
Mission: Movie Analytics
for Data Scientist

Instruksi Umum

Latihan

1. Bukalah link di **https://www.kaggle.com/datasets/rounakbanik/the-movies-dataset/data**
2. Terdapat dataset *ratings.csv*
3. Buatlah model *machine learning* menggunakan *full data* tersebut.
4. Jika memungkinkan, buatlah kolom baru *genre*, ambil *genre* pertama saja yang muncul apabila terdapat banyak *genre*
5. Buatlah EDA dari *genre* yang didapatkan
6. Buatlah model baru menggunakan kolom *genre* tersebut


Data Exploration
#RintisKarirImpian
MySkill

Favorite Movie

```
movies_rating["favorite_movies"] = (movies_rating["median"] >=3).astype("int")
movies_rating["favorite_movies"].value_counts().plot(kind = "pie")
plt.title("Favorite Movies Distribution")
plt.show()
```

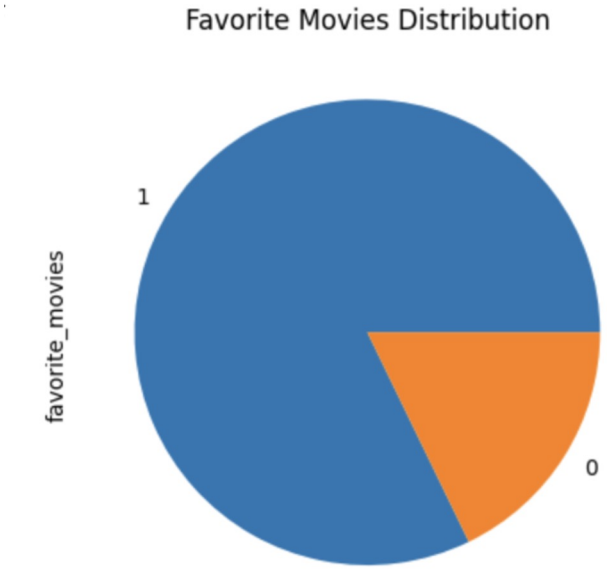

1. Film yang memiliki rating tinggi (>=3) terdapat sebanyak 80% dari total film

Movie Duration

```
movies_rating["duration_hours"] = movies_rating["runtime"].div(60).round(0).astype("int")
movies_rating["duration_hours"].value_counts().sort_index().plot(kind = "bar")
plt.title("Movie Duration in Hours")
plt.show()
```

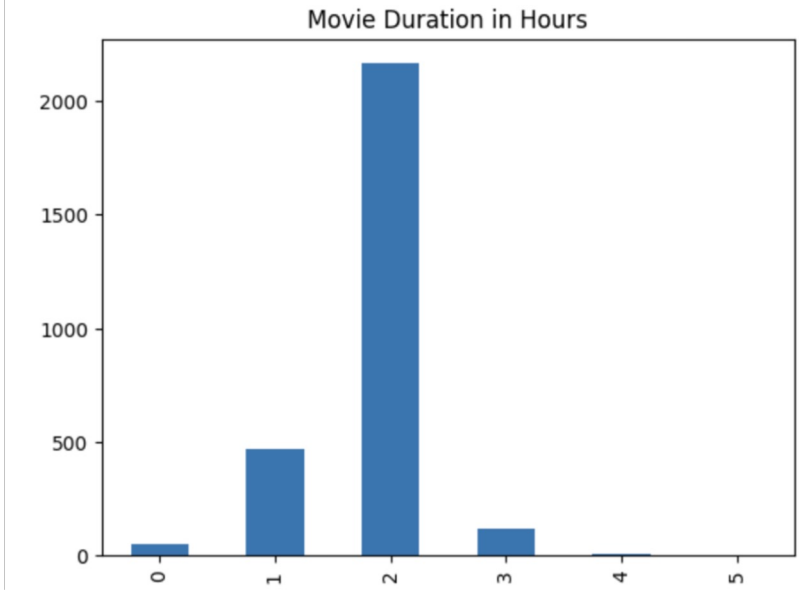

1. Durasi film terbanyak terdapat di antara durasi 2-3 jam
2. Terdapat beberapa film panjang yang berdurasi di atas 3 jam

Movie Duration vs Rating

```
sns.scatterplot(x = "runtime",
                y = "median",
                data = movies_rating)
plt.title("Duration vs Rating")
plt.show()
```

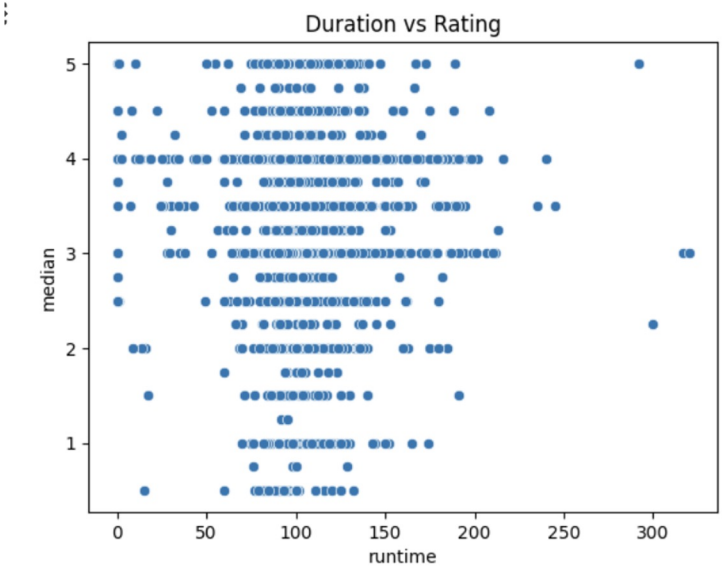

1. Pola berbentuk huruf V. artinya film yang memiliki durasi terlalu pendek atau terlalu panjang justru tidak memiliki rating yang rendah
2. Film rating rendah justru didominasi oleh film yang berdurasi 2-3 jam

Title Length

```
movies_rating["len_title"] = movies_rating["original_title"].str.len()
movies_rating["len_title"].hist(bins = 100)
```

```
<Axes: >
```

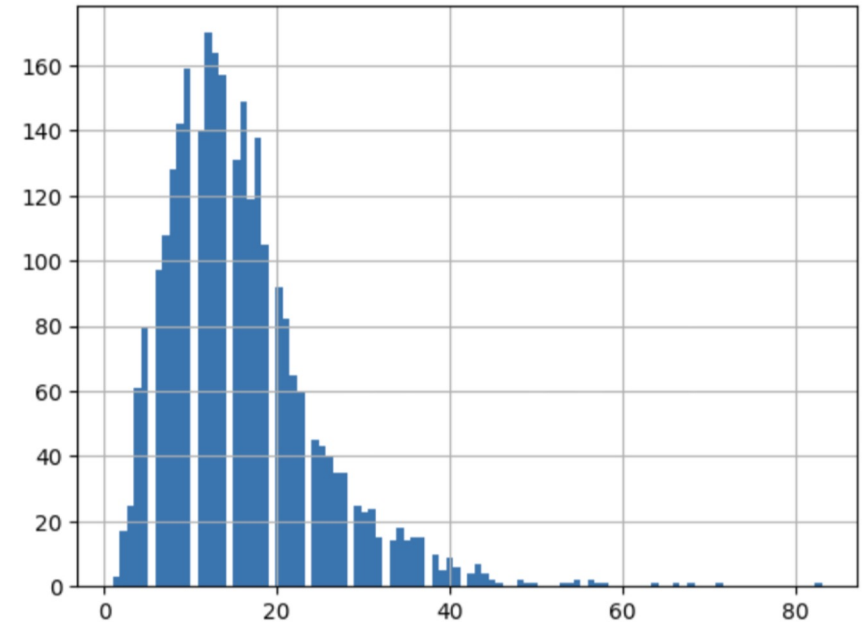

1. Sebagian besar film memiliki panjang judul < 30 huruf
2. Terdapat beberapa film yang memiliki judul yang cukup panjang, yaitu di atas >40 huruf


Train-Test Data
Concept

Modeling Workflow

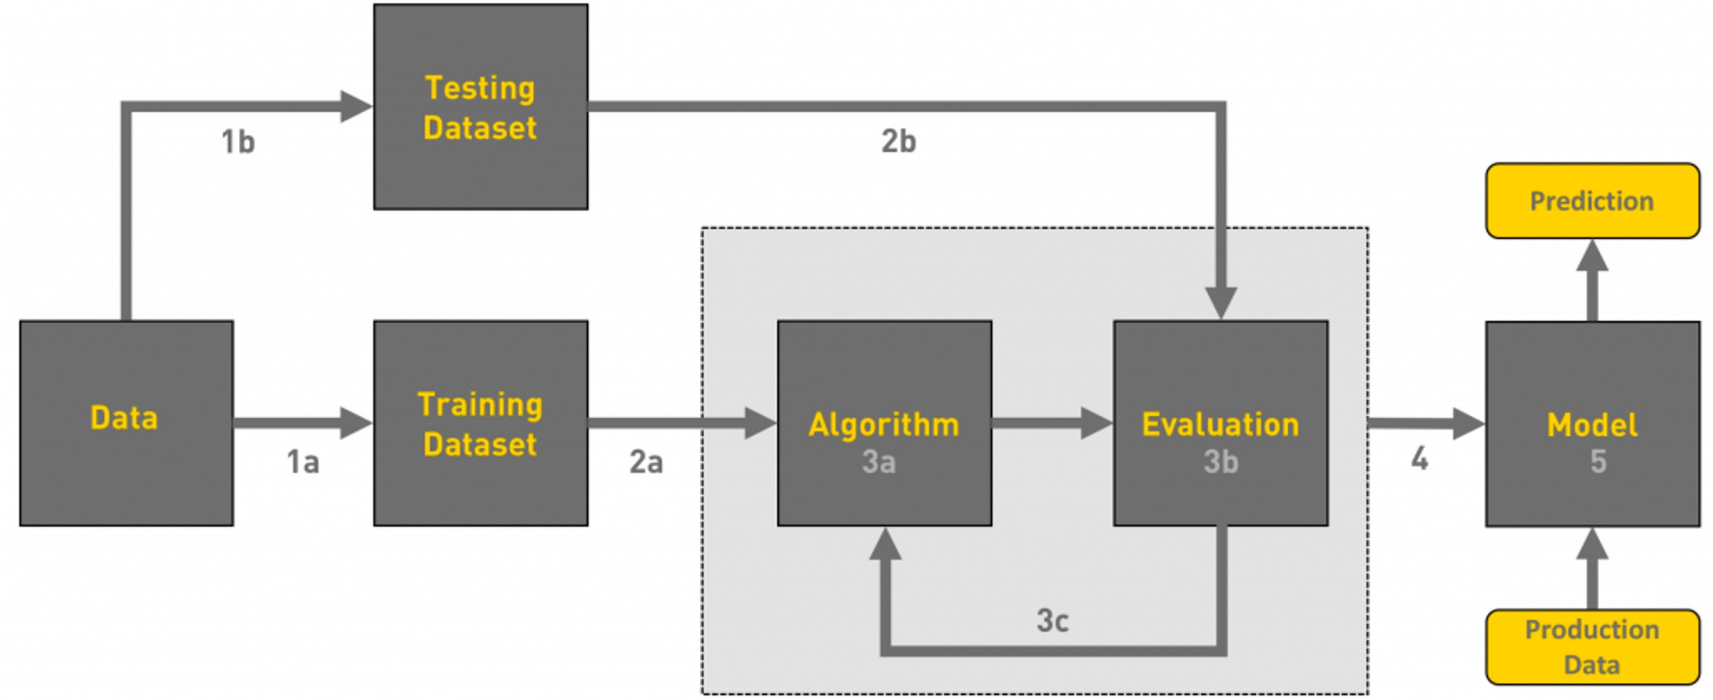

Holdout Validation

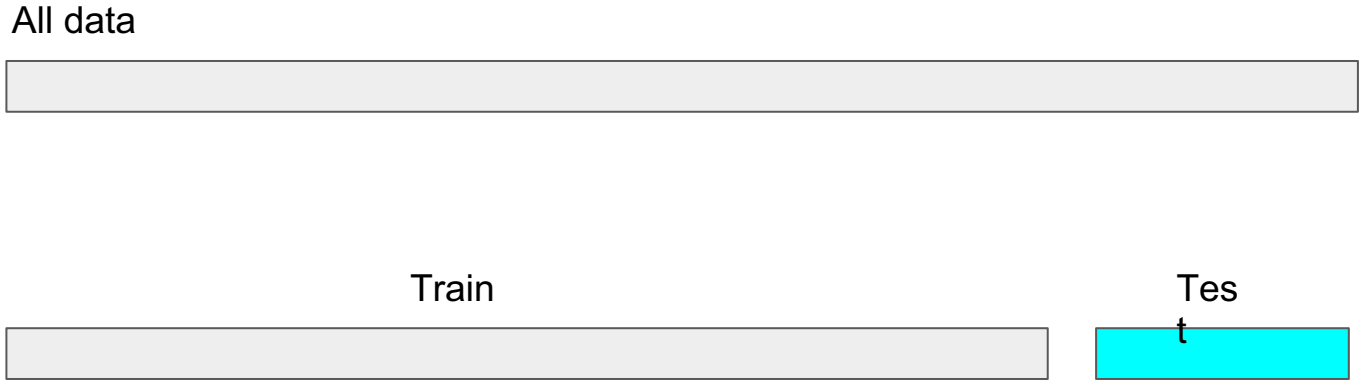

Cross Validation

All data

Split into *k* parts

Blue one is training dataset

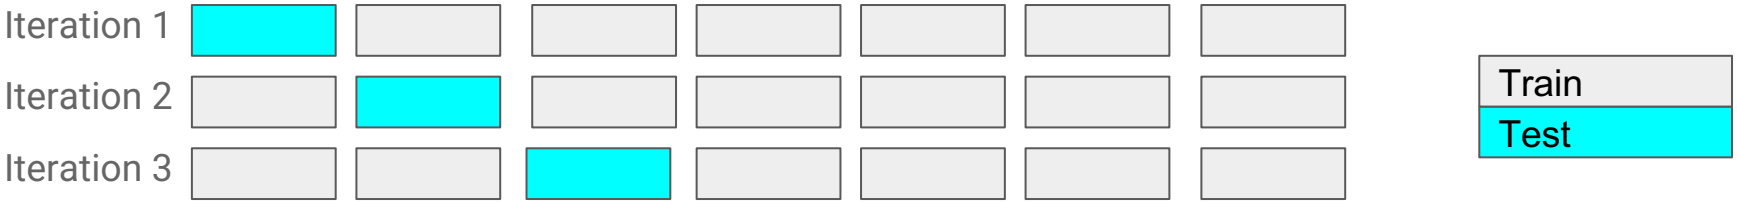

Machine Learning Workflow

1. Sebagian besar film memiliki panjang judul < 30 huruf
2. Terdapat beberapa film yang memiliki judul yang cukup panjang, yaitu di atas >40 huruf


Thank You!