	2017	1	15	33800	111	0	11350	1	0	3

## 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

▶ 8개의 모델을 사용해서 RMSLE를 비교하고, 가장 낮은 RMSLE가 나온 모델을 선정

- RMSLE (Root Mean Squared Log Error)
- 회귀 평가를 위한 지표는 실제 값과 회귀 예측값의 차이를 기반으로합니다.
- 이때 RMSLE가 작다는건 예측값과 실제값의 차이가 없다는 뜻으로 성능이 좋다는걸 알 수 있습니다.

$$RMSLE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\log(p_i + 1) - \log(a_i + 1))^2}$$

$p = Predicted, a = Actual$

# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

---

▶ RSMLE를 비교할 8개 모델 선정

- Linear Regression
- Ridge Regression
- Lasso Regression
- Elasticnet Regression
- Decision Tree
- RandomForest Regressor
- XGBoost Regressor
- LightGBM Regressor

# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

▶ 데이터 전처리 – 사용하지 않는 칼럼제거, 노원구 아파트 거래량 top20선정 그외 other로 정의  
Top20 선정 기준 -> df['아파트'].value\_count()[:60} 메소드 사용하여 60개 추출

```
df=df.drop('거래유형',axis=1)
df=df.drop('중개사소재지',axis=1)
df=df.drop('해제사유발생일',axis=1)
df=df.drop('해제여부',axis=1)
df=df.drop('도로명',axis=1)
df=df.drop('일련번호',axis=1)
df=df.drop('지번',axis=1)
df=df.drop('도로명건물본번호코드',axis=1)
df=df.drop('도로명건물부번호코드',axis=1)
df=df.drop('도로명시군구코드',axis=1)
df=df.drop('도로명일련번호코드',axis=1)
df=df.drop('도로명지상지하코드',axis=1)
df=df.drop('도로명코드',axis=1)
df=df.drop('법정동본번호코드',axis=1)
df=df.drop('법정동부번호코드',axis=1)
df=df.drop('법정동시군구코드',axis=1)
df=df.drop('법정동읍면동코드',axis=1)
df=df.drop('법정동지번코드',axis=1)
```

```
[ ] df['apt_counts'] = 0
df.groupby('아파트')['apt_counts'].count()
df = pd.merge(df, df.groupby('아파트')['apt_counts'].count(), on='아파트', how='left').drop('apt_counts_x', axis=1).rename(columns={'apt_counts_y':'apt_counts'})
```

```
[ ] # 노원구 아파트 데이터 위주로 내임작성
apt_names=['주공','중계','시영','사슴','한신','삼익','미릉','염광','극동','롯데','현대',
           '상계','태강','백산','한진','장미','보람','은빛','청솔','풍림','삼호']
```

```
[ ] df['transformed'] = False
```

```
▶ # 'apt_names_list'의 키워드에 아파트명이 포함되면 해당 키워드로 아파트명을 통일함
# 그리고 'transformed' 컬럼값을 True로 변경
for a in tqdm(apt_names):
    df.loc[df['아파트'].str.contains(a), '아파트'] = a
    df.loc[df['아파트'].str.contains(a), 'transformed'] = True

# 아파트 이름이 변경되지 않았을 경우('transformed=False' 일 경우) 아파트명을 'others'로 변경
for a in tqdm(apt_names):
    df.loc[~df['transformed'], '아파트'] = 'others'
print(df['아파트'].value_counts())
```

# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

▶ 아파트 벨류값, 동 벨류값 Xgboost와 LightGBM 사용을 위해 라벨링 후 int 자료형 변환

## 아파트 라벨링

```
▶ for i, a in enumerate(list(apt_price.index)):
    df.loc[df['아파트'] == a, '아파트'] = i # 라벨 인코딩
apt_price = df.groupby('아파트')['거래금액'].agg('mean').sort_values(ascending=False)
print('변환후\n', apt_price[:20])
```

변환후  
아파트

0	69014.687500
1	61384.427284
2	53810.741990
3	51117.391698
4	50894.237288
5	49942.435424
6	49802.899949
7	48543.924497
8	47669.158249
9	45060.111111
10	45010.266272
11	42072.413793
12	41838.505747
13	41185.472579
14	40490.429429
15	39072.831367
16	37824.399736
17	37349.097778
18	33483.879310
19	33070.512745

Name: 거래금액 dtype: float64

# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

▶ 아파트 벨류값, 동 벨류값 Xgboost와 LightGBM 사용을 위해 라벨링 후 int 자료형 변환

## 동 라벨링

```
# 가격기준으로 동을 정렬한 리스트를 바탕으로 dong에 대해 라벨 인코딩 진행 - 477 it.  
for i, d in tqdm(enumerate(list(dong_price.index)), total=len(dong_price)):  
    df.loc[df['법정동'] == d, '법정동'] = i  
# print(train_df.head())  
print(df.describe())
```

	Unnamed: 0	지역코드	건축년도	층	전용면적	#
count	39620.000000	39620.0	39620.000000	39620.000000	39620.000000	
mean	19809.500000	11350.0	1993.854366	8.079278	64.281776	
std	11437.453169	0.0	6.560588	4.878513	22.832953	
min	0.000000	11350.0	1976.000000	1.000000	12.060000	
25%	9904.750000	11350.0	1988.000000	4.000000	49.500000	
50%	19809.500000	11350.0	1992.000000	8.000000	59.390000	
75%	29714.250000	11350.0	1999.000000	12.000000	84.600000	
max	39619.000000	11350.0	2022.000000	36.000000	180.340000	

	년	월	일	거래금액	apt_counts
count	39620.000000	39620.000000	39620.000000	39620.000000	39620.000000
mean	2018.758001	5.330262	16.081045	45082.096870	399.644573
std	1.397460	3.218722	8.718482	19344.133549	307.326794
min	2017.000000	0.000000	1.000000	6750.000000	1.000000
25%	2017.000000	3.000000	9.000000	31000.000000	148.000000
50%	2019.000000	5.000000	16.000000	40900.000000	293.000000
75%	2020.000000	8.000000	24.000000	55000.000000	625.000000



## 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

- ▶ 아파트 벨류값, 동 벨류값 Xgboost와 LightGBM 사용을 위해 라벨링 후 int 자료형 변환  
자료형 변환

```
[ ] # 형변환
df['법정동'] = df['법정동'].astype('int64')
df['아파트'] = df['아파트'].astype('int64')
```



# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

▶ 거래금액이 왼쪽으로 치우쳐 있어, 정규화작업




# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

## ▶ 전용면적도 정규화 작업




# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

- ▶ 8개 모델로 데이터 분석, RMSLE 분석 결과  
제일 수치가 적게 나온 LightGBM Regressor 사용



# 04 프로젝트 수행 과정 및 결과 – 데이터 분석 (Model)

## ▶ 거래금액에 영향을 주는 값 시각화 및 예측



Microsoft Excel - 노원구아파트모델예측결과 보기.csv

	A	B	C	D	E
1	아파트	예측가격			
2	17	35355.03			
3	3	87572.09			
4	3	76395.11			
5	3	113694.1			
6	3	50078.84			
7	14	24878.36			
8	14	36318.82			
9	17	40705.32			
10	3	36394.02			
11	19	33077			
12	3	46985.77			
13	14	62122.94			
14	3	68833.18			
15	9	57641.21			
16	6	60536.57			
17	3	21857.12			
18	14	54060.96			
19	3	71709.39			
20	14	49967.24			
21	7	31206.79			
22	3	34129.19			
23	14	40355.87			
24	3	37581.74			
25	3	29787.08			
26	3	60322.89			
27	18	37004.58			
28	16	27385.42			
29	14	48615.66			
30	6	45919.57			

# 04 프로젝트 수행 과정 및 결과 -



```
target = target.groupby("transaction_at").agg("mean")
0.9s

target = target.sort_values(by=["transaction_at"])



target["y"] = target["거래금액"] / target["전용면적"] # 1 평당 3.3057 m^2
target["y"] = round(target["y"] * 10_000)
target["ds"] = target.index

target
0.1s
```







transaction_at	층	전용면적	거래금액	해제여부	y	ds
2017-01-09	10	59	31200	0	5247225	2017-01-09
2017-01-11	1	46	23000	0	4953694	2017-01-11
2017-01-18	11	50	28300	0	5717172	2017-01-18
2017-01-20	6	50	27500	0	5516550	2017-01-20
2017-01-25	10	50	28250	0	5707071	2017-01-25
...	...	...	...	...	...	...
2022-05-06	5	40	58500	0	14657980	2022-05-06
2022-05-20	5	50	63500	0	12828283	2022-05-20
2022-05-26	8	50	67000	0	13535354	2022-05-26
2022-06-07	1	40	52000	0	13029316	2022-06-07
2022-07-08	3	50	63000	0	12727273	2022-07-08

```
future = model.make_future_dataframe(periods=365)
pred = model.predict(future)
```

# 04 프로젝트 수행 과정 및 결과 -



# 04 프로젝트 수행 과정 및 결과 -



# 04 프로젝트 수행 과정 및 결과



🏠 **문단기** Home Bookmark Notice Talk




녹천역두산위브아파트  
서울특별시 노원구 아문로5길 25

단지정보

총매수	10층
전세매대수	326세대
사용승인일	2017-07-10T02:07:47
총층차대수	360세대
세대별입	입차+주차
복도유형	준합식
시행사	철계4구역(사)개발조합
시공사	두산건설주식회사
난방	개방난방
관리사무소	0290 00771
팩스번호	0290 00772

전용면적 ▼



## 05 자체 평가 의견

---

### ▶ 데이터 분석

**김혁\*** - 데이터분석 협업을 통해 잘 몰랐던 데이터분석을 공부하게 될 수 있는 계기가 되어서 좋았고, 2~3년뒤 데이터 엔지니어가 꿈인 저에게 좋은 경험이 되었다고 생각합니다.

**노태\*** - 데이터 전처리, 정규화 및 여러 모델을 비교해 모델을 선정하는 것 까지 좋은 경험이었다.

**안정\*** - raw data를 직접 찾으며 가공하고 모델을 만드는 것이 쉽지는 않았지만 궁금한 주제를 직접 선정하고 원하는 결과를 이끌어내는 과정이 의미깊었습니다. 주제에 대해 더 새로운 관점에서 바라볼 수 있는 시각을 길러서 다양한 도전을 해보고 싶다는 생각을 했습니다.

## 05 자체 평가 의견

---



**강현\*** - 장고와 스프링 둘 같이 써볼 수 있어 좋은 경험이었지만 아쉬운 것이 많이 남는 것 같다..

**전해\*** - API의 데이터 처리가 복잡했지만 도전해 볼 수 있어서 재밌었다.

**최광\*** - 데이터 처리만 좀 더 수월했다면하는 아쉬움이 남는 프로젝트였다.

감사합니다.