MACHINE LEARNING

Transformasi Data

Magister Teknik Informatika

Dr. Chairani, S.Kom., M.Eng

IIB DARMAJAYA, 2023/2024

Subject

- Kursus ini adalah bagian dari Data Preparation
- Data Preparation yang dibahasa adalah transformasi data yaitu:
  - Representasi Fitur, dan
  - Rekayasa Fitur
- Ada beberapa teknik transformasi data yang digunakan sesuai kebutuhan dan ketersediaan/jenis data baik numerik maupun kategorik

Data Transformation

- Representasi Fitur atau Pembelajaran Fitur:
  - Teknik-Teknik yang memungkinkan sistem bekerja otomatis menemukan representasi yang diperlukan (untuk deteksi fitur atau klasifikasi dari dataset),
  - menggantikan rekayasa fitur manual, dan
  - memungkinkan mesin mempelajari fitur dan menggunakannya untuk melakukan tugas tertentu.

- Rekayasa Fitur:
  - Proses mengubah data mentah menjadi fitur yang:
    - Mewakili masalah mendasar ke model prediktif,
    - menghasilkan akurasi model yang lebih baik pada data yang tidak terlihat.

Rekayasa Fitur

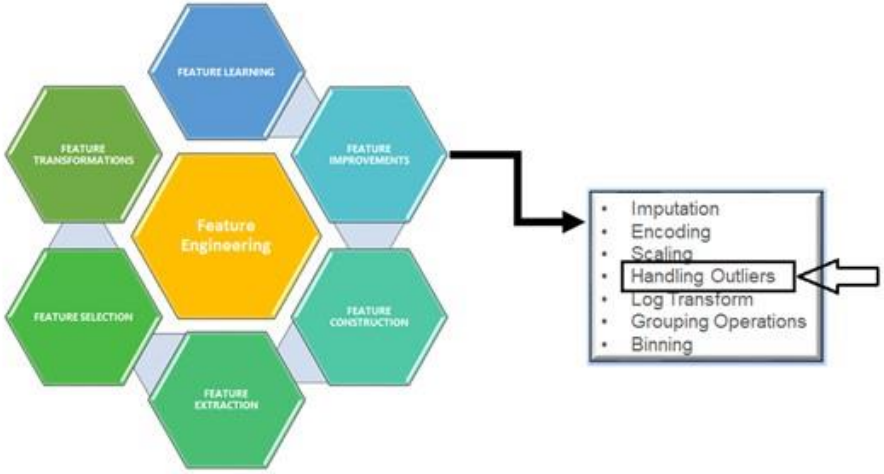

Outlier

Imputasi

- Pengertian: Mengganti nilai/data yang hilang (missing value; NaN; blank) dengan nilai pengganti.

- Jenis missing value:
  1. Missing Completely At Random (MCAR).
  2. Missing At Random (MAR).
  3. Missing Not At Random (MNAR).

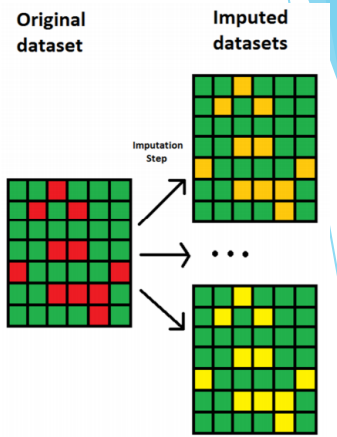

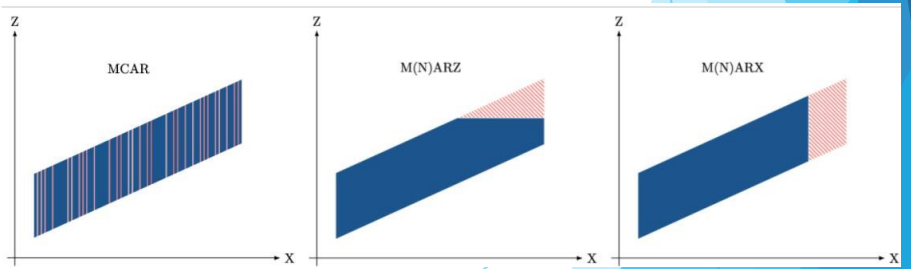

sum. gbr:
https://www.ucl.ac.uk/population-health-sciences/sites/population-health-sciences/files/mi_in_stata_2.pdf
https://rianneschouten.github.io/missing_data_science/assets/blogpost/blogpost.html

Missing At Random (MAR)

- Definisi: Probabilitas sebuah instance yang hilang mungkin bergantung pada nilai yang diketahui tetapi tidak pada nilai yang hilang itu sendiri.
- Contoh Sensor: Dalam kasus sensor suhu, fakta bahwa suatu nilai hilang tidak bergantung pada suhu, tetapi mungkin bergantung pada beberapa faktor lain, misalnya pada daya baterai termometer.
- Contoh survei: Apakah seseorang menjawab pertanyaan atau tidak - mis. tentang usia- dalam survei tidak tergantung pada jawaban itu sendiri, tetapi mungkin tergantung pada jawaban untuk pertanyaan lain, yaitu jenis kelamin perempuan.

Missing Not At Random (MNAR)

- Definisi: probabilitas sebuah instance hilang dapat bergantung pada nilai variabel itu sendiri.
- Contoh sensor: Dalam kasus sensor suhu, sensor tidak berfungsi dengan baik saat suhu lebih dingin dari 5°C.
- Contoh survei: Apakah seseorang menjawab pertanyaan atau tidak - mis. jumlah hari sakit - dalam survei memang tergantung pada jawabannya sendiri - seperti yang bisa terjadi pada beberapa orang yang kelebihan berat badan.

Tahapan dan Teknik Imputasi

- Jika tipe data Variabel Numerik
  - Imputasi mean atau median.
  - Imputasi nilai suka-suka (arbitrary).
  - Imputasi nilai/data ujung (end of tail).
- Jika tipe data Variabel Kategorik
  - Imputasi kategori yang sering muncul.
  - Tambah kategori yang hilang.

tahapan *imputation*

sumber gbr:
https://www.researchgate.net/publication/334213038_Missing_data_and_bias_in_[illegible]_for_using_multiple_imputation

Imputasi Mean atau Median

- Pro:
  - Mudah dan cepat.
  - Bekerja efektif untuk dataset numerik berukuran kecil.
  - Cocok untuk variabel numerik.
  - Cocok untuk data missing completely at random (MCAR)
  - Dapat digunakan dalam produksi (mis. dalam model deployment)
- Kontra:
  - Tidak memperhitungkan korelasi antar fitur, berfungsi pada tingkat kolom.
  - Kurang akurat.
  - Tidak memperhitungkan probabilitas/ketidakpastian.
  - Tidak cocok utk >5%missing data.
  - Mendistorsi variansi dan distribusi variabel asal/orijinal serta covariant variabel sisa data.

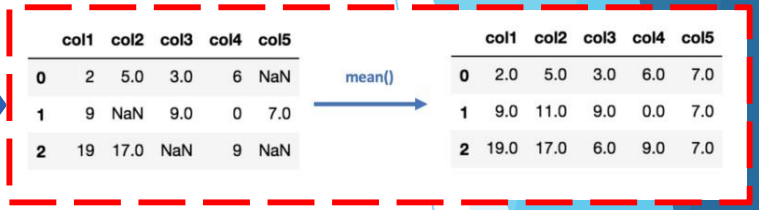

	col1	col2	col3	col4	col5
0	2	5.0	3.0	6	NaN
1	9	NaN	9.0	0	7.0
2	19	17.0	NaN	9	NaN

	col1	col2	col3	col4	col5
0	2.0	5.0	3.0	6.0	7.0
1	9.0	11.0	9.0	0.0	7.0
2	19.0	17.0	6.0	9.0	7.0

Age
29
43
NA
25
34
NA
50

mean
= (29 + 43 + 25 + 34 + 50)/5
= 36,2

Age
29
43
36.2
25
34
36.2
50

sumber gbr:
https://towardsdatascience.com/6-different-ways-to-compensate-for-missing-values-data-imputation-with-examples-6022d9ca0779
https://heartbeat.fritz.ai/hands-on-with-feature-engineering-techniques-imputing-missing-values-6c22b49d4060

Hands On

```
import pandas as pd
import numpy as np
```

Import pandas dan numpy

```
kolom = {'col1' : [2, 9, 19],
         'col2' : [5, np.nan, 17],
         'col3' : [3, 9, np.nan],
         'col4' : [6, 0, 9],
         'col5' : [np.nan, 7, np.nan]}

data = pd.DataFrame(kolom)
```

Masukkan data

pd.DataFrame() --> fungsi mengubah menjadi dataframe

```
data
```

	col1	col2	col3	col4	col5
0	2	5.0	3.0	6	NaN
1	9	NaN	9.0	0	7.0
2	19	17.0	NaN	9	NaN

Output

Hands On (Lanjutan)

```
data.fillna(data.mean())
```

Mengganti missing value dengan mean()

	col1	col2	col3	col4	col5
0	2	5.0	3.0	6	7.0
1	9	11.0	9.0	0	7.0
2	19	17.0	6.0	9	7.0

Output

```
umur = {'umur' : [29, 43,  np.nan, 25, 34, np.nan, 50]}
```

Masukan Data

```
data = pd.DataFrame(umur)
data
```

Ubah ke dataframe

	umur
0	29.0
1	43.0
2	NaN
3	25.0
4	34.0
5	NaN
6	50.0

Output

Mengganti missing value dengan mean pada kolom umur

```
data.fillna(data.mean())
```

data.fillna() --> fungsi mengganti missing value

	umur
0	29.0
1	43.0
2	36.2
3	25.0
4	34.0
5	36.2
6	50.0

Output

Imputasi Nilai Suka-suka

- Pro:
  - Asumsi data tidak *missing at random*.
  - Mudah dan cepat diterapkan untuk melengkapi dataset.
- Kontra:
  - Mendistorsi variansi dan distribusi variabel asal/orijinal serta covariant variabel sisa data.
  - Membentuk outlier (jika nilai arbitrer berada di akhir distribusi).
  - Semakin besar NA maka semakin besar distorsi.
  - Hindari memilih nilai arbitrer yg mendekati nilai mean atau median.

Age
29
43
NA
25
34
NA
50

Age
29
43
99
25
34
99
50

Hands On

```
import pandas as pd
import numpy as np
```

Import pandas dan numpy

```
umur = {'umur' : [29, 43,  np.nan, 25, 34, np.nan, 50]}
```

Masukan Data

```
data = pd.DataFrame(umur)
data
```

Ubah ke dataframe

	umur
0	29.0
1	43.0
2	NaN
3	25.0
4	34.0
5	NaN
6	50.0

Output

```
data.fillna(99)
```

Mengatasi nilai missing value dengan imputasi suka-suka

	umur
0	29.0
1	43.0
2	99.0
3	25.0
4	34.0
5	99.0
6	50.0

Output

Imputasi *End of Tail*

- Pro:
  - Mirip dengan imputasi *suka-suka*.
  - Cocok untuk variabel numerik.
- Ketentuan khusus:
  - Dalam memilih nilai arbitrer:
    - Jika variabel berdistribusi normal, maka nilai arbiter = mean + 3 * std deviasi.
    - Jika variabelnya *skew*, maka gunakan aturan IQR proximity (IQR = 75th Quantile – 25th Quantile; Upper limit = 75th Quantile + IQR ×3; Lower limit = 25th Quantile - IQR ×3).
  - Hanya digunakan pada data latih (training set).

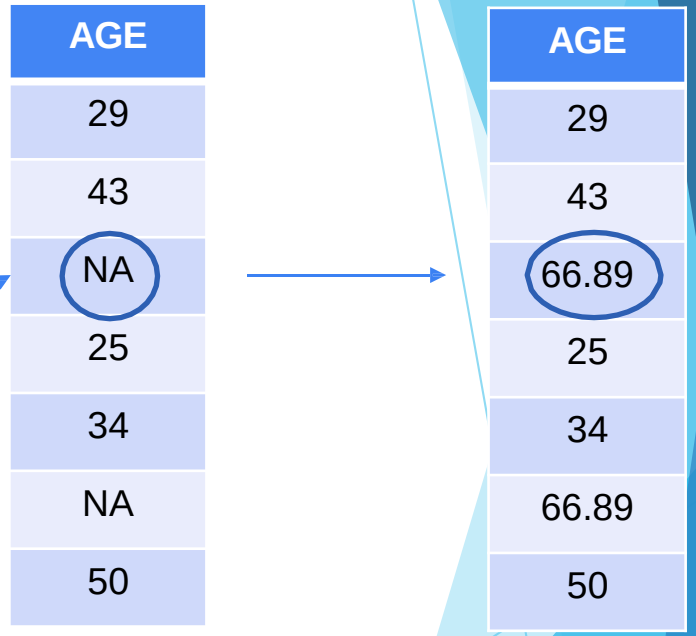

untuk data distribusi normal

Hands On

```
import pandas as pd
import numpy as np
```

import pandas dan numpy

```
umur = {'umur' : [29, 43,  np.nan, 25, 34, np.nan, 50]}

data = pd.DataFrame(umur)

data
```

masukkan data

	umur
0	29.0
1	43.0
2	NaN
3	25.0
4	34.0
5	NaN
6	50.0

Output

```
from feature_engine.imputation import EndTailImputer
```

import EndTailImputer

```
imputer = EndTailImputer(imputation_method='gaussian', tail='right')
```

membuat imputer

```
imputer.fit(data)
```

cocokan imputer ke set

```
test_t = imputer.transform(data)
```

mengubah data

```
test_t
```

	umur
0	29.000000
1	43.000000
2	66.896905
3	25.000000
4	34.000000
5	66.896905
6	50.000000

Output

Skewness (kecenderungan/kemiringan/kemencengan)

- Miring ke kanan (positif skew)

Data yang miring ke kanan memiliki ekor panjang yang memanjang ke kanan. Cara alternatif untuk membicarakan kumpulan data yang miring ke kanan adalah dengan mengatakan bahwa itu secara positif.

Jika rata-rata (mean) > median> modus, maka pada kurva distribusi frekuensi, nilai mean akan terletak di sebelah kanan, sedangkan median terletak di tengahnya dan modus di sebelah kiri

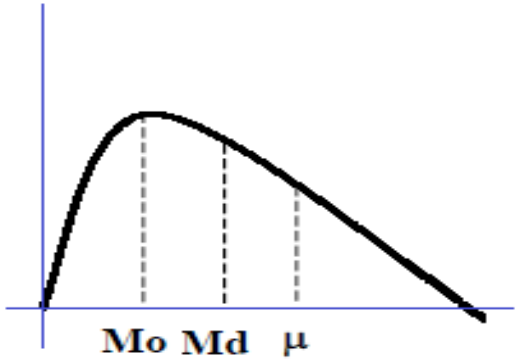

Skewness (kecenderungan/kemiringan/kemencengan)

- Miring ke kiri (negatif skew)

Data yang miring ke kiri memiliki ekor panjang yang memanjang ke kiri. Cara alternatif untuk membicarakan kumpulan data yang miring ke kiri adalah dengan mengatakan bahwa itu miring secara negatif.

Jika rata-rata (mean) < median < modus, maka pada kurva distribusi frekuensi, nilai mean akan terletak di sebelah kiri, sedangkan median terletak di tengahnya dan modus di sebelah kanan

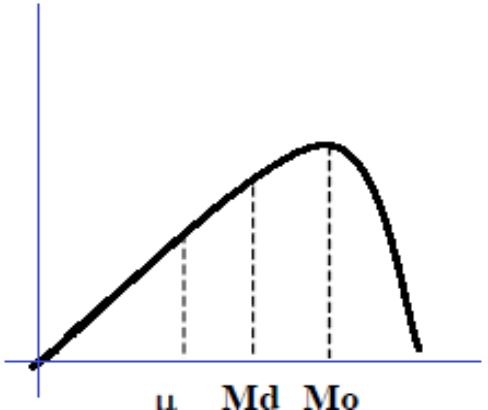

Imputasi *Frequent Category*/Modus

- Pro:
  - Cocok untuk data dengan missing at random.
  - Mudah dan cepat diterapkan.
  - Cocok utk data yang memiliki *skew*
  - Dapat digunakan dalam produksi (mis. dalam model deployment).
- Kontra:
  - Mendistorsi relasi label dengan frekuensi tertinggi vs variabel lain.
  - Menghasilkan over-representation jika banyak data yang missing.

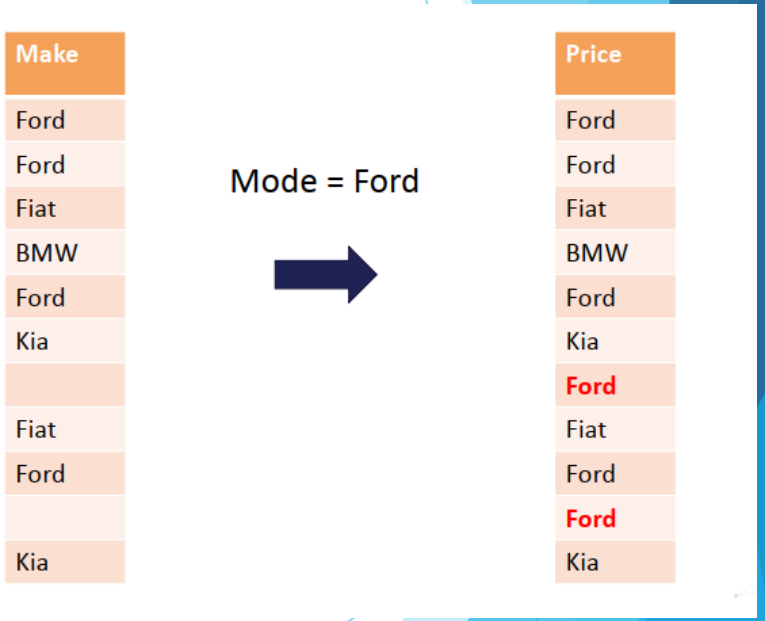

Hands On

```
import pandas as pd
import numpy as np
from sklearn.impute import SimpleImputer
```

Import pandas, SimpleImputer dari sklearn.impute, numpy

```
make = {'make' : ['Ford', 'Ford', 'Fiat', 'BMW', 'Ford', 'Kia', np.nan, 'Fiat', 'Ford', np.nan, 'Kia']}
```

Masukan Data

```
data = pd.DataFrame(make)

data
```

Ubah menjadi data frame

	make
0	Ford
1	Ford
2	Fiat
3	BMW
4	Ford
5	Kia
6	NaN
7	Fiat
8	Ford
9	NaN
10	Kia

Output

Hands On (Lanjutan)

```
imp = SimpleImputer(strategy='most_frequent')
```

```
imp.fit_transform(data)
```

```
array([['Ford'],
       ['Ford'],
       ['Fiat'],
       ['BMW'],
       ['Ford'],
       ['Kia'],
       ['Ford'],
       ['Fiat'],
       ['Ford'],
       ['Ford'],
       ['Kia']], dtype=object)
```

Mengatasi missing value dengan frequent category / modus

Output

Imputasi *Random Sample*

- Pro:
  - Cocok untuk data *missing at random*.
  - Ganti missing value dengan nilai lain dalam distribusi yang sama dari variabel asli.
  - Mudah dan cepat.
  - Mempertahankan varians dari variabel.
- Kontra:
  - Randomness.
  - Membutuhkan memori besar untuk deployment karena perlu untuk menyimpan data latih yg asli untuk ekstraksi nilai.

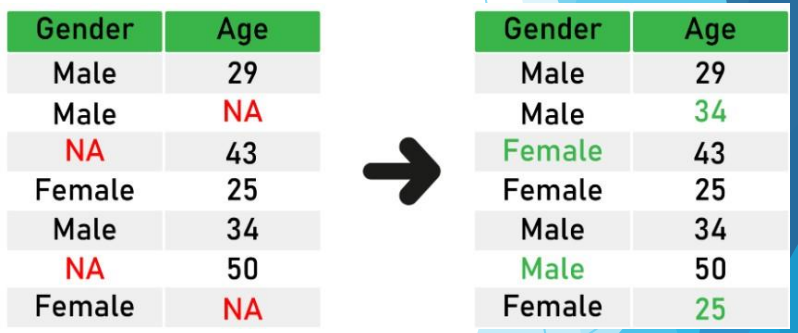

Gender	Age
Male	29
Male	NA
NA	43
Female	25
Male	34
NA	50
Female	NA

Gender	Age
Male	29
Male	34
Female	43
Female	25
Male	34
Male	50
Female	25

Hands On

```
from feature_engine.imputation import RandomSampleImputer
import pandas as pd
import numpy as np
```

import randomsample imputer, pandas, numpy

```
data = {'Gender' : ['Male', 'Male', np.nan, 'Female', 'Male', np.nan, 'Female'],
        'Age' : [29, np.nan, 43, 25, 34, 50, np.nan]}

df = pd.DataFrame(data)

df
```

masukkan data dan ubah menjadi dataframe

	Gender	Age
0	Male	29.0
1	Male	NaN
2	NaN	43.0
3	Female	25.0
4	Male	34.0
5	NaN	50.0
6	Female	NaN

Output

Hands On (Lanjutan)

```
imputer = RandomSampleImputer(random_state = 29)
```

Buat imputernya

```
imputer.fit(df)
```

Cocokan imputer ke set

```
test_t = imputer.transform(df)
```

Mengubah data

```
test_t
```

	Gender	Age
0	Male	29.0
1	Male	34.0
2	Male	43.0
3	Female	25.0
4	Male	34.0
5	Female	50.0
6	Female	50.0

Output

Imputasi Nilai Nol/Konstanta

- Pro:
  - Cocok untuk variabel kategorik.
- Kontra:
  - Tidak memperhitungkan korelasi antar fitur.
  - Memunculkan bias dalam data.

	col1	col2	col3	col4	col5
0	2	5.0	3.0	6	NaN
1	9	NaN	9.0	0	7.0
2	19	17.0	NaN	9	NaN

	col1	col2	col3	col4	col5
0	2	5.0	3.0	6	0.0
1	9	0.0	9.0	0	7.0
2	19	17.0	0.0	9	0.0

sumber gbr:
https://towardsdatascience.com/6-different-ways-to-compensate-for-missing-values-data-imputation-with-examples-6022d9ca0779

Hands On

```
#Contoh 1 - Imputasi Nilai Nol/Konstanta
#Masukkan  data

umur = {'umur' : [29, 43,  np.nan, 25, 34, np.nan, 50]}

#Ubah ke dataframe

data = pd.DataFrame(umur)

#Tampilkan nilai yang ada pada variabel 'umur' dalam bentuk dataframe 'data'

data
```

masukkan data dan ubah menjadi dataframe

	umur
0	29.0
1	43.0
2	NaN
3	25.0
4	34.0
5	NaN
6	50.0

Contoh nilai hilang

```
#Contoh 1 - Imputasi Nilai Nol/Konstanta
#Mengatasi nilai missing value dengan imputasi suka-suka
#Nilai suka-suka yang diberikan pada contoh adalah 99

data.fillna(0)
```

Imputasi nilai nol

	umur
0	29.0
1	43.0
2	0.0
3	25.0
4	34.0
5	0.0
6	50.0

Output

Imputasi dengan K-NN

- Pro:
  - Lebih akurat vs *mean/median/most frequent*.
- Kontra:
  - Biaya komputasi mahal (karena KNN bekerja dengan menyimpan seluruh dataset pelatihan dalam memori).
  - Sensitif terhadap outlier dalam data (tidak seperti SVM).

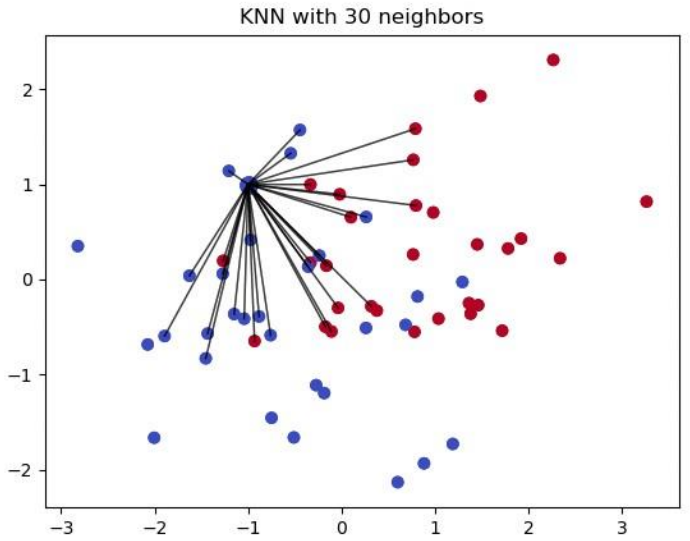

sumber gbr: https://towardsdatascience.com/6-different-ways-to-compensate-for-missing-values-data-imputation-with-examples-6022d9ca0779

Imputasi Regresi: Deterministik

- Deterministik
  - Mengganti missing value dengan prediksi yang tepat dari model regresi.
  - Tidak mempertimbangkan variasi acak di sekitar kemiringan (slope regresi).
  - Nilai imputasi seringkali terlalu tepat (precise) dan overestimasi dari korelasi X-Y.

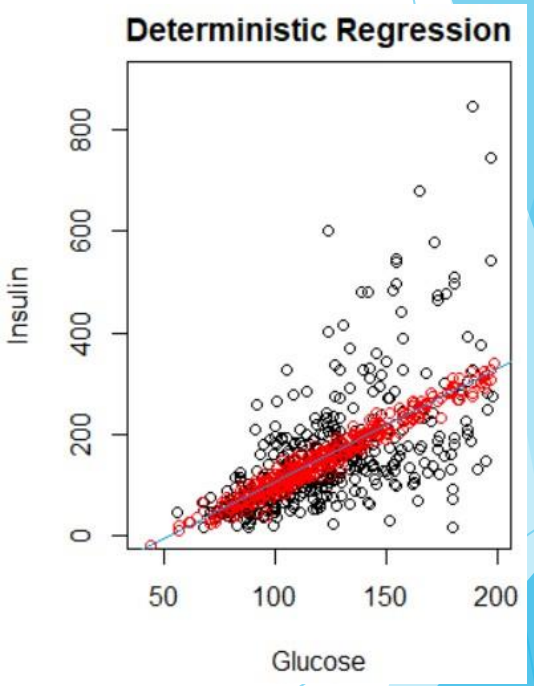

sumber gbr: https://statisticsglobe.com/regression-imputation-stochastic-vs-deterministic/

Hands On

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import missingno as mno
from sklearn import linear_model
%matplotlib inline
```

Import Library

```
df = pd.read_csv("diabetes.csv")
df.head(3)
```

Menentukan nilai yang hilang

	Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
0	6	148	72	35	0	33.6	0.627	50	1
1	1	85	66	29	0	26.6	0.351	31	0
2	8	183	64	0	0	23.3	0.672	32	1

Output

```
df.info()
```

melihat info dari dataframe

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 768 entries, 0 to 767
Data columns (total 9 columns):
 #   Column                    Non-Null Count  Dtype
---  ------                    --------------  -----
 0   Pregnancies               768 non-null    int64
 1   Glucose                   768 non-null    int64
 2   BloodPressure             768 non-null    int64
 3   SkinThickness             768 non-null    int64
 4   Insulin                   768 non-null    int64
 5   BMI                       768 non-null    float64
 6   DiabetesPedigreeFunction  768 non-null    float64
 7   Age                       768 non-null    int64
 8   Outcome                   768 non-null    int64
dtypes: float64(2), int64(7)
memory usage: 54.1 KB
```

Output

```
df.describe()
```

menghitung nilai statistik

	Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
count	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000
mean	3.845052	120.894531	69.105469	20.536458	79.799479	31.992578	0.471876	33.240885	0.348958
std	3.369578	31.972618	19.355807	15.952218	115.244002	7.884160	0.331329	11.760232	0.476951
min	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.078000	21.000000	0.000000
25%	1.000000	99.000000	62.000000	0.000000	0.000000	27.300000	0.243750	24.000000	0.000000
50%	3.000000	117.000000	72.000000	23.000000	30.500000	32.000000	0.372500	29.000000	0.000000
75%	6.000000	140.250000	80.000000	32.000000	127.250000	36.600000	0.626250	41.000000	1.000000
max	17.000000	199.000000	122.000000	99.000000	846.000000	67.100000	2.420000	81.000000	1.000000

Output

```
df.loc[df["Glucose"] == 0.0, "Glucose"] = np.NAN
df.loc[df["BloodPressure"] == 0.0, "BloodPressure"] = np.NAN
df.loc[df["SkinThickness"] == 0.0, "SkinThickness"] = np.NAN
df.loc[df["Insulin"] == 0.0, "Insulin"] = np.NAN
df.loc[df["BMI"] == 0.0, "BMI"] = np.NAN

df.isnull().sum()[1:6]
```

df.loc[] --> memilih table berdasarkan lokasi

```
Glucose          5
BloodPressure    35
SkinThickness    227
Insulin          374
BMI              11
dtype: int64
```

Output

Hands On (Lanjutan)

```
mno.matrix(df, figsize = (20, 6))
```

→ Membuat Matriks,
figsize --> ukuran figure

```
<AxesSubplot:>
```

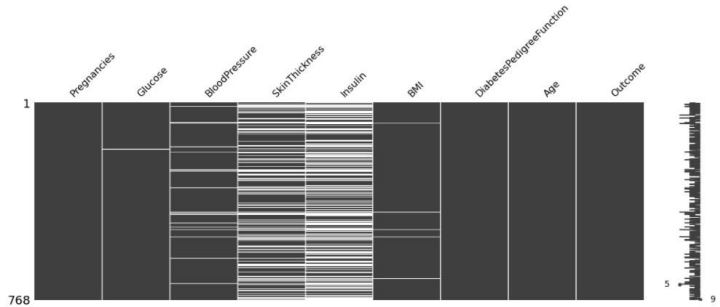

→ Output

```
missing_columns = ["Glucose", "BloodPressure", "SkinThickness", "Insulin", "BMI"]
```

```
def random_imputation(df, feature):

    number_missing = df[feature].isnull().sum()
    observed_values = df.loc[df[feature].notnull(), feature]
    df.loc[df[feature].isnull(), feature + '_imp'] = np.random.choice(observed_values, number_missing, replace = True)

    return df
```

→ Menggunakan Regresi untuk memperhitungkan data yang hilang

```
for feature in missing_columns:
    df[feature + '_imp'] = df[feature]
    df = random_imputation(df, feature)
```

Hands On (Lanjutan)

```
deter_data = pd.DataFrame(columns = ["Det" + name for name in missing_columns])

for feature in missing_columns:

    deter_data["Det" + feature] = df[feature + "_imp"]
    parameters = list(set(df.columns) - set(missing_columns) - {feature + '_imp'})
```

Deterministic Regression Imputation

```
    model = linear_model.LinearRegression()
    model.fit(X = df[parameters], y = df[feature + '_imp'])
```

Buat model Regresi Linier untuk memperkirakan data yang hilang

```
    deter_data.loc[df[feature].isnull(), "Det" + feature] = model.predict(df[parameters])[df[feature].isnull()]
```

amati bahwa kita menyimpan indeks data yang hilang dari kerangka data asli

```
mno.matrix(deter_data, figsize = (20,5))
```

membuat matriks

```
<AxesSubplot:>
```

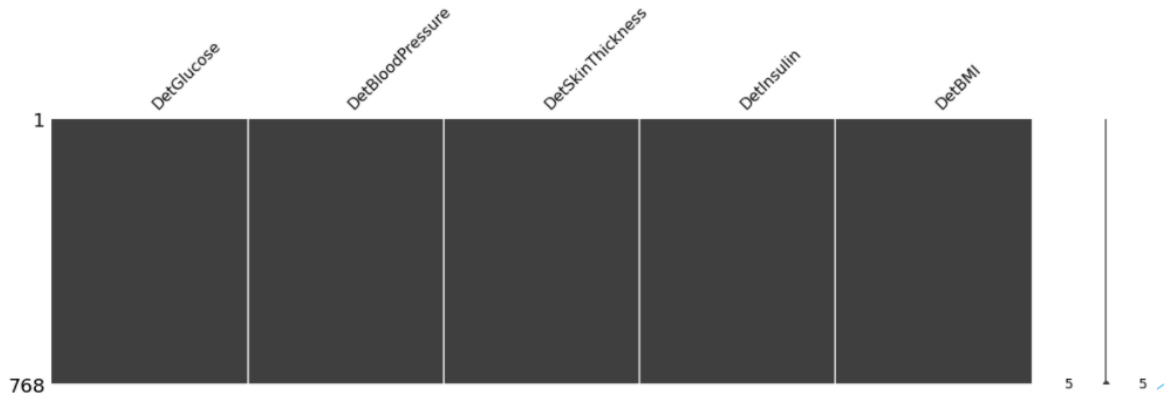

Output

Hands On (Lanjutan)

```
sns.set()
fig, axes = plt.subplots(nrows = 2, ncols = 2)
fig.set_size_inches(8, 8)

for index, variable in enumerate(["Insulin", "SkinThickness"]):
    sns.histplot(df[variable].dropna(), kde = False, ax = axes[index, 0])
    sns.histplot(deter_data["Det" + variable], kde = False, ax = axes[index, 0], color = 'red')

    sns.boxplot(data = pd.concat([df[variable], deter_data["Det" + variable]], axis = 1),
                ax = axes[index, 1])

plt.tight_layout()
```

membuat chart

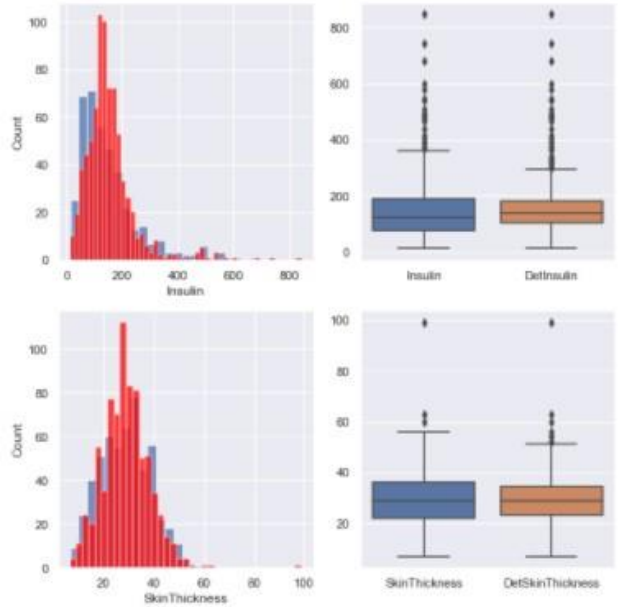

Output

```
pd.concat([df[["Insulin", "SkinThickness"]], deter_data[["DetInsulin", "DetSkinThickness"]]], axis = 1).describe().T
```

	count	mean	std	min	25%	50%	75%	max
Insulin	394.0	155.548223	118.775855	14.0	76.250000	125.000000	190.000000	846.0
SkinThickness	541.0	29.153420	10.476982	7.0	22.000000	29.000000	36.000000	99.0
DetInsulin	768.0	154.559890	89.394698	14.0	105.029991	140.217157	182.000000	846.0
DetSkinThickness	768.0	29.097247	9.189058	7.0	23.000000	29.000000	34.461758	99.0

Output

Imputasi Regresi: Stokastik

- Stokastik
  - Mengatasi masalah dalam imputasi regresi deterministik.
  - Menambahkan fitur "random error" sehingga reproduksi korelasi X-Y lebih tepat.

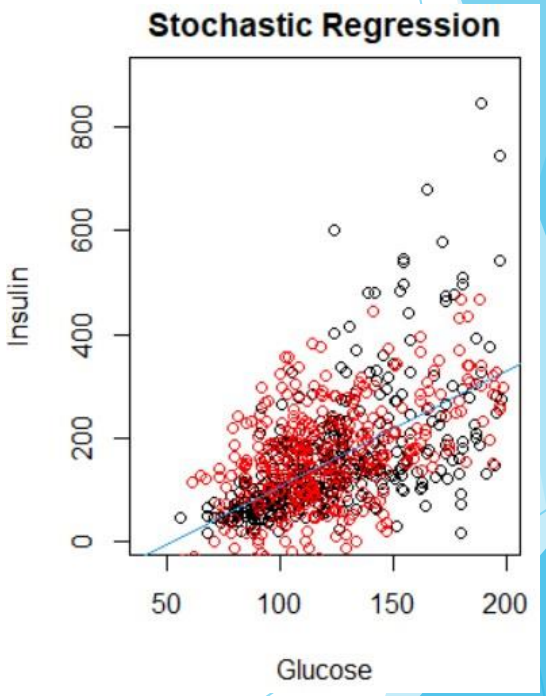

sumber gbr:
https://statisticsglobe.com/regression-imputation-stochastic-vs-deterministic/

Hands On

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import missingno as mno
from sklearn import linear_model
%matplotlib inline
```

→ import library

```
df = pd.read_csv("diabetes.csv")
df.head(3)
```

→ Menentukan nilai yang hilang

	Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
0	6	148	72	35	0	33.6	0.627	50	1
1	1	85	66	29	0	26.6	0.351	31	0
2	8	183	64	0	0	23.3	0.672	32	1

→ Output

```
df.info()
```

→ melihat info dari data frame

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 768 entries, 0 to 767
Data columns (total 9 columns):
 #   Column                    Non-Null Count  Dtype
---  ------                    --------------  -----
 0   Pregnancies               768 non-null    int64
 1   Glucose                   768 non-null    int64
 2   BloodPressure             768 non-null    int64
 3   SkinThickness             768 non-null    int64
 4   Insulin                   768 non-null    int64
 5   BMI                       768 non-null    float64
 6   DiabetesPedigreeFunction  768 non-null    float64
 7   Age                       768 non-null    int64
 8   Outcome                   768 non-null    int64
dtypes: float64(2), int64(7)
memory usage: 54.1 KB
```

→ Output

```
df.describe()
```

→ menghitung data statistik

	Pregnancies	Glucose	BloodPressure	SkinThickness	Insulin	BMI	DiabetesPedigreeFunction	Age	Outcome
count	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000	768.000000
mean	3.845052	120.894531	69.105469	20.536458	79.799479	31.992578	0.471876	33.240885	0.348958
std	3.369578	31.972618	19.355807	15.952218	115.244002	7.884160	0.331329	11.760232	0.476951
min	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.078000	21.000000	0.000000
25%	1.000000	99.000000	62.000000	0.000000	0.000000	27.300000	0.243750	24.000000	0.000000
50%	3.000000	117.000000	72.000000	23.000000	30.500000	32.000000	0.372500	29.000000	0.000000
75%	6.000000	140.250000	80.000000	32.000000	127.250000	36.600000	0.626250	41.000000	1.000000
max	17.000000	199.000000	122.000000	99.000000	846.000000	67.100000	2.420000	81.000000	1.000000

→ Output

```
df.loc[df["Glucose"] == 0.0, "Glucose"] = np.NAN
df.loc[df["BloodPressure"] == 0.0, "BloodPressure"] = np.NAN
df.loc[df["SkinThickness"] == 0.0, "SkinThickness"] = np.NAN
df.loc[df["Insulin"] == 0.0, "Insulin"] = np.NAN
df.loc[df["BMI"] == 0.0, "BMI"] = np.NAN

df.isnull().sum()[1:6]
```

→ df.loc[] --> memilih tabel berdasarkan lokasi

```
Glucose          5
BloodPressure    35
SkinThickness    227
Insulin          374
BMI              11
dtype: int64
```

→ Output

Hands On (Lanjutan)

```
mno.matrix(df, figsize = (20, 6))
```

```
<AxesSubplot:>
```

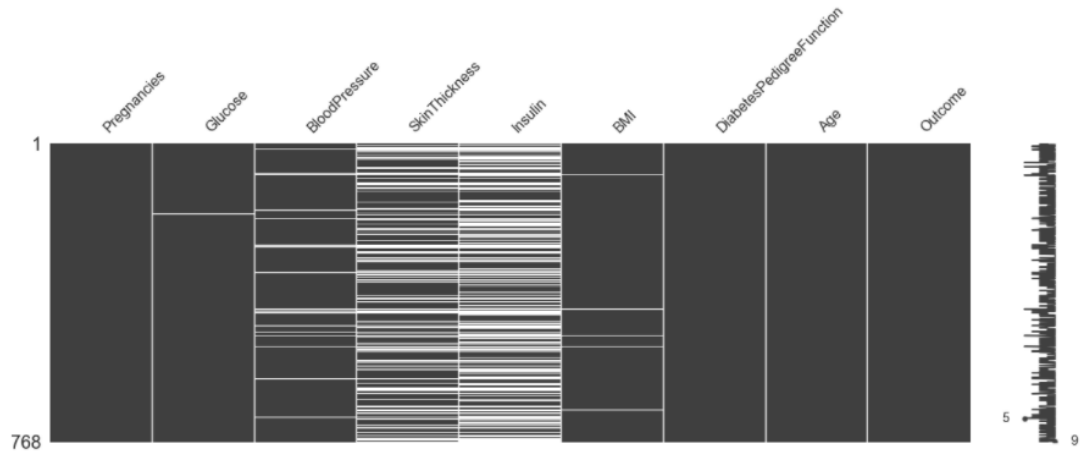

membuat matriks

Output

```
missing_columns = ["Glucose", "BloodPressure", "SkinThickness", "Insulin", "BMI"]
```

Menggunakan Regresi untuk memperhitungkan data yang hilang

```
def random_imputation(df, feature):

    number_missing = df[feature].isnull().sum()
    observed_values = df.loc[df[feature].notnull(), feature]
    df.loc[df[feature].isnull(), feature + '_imp'] = np.random.choice(observed_values, number_missing, replace = True)

    return df
```

```
for feature in missing_columns:
    df[feature + '_imp'] = df[feature]
    df = random_imputation(df, feature)
```

Hands On (Lanjutan)

```
random_data = pd.DataFrame(columns = ["Ran" + name for name in missing_columns])

for feature in missing_columns:

    random_data["Ran" + feature] = df[feature + '_imp']
    parameters = list(set(df.columns) - set(missing_columns) - {feature + '_imp'})

    model = linear_model.LinearRegression()
    model.fit(X = df[parameters], y = df[feature + '_imp'])
```

Stochastic Regression Imputation

```
predict = model.predict(df[parameters])
std_error = (predict[df[feature].notnull()] - df.loc[df[feature].notnull(), feature + '_imp']).std()
```

amati bahwa kita menyimpan indeks data yang hilang dari kerangka data asli

```
random_predict = np.random.normal(size = df[feature].shape[0],
                                  loc = predict,
                                  scale = std_error)
random_data.loc[(df[feature].isnull()) & (random_predict > 0), "Ran" + feature] = random_predict[(df[feature].isnull()) &
                                                                                  (random_predict > 0)]
```

Kesalahan Standar dari perkiraan regresi sama dengan std() dari kesalahan setiap perkiraan

Hands On (Lanjutan)

```
sns.set()
fig, axes = plt.subplots(nrows = 2, ncols = 2)
fig.set_size_inches(8, 8)

for index, variable in enumerate(["Insulin", "SkinThickness"]):
    sns.histplot(df[variable].dropna(), kde = False, ax = axes[index, 0])
    sns.histplot(random_data["Ran" + variable], kde = False, ax = axes[index, 0], color = 'red')
    axes[index, 0].set(xlabel = variable + " / " + variable + '_imp')

    sns.boxplot(data = pd.concat([df[variable], random_data["Ran" + variable]], axis = 1),
                ax = axes[index, 1])

    plt.tight_layout()
```

→ membuat chart

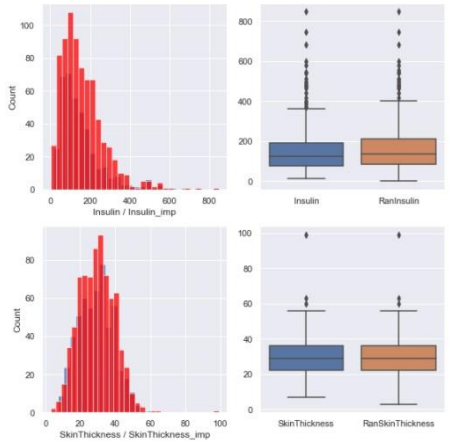

→ Output

Hands On (Lanjutan)

```
pd.concat([df[["Insulin", "SkinThickness"]], random_data[["RanInsulin", "RanSkinThickness"]]], axis = 1).describe().T
```

	count	mean	std	min	25%	50%	75%	max
Insulin	394.0	155.548223	118.775855	14.000000	76.250000	125.000000	190.000000	846.0
SkinThickness	541.0	29.153420	10.476982	7.000000	22.000000	29.000000	36.000000	99.0
RanInsulin	768.0	159.817877	107.962192	1.350895	82.852612	137.134053	212.448998	846.0
RanSkinThickness	768.0	29.056917	10.211228	2.984951	22.000000	29.000000	36.000000	99.0

→ Output

Kesimpulan Teknik Imputasi

- Dua kategori imputasi:
  - Berdasarkan layer/tahapan: single imputation dan multiple imputation
- Tidak ada cara sempurna untuk mengkompensasi missing value (nilai yang hilang) dalam kumpulan data.
- Setiap strategi memiliki kinerja lebih baik untuk kumpulan data tertentu dan tipe data yang hilang tetapi dapat berkinerja jauh lebih buruk pada jenis kumpulan data lainnya.

Mengatasi (*Handling*) *Outlier* (HO)

- Definisi *Outlier*:
  - Titik data yang sangat berbeda dari data lainnya.
  - Pengamatan yang menyimpang dari pola keseluruhan pada sampel.
- Penyebab:
  - Error percobaan, salah input, error instrumen, kesengajaan (untuk pengujian), error pemrosesan data, error sampling, kewajaran karena keanehan dalam data (bukan error).

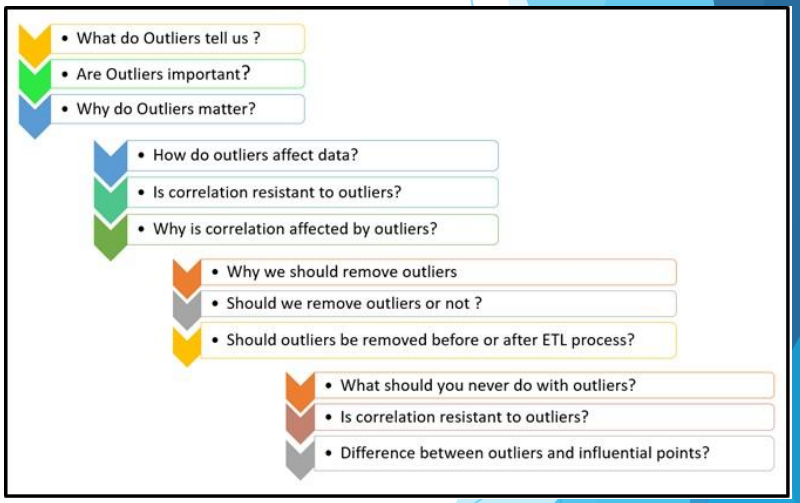

sumber gbr:
https://heartbeat.fritz.ai/hands-on-with-feature-engineering-techniques-dealing-with-outliers-fcc9f57cb63b
https://www.analyticsvidhya.com/blog/2021/03/zooming-out-[illegible]-them-indata-science/

Mengatasi (*Handling*) *Outlier* (HO)

- Jenis/kategori:
  - Univariate vs multivariate
  - Parametrik vs non-parametrik
- Deteksi dan Cari Outlier dengan:
  - Visualisasi
  - Distribusi normal

Teknik Mengatasi Outlier:

- Trimming
- Winsorizing
- Imputing
- Discretization
- Censoring
- Z-score
- Linear Regression Model

Deteksi Outlier

- Visualiasi dgn Boxplot dan Scatterplot
  - Sebagian besar titik data terletak di tengah, tetapi ada satu titik yang jauh dari pengamatan lainnya; ini bisa menjadi outlier.
- Distribusi Normal
  - Dalam distribusi normal, sekitar 99,7% data berada dalam tiga standar deviasi dari mean.
  - Jika ada pengamatan yang lebih dari tiga kali standar deviasi, kemungkinan itu adalah outlier.
- Z-score
- Inter Quantile Range (IQR)

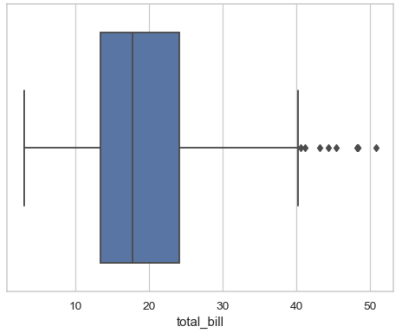

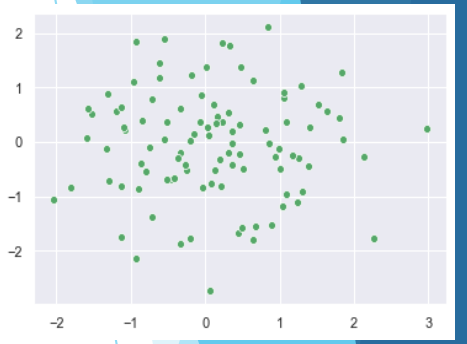

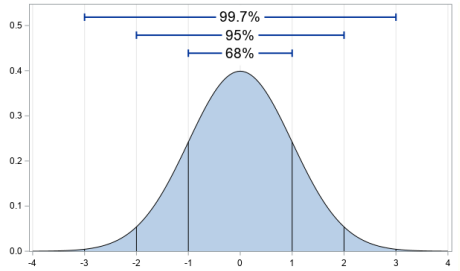

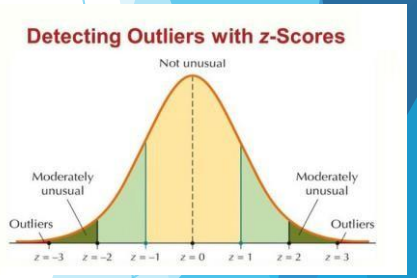

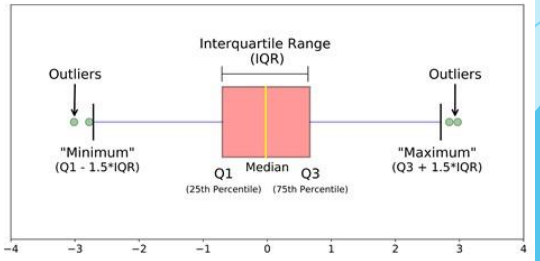

sumber gbr:
https://heartbeat.fritz.ai/hands-on-with-feature-engineering-techniques-dealing-with-outliers-fcc9f57cb63b
https://[illegible]svidhya.com/blog/2021/05/detecting-and-treating-outliers-treating-the-odd-one-out/

Teknik HO: Trimming (Pangkas) vs Winsorizing

- Nama lain: Truncation (Potong)
- Definisi: Menghapus outlier dari dataset
- Perlu memutuskan metrik untuk menentukan outlier.

Definisi:
Mengganti outlier dari dataset dengan nilai persentil setiap ujung/batas atas dan bawah.

Trimming vs Winsorizing

- Contoh kasus: laporan jumlah pasien yang ditangani tiap dokter/bulan (di bawah 100 pasien), dengan 4% dilaporkan lebih dari 100 pasien.

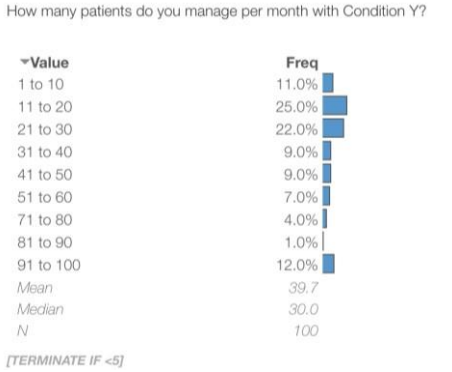

range [5,100]. Outlier tidak dibuang, namun dimasukan ke dalam range terdekat. Sehingga nilai mean mengecil. Median dan N tidak berubah.

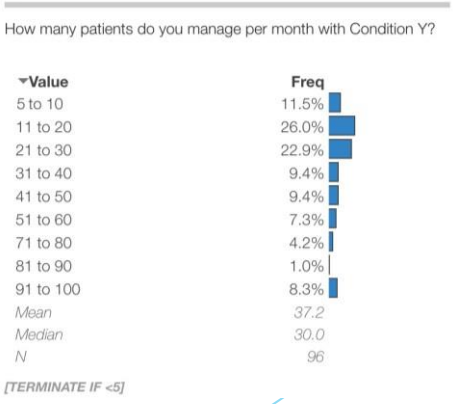

Membuang data yang berada di luar range. Nilai N berubah, mean mengecil, median masih dinilai yg sama.

sumber gbr: https://protobi.com/post/extreme-values-winsorize-trim-or-retain

Hands On

```
import numpy as np
from scipy.stats.mstats import winsorize
from scipy.stats.mstats import trima
```

→ import numpy dan scipy

```
a = np.array([10, 4, 9, 8, 5, 3, 7, 2, 1, 6])
```

→ Masukkan array berisi 1 - 10

```
wins = winsorize(a, limits=[0.1, 0.2])
wins
```

→ Winsorize akan mengganti 10% nilai terendah dan 20% nilai tinggi

```
masked_array(data=[8, 4, 8, 8, 5, 3, 7, 2, 2, 6],
             mask=False,
       fill_value=999999)
```

→ Output

```
trims = trima(a, limits=(2,8))
print(trims)
```

→ Trims akan memotong nilai dengan batas tertentu

```
[-- 4 -- 8 5 3 7 2 -- 6]
```

→ Output

Discretization

- Definisi:
  - Proses mengubah fungsi, model dan variabel kontinu menjadi diskret (data kontinu di *Ukur* (measured) vs data kontinu di *Hitung* (counted)).
- Nama lain: Binning.
- Dasar Pertimbangan:
  - Data kontinu memiliki derajat kebebasan (DoF) yang tak hingga.
  - Data kontinu lebih mudah dipahami dan disimpan dalam bentuk kategori/grup
    - misal berat badan < 65 kg (ringan); 65 – 80 kg (mid); >80 kg (berat).

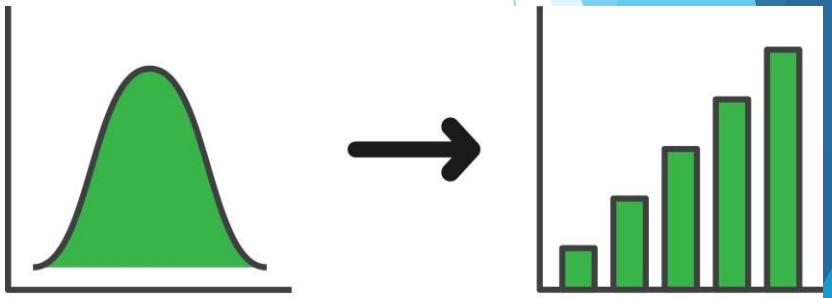

Discretization Process

Discretization

- Jenis:
  - Supervised
    - Decision Tree.
  - Unsupervised
    - Equal-width discretization.
    - Equal-frequency discretization.
    - K-means discretization.
  - Lainnya
    - Custom discretization.

Taksonomi Discretization

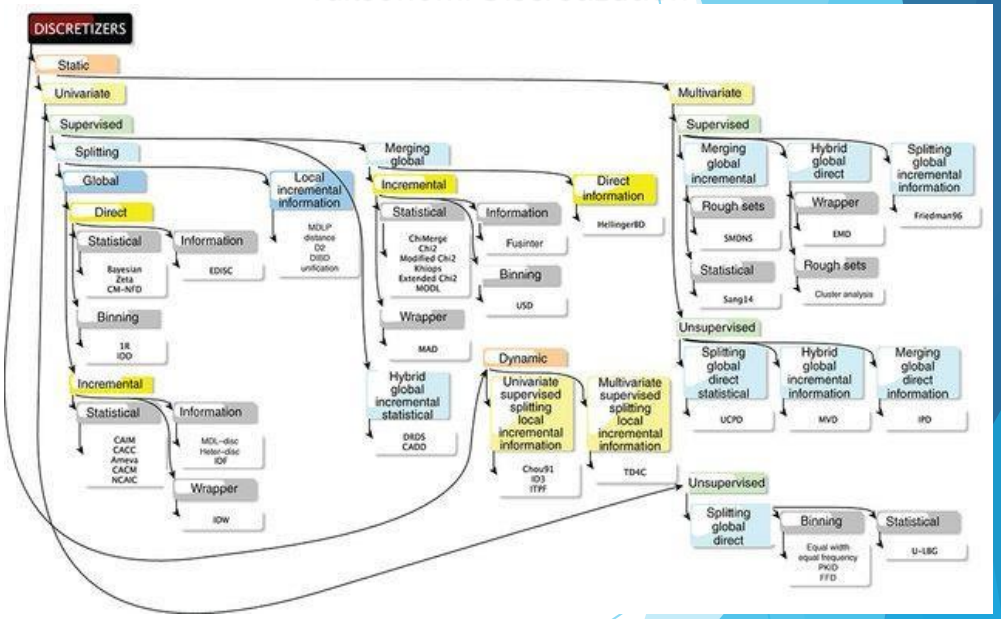

Binning

- Pro:
  - Dapat diterapkan pada data kategorik dan numerik.
  - Model lebih robust dan mencegah overfitting.
- Kontra:
  - Meningkatnya biaya kinerja perhitungan.
  - Mengorbankan informasi.
  - Untuk kolom data numerik, dapat menyebabkan redudansi untuk beberapa algoritma.
  - Untuk kolom data kategorik, label dengan frekuensi rendah berdampak negatif pada robustness model statistik.
  - Untuk ukuran data dengan 100 ribu baris, disarankan menggabungkan label/kolom dengan record yang < 100 menjadi kategori baru, misal "Lain-lain".

Ilustrasi binning untuk data numerik

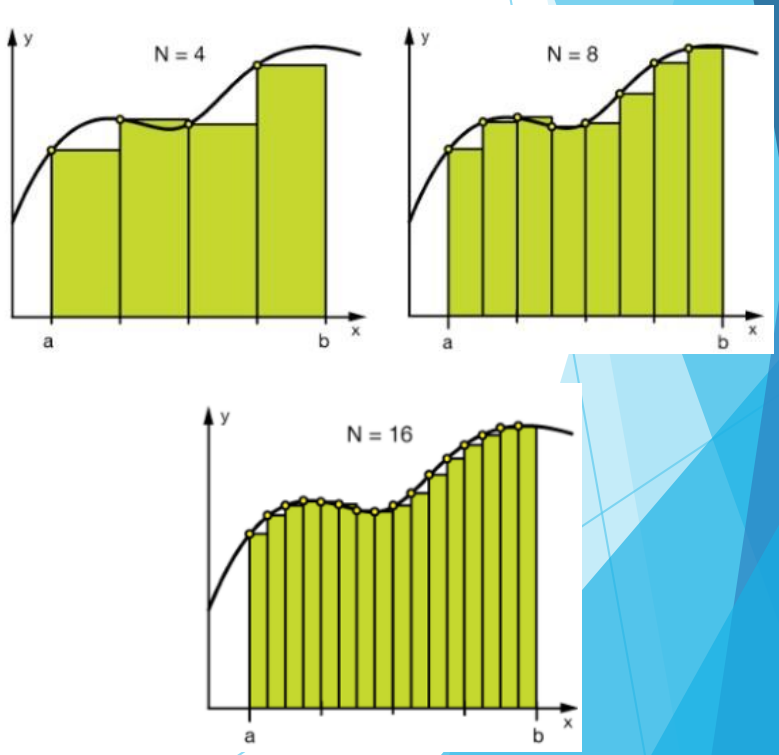

Hands On

```
import pandas as pd
import numpy as np

df = pd.read_csv('bins.csv')
df
```

→ import pandas, numpy

	Item	Harga
0	Item_1	1500
1	Item_2	3300
2	Item_3	11000
3	Item_4	87500
4	Item_5	45000
5	Item_6	28600
6	Item_7	39900
7	Item_8	91000
8	Item_9	64700
9	Item_10	6000
10	Item_11	19000
11	Item_12	2700

→ Output

membuat array yang berisi sejumlah angka dengan jarak yang sama dengan linspace(), linspace --> numpy.linspace(nilai minimum, nilai maksimum, jumlah elemen)

```
bins = np.linspace(min(df['Harga']), max(df['Harga']), 4)
bins
```

```
array([ 1500.        , 31333.33333333, 61166.66666667, 91000.        ])
```

→ Output

```
df = pd.read_csv('bins.csv')
kategori = ['Murah', 'Standar', 'Mahal']
df['Harga Binned'] = pd.cut(df['Harga'], bins, labels=kategori, include_lowest=True)
df
```

	Item	Harga	Harga Binned
0	Item_1	1500	Murah
1	Item_2	3300	Murah
2	Item_3	11000	Murah
3	Item_4	87500	Mahal
4	Item_5	45000	Standar
5	Item_6	28600	Murah
6	Item_7	39900	Standar
7	Item_8	91000	Mahal
8	Item_9	64700	Mahal
9	Item_10	6000	Murah
10	Item_11	19000	Murah
11	Item_12	2700	Murah

→ Output

- bins --> mengelompokkan data
- binning dengan cut()
- membuat kategori harga

```
df = pd.read_csv('bins.csv')
interval_range = pd.interval_range(start=0, freq=10000, end=100000)
df['Harga Binned 2'] = pd.cut(df['Harga'], bins = interval_range)
df
```

	Item	Harga	Harga Binned 2
0	Item_1	1500	(0, 10000]
1	Item_2	3300	(0, 10000]
2	Item_3	11000	(10000, 20000]
3	Item_4	87500	(80000, 90000]
4	Item_5	45000	(40000, 50000]
5	Item_6	28600	(20000, 30000]
6	Item_7	39900	(30000, 40000]
7	Item_8	91000	(90000, 100000]
8	Item_9	64700	(60000, 70000]
9	Item_10	6000	(0, 10000]
10	Item_11	19000	(10000, 20000]
11	Item_12	2700	(0, 10000]

→ Output

menggunakan interval range untuk binning data dengan cut()

Hands On (Lanjutan)

```
df = pd.read_csv('bins.csv')
df['Harga Binned 3'] = pd.qcut(df['Harga'], 3)
df
```

→ binning dengan qcut()

	Item	Harga	Harga Binned 3
0	Item_1	1500	(1499.999, 9333.333]
1	Item_2	3300	(1499.999, 9333.333]
2	Item_3	11000	(9333.333, 41600.0]
3	Item_4	87500	(41600.0, 91000.0]
4	Item_5	45000	(41600.0, 91000.0]
5	Item_6	28600	(9333.333, 41600.0]
6	Item_7	39900	(9333.333, 41600.0]
7	Item_8	91000	(41600.0, 91000.0]
8	Item_9	64700	(41600.0, 91000.0]
9	Item_10	6000	(1499.999, 9333.333]
10	Item_11	19000	(9333.333, 41600.0]
11	Item_12	2700	(1499.999, 9333.333]

→ Output

Scaling (Penskalaan)

- Dasar:
  - Sering diabaikan oleh pemula di Data Science.
  - Data numerik (biasanya) tidak memiliki range. range "Usia" vs range "Gaji" tidak sama (karakteristik berbeda). *Usia* memiliki rentang dari 1 sampai 150 (dalam tahun), sedangkan *Gaji* memiliki rentang dari 10 ribu sampai 100 ribu (dalam dolar). Untuk itu membandingkan perlu *scaling*.
  - Beberapa algoritma Machine Learning (regresi linear dan logistik dan Neural Network; SVM, KNN, K-means; LDA; PCA) yang menggunakan teknik optimasi Euclidian Distance 2 poin (titik).

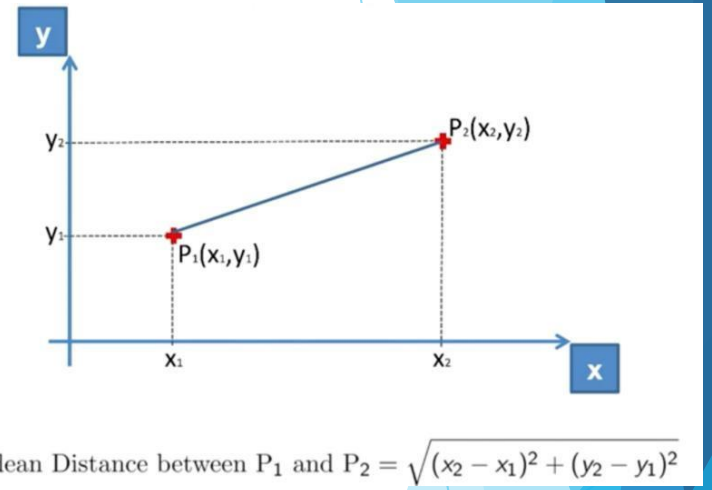

- Dengan menggunakan rumus Euclidean Distance diatas, maka jelas bahwa hasil perhitungan pada kolom *Usia* dan *Gaji* akan memiliki jarak (distance) yang sangat jauh. Disinilah proses Feature Scaling dibutuhkan.
- Feature Scaling adalah suatu cara untuk membuat numerical data pada dataset memiliki rentang nilai (scale) yang sama. Tidak ada lagi satu variabel data yang mendominasi variabel data lainnya.

sumber gbr:
https://medium.com/machine-learning-id/melakukan-feature-scaling-pada-dataset-229531bb08de

Hands On

```
import pandas as pd
from sklearn.preprocessing import Normalizer
```

→ import library

```
data = pd.read_csv("scalling.csv")
```

→ membaca data

```
max_abs = Normalizer(norm = 'l2')
```

→ buat objek skalar dengan normalizer

```
max_abs.fit(data)
```

→ sesuaikan scaler dengan data

```
train_scaled = max_abs.transform(data)
```

→ mengubah data

```
train_scaled
```

```
array([[6.11110997e-04, 9.99999813e-01],
       [5.62499911e-04, 9.99999842e-01],
       [5.55555470e-04, 9.99999846e-01],
       [6.22950699e-04, 9.99999806e-01],
       [7.99999744e-04, 9.99999680e-01],
       [6.03448166e-04, 9.99999818e-01],
       [5.19230699e-04, 9.99999865e-01],
       [6.07594825e-04, 9.99999815e-01],
       [6.02409529e-04, 9.99999819e-01],
       [5.52238722e-04, 9.99999848e-01]])
```

→ Output

Scaling: Jenis

Standardisation	Normalisation
$x_{\text{stand}} = \frac{x - \text{mean}(x)}{\text{standard deviation } (x)}$	$x_{\text{norm}} = \frac{x - \min(x)}{\max(x) - \min(x)}$

Scaling: Normalisasi

- Nama Lain: Min-Max Scaling.
- Definisi: Teknik penskalaan di mana nilai-nilai digeser dan diubah skalanya sehingga nilainya berkisar antara 0 dan 1 (rentang [0,1]).

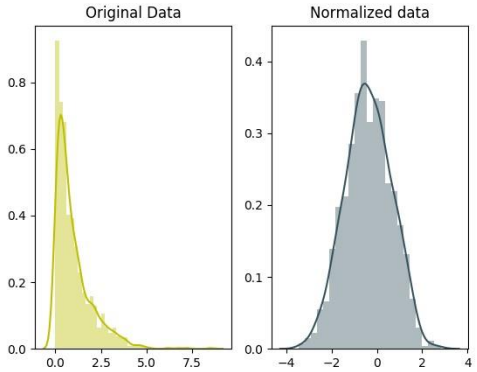

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Di sini, Xmax dan Xmin masing-masing adalah nilai maksimum dan minimum dari fitur.

- Ketika nilai X adalah nilai minimum dalam kolom, pembilangnya adalah 0, dan karenanya X' adalah 0.
- Sebaliknya, ketika nilai X adalah nilai maksimum dalam kolom, pembilangnya sama dengan penyebutnya sehingga nilai X' adalah 1.
- Jika nilai X berada di antara nilai minimum dan maksimum, maka nilai X' berada di antara 0 dan 1.

Hands On

```
import pandas as pd
import numpy as np
```

import pandas dan numpy

```
data = pd.read_csv("scalling.csv")
data
```

membaca data

	Age	Income
0	44	72000
1	27	48000
2	30	54000
3	38	61000
4	40	50000
5	35	58000
6	27	52000
7	48	79000
8	50	83000
9	37	67000

Output

```
means = data.mean(axis = 0)
```

menghitung mean

```
max_min = data.max(axis = 0) - data.min(axis = 0)
```

menghitung max - min

```
train_scaled = (data - means) / max_min
```

menerapkan transformasi ke data

```
train_scaled
```

	Age	Income
0	0.278261	0.274286
1	-0.460870	-0.411429
2	-0.330435	-0.240000
3	0.017391	-0.040000
4	0.104348	-0.354286
5	-0.113043	-0.125714
6	-0.460870	-0.297143
7	0.452174	0.474286
8	0.539130	0.588571
9	-0.026087	0.131429

Output

Scaling: Standardisasi

- Tujuan: Berfokus pada mengubah data mentah menjadi informasi yang dapat digunakan sebelum dianalisis.
- Definisi: Teknik yang menskalakan data shingga memiliki mean =0 dan standar deviasi =1
- Kontra:
  - Menambah langkah dalam data preparation
  - Waktu bertambah

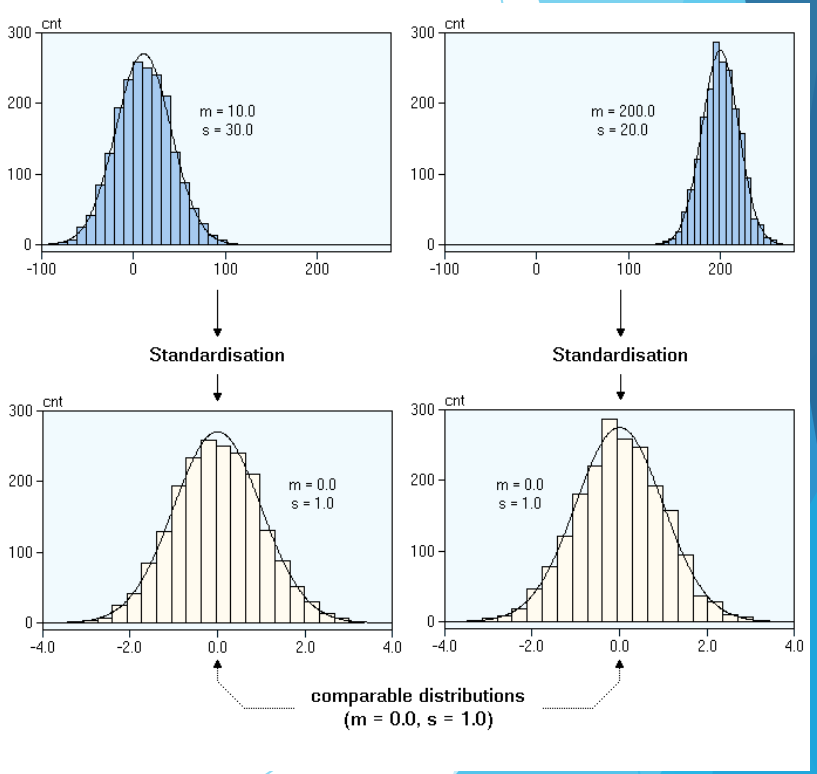

sumber:
https://www.cnblogs.com/qui

Hands On

```
import pandas as pd
from sklearn.preprocessing import StandardScaler
```

→ import library

```
data = pd.read_csv("scalling.csv")

data
```

→ membaca data

	Age	Income
0	44	72000
1	27	48000
2	30	54000
3	38	61000
4	40	50000
5	35	58000
6	27	52000
7	48	79000
8	50	83000
9	37	67000

→ Output

```
scaler = StandardScaler()
```

→ buat objek scaler

```
scaler.fit(data)
```

→ sesuaikan scaler dengan data

```
train_scaled = scaler.transform(data)
```

→ mengubah data kereta dan uji

```
train_scaled
```

```
array([[ 0.8273403 ,  0.81886943],
       [-1.37028238, -1.22830415],
       [-0.98246661, -0.71651075],
       [ 0.05170877, -0.11941846],
       [ 0.31025261, -1.05770635],
       [-0.336107  , -0.37531516],
       [-1.37028238, -0.88710855],
       [ 1.34442799,  1.41596173],
       [ 1.60297184,  1.75715732],
       [-0.07756315,  0.39237494]])
```

→ Output

Contoh Kasus *Scaling*

	Country	Age	Salary	Purchased
1	France	44	72000	No
2	Spain	27	48000	Yes
3	Germany	30	54000	No
4	Spain	38	61000	No
5	Germany	40		Yes
6	France	35	58000	Yes
7	Spain		52000	No
8	France	48	79000	Yes
9	Germany	50	83000	No
10	France	37	67000	Yes

The range of Age: 27 - 50

The range of Salary:48,000 - 83,000

```
dataset['Age'].min()
```

```
27.0
```

```
dataset['Salary'].min()
```

```
48000.0
```

```
dataset['Age'].max()
```

```
50.0
```

```
dataset['Salary'].max()
```

```
83000.0
```

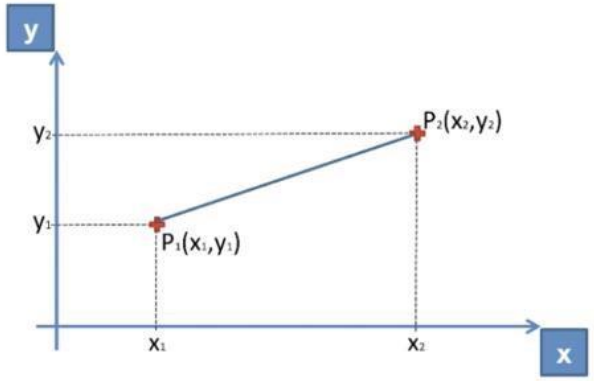

Euclidean Distance between P_1 and $P_2 = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$

Let x be the no. of Salary and y be the no. of Age

Example: x1&y1 are in row 2, x2&y2 are in row 9

(x2-x1)^2= (83000-48000)^2

=1225000000

(y2-y1)^2=(50-27)^2

=529

sumber gbr:
https://www.kdnuggets.com/2020/04/data-transformation-standardization-normalization.html

Contoh Kasus *Scaling*

- Ketika kita menghitung persamaan jarak (distance) Euclidean, jumlah $(x2\text{-}x1)^2$ jauh lebih besar daripada jumlah $(y2\text{-}y1)^2$ yang berarti jarak Euclidean akan didominasi oleh *Gaji* jika kita tidak menerapkan penskalaan. Perbedaan *Usia* berkontribusi lebih sedikit terhadap perbedaan keseluruhan.
- Oleh karena itu, kita harus menggunakan penskalaan untuk membawa semua nilai ke besaran yang sama dan dengan demikian, menyelesaikan masalah ini.

Standardisation

	Age	Salary
0	0.758874	7.494733e-01
1	-1.711504	-1.438178e+00
2	-1.275555	-8.912655e-01
3	-0.113024	-2.532004e-01
4	0.177609	6.632192e-16
5	-0.548973	-5.266569e-01
6	0.000000	-1.073570e+00
7	1.340140	1.387538e+00
8	1.630773	1.752147e+00
9	-0.258340	2.937125e-01

Max-Min Normalization

	Age	Salary
0	0.739130	0.685714
1	0.000000	0.000000
2	0.130435	0.171429
3	0.478261	0.371429
4	0.565217	0.450794
5	0.347826	0.285714
6	0.512077	0.114286
7	0.913043	0.885714
8	1.000000	1.000000
9	0.434783	0.542857

Contoh Kasus *Scaling*

After Feature scaling.

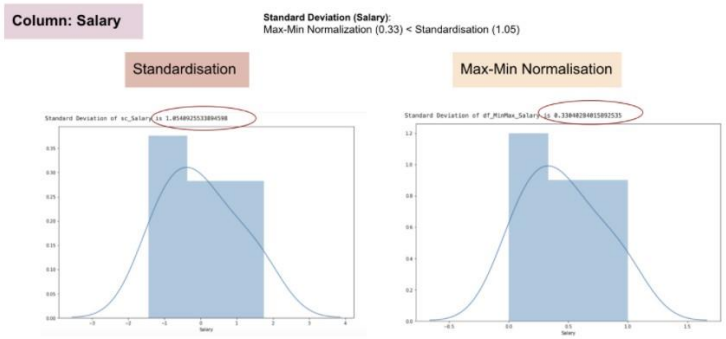

Normal distribution and Standard Deviation of Salary.

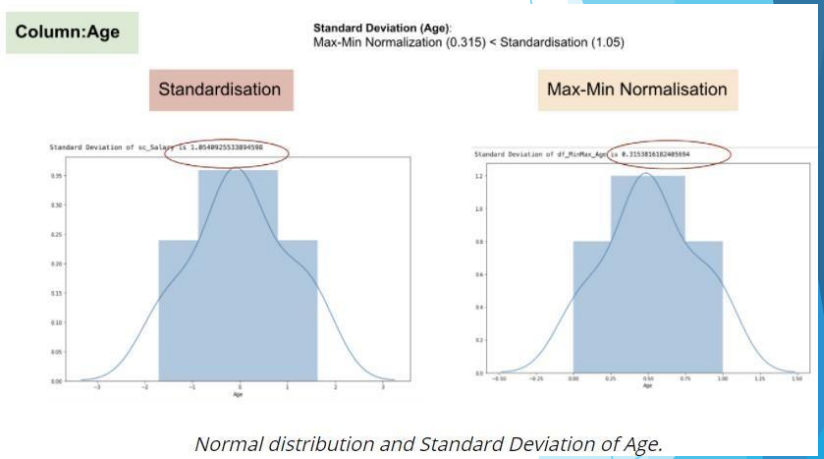

Normal distribution and Standard Deviation of Age.

sumber gbr:
https://www.kdnuggets.com/2020/04/d[illegible]-normalization.html

Referensi

- https://www.ucl.ac.uk/population-health-sciences/sites/population-health-sciences/files/quartagno_1.pdf
- https://rianneschouten.github.io/missing_data_science/assets/blogpost/blogpost.html
- https://towardsdatascience.com/tf-term-frequency-idf-inverse-document-frequency-from-scratch-in-python-6c2b61b78558
- https://dataaspirant.com/nlp-text-preprocessing-techniques-implementation-python
- https://www.oreilly.com/library/view/blueprints-for-text/9781492074076/assets/btap_0401.png
- https://monkeylearn.com/unstructured-data
- https://medium.com/machine-learning-id/melakukan-feature-scaling-pada-dataset-229531bb08de
- https://protobi.com/post/extreme-values-winsorize-trim-or-retain
- https://heartbeat.fritz.ai/hands-on-with-feature-engineering-techniques-dealing-with-outliers-fcc9f57cb63b
- https://www.analyticsvidhya.com/blog/2021/05/detecting-and-treating-outliers-treating-the-odd-one-out/

Tools /Lab Online

- Jupyter Notebook
- Google Collabs

Summary

- Transformasi Data adalah bagian dari Data Preparation
- Membutuhkan pengetahuan dasar dan detail serta waktu yang mayoritas untuk menjamin data yang akan dianalisis sebersih mungkin
- Tranformasi data dapat menggunakan beberapa teknik rekayasa fitur (feauture engineering)
- Normalisasi, Standardisasi adalah bagain proses atau tahapan yang diperlukan untuk mentransformasi data
- Selain data terstruktur, transformasi data juga krusial dilakukan untuk data yang semi terstruktur dan tidak terstruktur (unstructured) seperi teks, image, audio dan video

TERIWAKASHI