PREDIKSI HARGA TELEVISI DENGAN MENGGUNAKAN PENERAPAN METODE *RANDOM FOREST* DAN *FRAMEWORK FLASK*

TUGAS AKHIR

Disusun Oleh:

RISMITA WAHYU WIDYASTUTI

16611088

PROGRAM STUDI STATISTIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS ISLAM INDONESIA

YOGYAKARTA

2020

HALAMAN PERSETUJUAN PEMBIMBING

TUGAS AKHIR

Judul	:	Prediksi Harga Televisi dengan Menggunakan Penerapan Metode *Random Forest* dan *Framework Flask.*
Nama Mahasiswa	:	Rismita Wahyu Widyastuti
Nomor Mahasiswa	:	16611088

TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI UNTUK DIAJUKAN

Yogyakarta, 29 April 2020

Menyetujui,

Pembimbing

(Dr. Raden Bagus Fajriya Hakim, S.Si., M.Si.)

HALAMAN PENGESAHAN

TUGAS AKHIR

PREDIKSI HARGA TELEVISI DENGAN MENGGUNAKAN PENERAPAN METODE *RANDOM FOREST* DAN *FRAMEWORK FLASK*

Nama : Rismita Wahyu Widyastuti

NIM : 16611088

TUGAS AKHIR INI TELAH DIAJUKAN

PADA TANGGAL 29 April 2020

Nama Penguji	**Tanda Tangan**
1. Dina Tri Utari, S.Si., M.Sc.	.....
2. Tuti Purwaningsih, S.Stat., M.Si	.....
3. Dr. Raden Bagus Fajriya Hakim, S.Si., M.Si.	.....

Mengetahui,
Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Islam Indonesia

Prof. Riyanto, S.Pd., M.Si., Ph.D.

KATA PENGANTAR

بِسْمِ اللَّهِ الرَّحْمَٰنِ الرَّحِيمِ

Assalamu'alaikum Wr.Wb

Alhamdulillahirabbil'alamin, puji syukur penulis panjatkan kehadirat Allah SWT yang Maha Esa, yang telah melimpahkan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan laporan Tugas Akhir ini. Shalawat serta salam penulis haturkan kepada junjungan Nabi Muhammad SAW beserta keluarga, sahabat, dan umatnya.

Laporan Tugas Akhir yang berjudul "Prediksi Harga Televisi dengan Menggunakan Penerapan Metode *Random Forest* dan *Framework Flask*" disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.

Penulis dalam menyelesaikan laporan Tugas Akhir ini banyak mendapatkan bantuan dari berbagai pihak, baik berupa saran, bimbingan maupun bantuan lainnya sehingga dapat memperlancar penyusunan laporan Tugas Akhir ini. Oleh karena itu, dalam kesempatan ini penulis ingin menyampaikan ucapan terima kasih kepada :

1. Bapak Fathul Wahid, S.T., M.Sc., Ph.D. Selaku Rektor Universitas Islam Indonesia
2. Bapak Prof. Riyanto, S.Pd., M.Si., Ph.D. Selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.
3. Bapak Dr. Edy Widodo, S.Si., M.Si. Selaku Kepala Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.
4. Bapak Dr. R. B. Fajriya Hakim, S.Si., M.Si. Selaku Dosen Pembimbing Tugas Akhir atas segala waktu yang diberikan dalam memberikan bimbingan kepada penulis selama proses pengerjaan Tugas Akhir.
5. Seluruh Dosen Pengajar di Program Studi Statistika Universitas Islam Indonesia yang telah memberikan ilmu kepada penulis.
6. Orang tua yang senantiasa memberikan kasih sayang, dukungan dan

doanya sehingga penulis dapat menyelesaikan studi Starta Satu (S1) di Jurusan Statistika, Universitas Islam Indonesia.

7. Rahadyan Nandiwardhana, terima kasih telah menjadi salah satu *support system* di kehidupan penulis.
8. Teman-teman Statistika UII Angkatan 2016 (ARTCOS) yang bersama-sama menjadi pejuang gelar S.Stat.
9. Serta semua pihak lainnya yang tidak bisa dituliskan penulis satu per satu yang telah membantu selama pembuatan Tugas Akhir ini.

Demikian laporan Tugas Akhir ini, penulis mengucapkan terima kasih kepada semua pihak yang telah membantu penulis sehingga laporan Tugas Akhir ini dapat diselesaikan. Penulis menyadari bahwa laporan Tugas Akhir ini masih jauh dari kata sempurna dan masih banyak kekurangan. Oleh karena itu, penulis mengharapkan kritik dan saran yang membangun dari pembaca untuk dapat menyempurnakan penulisan laporan Tugas Akhir ini. Semoga laporan Tugas Akhir ini dapat memberikan manfaat khususnya bagi penulis dan umumnya bagi semua pihak yang membaca. Akhir kata, semoga Allah SWT senantiasa melimpahkan rahmat serta hidayah-Nya.

Wassalamualaikum Wr.Wb

Yogyakarta, 29 April 2020

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN PEMBIMBING ii

HALAMAN PENGESAHAN iii

KATA PENGANTAR iv

DAFTAR TABEL ix

DAFTAR GAMBAR x

PERNYATAAN xii

INTISARI xiii

ABSTRACT xiv

BAB I PENDAHULUAN 1

1.1 Latar Belakang Masalah 1

1.2 Rumusan Masalah 4

1.3 Batasan Masalah 5

1.4 Tujuan Penelitian 5

1.5 Manfaat Penelitian 5

BAB II TINJAUAN PUSTAKA 6

BAB III LANDASAN TEORI 20

3.1 Televisi 20

3.2 Sejarah Televisi 20

3.3 *Artificial Intelligence* 21

3.4 *Machine Learning* 22

3.5 Klasifikasi 24

3.6 Analisis Regresi 24

3.7 *Decision Tree* 25

3.8 *Random Forest* 27
3.8.1 *Tuning Hyperparameter* 29
3.8.2 *K-Fold Cross Validation* 29
3.8.3 *Variable Importance* 30
3.9 Evaluasi Model 30
3.9.1 *Root Mean Square Error* (RMSE) 30
3.9.2 Akurasi 30
3.10 *Scraping Web* 31
3.11 *Website* 31
3.12 *Feature Encoding* 32
3.13 *Framework Flask* 33
3.14 *Heroku* 33
BAB IV METODOLOGI PENELITIAN 34
4.1 Populasi dan Sampel Penelitian 34
4.2 Teknik Pengumpulan Data 34
4.3 Variabel dan Definisi Operasional 34
4.4 Metode Analisis 35
4.5 Tahapan Analisis Data 36
BAB V PEMBAHASAN 37
5.1 Pengumpulan Data 37
5.2 *Pre-processing* Data 78
5.3 Statistika Deskriptif 79
5.4 *Label Encoder* 82
5.5 *Random Forest* 84
5.5.1 *Tuning Hyperparameter* 86
5.6 Tahapan Pembuatan *Website* 90

5.7 *Deploy Website* Menggunakan Heroku 94

BAB VI KESIMPULAN 98

6.1 Kesimpulan 98

6.2 Saran 99

LAMPIRAN 100

DAFTAR PUSTAKA 137

DAFTAR TABEL

Tabel 2.1 Hasil Penelitian Sebelumnya 12
Tabel 4.2 Definisi Operasional Variabel..... 35

DAFTAR GAMBAR

Gambar 1.1 Media Massa yang Paling Banyak Diakses Pada Tahun 2015 2
Gambar 3.1 Perbedaan *Artificial Intelligence, Machine Learning*, dan *Deep Learning* 22
Gambar 3.2 Konsep Dasar *Decision Tree* 26
Gambar 3.3 Ilustrasi Konstruksi Regresi *Random Forest* 28
Gambar 4.1 *Flowchart* Tahapan Penelitian 36
Gambar 5.1 Tampilan Website 37
Gambar 5.2 Proses *Input url Web* yang akan di *Scraping Web* 74
Gambar 5.3 Fungsi Mengambil Data Pada Halaman *Website* 75
Gambar 5.4 *Inspect Element* Variabel Produk, Nama, dan Merek 76
Gambar 5.5 Tampilam *Inspect Element* untuk Variabel Ukuran dan Tipe 77
Gambar 5.6 Tampilam *Inspect Element* untuk Variabel Harga 77
Gambar 5.7 Proses Menyimpan Hasil *Scraping* Menjadi *File csv* 77
Gambar 5.8 Data Hasil *Scraping Website* 77
Gambar 5.9 Langkah *Pre-Processing* Variabel Harga 78
Gambar 5.10 Langkah *Pre-Processing* Variabel Ukuran 79
Gambar 5.11 Langkah *Pre-Processing* Variabel Tipe 79
Gambar 5.12 *Plot* Jumlah Merek Terbanyak 79
Gambar 5.13 *Plot* Jumlah Tipe Layar Terbanyak 80
Gambar 5.14 *Plot* Jumlah Ukuran Layar Terbanyak 80
Gambar 5.15 *Plot* Produk Televisi dengan Harga Jual Termahal 81
Gambar 5.16 *Plot* Merek Televisi dengan Harga Jual Termahal 81
Gambar 5.17 Deskriptif Variabel Harga 82
Gambar 5.18 Mengubah Tipe Data Menjadi *Category* 83
Gambar 5.19 Konversi Variabel Produk, Merek dan Tipe 83
Gambar 5.20 Hasil Konversi Variabel Produk, Merek, dan Tipe 83
Gambar 5.21 Hasil Konversi dengan Metode *Label Encoder* 84
Gambar 5.22 Langkah Penentuan Atribut dan Label 84
Gambar 5.23 Pembagian Data *Training* dan Data *Testing* 85
Gambar 5.24 Pembuatan Model *Random Forest* dengan Parameter *Default* 85
Gambar 5.25 Hasil Model *Random Forest* dengan Parameter *Default* 85

Gambar 5.26 Hasil Pemilihan Sampel Parameter 86
Gambar 5.27 *Tuning Hyperparameter* 87
Gambar 5.28 Parameter Optimal Hasil *Tuning hyperparameter* 87
Gambar 5.29 Model *Random Forest* dengan Parameter Optimal 88
Gambar 5.30 Hasil Evaluasi Model *Random Forest* dengan Parameter Optimal Hasil *Tuning hyperparameter* 88
Gambar 5.31 Penyimpanan Model Menggunakan *Pickle* 89
Gambar 5.32 *Variable Importance* 89
Gambar 5.33 Pembuatan *Form HTML* Variabel Spesifikasi 91
Gambar 5.34 Pembuatan *Form HTML* Variabel Harga 92
Gambar 5.35 Pembuatan *Framework Flask* 92
Gambar 5.36 Pembuatan *Flask* Prediksi 93
Gambar 5.37 Login Ke Heroku 94
Gambar 5.38 Tampilan *Log In to the Heroku CLI* 94
Gambar 5.39 Pembuatan Nama Aplikasi 95
Gambar 5.40 Tampilan *Dashboard* Heroku 95
Gambar 5.41 Proses *Git Init* 95
Gambar 5.42 Proses *Git Remote* 95
Gambar 5.43 Proses *Git Add* 96
Gambar 5.44 Proses *Git Commit* 96
Gambar 5.45 Proses *Git Push Heroku Master* 96
Gambar 5.46 Hasil Prediksi Harga Penjualan Televisi 97

PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan orang lain, kecuali yang diacu dalam naskah ini dan disebutkan dalam daftar pustraka.

Yogyakarta, 29 April 2020

(Rismita Wahyu Widyastuti)

PREDIKSI HARGA TELEVISI DENGAN MENGGUNAKAN PENERAPAN METODE *RANDOM FOREST* DAN *FRAMEWORK FLASK*

Rismita Wahyu Widyastuti

Program Studi Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Islam Indonesia

INTISARI

Dengan adanya perkembangan teknologi informasi dan komunikasi memiliki peranan yang penting bagi masyarakat dalam memenuhi kebutuhan informasi, karena berbagai aspek kehidupan tidak dapat luput dari teknologi informasi dan komunikasi. Media hasil teknologi yang dapat menyampaikan informasi secara massa yaitu media massa. Media massa terbagi menjadi dua jenis yaitu media cetak dan media elektronik. Televisi adalah media massa elektronik yang paling efektif dalam penyebaran informasi menggunakan perpaduan antara media *audio* dan *visual*. Televisi banyak diminati oleh masyarakat Indonesia, karena televisi sebagai media komunikasi yang cepat, relatif murah, dan dapat juga sebagai media hiburan. Tujuan dalam penelitian ini adalah untuk memprediksi harga penjualan televisi dengan mengimplementasi *machine learning* yaitu *Random Forest.* Variabel independen yang digunakan antara lain: nama produk, merek, ukuran layar dan tipe layar, sedangkan variabel dependen adalah harga. *Random Forest* merupakan pengembangan dari *Decision Tree* model *Classification and Regression Tree* (CART). Model *Random Forest* dianalisis dengan bahasa pemrograman *python* dan diaplikasikan menjadi sebuah *website* dengan menggunakan *framework flask.* Berdasarkan hasil analisis *random forest* menggunakan data *training* dan data *testing* dengan perbandingan 75%:25%. Dilakukan pelatihan pertama dengan membuat model *random forest regressor* menggunakan parameter *default* menghasilkan akurasi sebesar 75,75%. Dalam meningkatkan akurasi dilakukan *tuning hyperparameter* untuk mendapatkan parameter optimal antara lain: *n_estimators* (n_{tree}) optimal sebanyak 1.000 pohon dan parameter *max_features* (m_{try}) optimal sebanyak 4 variabel. Dilakukan pelatihan kedua dengan membuat model *random forest regressor* menggunakan parameter optimal hasil *tuning hyperparameter* sehingga didapatkan akurasi sebesar 75,81%.

Kata Kunci: Televisi, *Random Forest, Flask, Machine Learning, Website*

PRICE PREDICTION OF TELEVISION USING RANDOM FOREST ALGORITHM AND FLASK FRAMEWORK

Rismita Wahyu Widyastuti

Statistics Department, Faculty of Mathematics and Natural Science
University Islam Indonesia

ABSTRACT

Development of technology, the role of information and communication technology is very important for the community in meeting information needs because various aspects of life cannot be separated from information technology. Mass media is divided into two types, namely print media and electronic media. Television is the most effective electronic mass media in the dissemination of information using a combination of sound (audio) and image (visual) media. Television is much in demand by the people of Indonesia, because television is a medium of communication that is fast, relatively inexpensive, and can also be a medium of entertainment. The purpose of this research is to predict the price of television sales by implementing machine learning, namely Random Forest. The independent variables used are product name, brand, layer size and layer type, while the dependent variable is price. Random Forest is a development of the Decision Tree model of Classification and Regression Tree (CART). The Random Forest model was analyzed using the python programming language and made into a website using the framework flask and HTML until the deployment process to Heroku. Based on the results of random forest analysis using training data and testing data with a ratio of 75%: 25%. The first random forest model using default parameters resulting in an accuracy of 75.75%. In improving the accuracy use tuning hyperparameter to get optimal parameters, including: n_estimators (n_tree) of 1.000 trees and max_features (m_try) of 4 variables. The second random forest model using the optimal parameters of result tuning hyperparameter so that an accuracy of 75.81%.

***Key Words*:** *Television, Random Forest, Flask, Machine Learning, Website*

BAB I
PENDAHULUAN

1.1 Latar Belakang Masalah

Dengan adanya perkembangan teknologi di bidang informasi dan komunikasi telah membawa perubahan yang berdampak besar dalam berbagai aspek kehidupan manusia. Dalam era globalisasi, peranan teknologi informasi dan komunikasi sangat penting bagi masyarakat dalam memenuhi kebutuhan akan informasi. Hal ini dikarenakan berbagai aspek kehidupan masyarakat tidak dapat luput dari teknologi informasi dan komunikasi. Masyarakat sangat membutuhkan informasi dengan kualitas informasi yang aktual dan akurat dalam pemenuhan kebutuhan informasi dan memperluas pengetahuan. Salah satu sumber informasi yang dapat digunakan untuk memenuhi kebutuhan dalam menyediakan informasi yaitu media massa. Media yang dimaksud adalah hasil teknologi sebagai media komunikasi yang dapat menyampaikan informasi secara massa.

Media massa merupakan sarana penyampaian komunikasi dan informasi dengan penyebarannya kepada khalayak yang bersifat massa dan dapat diakses secara luas. (Wiryanto, 2004). Pengertian media massa dijelaskan bahwa media massa menghasilkan suatu produk informasi berupa berita, hiburan, ruang publik, ekonomi, budaya, dan politik yang dapat diakses oleh semua lapisan masyarakat. Media massa terbagi menjadi dua jenis yaitu media cetak dan media elektronik. Media cetak adalah media komunikasi massa melalui tulisan yang tercetak, seperti surat kabar, majalah, dan buku. Sedangkan media massa elektronik adalah media komunikasi melalui perangkat elektronik seperti televisi dan radio. Berdasarkan kedua jenis media massa tersebut, diketahui bahwa media elektronik lebih diminati oleh masyarakat Indonesia, terutama televisi. Teknologi yang berkembang pesat semakin membuat media massa elektronik memiliki kelebihan yang terletak pada kecanggihan tampilan *visual*, warna dan suara. Media televisi merupakan media elektronik yang banyak diminati oleh masyarakat Indonesia, karena televisi sebagai media komunikasi yang cepat, relatif murah, dan dapat juga sebagai media hiburan yang menarik.

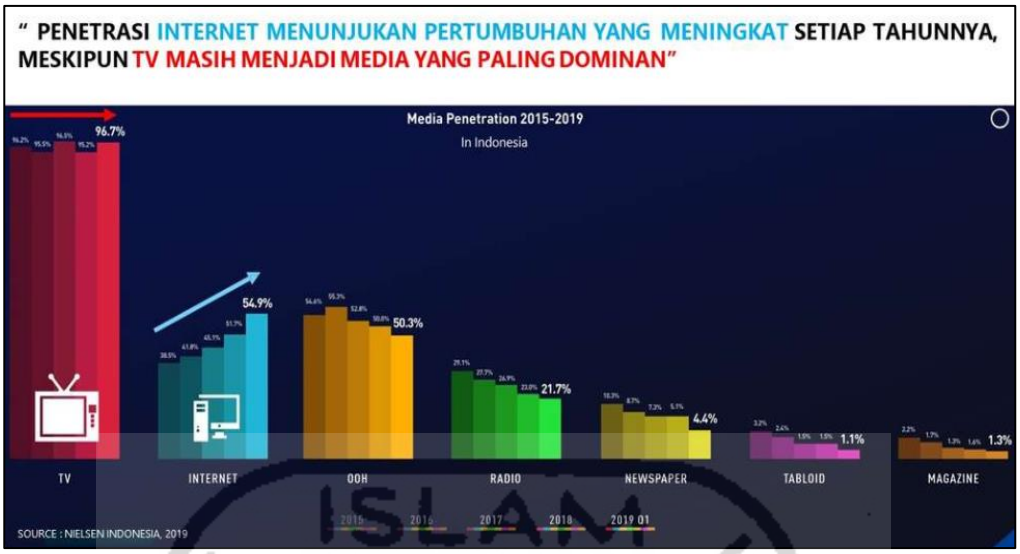

Gambar 1.1 Media Penetrasi yang Diakses Pada Tahun 2015-2019

Sebuah data hasil riset dari Nielsen *Company Consumer Media View* tahun 2019, media penetrasi televisi masih memimpin dengan 96,7% disusul dengan internet (54,9%), media luar ruang (50,3%), radio (21,7%), koran (4,4%), tabloid (1,1%) dan majalah (1,3%). Meski banyak orang yang mengklaim tak lagi menonton televisi, hasil survei yang dilakukan oleh Nielsen menunjukkan hal sebaliknya. Data Nielsen *Consumer Media View & Radio Audience Measurenment* pada kuartal kedua 2019 menunjukkan bahwa mayoritas dari sekitar 17 ribu responden berusia di atas 10 tahun sekitar 96 persen menjawab masih menonton televisi. (Azizah, 2019)

Televisi merupakan salah satu media massa yang paling efektif dalam penyebaran informasi yang penyampaian informasinya menggunakan perpaduan antara media suara (*audio*) dan gambar (*visual*). Televisi merupakan salah satu media massa yang memberikan informasi (fungsi informatif) sehingga masyarakat dapat mengetahui informasi terkini melalui berita yang disiarkan. Sebagai alat yang mendidik (fungsi edukatif) yang dapat memperluas wawasan dan keterampilan. Selain itu, televisi juga sebagai media penghibur (fungsi *entertaintment*) yang dapat memberikan hiburan.

Sejarah televisi lahir karena perkembangan teknologi dalam penemuan hukum gelombang elektromagnetik yang ditemukan oleh Michael Faraday di tahun 1831. Pada tahun 1884, Ilmuan Paul Nipkov dalam gagasannya berhasil menciptakan teleskop elektrik yang menyalurkan sinyal gambar untuk

mengirim gambar elektronik melalui udara. Pada saat itulah Paul Nipkow mendapat julukan sebagai Bapak Televisi. (J.B, Wahyudi, 1983)

Perkembangan teknologi yang mendorong dalam menciptakan inovasi untuk mempermudah pekerjaan manusia di bidang perdagangan. Dengan kemajuan teknologi internet dalam dunia bisnis perdagangan, menjadikan alat untuk mengaplikasikan strategi bisnis melalui internet yang dikenal sebagai *e-commerce* yaitu aktivitas penjualan, pembelian, pemasaran produk dengan jaringan internet. Di Indonesia, perdagangan melalui *e-commerce* semakin meningkat, karena dari sebelumnya semua proses yang dilakukan secara manual berubah menjadi lebih mudah dan cepat dengan mengakses *e-commerce* tanpa perlu mengunjungi toko secara langsung. Salah satu jenis produk yang saat ini juga sudah mulai merambah menggunakan *e-commerce* adalah produk-produk elektronik salah satunya televisi. (Heriyanti, 2018)

Perkembangan teknologi yang berada di era digital, setiap aspek kehidupan manusia sangat berhubungan dengan teknologi komputasi yang diikuti dengan berkembangnya kebutuhan data. Untuk memproses sebuah data, dibutuhkan model untuk menjelaskan data tersebut dengan pengaplikasianya menggunakan *Machine Learning*. *Machine Learning* merupakan salah satu cabang dari ilmu Kecerdasan Buatan (*Artificial Intelegence*) yang kemampuan komputer untuk melakukan pembelajaran tanpa harus menjelaskan secara eksplisit kepada komputer. *Machine learning* merujuk pada sebuah metode yang membuat komputer memiliki kemampuan dalam mempelajari dan melakukan sebuah pekerjaan secara otomatis. (Samuel, 1959).

Salah satu model yang sederhana dan sering digunakan di data science dalam pemodelan prediksi data adalah model *Random Forest.* Definisi *random forest* adalah salah satu metode pengklasifikasian yang terdiri dari kumpulan pohon terstruktur dan setiap pohon memberikan suara (*vote*) untuk menentukan kelas dengan jumlah *vote* terbanyak. Dengan kata lain, *Random Forest* terdiri dari kumpulan *decision tree* yang tidak saling berkorelasi dan digunakan untuk mengklasifikasi data ke dalam suatu kelas. Konsep *random forest* dengan terdapatnya banyak pohon *(tree)* yang dihasilkan yang akhirnya membentuk sebuah hutan (*forest*). Metode ini menghubungkan banyak pohon untuk

membuat klasifikasi dan kelas prediksi. *Random Forest* menjadi salah satu metode klasifikasi populer untuk diimplementasikan di berbagai bidang. (Adnyana, 2016).

Pengembangan *website* adalah menciptakan konsep, membuat, dan mengoperasikan *website*. Dengan perkembangan teknologi saat ini, terdapat banyak alat untuk *web development*, salah satunya adalah *web framework* yang dibuat menggunakan bahasa pemrograman *Python*. *Framework web development* pada *Python* yang paling populer digunakan adalah *Django* dan *Flask*. *Flask* adalah *microframework web python* yang membantu membuat kerangka *website* dan *Flask* dapat digunakan untuk pengembang *website* untuk pemula karena mudah untuk dipelajari dan mudah digunakan. Dalam mengaplikasikan model *machine learning* akan dibuat menjadi sebuah *website application* dengan menggunakan *framework Flask* dan Heroku.

Berdasarkan latar belakang yang telah diuraikan, maka dalam penelitian ini akan dilakukan implementasi *machine learning* dengan menggunakan metode *Random Forest* dan diaplikasikan menjadi sebuah *website application* dengan menggunakan *framework Flask* dan Heroku yang digunakan untuk memprediksi harga televisi di Indonesia.

1.2 Rumusan Masalah

Berdasarkan penjelasan latar belakang, maka rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membuat model *machine learning* dengan mengimplementasikan metode *Random Forest* yang digunakan untuk memprediksi harga televisi?
2. Bagaimana tingkat akurasi yang dihasilkan dengan mengimplementasikan metode *Random Forest* dalam memprediksi harga televisi?
3. Variabel apa yang memberikan pengaruh terbesar dalam mempengaruhi harga televisi?
4. Bagaimana membuat sebuah *website* dengan mengimplementasikan metode *Random Forest* dan *framework Flask* dalam bahasa *Python* yang digunakan untuk memprediksi harga televisi?

1.3 Batasan Masalah

Dalam penelitian ini terdapat beberapa batasan sehingga penelitian dapat lebih spesifik, beberapa batasan masalah yang dimiliki sebagai berikut:

1. *Dataset* yang digunakan adalah data harga penjualan televisi yang didapatkan dengan cara *scrapping web* diambil dari *website* Pricebook.
2. Metode yang digunakan dalam penelitian yaitu metode *Random Forest* yang digunakan untuk memprediksi harga televisi.
3. Dalam penelitian ini menggunakan empat variabel prediktor untuk memprediksi harga televisi antara lain: nama produk, merek, tipe layar, dan ukuran layar (satuan *inch*).
4. Dalam pembuatan *website* menggunakan *framework flask* dengan bahasa pemrograman *Python* dan proses *deploy website* menggunakan Heroku.
5. Alat pendukung dalam penelitian ini adalah *Ms Excel* dan *Python.*

1.4 Tujuan Penelitian

Tujuan dalam penelitian ini sebagai berikut:

1. Mengetahui pembuatan model dengan mengimplementasikan metode *Random Forest* yang digunakan untuk memprediksi harga televisi.
2. Mengetahui tingkat akurasi yang dihasilkan berdasarkan hasil implementasi metode *Random Forest* dalam memprediksi harga televisi.
3. Mengetahui variabel yang memberikan pengaruh terbesar dalam mempengaruhi harga televisi.
4. Mengetahui proses pembuatan *website* dengan mengimplementasikan metode *Random Forest* dan *framework Flask* dalam bahasa pemrograman *Python* yang digunakan untuk memprediksi harga televisi.

1.5 Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah memberikan tambahan wawasan tentang implementasi *machine learning* dalam memprediksi harga televisi dengan menggunakan metode *Random Forest* dan pembuatan *website* dengan menggunakan *framework flask.* Selain itu, dalam penelitian ini juga diharapkan dengan *output* yang dihasilkan berupa *website* dapat membantu masyarakat Indonesia (konsumen) yang ingin membeli televisi sesuai dengan kebutuhan dan harga yang sesuai kemampuan daya beli.

BAB II
TINJAUAN PUSTAKA

Berhubungan dengan penelitian yang sedang dilakukan, diperlukan untuk merujuk beberapa referensi dari penelitian terdahulu dengan tujuan untuk mengetahui hubungan antara penelitian yang penulis lakukan dengan penelitian terdahulu sehingga dapat menghindari suatu duplikasi dalam penelitian yang akan dilakukan.

Penelitian yang dilakukan oleh Agenda Yudha Samudra, mengenai pendekatan *random forest* untuk model peramalan harga tembakau rajangan di Kabupaten Temanggung. Dalam penelitiannya mengenai tidak adanya standarisasi harga dan mutu tembakau menyebabkan harga kerugian di pihak petani dikarenakan untuk menentukan harga tembakau rajangan masih bergantung kepada *grader* pabrik. Oleh karena itu, dalam penelitian ini dibangun perangkat lunak untuk memprediksi harga tembakau rajangan di kabupaten Temanggung dengan menggunakan metode *Random Forest* dan diimplementasikan menggunakan *Python*. Metode *Random Forest* merupakan pengembangan dari CART dengan menerapkan metode *bagging* dan *random feature selection*. Tidak hanya menghasilkan satu pohon tetapi puluhan hingga ratusan pohon dari data *replacement* yang selanjutnya dilakukan pengumpulan informasi sehingga *Random Forest* dapat dihasilkan pohon dengan ukuran yang berbeda-beda. Ini dikarenakan pohon yang dihasilkan oleh dari *bootstrap* dan *replacement* tidak dilakukan pemangkasan. Pada proses klasifikasi, didasarkan pada *vote* dari suara terbanyak pada kumpulan populasi pohon, sedangkan untuk regresi menggunakan hasil rata-rata populasi pohon. Atribut yang digunakan dalam penelitian ini adalah suhu rata-rata, kelembaban rata-rata, curah hujan, lama penyinaran, seri, g*rade* dan harga. Berdasarkan hasil penelitian ini dapat diketahui bahwa dengan menggunakan data iklim dan penjualan tembakau sebanyak 1244 *record*, menunjukkan bahwa hasil prediksi mencapai akurasi 82.39%. (Samudra A. , 2019).

Penelitian yang dilakukan oleh Vanissa Wanika Siburian dan Ika Elvina Mulyana, mengenai prediksi harga ponsel menggunakan metode *random forest*. Dalam penelitiannya mengenai harga ponsel dapat dipengaruhi oleh spesifikasi yang dimiliki ponsel tersebut. Dengan spesifikasi harga dapat ditentukan. Pada

penelitian ini dilakukan klasifikasi untuk memprediksi harga ponsel dengan spesifikasi yang diberikan dengan metode Random Forest. Berdasarkan hasil penelitian ini dapat diketahui bahwa pengklasifikasian ini menggunakan tujuh variabel prediksi dan satu variabel respon menghasilkan akurasi sebesar 81%. Kemudian tingkat akurasi tertinggi pada variabel respon terdapat pada kategori harga murah. (Siburian & Mulyana, 2018).

Penelitian yang dilakukan oleh Reinardus Aji Haristu**,** mengenai penerapan metode *random forest* untuk prediksi *win ratio* pemain *player unknown battleground*. Dalam penelitiannya mengenai strategi bermain yang efektif pada *game Player Unknown Battleground* dengan melakukan penambangan data terhadap data statistic pemain yang diambil dari *website Kaggle*. Dari data tersebut akan dibuat model untuk memprediksi *win ratio* dari setiap pemain menggunakan metode *Random Forest*. Percobaan prediksi *win ratio* dengan metode *Random Forest* menghasilkan akurasi tertinggi sebesar 88.19%. Hasil tersebut didapatkan dengan menggunakan *dataset* statistic Pemain *Player Unknown Battleground* tanpa membuang data *outlier* dan data yang tidak ternomalisasi dengan jumlah *tree* sebanyak 70. Dari model yang berhasil dibuat, atribut yang paling berpengaruh dalam melakukan klasifikasi adalah atribut "solo_KillDeathRatio". (Haristu, 2019)

Penelitian yang dilakukan oleh Syauqi Amri Yahya**,** mengenai klasifikasi ketepatan lama studi mahasiswa menggunakan metode *support vector machine* dan *random forest* (studi kasus: data lama studi alumni Universitas Islam Indonesia tahun kelulusan 2000-2017). Dalam penelitiannya mengenai setiap perguruan tinggi berusaha untuk terus memperbaiki manajemennya, supaya meningkatkan mutu pendidikan dan meningkatkan akreditasi. Salah satu elemen penilaian akreditasi perguruan tinggi adalah lulus tepat waktu. Selain itu, ketepatan lama studi mahasiswa merupakan isu yang penting karena ketepatan tersebut menjadi dasar efektifnya suatu perguruan tinggi. Universitas Islam Indonesia (UII) adalah salah satu perguruan tinggi swasta terkemuka di Indonesia. Sebagai universitas yang sudah cukup tua di Indonesia, UII sudah berakreditas-A dan sudah menghasilkan banyak alumni dari berbagai daerah dan latar belakang. Untuk terus meningkatkan universitas, UII tentunya harus mempertimbangkan juga aspek ketepatan waktu mahasiswanya untuk menempuh lama studi, karena itu merupakan salah satu aspek

penilaian akreditasi dari BAN-PT. Klasifikasi adalah metode untuk memprediksi suatu kejadian atau keputusan yang akan datang berada di suatu titik tertentu. Analisis klasifikasi bisa digunakan untuk memprediksi bahwa seorang mahasiswa dikatakan lulus tepat waktu atau tidak. Metode *Support Vector Machine* (SVM) dan *Random Forest* adalah bagian dari metode klasifikasi. Analisis klasifikasi SVM dan Random Forest dilakukan dengan menggunakan data historis dari alumni UII tahun kelulusan 2000-2017. Berdasarkan hasil penelitian ini dapat diketahui bahwa tingkat akurasi SVM kernel RBF dengan nilai optimum C=1 dan gamma = 1 adalah 77%, akurasi SVM kernel sigmoid dengan nilai optimum C=10, dan gamma = 1 adalah 68%, dan akurasi Random Forest dengan nilai optimum m = 2 dan k = 500 adalah 80%. Oleh karena itu, metode terbaik untuk menentukan ketepatan lama studi mahasiswa UII adalah *Random Forest*. (Yahya, 2018)

Penelitian yang dilakukan oleh Maulana Dhawangkhara dan Edwin Riksakomara, mengenai prediksi intensitas hujan kota Surabaya dengan matlab menggunakan teknik *random forest* dan CART (studi kasus kota Surabaya). Keakuratan prediksi potensi curah hujan di Kota Surabaya dibutuhkan untuk antisipasi bencana akibat hujan seperti banjir bandang, membantu memprediksi kondisi penerbangan dan membantu majaemen saluran sanitasi di Surabaya. Prediksi dilakukan dengan data hari sebelumnya menggunakan perbandingan teknik *Classification and Regression Trees* (CART) dan *Random Forest* (RF) pada data cuaca selama 17 tahun (2000-2016) berasal dari stasiun cuaca Juanda, Surabaya melalui website NCDC yang terdiri dari data suhu udara, titik embun, keepatan angin, tekanan udara, visibilitas dan curah hujan. Evaluasi pembuatan model dengan pengukuran akurasi, precision dan recall menunjukkan bahwa baik metode CART maupun *Random Forest* mampu mengklasifikasi dengan akurasi baik sebesar 78% untuk 4 dari 5 kelas intensitas hujan, dengan kelas terakhir belum mampu diklasifikasi oleh kedua metode. Metode Random forest memiliki nilai performa sedikit lebih baik dibandingkan dengan CART sebesar 6%. Eksperimen *tuning hyperparameter* untuk kedua metode membuktikan performa lebih baik dibandingkan parameter *default* metode dan mampu memberikan kestabilan hasil performa dari segi uji coba proporsi data training dan testing. Variabel yang berpengaruh besar dalam model CART dan random forest dengan nilai uji performa

yang baik antara lain adalah suhu udara, titik embun, suhu udara maksimum dan suhu udara minimum beserta variabel turunannya (selisih suhu udara maksimum dan minimum, selisih suhu udara dan titik embun dan kelembapan relatif). Penelitian ini menghasilkan aplikasi pengklasifikasi intensitas hujan yang memiliki akurasi baik atas kelas intesitas hujan (tidak hujan, ringan, sedang, deras, sangat deras). (Dhawangkhara & Riksakomara , 2017)

Penelitian yang dilakukan oleh Nariswari Karina Dewi dan Utami Dyah Syafitri, mengenai penerapan metode *random forest* dalam *driver analysis*. Penelitian ini menunjukkan bahwa *Random Forest* dapat diaplikasikan dalam bidang biostatistika. Dari hasil penelitian ini menunjukkan penyusunan *driver analysis* berdasarkan MDG menghasilkan *driver analysis* yang stabil jika ukuran *Random Forest* lebih dari 500. Untuk penyusunan *driver analysis* berdasarkan rataan MDG dari 1000 *driver analysis* cukup stabil meskipun menggunakan *Random Forest* dengan ukuran yang kecil. Hasil analisis juga stabil pada ukuran pada contoh peubah penjelas. (Dewi & Syafitri , 2011).

Penelitian yang dilakukan oleh Alfina Nur Firmani, mengenai penyelesaian regresi semiparametrik menggunakan regresi *random forest*. Studi kasus yang digunakan pada penelitian adalah mengestimasi persentase kemiskinan berdasarkan faktor-faktor yang mempengaruhinya. Analisis regresi merupakan analisis yang sering digunakan untuk mengetahui hubungan yang terjadi antara variabel dependen dan independennya. Namun metode ini masih cenderung terbatas pada asumsi dan keadaan data tertentu, terutama dalam penyelesaian regresi semiparametrik. Oleh karena itu muncul metode regresi yang sangat fleksibel dan mudah, yang merupakan pengembangan dari pohon keputusan. Metode ini dinamakan regresi *Random Forest*. Regresi *Random Forest* merupakan gabungan dari banyak CART yang ditumbuhkan sehingga akurasi yang dihasilkan akan lebih akurat dari pohon tunggal. Dari hasil regresi ini didapatkan hasil bahwa faktor angka melek huruf merupakan faktor utama penyebab kemiskinan. Dari hasil tersebut diusulkan saran penanggulangan kemiskinan dengan memfokuskan pada faktor utama, sehingga penekanan jumlah penduduk miskin menjadi lebih efisien. Penelitian ini menunjukkan bahwa Random Forest dapat digunakan untuk menyelesaikan regresi. Hasil penelitian menunjukkan bahwa estimasi presentasse

kemiskinan dan variabel yang paling berpengaruh terhadap presentase kemiskinan adalah angka melek huruf, MSE yang dihasilkan adalah 0.000308. (Firmani, 2016)

Penelitian yang dilakukan oleh Muhammad Irhamna Putra, mengenai sistem rekomendasi kelayakan kredit menggunakan metode *random forest* pada BRI kantor cabang Pelaihari. Penelitian ini melakukan pembahasan tentang penggunaan salah satu algoritma *machine learning* untuk klasifikasi yang bernama *random forest* untuk melakukan prediksi terhadap potensi kelayakan kredit seorang calon nasabah untuk dijadikan acuan dasar oleh bank sebelum diproses lebih lanjut. Permasalahan yang ada pada bank adalah tidak adanya sistem rekomendasi untuk sistem pendukung keputusan yang dapat melakukan perhitungan secara otomatis untuk mengurangi resiko kredit dalam bank, dalam hal ini mencegah adanya potensi kredit macet. untuk itu dibangunlah sebuah sistem rekomendasi atau sistem pendukung keputusan untuk melakukan prediksi potensi kelayakan suatu nasabah sebagai acuan dasar oleh pihak bank agar nantinya dilakukan proses analisa kredit tindak lanjut berdasarkan analisis 5C tentang perbankan yang berbasis *webservice*. Berdasarkan hasil penelitian ini, model perhitungan prediksi yang telah dilakukan *testing* dengan beberapa skenario data *training* menggunakan *record* data tagihan kredit nasabah, memiliki rata – rata ditemui rata – rata hasil *accuracy* sebesar 96,57%%, *precision* sebesar 96,46% dan *recall* sebesar 100%. (Putra M. , 2019)

Penelitian yang dilakukan oleh Anugerah Ganda Putra, mengenai klasifikasi tulisan tangan berupa angka menggunakan *random forest* dan *histogram of oriented gradient*. Penelitian ini melakukan pembahasan tentang membuat mesin atau komputer mngenali tulisan tangan masih merupakan masalah yang terus diteliti di bidang Computer Vision. Angka sendiri tidak bisa dipisahkan dari kehidupan manusia sehingga kemampuan mengenali tulisan tangan berupa angka akan sangat membantu pekerjaan manusia. Berbagai jenis algoritma klasifikasi yang tersedia seperti ANN dan SVM mampu mengenali tulisan tangan, namun kelemahan keduanya terletak pada komplesitas waktu training yang cukup lama Random Forest menjadi salah satu algoritma alternatif dan diuji dalam kasus klasifikasi tulisan tangan berupa angka pada Tugas Akhir ini. Random Forest tidak membutuhkan preprocessing khusus dalam pengimpelementasiannya untuk mencapai akurasi yang bagus. Diuji juga performansi Random Forest menggunakan

fitur ciri Histogram of Gradient yang sering dipakai untuk mengenali objek dalam citra. Hasil pengujian menunjukkan Random Forest dengan jumlah 10 tree dan vektor ciri HOG yang berukuran mampu mengklasifikasi tulisan tangan berupa angka dalam dataset MNIST dengan akurasi bagus yang mencapai 97% dan waktu training sekitar 4 menit. (Putra A. , 2014)

Penelitian yang dilakukan oleh I Made Budi Adnyana, mengenai prediksi lama studi mahasiswa dengan metode *random forest* (studi kasus: STIKOM Bali). Kelulusan tepat waktu merupakan salah satu elemen penilaian akreditasi dari perguruan tinggi. Selain itu wisuda tepat waktu merupakan isu yang penting karena tingkat kelulusan sebagai dasar efektifnya suatu perguruan tinggi. Kurangnya informasi dan analisa yang diperoleh Bidang Akademik STIKOM Bali mengakibatkan sulitnya melakukan prediksi lama studi mahasiswa. Prediksi lama studi mahasiswa dapat membantu Bidang Akademik dalam menyusun strategi yang tepat untuk menekan atau memperpendek lama studi mahasiswa. Pada permasalahan ini dapat diterapkan teknik data mining untuk melakukan prediksi yaitu dengan menggunakan metode klasifikasi Random Forest. Random Forest merupakan suatu kumpulan dari beberapa tree, dimana masing-masing tree bergantung pada nilai piksel pada tiap vektor yang daimbil secara acak dan independen. Data sampel diperoleh langsung dari bagian Akademik STIKOM Bali. Data yang digunakan adalah data lulusan 2 tahun terakhir, meliputi IPK, SKS, jumlah cuti dan non-aktif, nilai mahasiswa, dan lama studi mahasiswa. Output dari sistem ini berupa klasifikasi yang terdiri dari 2 kelas, yaitu lulus tepat waktu dan lulus lewat batas waktu. Dari hasil eksperimen diperoleh nilai akurasi adalah 83.54%. (Adnyana, 2016)

Tabel 2.1 Hasil Penelitian Sebelumnya

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
1	Agenda Yudha Samudra	Pendekatan *Random Forest* Untuk Model Peramalan Harga Tembakau Rajangan Di Kabupaten Temaggung	2019	- Dalam penelitiannya dibangun perangkat lunak untuk memprediksi harga tembakau rajangan di kabupaten Temanggung dengan menggunakan metode *Random Forest* dan diimplementasikan menggunakan *Python*. - Berdasarkan hasil penelitiannya dengan menggunakan data iklim dan penjualan tembakau menghasil prediksi akurasi sebesar 82.39%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitiannya berupa peramalan harga tembakau rajangan di Kabupaten Temaggung. - Perbandingan pembagian data *training* dan data *testing* sebesar 70%:30%. - Pembangunan *random forest* menggunakan parameter *bootstrap = true* dan *n_estimators*. - Jumlah pohon optimal adalah 64 pohon. - Hasil akurasi prediksi sebesar 82,39%.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
2	Vanissa Wanika Siburian dan Ika Elvina Mulyana	Prediksi Harga Ponsel Menggunakan Metode *Random Forest*	2018	- Dalam penelitiannya prediksi harga ponsel yang dipengaruhi oleh spesifikasi yang dimiliki dan klasifikasi untuk memprediksi harga ponsel dengan metode *Random Forest*. - Hasil klasifikasi mengunakan 7 variabel prediksi dan 1 variabel respon dan hasil akurasi sebesar 81%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitiannya: prediksi harga ponsel. - Perbandingan pembagian data *training* dan data *testing* sebesar 70%:30%. - Variabel respon dengan *range price* murah, standar, mahal dan sangat mahal. - Hasil akurasi prediksi sebesar 81%.
3	Reinardus Aji Haristu	Penerapan Metode *Random Forest* Untuk Prediksi *Win Ratio* Pemain *Player Unknown Batleground*	2019	- Penelitian model prediksi *win ratio* dari setiap pemain dengan *Random Forest.* - Akurasi tertinggi dari hasil prediksi *Random Forest* adalah 88,19%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitian : prediksi *win ratio* pemain PUBG. - Jumlah pohon optimal adalah 70 pohon. - Hasil akurasi sebesar 88,19%.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
4	Syauqi Amri Yahya	Klasifikasi Ketepatan Lama Studi Mahasiswa Menggunakan Metode *Support Vector Machine* dan *Random Forest* (Studi Kasus: Data Lama Studi Alumni Universitas Islam Indonesia Tahun Kelulusan 2000-2017)	2018	- Dalam penelitiannya memprediksi mahasiswa UII lulus tepat waktu atau tidak dengan SVM dan *Random Forest*. - Hasil akurasi SVM kernel RBF dengan C=1 dan gamma = 1 adalah 77%, akurasi SVM kernel sigmoid dengan C=10, dan gamma = 1 adalah 68%, dan akurasi *Random Forest* dengan m = 2 dan k = 500 adalah 80%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitian : prediksi ketepatan lama studi mahasiswa UII. - Perbandingan SVM dengan parameter C dan gamma, *random forest* dengan *ntree* (k) dan jumlah variabel (m). - Hasil akurasi optimal SVM kernel RBF dengan C=1 dan gamma=1 adalah 77%, akurasi SVM kernel sigmoid dengan C=10, dan gamma = 1 adalah 68%, dan akurasi *Random Forest* dengan m = 2 dan k = 500 adalah 80%.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
5	Maulana Dhawangkhara dan Edwin Riksakomara	Prediksi Intensitas Hujan Kota Surabaya dengan Matlab Mengunakan Teknik Random Forest dan CART (Studi kasus Kota Surabaya)	2017	- Dalam penelitiannya bertujuan untuk memprediksi kondisi penerbangan dan membantu manajemen saluran sanitasi di Surabaya. Prediksi dengan data cuaca selama 17 tahun (2000-2016) dari stasiun cuaca Juanda dengan menggunakan CART dan *Random Forest*. - Hasil akurasi tertinggi dengan *random forest* sebesar 78%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitian : prediksi kelas intesitas hujan (tidak, ringan, sedang, lebat, sangat lebat) - Kombinasi parameter model terbaik dengan akurasi tertinggi klasifikasi kelas 0,1,2,3, untuk CART dengan *leaf* (1-5) dan *parent* (30). Untuk *random forest* dengan jumlah variabel acak (6) dan jumlah pohon (10). - Hasil akurasi prediksi dengan CART sebesar 0,72% dan *Random Forest* sebesar 0,78 %.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
6	Nariswari Karina Dewi dan Utami Dyah Syafitri	Penerapan Metode *Random Forest* Dalam *Driver Analysis*	2011	- *Driver analysis* dilakukan untuk memahami pengaruh peubah penjelas terhadap respons sehingga diketahui prioritas setiap peubah penjelas dalam menggerakkan peubah respons. - Penyusunan *driver analysis* dengan MDG menghasilkan *driver analysis* yang stabil jika *random forest* lebih dari 500. *Random forest* dengan peubah penjelas sebesar 4 dan memberikan akurasi tingkat misklasifikasi berkisar antara 33% dan 35.5% dengan nilai rataannya sebesar 34.5%.	Menggunakan metode analisis yang sama yaitu *Random Forest.*	- Objek penelitian tentang *driver analysis* dengan peubah respon status kesediaan untuk membeli produk dan peubah penjelasnya status setuju tehadap produk - *Driver analysis* dengan stabil MDG terbaik saat k lebih dari 500 pohon dan jumlah peubah penjelas = 4. - Tingkat misklsifikasi terendah akurasi *random forest* antara 33% - 35.5%, dan pemusatan rataan 34.5%.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
7	Alfina Nur Firmani	Penyelesaian Regresi Semi Parametrik dengan Mengunakan Regresi *Random Forest*	2019	- Dalam penelitiannya mengetahui persentase kemiskinan dan faktor-faktor yang mempengarhinya. Nilai prediksi terbaik dengan *m* = 2 dan jumlah pohon 200 dan MSE sebesar 0,000308	Menggunakan metode analisis yang sama yaitu *Random Forest*	- Objek penelitian : prediksi faktor-faktor yang mempengaruhi kemiskinan. - Model *random forest* optimal dengan jumlah peubah penjelas = 2 dan jumlah pohon = 200.
8	Muhammad Irhamna Putra	sistem rekomendasi kelayakan kredit mengunakan metode *random forest* pada BRI kantor cabang Pelaihari	2019	- Penelitian ini penggunaan *random forest* melaukan prediksi terhadap potensi kelayakan kredit calon nasabah berdasarkan usia, alamat, pekerjaan, jumlah pinjaman, dan jangka waktu. - Hasil rata-rata *accuracy* sebesar 96,57%, *precision* sebesar 96,46% dan *recall* sebesar 100%.	Menggunakan metode analisis yang sama yaitu *Random Forest*	- Objek penelitian : prediksi potensi kelayakan kredit calon nasabah lancar atau kurang. - *Random forest* dengan jumlah pohon = 10. - Hasil *acuracy*, *precision*, dan *recall* = 96,57%, 96,46% dan 100%.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
9	Anugerah Ganda Putra	Klasifikasi Tulisan Tangan Berupa Angka Mengunakan *Random Forest* dan *Histogram Of Oriented Gradient*	2014	- Random Forest diuji kasus klasifikasi dan *Histogram of Gradient* untuk mengenali objek dalam citra tulisan tangan berupa angka dari dataset MNIST. - Pengujian jenis vector ciri menggunakan HOG menghasilkan akurasi lebih baik. - Jumlah tree yang paling akurat =15 dengan akurasi 97,29%. - Parameter jumlah atribut yang diseleksi secara acak dan jumlah data minimum splitting, tidak terlihat hubungan dengan akurasi klasifikasi.	Menggunakan metode analisis yang sama yaitu *Random Forest*	- Objek penelitian : klasifikasi tulisan tangan angka MNIST. - Tahap ektraksi citra angka dengan HOG menghasilkan akurasi lebih baik. - Jumlah tree paling akurat dan efesien waktu = 15 dengan akurasi97,29% - Parameter jumlah atribut secara acak dan jumlah data minimum *splitting* tidak ada hubungan dengan akurasi karena tidak mempengaruhi secara signifikan.

No	Nama Peneliti	Judul Penelitian	Tahun	Hasil Penelitian	Perbandingan	
					Persamaan	Perbedaan
10	I Made Budi Adnyana	Prediksi Lama Studi Mahasiswa Dengan Metode *Random Forest* (Studi Kasus: STIKOM Bali)	2016	- Prediksi lama studi mahasiswa STIKOM Bali dengan metode *Random Forest*. - Data diperoleh dari Akademik STIKOM Bali. Data yang digunakan adalah data lulusan 2 tahun terakhir, meliputi IPK, SKS, jumlah cuti dan non-aktif, nilai mahasiswa, dan lama studi mahasiswa. - *Output* klasifikasi terdiri dari 2 kelas, yaitu lulus tepat waktu dan lulus lewat batas waktu. - Hasil eksperimen diperoleh nilai akurasi adalah 83.54%.	Menggunakan metode analisis yang sama yaitu *Random Forest*	- Objek penelitian : prediksi lama studi mahasiswa kelulusan STIKOM Bali. - Perbandingan data *training* dan data *testing* sebesar 60%:40%. - Pengujian random forest dengan 10 *tree* dan jumlah peubah 3 fitur. - Hasil akurasi kelas Lulus Tepat Waktu sebesar81,81% dan akurasi kelas Lulus Lewat Waktu Studi sebesar 84,98%. Hasil akurasi keseluruhan sebesar 83.54%.

BAB III
LANDASAN TEORI

3.1 Televisi

Definisi televisi secara etimologi, televisi terbentuk dari kata *tele* yang berarti "jarak" dalam bahasa Yunani dan kata *visi* yang berarti "citra atau gambar" dalam bahasa Latin. Jika digabungkan, maka televisi memiliki makna yaitu suatu sistem penyajian gambar dan suara dari suatu tempat yang berjarak jauh. Sedangkan definisi televisi secara terminologi yaitu sistem yang menggunakan peralatan yang mengubah cahaya dan suara ke dalam gelombang elektrik dan mengubahnya kembali menjadi berkas cahaya yang dapat dilihat dan suara yang dapat didengar. (Sutisno, 1993)

3.2 Sejarah Televisi

Cikal bakal penemuan televisi terlahir adanya perkembangan teknologi informasi dan komunikasi. Dengan seiringnya kemajuan teknologi digital membuat televisi yang mengalami perkembangan. Awal mula terlahirnya televisi tidak dapat dipisahkan dari penemuan hukum gelombang elektromagnetik yang ditemukan oleh Joseph Henry dan Michael Faraday di tahun 1831. Sejak ditemukannya hukum gelombang elektromagnetik, penemuan dasar televisi berkembang pesat yang dikembangkan oleh banyak penemu di dunia.

Pada tahun 1884, Ilmuan Paul Nipkov dalam gagasannya berhasil menciptakan teleskop elektrik yang menyalurkan sinyal gambar untuk mengirim gambar elektronik melalui udara dengan menggunakan kepingan logam. Pada tahun 1897, terlahirlah televisi tabung *Cathoda Ray Tube* (CRT) hitam putih pertama yang diciptakan oleh ilmuwan Karl Ferdinand Braun yang dibuat dengan layar berpendar apabila terkena sinar. Televisi tabung dilakukan penyempurnaan hingga pada tahun 1940 terciptalah televisi tabung berwarna oleh Peter Goldmark. Setelah peristiwa Perang Dunia II berkahir, kemajuan teknologi yang berkembang pesat membuat permintaan televisi meningkat. Memasuki era digital ditandai dengan munculnya televisi digital (berbasis komputer). Pada tahun 1964,

prototype sel tunggal *display* televisi plasma pertama kali diciptakan oleh Donald Bitzer dan Gene Slottow. Pada tahun 1975, Larry Weber berhasil menciptakan televisi layar plasma yang lebih stabil dan berwarna. Selanjutnya ilmuan Walter Spear dan Peter Le Comber membuat display warna *Liquid Crystal Display* (LCD) dari bahan *thin film transfer* yang ringan. Para ilmuwan dari perusahaan Kodak di tahun 1979, berhasil menciptakan tampilan televisi dengan teknologi *Organic Light Emitting Diode* (OLED) dan mematenkan OLED sebagai peralatan *display* pertama kali pada tahun 1987. Memasuki abad 20, penemuan dan inovasi televisi layar semakin disempurnakan, baik layar dengan teknologi LCD, Plasma maupun LED. (J.B, Wahyudi, 1983)

Televisi merupakan gabungan dari suara dan gambar yang bersifat informatif, hiburan, dan pendidikan, atau bahkan gabungan dari ketiga unsur tersebut. Informasi yang disampaikan oleh televisi, akan lebih mudah dimengerti karena informasi diterima dengan terdengar secara audio dan terlihat secara visual. Televisi pada umumnya menyiarkan informasinya secara massa. (Ardianto, 2007)

3.3 *Artificial Intelligence*

Kecerdasan Buatan (*Artificial Intelligence*) adalah bidang ilmu komputer yang mempelajari bagaimana menjadikan komputer dapat berfikir dan bekerja seperti dan sebaik yang dilakukan oleh manusia. *Artificial Intelligence* merupakan teknologi yang meliputi pemrograman komputer dengan mesimulasikan kecerdasan manusia untuk penyelesaian suatu masalah dengan meniru bagaimana cara pemikiran manusia.

Menurut McCarthy (1956), *artificial intelligence* adalah suatu sistem komputer yang bertujuan untuk mengetahui atau memodelkan proses berpikir manusia dan mendesain mesin sehingga bisa menirukan perilaku manusia. *Artificial Intelligence* (AI) merupakan salah satu disiplin ilmu yang luas yang terbagi menjadi beberapa pengaplikasian antara lain: pengolahan bahasa alami (*Natural Language Processing*), sistem pakar (*Expert System)*, pengenalan ucapan (*Speech Recognition*), robotika dan sistem sensor, dan *computer vision.*

Artificial Intelligence adalah suatu cara untuk menjadikan komputer berpikir secerdas manusia dengan tujuan untuk komputer dapat memiliki kemampuan berperilaku, berpikir, dan mengambil keputusan layaknya manusia. Dengan kemajuan perkembangan *Artificial Intelligence* secara signifikan melahirkan dua konsep kecerdasan buatan yaitu *machine learning* dan *deep learning*. *Artificial Intelligence* diibaratkan payung yang lebih luas, *Machine Learning* merupakan cabang ilmu dari *Artificial Intelligence* dan *Deep Learning* berada di dalam lingkup *Machine Learning*. Secara visualisasi digambarkan pada Gambar 3.1 yang menunjukkan *Artificial Intelligence* merupakan bidang ilmu terbesar, kemudian *Machine Learning* adalah bagian dari *Artificial Intelligence*, dan *Deep Learning* adalah bagian dari *Machine Learning*.

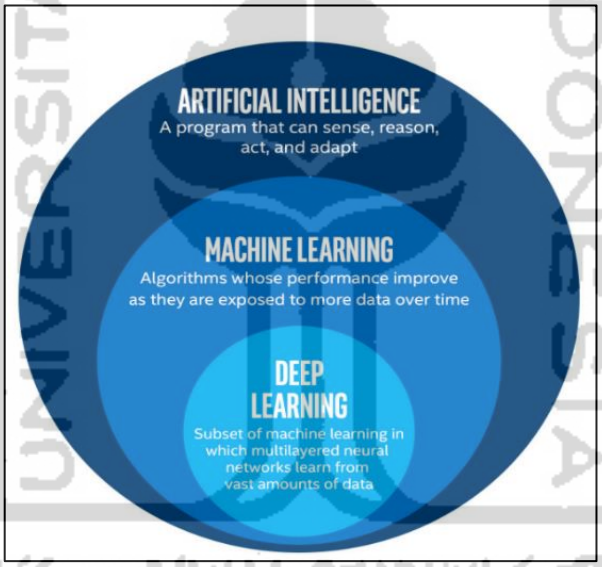

(Sumber: Towards Data Science)

Gambar 3.2 Perbedaan *Artificial Intelligence, Machine Learning,* dan *Deep Learning*

3.4 *Machine Learning*

Machine Learning merupakan salah satu cabang dari ilmu Kecerdasan Buatan (*Artificial Intelegence*) yang kemampuan komputer untuk melakukan pembelajaran tanpa harus menjelaskan secara eksplisit kepada komputer. *Machine learning* merujuk pada sebuah metode yang membuat komputer memiliki kemampuan dalam mempelajari dan melakukan sebuah pekerjaan secara otomatis. Proses *machine learning* dilakukan melalui algoritma tertentu, sehingga pekerjaan yang diperintahkan kepada komputer dapat

dilakukan secara otomatis. Algoritma semacam ini bekerja dengan cara membangun sebuah model dari *input* untuk dapat menghasilkan suatu prediksi atau pengambilan keputusan berdasarkan data yang ada.

Machine Learning merupakan sebuah pemrograman komputer yang digunakan untuk mengoptimalkan performa sebuah pekerjaan menggunakan beberapa contoh data atau *experience* masa lalu. Peneliti memiliki sebuah model yang didefinisikan dengan satu atau beberapa buah parameter, sedangkan proses pembelajaran atau *learning* dilakukan dengan pemrograman komputer untuk mengoptimalkan parameter dari model menggunakan data *training* atau *experience* masa lalu. Model memungkinkan untuk digunakan dalam memprediksi permasalahan kedepan atau analisis deskriptif untuk mendapatkan pengetahuan dari data. (Alpaydin, 2010).

Machine learning menggunakan teori statistika untuk membangun model matematis. Hal ini didasarkan pada tujuan yang ingin dicapai yaitu mengambil kesimpulan dari sampel data. Peran *computer science* terbagi menjadi dua bagian yaitu *Training* yang peneliti membutuhkan algoritma yang efisien untuk menyelesaikan permasalahan dengan optimal. Dan *Testing* setelah model dapat dilatih, representasi dan solusi algoritmiknya untuk inferensi juga harus efisien, sehingga perlu dilakukan pengujian akurasi prediksi. Dalam pembelajaran *machine learning*, terdapat beberapa tipe algoritma *machine learning* antara lain: (Russel & Norvig, 1995).

1. *Supervised Learning*

   Pada *supervised learning*, data yang dimiliki dilengkapi dengan label yang menunjukkan kelompok data tersebut. Algoritma yang belajar berdasarkan sekumpulan contoh pasangan masukan dan keluaran yang diinginkan. Model yang dihasilkan adalah model prediksi dari data yang telah diberi label dengan memetakan masukan yang baru menjadi keluaran yang tepat.

2. *Unsupervised Learning*

   Pada *Unsupervised Learning*, data pembelajaran tidak memiliki label sehingga harus mencari struktur atau pola dari data yang ada, kemudian melakukan pengelompokan berdasarkan informasi yang dimiliki.

Setelah itu mencoba untuk mengelompokan data berdasarkan karakteristik yang ditemui. Salah satu algoritma *unsupervised learning* yang paling umum digunakan adalah *clustering.*

3. *Reinforcement Learning*

   Pada skenario *reinforcement learning* fase pembelajaran dan tes saling dicampur. Untuk mengumpulkan informasi pembelajar secara aktif dengan berinteraksi ke lingkungan sehingga untuk mendapatkan balasan untuk setiap aksi dari pembelajar.

3.5 Klasifikasi

Klasifikasi adalah proses untuk menemukan model atau fungsi yang dapat menjelaskan atau membedakan konsep atau kelas data. Tujuan klasifikasi adalah untuk memperkirakan kelas dari suatu objek yang labelnya tidak diketahui. Proses klasifikasi biasanya dibagi menjadi dua fase yaitu *fase learning* dan *fase test*. Pada *fase learning*, sebagian data yang telah diketahui kelas datanya diumpankan untuk membentuk model perkiraan. Kemudian pada *fase test* model yang sudah terbentuk diuji dengan sebagian data lainnya untuk mengetahui akurasi dari model. Teknik ini dapat memberikan klasifikasi pada data baru dengan memanipulasi data yang ada yang telah diklasifikasi. (Ulwan, 2016).

3.6 Analisis Regresi

Analisis regresi adalah persamaan matematik yang dapat meramalkan nilai suatu variabel tak bebas dari nilai variabel bebas (Walpole R. , 1992). Analisis regresi adalah salah satu metode statistik yang digunakan secara luas pada ilmu terapan untuk menyelesaikan masalah sebab-akibat yang digunakan untuk mempelajari hubungan antara satu variabel dengan variabel lainnya. Analisis regresi bertujuan untuk menentukan hubungan antara dua variabel atau lebih, sehingga dapat mengetahui pola hubungannya. Analisis regresi dapat digunakan untuk mengetahui bagaimana variabel bebas mempengaruhi variabel tak bebas, sehingga dapat memprediksi perubahan variabel tak bebas apabila diberikan nilai variabel bebas. Pada dasarnya analisis regresi sebagai kajian terhadap hubungan satu variabel yang diterangkan dengan satu atau lebih variabel yang menerangkan.

Analisis regresi terdapat tiga pendekatan antara lain: regresi parametrik, regresi non-parametrik dan regresi semiparametrik. Regresi parametrik

mengasumsikan hubungan antara variabel prediktor dan variabel dependen diketahui seperti linear, kubik, polynomial, eksponensial dan lain-lain. Regresi non-parametrik digunakan sebagai alternatif untuk mengatasi masalah pola hubungan antar variabel yang tidak diketahui hubungannya serta tidak memperhatikan asumsi. Regresi semiparametrik merupakan kombinasi dari regresi parametrik dan non-paramterik. Namun pendekatan semiparametrik belum dapat memberikan solusi secara menyeluruh karena tergolong tidak sederhana dan memiliki asumsi yang harus dipenuhi.

Perkembangan kemajuan teknologi komputasi, menemukan solusi algoritma yang dapat mengatasi permasalahan regresi dengan pola hubungan yang tidak diketahui dan masih cenderung terbatas pada asumsi dan keadaan data tertentu, terutama dalam penyelesaian regresi semiparametrik. Oleh karena itu muncul metode regresi yang sangat fleksibel dan mudah, yang merupakan pengembangan dari pohon keputusan yaitu *Random Forest*. *Random forest* adalah algoritma gabungan klasifikasi dan regresi yang menjadi bagian dari kelompok *ensemble learning* yang dapat memecahkan masalah regresi dengan fleksibel dan menghasilkan akurasi prediksi yang lebih baik.

3.7 *Decision Tree*

Pohon keputusan (*Decision tree*) merupakan metode klasifikasi yang menggunakan ilustrasi struktur pohon. Metode *Decision tree* merupakan metode klasifikasi yang paling popular digunakan karena hasil model yang dibangun lebih mudah untuk diinterpretasi oleh manusia. Hal ini dikarenakan pemetaan yang terbentuk mirip dengan bentuk pohon dalam alternatif-alternatif pemecahan masalah. Dengan visualisasi percabangan pohon dapat memperlihatkan faktor-faktor probabilitas yang mempengaruhi keputusan dan hasil akhir dalam mengambil alternatif keputusan tersebut.

Decision Tree merupakan suatu metode klasifikasi yang menggunakan struktur pohon dan setiap *node*nya merepresentasikan atribut dan cabangnya merepresentasikan nilai dari atribut, sedangkan daunnya digunakan untuk merepresentasikan kelas. Metode ini merupakan metode yang mudah untuk

dipahami, dinamakan pohon keputusan karena aturan yang terbentuk mirip dengan bentuk pohon. (Bernard, Heutte, & Adam, 2009).

Pohon *(tree)* adalah sebuah struktur data yang terdiri dari simpul *(node)* dan rusuk *(edge). Decision tree* adalah sebuah diagram alir yang berbentuk struktur pohon, setiap *internal node* menunjukan pengujian terhadap atribut, setiap cabang menunjukan hasil pegujian dan *leaf node* menunjukan kelas. *Node* yang teratas adalah *root node* yang tidak memiliki *edge* masuk tapi memiliki beberapa *edge* keluar. Pada *internal node* akan memiliki satu *edge* masuk dan beberapa *edge* keluar, sedangkan *leaf node* hanya akan memiliki satu *edge* masuk tanpa memiliki *edge* keluar. (Hermawati, 2013).

Konsep dari *decision tree* adalah mengklasifikasikan data yang belum diketahui kelasnya lalu dimasukan ke dalam prediksi kelas dengan pemetaan proses pengambilan keputusan, sehingga pengambil keputusan akan lebih menginterpretasikan solusi dari permasalahan. Pada *decision tree* memiliki 3 jenis *node* antara lain:

1. *Root Node* merupakan node teratas dengan tidak memiliki *input* dan bisa memiliki *output* lebih dari satu.
2. *Internal Node* merupakan *node* percabangan, pada *node* ini hanya memiliki satu *input* dan memiliki *output* minimal dua.
3. *Leaf node* merupakan *node* akhir yang hanya memiliki satu *input* dan tidak mempunyai *output*, dan pada *leaf node* terdapat keputusan akhir.

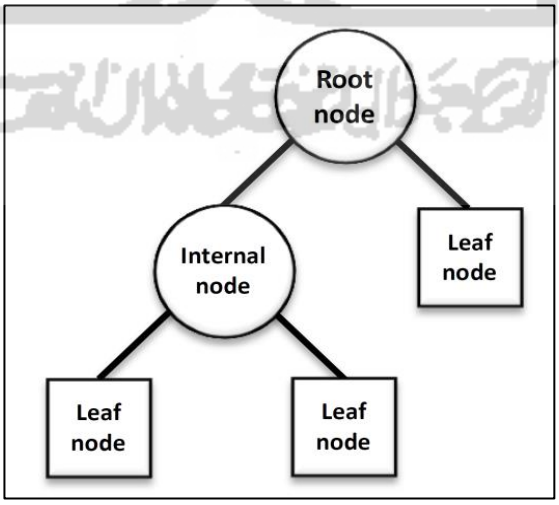

(Sumber: researchgate.net)

Gambar 3.3 Konsep Dasar *Decision Tree*

3.8 *Random Forest*

Random Forest pertama kali tahun 2001 diperkenalkan oleh Breiman. *Random Forest* adalah algoritma yang digunakan untuk menyelesaikan klasifikasi dan regresi berdasarkan agregasi sejumlah pohon keputusan. *Random Forest* adalah pengembangan lebih lanjut dari *Classification and Regression Tree* (CART) yang menerapkan *Bootstrap Aggregating* (*Bagging)* dan *Random Feature Selection*. *Random Forest* menjadi metode klasifikasi populer untuk diimplementasikan di berbagai bidang. Model *random forest* sering dipakai untuk masalah klasifikasi seperti prediksi karena *random forest* bekerja lebih efisien khususnya menggali informasi pada data yang berukuran besar, model relatif cukup efektif untuk data diskrit dan data kontinu, algoritma klasifikasi yang dikenal mampu mencapai akurasi yang bagus tanpa melakukan pencarian yang banyak pada parameter, efektif ketika berhadapan dengan data yang memiliki *missing value*, mampu menghasilkan keputusan kompleks menjadi lebih sederhana dan membangun lebih dari satu pohon keputusan sehingga memungkinkan untuk meningkatkan hasil prediksi. (Breiman, 2001).

Teknik dasar *Random Forest* adalah *decision tree*. Pada *decision tree*, data dimasukan pada bagian *root node* kemudian dilanjutkan ke *leaf node* untuk menentukan suatu kelas prediksi. *Random forest* adalah salah satu metode pengklasifikasian yang terdiri dari kumpulan pohon terstruktur dan setiap pohon memberikan suara (*vote*) untuk menentukan kelas dengan jumlah *vote* terbanyak. Dengan kata lain, *Random Forest* terdiri dari kumpulan *decision tree* yang tidak saling berkorelasi dan digunakan untuk mengklasifikasi data ke dalam suatu kelas. Konsep *random forest* dengan terdapatnya banyak pohon *(tree)* yang dihasilkan yang akhirnya membentuk sebuah hutan (*forest*). Algoritma *random forest* merupakan algoritma yang tidak memiliki pemangkasan variabel seperti pada algoritma *decision tree*. Metode ini menghubungkan banyak pohon untuk membuat klasifikasi dan kelas prediksi. Pada *random forest* pembuatan pohon dilakukan dengan cara melakukan pelatihan sampel data. Variabel digunakan untuk menentukan pemisahan (*split*) terbaik ditentukan secara acak dengan cara *voting* dari masing-masing pohon (*tree*), sehingga kelas dengan jumlah *vote* terbanyak

akan menjadi kelas pemenang keputusan. *Random Forest* merupakan sebuah metode *ensemble* yang merupakan cara untuk meningkatkan akurasi metode klasifikasi dengan cara mengkombinasikan metode klasifikasi. Klasifikasi berbasis *ensemble* akan mempunyai performa yang maksimal jika antar *basic learner* mempunyai korelasi yang rendah. Sebuah *ensemble* harus membangun *basic learner* yang lemah, karena *learner* yang kuat kemungkinan besar akan mempunyai korelasi yang tinggi dan biasanya juga menyebabkan *overfitting*, sedangkan *random forest* meminimalkan korelasi serta mempertahankan kekuatan klasifikasi dengan cara melakukan pengacakan pada proses *training*, yaitu dengan memilih sejumlah fitur secara acak dari semua fitur yang ada pada setiap melakukan *training tree*, kemudian menggunakannya menggunakan fitur-fitur yang terpilih untuk mendapatkan percabangan *tree* yang optimal. (Han, 2001).

Bagging atau *Bootstrap Aggregating* merupakan metode yang dapat memperbaiki hasil dari *algorithm* klasifikasi. *Bagging* merupakan salah satu metode yang berdasarkan pada *ensemble method*, yaitu metode yang menggunakan kombinasi dari beberapa model. *Bagging* prediktor adalah metode yang digunakan untuk membangkitkan *multiple version* dari prediktor dan menggunakannya untuk mendapatkan kumpulan prediktor, *multiple version* dibentuk dari replikasi *(replacement) bootstrap* dari sebuah data percobaan atau data *train*. (Breiman, 1996).

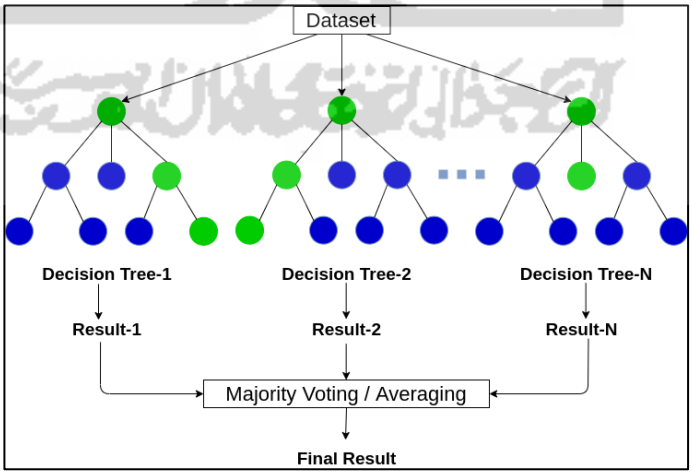

(Sumber: medium)

Gambar 3.4 Ilustrasi Konstruksi Regresi *Random Forest*

3.8.1 *Tuning Hyperparameter*

Dilakukannya *tuning* (penyetelan) parameter pada pemodelan dengan *Random Forest* bertujuan untuk meningkatkan kemampuan prediksi atau membuat lebih mudah untuk melakukan pelatihan pada model. Regresi *Random Forest* terdapat dua parameter yang yang dapat disesuaikan dan dilakukan *tuning* yaitu jumlah pohon (n_{tree}) dan jumlah fitur acak untuk setiap *split* (m_{try}) pada hutan yang akan dibangun. (Liaw & Wiener, 2002). *Tuning hyperparameter* adalah nilai parameter *Random Forest* yang harus dioptimalkan sehingga dapat meningkatkan hasil prediksi dibandingkan dengan *default* parameter.

Banyaknya jumlah pohon (n_{tree}) adalah salah satu parameter regresi *Random Forest* yang dapat dioptimalkan untuk mendapatkan hasil prediksi yang optimal. Salah satu sentral parameter dari *Random Forest* adalah jumlah fitur acak untuk setiap *split* (m_{try}), yang didefinisikan sebagai jumlah kandidat fitur pada setiap pemisahan merupakan parameter yang nilai optimalnya tergantung pada *dataset* yang terpilih ketika membangun *tree*. Pada metode pemilihan jumlah fitur acak yang disarankan Breiman yaitu $\sqrt{p}$ untuk klasifikasi dan *p/3* untuk regresi, dan *p* adalah jumlah fitur.

3.8.2 *K-Fold Cross Validation*

Cross-validation (CV) adalah metode yang digunakan untuk mengevaluasi kinerja model. Teknik *Cross Validation* digunakan untuk melakukan prediksi model dan memperkirakan seberapa akurat sebuah model prediksi. Dalam masalah prediksi, model biasanya diberikan *dataset* yang diketahui untuk digunakan dalam menjalankan *dataset* pelatihan terhadap *dataset* pengujian. Cara kerja *K-fold cross validation* yaitu dengan mengelompokkan data latih dan data uji yang saling terpisah, kemudian melakukan pengujian yang diulang sebanyak *K* kali.

K-fold adalah metode *Cross Validation* yang popular. Metode standar untuk evaluasi yaitu *10-fold cross-validation* dengan nilai *k*=10 sangat umum diterapkan di bidang *machine learning* dan banyak hasil eksperimen menunjukan bahwa menggunakan *k*=10 adalah pilihan terbaik untuk mendapatkan estimasi hasil prediksi yang akurat. (Schneider, 1997)

3.8.3 *Variable Importance*

Variabel *importance* adalah ukuran yang mencerminkan kepentingan variabel prediktor dalam memprediksi. Ukuran variabel *importance* ini juga dapat menangkap hubungan *non-linear* dan efek interaksi dan juga berlaku ketika lebih banyak variabel daripada jumlah observasi. (Breiman, 2001)

Nilai *variable importance* diukur berdasarkan pemilihan variabel prediktor menjadi variabel pemisah terhadap *error*. Pada data *X*, *x* dikatakan kuat mempengaruhi variabel y jika menghasilkan penurunan *error* yang signifikan dalam memilih *x* dari hasil *random subset* untuk dijadikan pemisahan. *Variable importance* hanya menghitung seberapa penting variabel prediktor dalam mempengaruhi variabel responnya.

3.9 Evaluasi Model

3.9.1 *Root Mean Square Error* (RMSE)

Root Mean Square Error (RMSE) sering digunakan untuk mengukur perbedaan antara nilai yang diprediksi oleh model dan nilai aktual.

$$\boldsymbol{RMSE = \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{n}}} \tag{3.1}$$

3.9.2 Akurasi

Evaluasi model prediksi dengan mengukur tingkat akurasi dalam memprediksi menggunakan pendekatan ukuran *error* dari hasil prediksi. Nilai *error* dapat dihitung dengan menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE adalah rata-rata dari keseluruhan persentase selisih antara data aktual dan data hasil prediksi. MAPE dirumuskan sebagai berikut:

$$MAPE = \frac{1}{N}\sum_{t=1}^{N}\left|\frac{A_t - F_t}{A_t}\right| \tag{3.2}$$

Keterangan:

A_t = nilai data sesungguhnya (data aktual)

F_t = nilai data hasil prediksi

N = jumlah banyaknya observasi

t = waktu

Nilai akurasi didapatkan dengan persamaan sebagai berikut:

$$Akurasi = (1 - MAPE)x100 \tag{3.3}$$

3.10 *Scraping Web*

Scraping web adalah salah satu teknik pengambilan data semi terstruktur dari internet pada umumnya berupa halaman *website* dalam bahasa *HTML* atau *XTML,* untuk mempermudah mengambil data dari sebuah *website* secara otomatis tanpa perlu menyalin data secara manual dan menganalisa dokumen tersebut untuk diambil data tertentu dari halaman *website* yang digunakan untuk kepentingan lain. (Turland, 2010).

Proses pengumpulan data menggunakan teknik *scraping web*. Adapun metode *scraping web* yang dilakukan dengan cara mengambil data tertentu dari *website* dengan menggunakan *Python* dan *BeautifulSoup*. *BeautifulSoup* adalah salah satu *Python library* yang dapat digunakan untuk melakukan *web scraping* yang mengekstraksi *file website*. *BeautifulSoup* menawarkan metode sederhana dan efektif untuk navigasi, pencarian dan modifikasi data tertentu. Proses *scraping web* dengan bantuan *library BeautifulSoup* memiliki fungsi yang diperlukan untuk mengambil data dari sebuah halaman *website* karena mudah untuk diaplikasikan.

3.11 *Website*

Website merupakan halaman yang akan digunakan pada tampilan informasi, gambar, video maupun gabungan dari keseluruhan tersebut untuk sifat yang tetap (statis) dan juga yang berubah-ubah (dinamis), akan membentuk suatu rangkaian yang saling terkait, dan dihubungkan menggunakan *link*. Pada desain *website* menggunakan beberapa *software* seperti bahasa pemrograman *HTML* dan *CSS*. Dalam membangun sebuah *website* menggunakan *HTML* dan *CSS* dengan tugas yang berbeda namun berkesinambungan. *HTML* digunakan untuk membangun suatu *website* sedangkan *CSS* digunakan untuk mendesain tampilan *website* yang dibangun dengan bahasa *HTML*. (Hadi, 2016).

HTML (Hypertext Markup Language) adalah sebuah bahasa *formatting* yang digunakan dalam membuat *page website.* Dalam bidang pemrograman berbasis *website*, *HTML* menjadi dasar pada *page website.* Sebuah *file HTML* disimpan dengan ekstensi `.html` dan dapat diakses menggunakan *web browser*. *HTML* memiliki beberapa elemen yang tersusun dari *tag* yang

memiliki fungsinya masing-masing, seperti tag *heading*, paragraf, *form*, *button*, *list*, membuat *hyperlink* yang menghubungkan antar halaman *website* dan lain-lain.

CSS (Cascading Style Sheets) adalah bahasa pemrograman yang digunakan untuk *web design. CSS* digunakan untuk mendesain sebuah tampilan halaman *web.* Dalam melakukan *design* halaman *web, CSS* menggunakan penanda yang dikenal dengan *id* dan *class. CSS* dapat mengubah *font, size,* dan *colour* serta format *font,* mengatur ukuran *layout*, warna elemen, mengubah tampilan *form,* membuat halaman *website* yang responsif, menarik dan lain-lain.

3.12 *Feature Encoding*

Dalam banyak ilmu *Machine Learning*, terdapat satu hal yang perlu diperhatikan bahwa sebagian besar algoritma bekerja lebih baik dengan data bertipe numerik untuk mencapai hasil yang lebih baik. Perkembangan data secara pesat membuat tipe data tidak hanya berupa numerik, namun juga berupa teks atau label pada suatu *dataset*. Oleh karena itu, dalam penelitian perlu dilakukan mengubah data menjadi numerik untuk membuat sebuah model. Salah satu teknik yang dapat dilakukan adalah *feature encoding* yaitu teknik mengkonversi variabel teks atau kategorik menjadi nilai numerik.

Terdapat dua cara yang paling umum dilakukan dengan menggunakan *Label Encoder* atau *One Hot Encoder* sebagai berikut:

1. *Label Encoding*: metode ini mengacu pada konversi label ke dalam bentuk angka sehingga dapat mengubahnya menjadi bentuk yang dapat dibaca oleh mesin, langkah ini merupakan *pre-processing* data yang penting untuk *dataset* terstruktur dalam *supervised learning.*
2. *One Hot Encoding*: metode ini akan mengkonversi setiap labelnya menjadi 0 dan 1, dan setiap label akan dipecah menjadi beberapa kolom sesuai dengan banyak label.

3.13 *Framework Flask*

Flask adalah sebuah *web framework* dengan bahasa *python* yang menyediakan *library* yang dapat digunakan untuk membangun *website*. Untuk membuat *website* dengan menggunakan *Python* diperlukan *framework* pengembangan *web*. Pada *python framework* pengembangan *web* yang populer dan mudah dipelajari terdiri dari *Django* dan *Flask*. Sebagai pemula untuk membuat sebuah *web* dengan bahasa *python* sebaiknya menggunakan *framework flask*, karena dapat membuat *website* dengan lebih mudah dan dapat diterapkan untuk membuat *website* berskala kecil. *Flask* adalah salah satu *framework* yang tersedia di *repository* publik *python* yang semua orang dapat mengunduh dan menggunakannya.

3.14 *Heroku*

Heroku adalah sebuah *cloud platform* yang menjalankan bahasa pemrograman tertentu seperti *Phyton, Ruby, Java, PHP, Node.js* dan lain-lain. Heroku adalah salah satu *web hosting* berbasis *cloud* dan *cloud computing* merupakan salah satu contoh dari komputasi modern. *Cloud computing* ini berfungsi dalam hal *deployment* sebuah aplikasi *web*. Heroku termasuk ke dalam salah satu model layananan *cloud computing* yaitu *Platform As A Service* (PaaS), sehingga dalam melakukan *deploy* aplikasi *web* ke Heroku cukup dengan melakukan konfigurasi aplikasi yang ingin di-*deploy* dan menyediakan *platform* yang memungkinkan pelanggan untuk mengembangkan, menjalankan, dan mengelola aplikasi tanpa kompleksitas membangun dan memelihara infrastruktur yang biasanya terkait dengan pengembangan dan peluncuran aplikasi. Hal yang bersangkutan dengan *server*, *building*, *deploying*, *running*, dan *scaling* aplikasi dapat dilakukan oleh Heroku. Heroku dapat melakukan *deploy* secara otomatis terhadap aplikasi *web* yang di-*upload* menggunakan *git*. Untuk menggunakan Heroku ini pastikan bahwa telah terpasang perangkat *git*, karena aplikasi yang akan dibangun terhubung dengan Heroku melalui *git.* (Hanjura , 2014)

BAB IV
METODOLOGI PENELITIAN

4.1 Populasi dan Sampel Penelitian

Populasi dalam penelitian ini adalah data penjualan televisi dengan spesifikasi yang dimiliki masing-masing televisi yang ditampilkan pada *website* "Pricebook". Sedangkan dalam pemilihan sampel dalam penelitian ini adalah data penjualan televisi dengan hanya mengambil beberapa variabel antara lain: Nama Produk, Merek, Tipe Layar, Ukuran Layar dan Harga dengan total keseluruhan data sebanyak 925 data.

4.2 Teknik Pengumpulan Data

Pada penelitian ini menggunakan data penjualan televisi di Indonesia dengan spesifikasi yang dimiliki. Data diperoleh dari sebuah situs *website* yang bersumber di *internet* dan untuk mendapatkan data tersebut dapat dilakukan dengan teknik *web scraping.* Dengan dilakukannya *web scraping* dalam penelitian ini mempermudah untuk mengambil data dari sebuah *website* secara otomatis tanpa perlu menyalin data secara manual.

Proses pengumpulan data pada penelitian ini menggunakan teknik *scraping web*. Adapun metode *scraping web* yang dilakukan adalah dengan cara mengambil data tertentu dari *website* dengan menggunakan *Python* dan *BeautifulSoup*. *BeautifulSoup* adalah salah satu *Python library* yang dapat digunakan untuk melakukan *web scraping* yang mengekstraksi *file website* dengan format *HTML* atau *XTML*. *BeautifulSoup* adalah alat yang mudah untuk melakukan *scraping web* berbagai data.

4.3 Variabel dan Definisi Operasional

Variabel yang digunakan dalam penelitian ini terdapat lima variabel yang terdiri dari satu variabel terikat (*dependent variable*) yaitu variabel harga dan empat variabel bebas (*independent variable*) antara lain: nama produk, merek, ukuran layar dan tipe layar. Penjelasan setiap variabel yang digunakan dalam penelitian ini ditampilkan pada tabel 4.1 sebagai berikut:

Tabel 4.2 Definisi Operasional Variabel

No	Variabel	Definisi Variabel
1.	Produk	Variabel yang mencantumkan nama televisi beserta nomor serinya yang bertujuan untuk membedakan produk televisi satu dengan lainnya.
2.	Merek	Variabel yang mencatumkan nama merek dagang televisi yang diproduksi oleh suatu perusahaan elektronik tertentu.
3.	Tipe	Variabel yang menunjukan televisi hadir dalam berbagai tipe layar seperti: Plasma, LCD, LED, OLED, dan QLED.
4.	Ukuran	Variabel yang menunjukan ragam ukuran layar televisi dalam satuan *inch*.
5.	Harga	Variabel yang mencantumkan nominal harga penjualan televisi berdasarkan spesifikasi televisi yang dimiliki.

4.4 Metode Analisis

Metode analisis yang digunakan dalam penelitian ini adalah *Random Forest* dengan bahasa pemrograman *Python* yang digunakan untuk memprediksi harga penjualan televisi. Perangkat yang digunakan dalam penelitian ini menggunakan *Microsoft Excel* dan *Python* 3.7.0. Adapun tahapan metode analisis yang dilakukan dalam penelitian ini antara lain: *scraping web*, *pre-processing* data, analisis deskriptif, melatih model *Random Forest* dalam memprediksi harga penjualan televisi, pembuatan *website* prediksi harga penjualan televisi dengan menggunakan *framework Flask* dan *deploy* aplikasi *web* menggunakan Heroku.

4.5 Tahapan Analisis Data

Tahapan atau langkah dalam penelitian ini digambarkan dalam *flowchart* sebagai berikut:

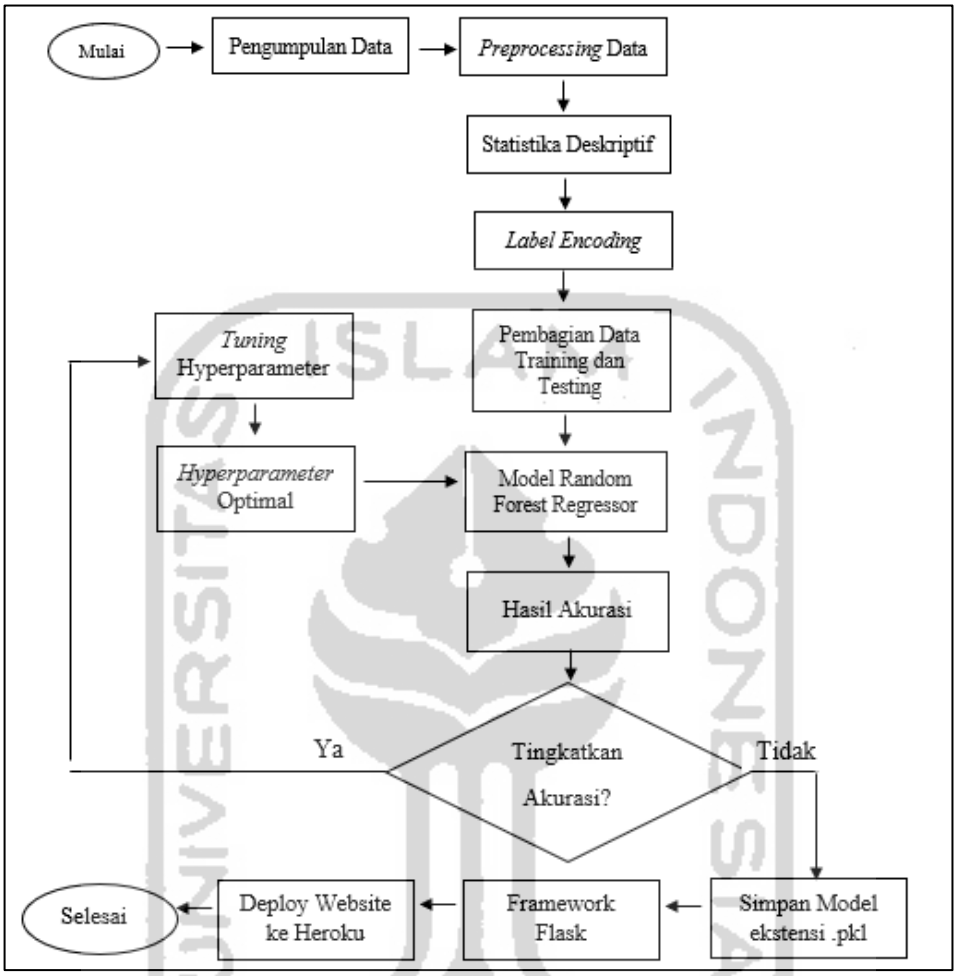

Gambar 4.5 *Flowchart* Tahapan Penelitian

BAB V
PEMBAHASAN

5.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah data penjualan televisi yang terdapat pada suatu situs *website* Pricebook yang dapat diakses dengan menggunakan internet. Proses pengumpulan data pada penelitian ini menggunakan teknik *scraping website*. Adapun metode *scraping web* yang dilakukan adalah dengan cara mengambil data tertentu dari *website* tersebut dengan menggunakan *Python* dan *BeautifulSoup*. *BeautifulSoup* adalah salah satu *Python library* yang dapat digunakan untuk melakukan *scraping web* yang mengekstraksi *file website* dengan format *HTML* atau *XTML*. *BeautifulSoup* adalah alat yang mudah untuk melakukan *scraping* berbagai data, seperti daftar, paragraf, tabel dan lainnya. *BeautifulSoup* menawarkan metode sederhana dan efektif untuk navigasi, pencarian dan modifikasi data tertentu. Proses *scraping web* dengan bantuan *library BeautifulSoup* memiliki fungsi yang diperlukan untuk mengambil data dari sebuah halaman *website* karena mudah untuk diaplikasikan.

Data penjualan televisi yang digunakan dalam penelitian ini hanya menggunakan beberapa variabel antara lain: nama produk, merek, tipe layar, ukuran layar dan harga. Tampilan halaman *website* Pricebook yang akan dilakukan proses *scraping web* sebagai berikut:

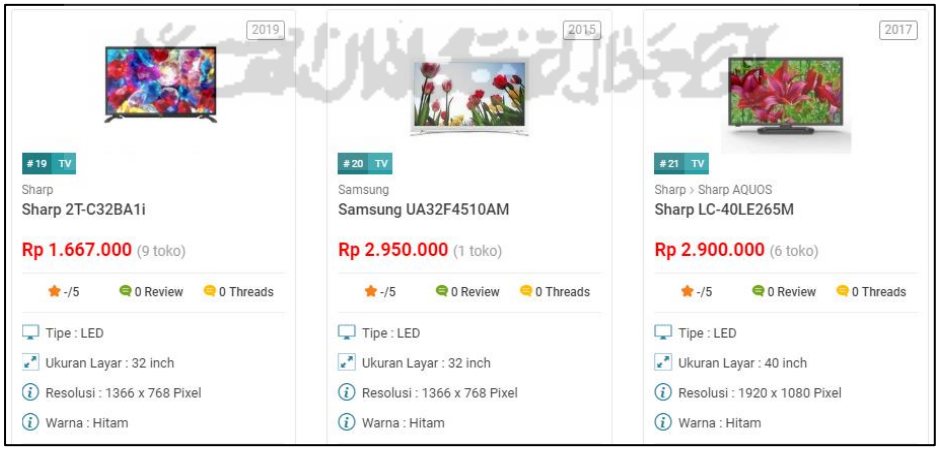

Gambar 5.6 Tampilan *Website*

Dalam proses *scraping web* yang dilakukan dengan menggunakan *python* dan *BeautifulSoup* untuk *scraping* data dari *website* yang menjadi sumber data dan hasil *scraping web* tersebut akan disimpan ke dalam *file excel* yang berekstensi *csv*.

Dalam penelitian ini, hal pertama yang dilakukan dalam proses *scraping web* dengan menggunakan *BeautifulSoup* adalah meng-*install* modul yang digunakan yaitu *BeautifulSoup* dengan cara: "`pip install beautifulsoup4`" pada *command prompt.* Penulis melakukan proses *scraping web* pada *Jupyter Notebooks,* sehingga perlu meng*import* beberapa *packages* yang dibutuhkan antara lain: *pandas, numpy, BeautifulSoup, urlopen* dan *requests*.

```
print("Masukkan keyword : ")
keyword = input(" > ")
url = requests.get("https://www.pricebook.co.id/"+keyword)
url = url.text
url_base_page = "https://www.pricebook.co.id/"+keyword+"?price=100000---9999999999&page="
url_page = [url]
page_dicari = input (" Total Pencarian Page :  ")
page_dicari = int(page_dicari)

for i in range(1,page_dicari) :
    i += 1
    prhalaman = requests.get(url_base_page + str(i))
    prhalaman = prhalaman.text
    url_page.append(prhalaman)
```

Gambar 5.7 Proses *Input url Web* yang akan di *Scraping Web*

Dalam penelitian ini ingin men*scraping* data penjualan televisi dari *website* Pricebook, pada Gambar 5.2 terlihat *syntax* untuk mendeklarasikan alamat URL terlebih dahulu dengan memasukan alamat *website* (*link*) dan selanjutnya melakukan *request* dengan menggunakan *urlopen* untuk membuka *link* tersebut dan untuk mengambil data *website* yang akan di*scraping.* Dalam proses *scraping web* ini, menggunakan *keyword* yang ditambahkan setelah *link* utama dari Pricebook. *Keyword* dapat digunakan untuk meng*input* kata kunci nama kategori yang ingin dicari dalam *website* tersebut. Sebagai contoh dalam penelitian ini, akan dilakukan *scraping web* untuk mendapatkan data penjualan televisi sehingga *keyword* yang di*input*kan adalah kategori "tv". Dalam *scraping web* dapat dilakukan proses *scraping* untuk mendapatkan data dari keseluruhan halaman dalam sekali *running*. Dalam satu halaman di *website* tersebut terdapat 21 daftar televisi. Dalam proses *scraping* ini, penulis melakukan pembatasan harga dengan minimal harga 100.000 hingga 9.999.999.999 (tidak terdapat batasan harga maksimal) dengan tujuan untuk

mendapatkan data penjualan televisi yang telah tercantumkan harganya. Selanjutnya diperlukan meng*input* "Total Pencarian *Page*: " yang berarti mengetikan jumlah berapa banyak halaman yang akan di-*scraping* yaitu sebanyak 45 halaman. Selanjutnya dilakukan perulangan dari halaman pertama hingga sebanyak halaman yang di-*input* sebelumnya, untuk mendapatkan data *scraping* semua halaman dalam sekali *running*.

```
nama_produk = []
merek_produk = []
ukuran_produk = []
tipe_layar = []
harga_produk = []

for halaman in url_page :
    soup = BeautifulSoup(halaman, "lxml")
    produk = soup.find_all("div", "feat-prod")
    for p in produk:
            nama = p.find("a", "link-inherit").get_text()
            merek = p.find('div','category-breadcrumb').contents[1].contents[1].get_text()
            UnJ = p.find_all("span","pb-primary-specification")
            ukuran = UnJ[1].get_text()
            tipe = UnJ[0].get_text()
            harga = p.find("h4", "title-price").get_text()
```

Gambar 5.3 Fungsi Mengambil Data Pada Halaman *Website*

Selanjutnya seperti pada Gambar 5.3 ditunjukan koding untuk membuat suatu nama variabel yang fungsinya untuk menyimpan hasil *scraping* masing-masing variabel ke dalam bentuk *array*. Misalkan variabel nama_produk akan menyimpan data hasil *scraping* untuk variabel nama-nama produk TV dan seterusnya untuk variabel lainnya. Selanjutnya melakukan proses *parsing* (mengurai) *html* untuk setiap halaman pada keseluruhan halaman yang dicari yang sebelumnya telah didefinisikan oleh variabel *url_page* dan menggunakan *parser* "lxml" yang tersedia di *Library BeautifulSoup* yang akan disimpan ke dalam variabel *soup*.

Pada tahap selanjutnya adalah mens*craping* data spesifik yang diinginkan untuk masing-masing variabel. Dalam proses *scraping* setiap variabel atau elemen perlu diketahui *tag html* elemen yang didapatkan dengan cara *inspect element.* Selanjutnya dalam pendefinisian variabel produk yang menunjukan untuk menyeleksi semua *tag* setiap elemen yang tersimpan di dalam *class* yang sama. Oleh karena itu, pada variabel produk dengan menggunakan fungsi *find_all( )* untuk mencari seluruh *tag div* yang berada di dalam *class name container* "*feat-prod*". Selanjutnya untuk setiap "*p*" di dalam variabel produk, dilakukan pendefinisian untuk masing-masing variabel menggunakan *tag* elemen sesuai dengan *class*nya. Selanjutnya untuk variabel

nama menggunakan fungsi *find( )* dengan *tag* berupa *a* yang berada di dalam *class "link-inherit"* dengan menggunakan *get_text( )* untuk mengekstrak teks nama TV. Pada variabel merek menggunakan fungsi *find( )* dengan tag berupa *div* yang berada di dalam *class "category-breadcrumb"* dan mengambil *child class* dengan menggunakan perintah *contents[ ]* untuk mengambil nama merek. Pada Gambar 5.4 merupakan tampilan *inspect element* untuk nama produk televisi dan merek televisi sebagai berikut:

Gambar 5.4 *Inspect Element* Variabel Nama dan Merek

Selanjutnya pada variabel UnJ (ukuran dan jenis) yang terdiri dari ukuran layar dan tipe layar yang disebabkan karena keduanya terdapat di dalam satu *class* yang sama yaitu *class "pb-primary-specification"*. Oleh karena itu, diproses dengan menggunakan fungsi *find_all( )* dengan tag *span* yang berada di dalam *class "pb-primary-specification"*, selanjutnya dipisahkan antara variabel ukuran dan tipe dengan mengidentifikasi informasi berdasarkan posisinya di dalam daftar atau urutan, sehingga *item* data pertama dalam baris diidentifikasikan oleh indeks [0] dan yang kedua atau berada dibawahnya diidentifikasikan oleh indeks [1] serta mengaplikasikan fungsi *get_text* untuk mengekstrak teks kedua elemen variabel (ukuran dan tipe) yang berada di dalam *class* yang sama. Oleh karena itu, dalam pemisahan variabel ukuran dan tipe dapat diketahui dengan melihat posisi urutannya. Variabel tipe berada di urutan atas maka diindentifikasikan dengan indeks [0] dan untuk variabel ukuran karena urutannya berada di bawahnya maka diindentifikasikan dengan indeks [1]. Pada Gambar 5.5 merupakan tampilan *inspect element* untuk ukuran televisi dan tipe televisi sebagai berikut:

Gambar 5.5 Tampilam *Inspect Element* untuk Variabel Ukuran dan Tipe

Selanjutnya untuk variabel harga dengan menggunakan fungsi *find( )* dengan *tag* berupa *h4* yang berada di dalam *class "title-price"* dengan menggunakan *get_text( )* untuk mengekstrak harga TV. Pada Gambar 5.6 merupakan tampilan *inspect element* untuk harga televisi sebagai berikut:

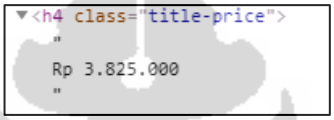

Gambar 5.6 Tampilam *Inspect Element* untuk Variabel Harga

Selanjutnya pada Gambar 5.7 terlihat koding untuk hasil akhir *scraping website* yang disimpan ke dalam *file excel* berekstensi *csv* terdiri dari beberapa kolom antara lain: produk, merek, ukuran, tipe, dan harga sebagai berikut:

```
'''result disimpan pada file csv'''
produk_dict = {"produk":nama_produk,"merek":merek_produk,
               "ukuran":ukuran_produk,"tipe":tipe_layar,
               "harga":harga_produk}
df = pd.DataFrame(produk_dict,columns = ["produk","merek","ukuran","tipe", "harga"])
df.sort_values('harga')
df.to_csv("dataTVfix.csv",sep=",")
```

Gambar 5.7 Proses Menyimpan Hasil *Scraping* Menjadi *File csv*

Selanjutnya data penjualan televisi dari hasil *scraping website* disajikan dalam *file excel* yang berekstensi *csv* terlihat pada Gambar 5.8 sebagai berikut:

	A	B	C	D	E
1	produk	merek	ukuran	tipe	harga
2	CooCaa 40S5G	CooCaa	40	OLED	2225000
3	CooCaa 32S5C	CooCaa	32	OLED	1870000
4	LG 43UM7100	LG	43	LED	4490000
5	Sharp AQUOS LC-32LE180i	Sharp	32	LED	1648000
6	Polytron PLD 20D901	Polytron	20	LED	1090000
7	Toshiba 40PU200EJ	Toshiba	40	LED	4350000
8	Sharp AQUOS LC-24LE175i	Sharp	24	LED	1169000
9	Polytron PLD 43TV865	Polytron	43	LED	4250000
10	Polytron Cinemax Soundbar PLD-32B1550	Polytron	32	LED	1998000

Gambar 5.8 Data Hasil *Scraping Website*

5.2 *Pre-processing* Data

Tahapan *pre-processing* perlu untuk dilakukan karena terdapat proses data transformasi dan data *cleaning* yang bertujuan untuk menghasilkan data dengan variabel-variabel yang siap digunakan untuk analisis selanjutnya. Dalam tahapan *pre-processing* ini menggunakan *regular expressions*, sehingga perlu untuk *import* modul "*re*". Dilakukan *pre-processing* untuk variabel harga, tipe dan ukuran dengan menggunakan *regular expressions*.

Pada variabel harga merupakan variabel yang menyimpan nominal harga setiap televisi. Pada variabel harga diharapkan hasil akhirnya berupa *integer*, sehingga dilakukan proses transformasi bentuk dengan menghilangkan kata "Rp" yang berada di depan nominal harga dan menghilangkan tanda titik pada nominal harga. Pada variabel harga dengan menggunakan metode `re.sub()` untuk mengganti semua karakter di dalam *tag html* yang ditemukan dan menggantinya ke dalam bentuk *empty string*. Selanjutnya dilakukan eliminasi hasil *string* yang didapatkan yang berbentuk selain dalam *range* 0 sampai dengan 9 (*integer*), maka menggantinya menjadi *null*. Proses *pre-processing* untuk variabel harga untuk mendapatkan hasil dalam *integer* ditunjukan pada Gambar 5.9 sebagai berikut:

```
harga = re.sub("([\(\[]).*?([\)\]])", "\g<1>\g<2>", harga)
harga = re.sub('[^0-9]','',harga)
```

Gambar 5.9 Langkah *Pre-Processing* Variabel Harga

Pada variabel ukuran merupakan variabel yang menyimpan nilai ukuran layar setiap televisi. Pada variabel ukuran ingin didapatkan hasil berupa *integer*, maka menggunakan metode `re.sub()` untuk mengganti semua karakter di dalam *tag html* yang ditemukan dan menggantinya ke dalam bentuk *empty string*. Selanjutnya dilakukan eliminasi hasil *string* yang didapatkan yang berbentuk selain dalam *range* 0 sampai dengan 9 (*integer*), maka menggantinya menjadi *null*. Selanjutnya pada variabel ukuran juga dilakukan penghapusan "\n" dan menggantinya menjadi *null*. Proses *pre-processing* untuk variabel ukuran untuk mendapatkan hasil *integer* ditunjukan pada Gambar 5.10 sebagai berikut:

```
ukuran = re.sub("([\(\[]).*?([\)\]])", "\g<1>\g<2>", ukuran)
ukuran = re.sub('[^0-9]','',ukuran)
ukuran = ukuran.replace("\n","")
```

Gambar 5.10 Langkah *Pre-Processing* Variabel Ukuran

Selanjutnya variabel tipe merupakan variabel yang menyimpan tipe layar setiap televisi. Pada variabel tipe juga dilakukan pengahapusan kata "Tipe : " dan menggantinya menjadi *null*, sehingga hasil variabel tipe hanya berupa nama tipe layar. Selain itu juga dilakukan pembersihan spasi yang terletak di depan nama tipe layarnya dengan cara menghapus spasi (" ") dan menggantinya menjadi *null*. Proses *pre-processing* untuk variabel tipe ditunjukan pada Gambar 5.11 sebagai berikut:

```
tipe = tipe.replace("Tipe :","")
tipe = tipe.replace(" ","")
```

Gambar 5.11 Langkah *Pre-Processing* Variabel Tipe

5.3 Statistika Deskriptif

Analisis statistika deskriptif adalah suatu metode yang berfungsi untuk mendeskripsikan atau memberikan gambaran umum terhadap objek yang diteliti melalui data atau sampel yang telah terkumpul, tanpa melakukan analisis ataupun menarik kesimpulan. (Sugiyono, 2009)

Selanjutnya statistika deskriptif digunakan untuk mengetahui gambaran umum dari data dalam penelitian ini yaitu penjualan televisi sebagai berikut:

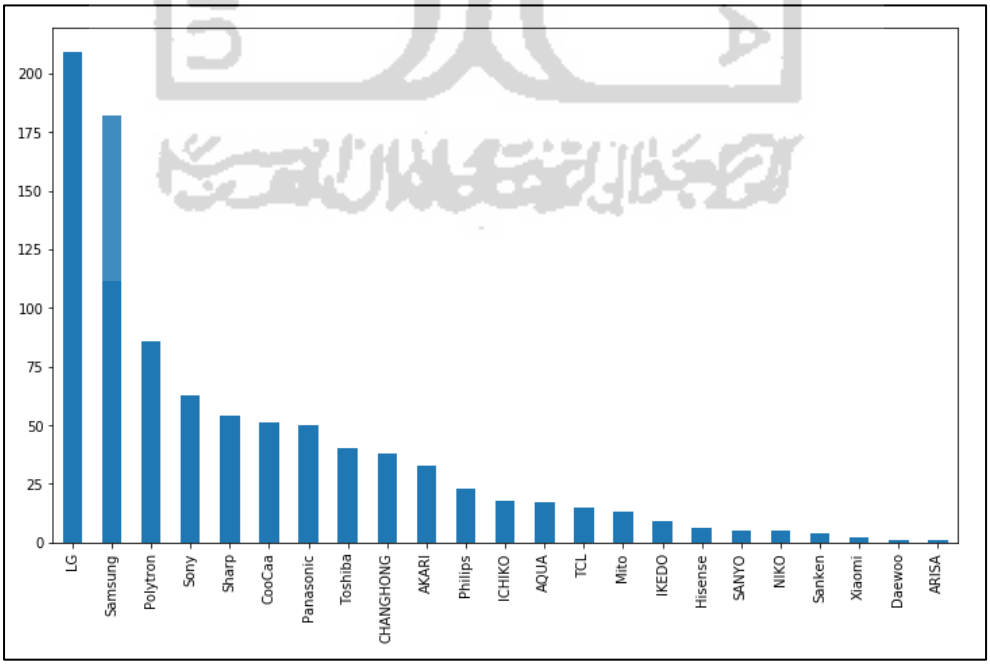

Gambar 5.12 *Plot* Jumlah Merek Terbanyak

Berdasarkan *bar chart* pada Gambar 5.12, diketahui bahwa LG merupakan merek televisi dengan jumlah data terbanyak yang tersedia di dalam *dataset* yaitu sebanyak 209 unit, disusul oleh merek Samsung sebanyak 182 unit, merek Polytron sebanyak 86 unit dan merek lainnya.

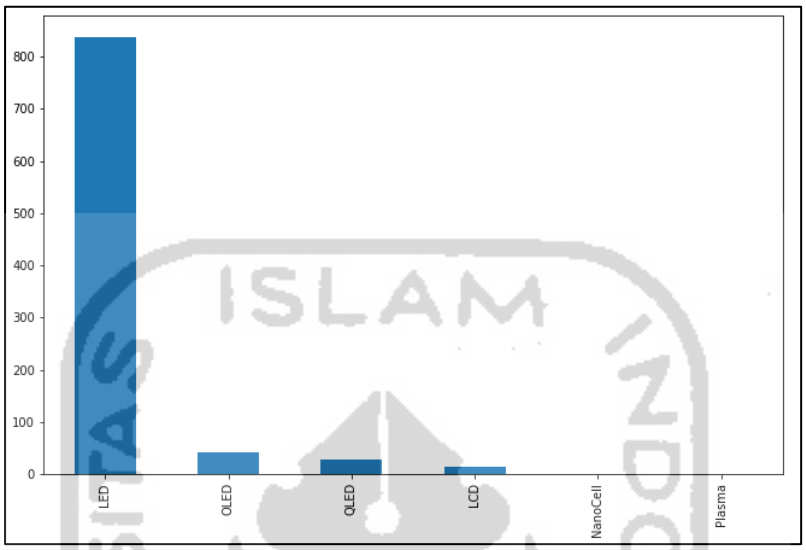

Gambar 5.13 *Plot* Jumlah Tipe Layar Terbanyak

Berdasarkan *bar chart* pada Gambar 5.13, diketahui bahwa televisi dengan tipe layar LED merupakan tipe layar televisi dengan jumlah data terbanyak yang tersedia di dalam *dataset* yang mencapai 838 unit, disusul oleh tipe layar OLED sebanyak 42 unit, QLED sebanyak 29 unit, LCD sebanyak 14 unit, tipe layar *nanocell* dan plasma masing-masing sebanyak 1 unit.

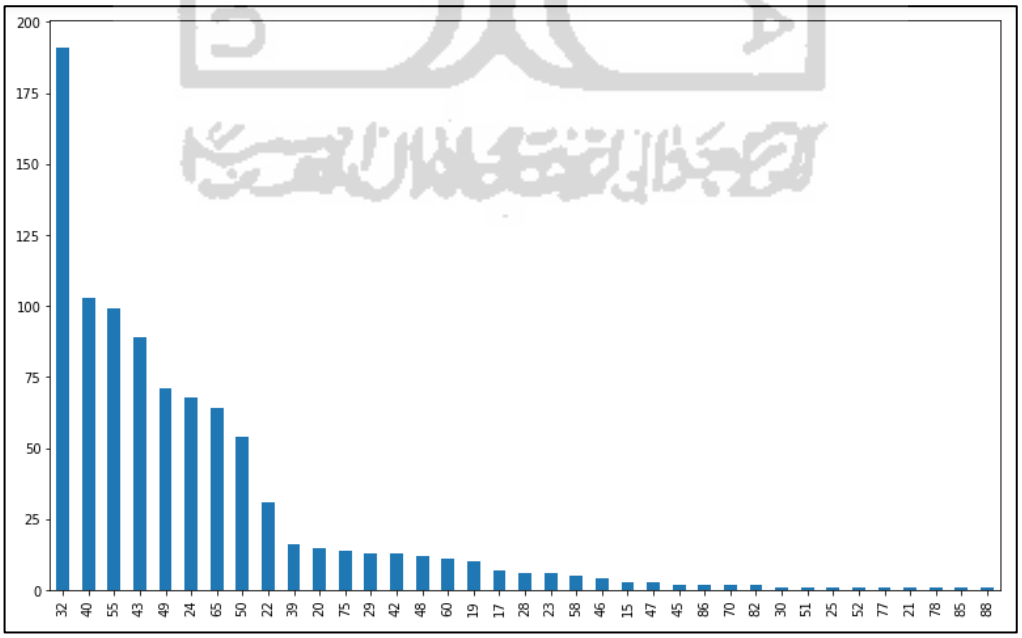

Gambar 5.14 *Plot* Jumlah Ukuran Layar Terbanyak

Berdasarkan *bar chart* pada Gambar 5.14, diketahui bahwa televisi dengan ukuran layar 32 *inch* merupakan ukuran layar televisi dengan jumlah data terbanyak yang tersedia di dalam *dataset* yang mencapai 191 unit. Ukuran layar terbanyak urutan kedua disusul oleh ukuran 40 *inch* sebanyak 103 unit, urutan ketiga disusul oleh ukuran 55 *inch* sebanyak 99 unit dan seterusnya.

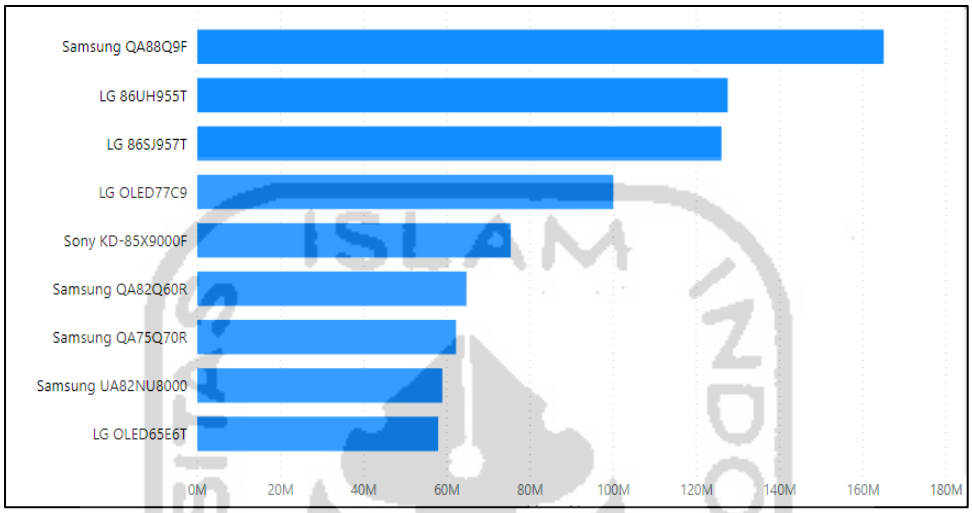

Gambar 5.15 *Plot* Produk Televisi dengan Harga Jual Termahal

Berdasarkan *bar chart* pada Gambar 5.15, diketahui bahwa produk televisi urutan pertama dengan harga jual termahal yaitu Samsung QA88Q9F sebesar Rp 165.000.000. Selanjutnya pada urutan kedua produk dengan harga jual termahal yaitu LG 86UH955T sebesar Rp 127.500.000 dan disusul oleh produk LG 86SJ957T sebesar Rp 126.000.000 dan seterusnya.

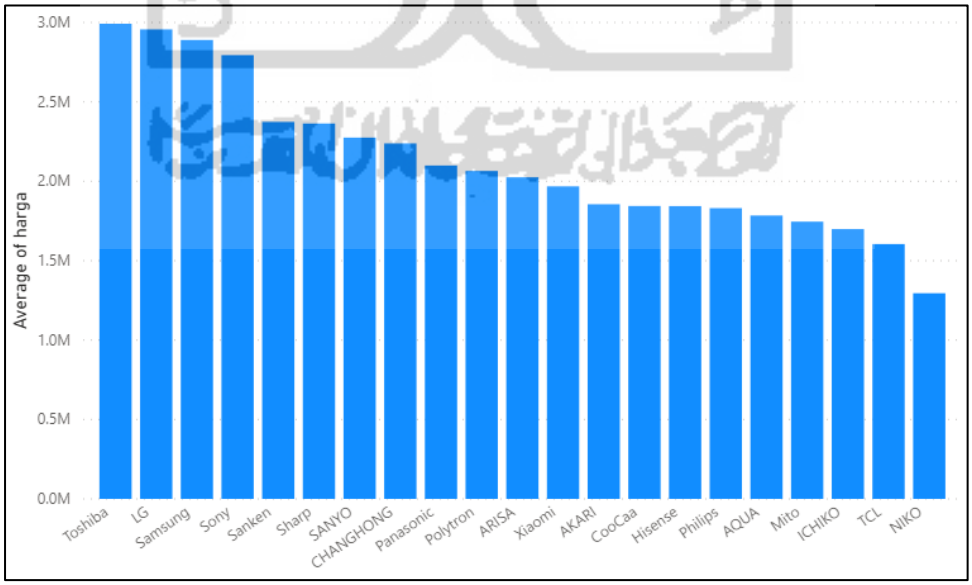

Gambar 5.16 *Plot* Rata-Rata Harga Jual Berdasarkan Merek Televisi dengan Ukuran Layar 32 *inch*

Berdasarkan *bar chart* pada Gambar 5.16, diketahui bahwa merek televisi urutan pertama dengan rata-rata harga penjualan tertinggi dengan *cluster* ukuran layar 32*inch* yaitu merek Sony sebesar Rp 2.992.000. Selanjutnya pada urutan kedua merek LG dengan rata-rata harga penjualan sebesar Rp 2.956.000 dan pada urutan ketiga merek Samsung dengan rata-rata harga penjualan sebesar Rp 2.889.000 dan seterusnya.

Selanjutnya gambaran umum harga penjualan televisi sebagai berikut:

```
     harga
Min.    :   100000
1st Qu.:  1850000
Median :  3799000
Mean   :  7355444
3rd Qu.:  7989000
Max.   :165000000
```

Gambar 5.17 Deskriptif Variabel Harga

Diketahui pada Gambar 5.17 diketahui harga penjualan televisi secara umum bahwa harga penjualan televisi terendah yaitu dengan harga Rp 100.000 pada produk Sharp AQUOS LC-24LE155M, sedangkan harga penjualan televisi tertinggi dengan harga Rp 165.000.000 pada produk Samsung QA88Q9F. Rata-rata harga jual televisi yaitu Rp 7.355.444.

5.4 *Label Encoder*

Dalam banyak ilmu *Machine Learning*, terdapat satu hal yang perlu diperhatikan bahwa sebagian besar algoritma bekerja lebih baik dengan data bertipe numerik untuk mencapai hasil lebih baik. Oleh karena itu, dalam penelitian perlu dilakukan mengubah data kategorikal menjadi data numerik untuk membuat sebuah model. Ada banyak cara untuk mengubah nilai teks atau kategorik menjadi nilai numerik, penulis menggunakan metode *Label-Encoder* yang tersedia dalam bagian dari *SciKit-learn* yang digunakan untuk mengubah data kategorik menjadi data numerik.

Pendekatan *Categorical's Codes* mengharuskan kolom variabel kategorik memiliki tipe data '*category*'. Secara *default*, kolom *non*-numerik akan bertipe '*object*'. Oleh karena itu, perlu mengubahnya menjadi tipe data '*category*' pada variabel yang akan dilakukan konversi dari kategorik menjadi numerik seperti variabel produk, merek, dan tipe menggunakan metode "`astype`" yang ditampilkan pada Gambar 5.18 sebagai berikut:

```
dataTV["produk"] = dataTV["produk"].astype('category')
dataTV["merek"] = dataTV["merek"].astype('category')
dataTV["tipe"] = dataTV["tipe"].astype('category')
dataTV.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 925 entries, 0 to 924
Data columns (total 5 columns):
produk    925 non-null category
merek     925 non-null category
ukuran    925 non-null int64
tipe      925 non-null category
harga     925 non-null int64
dtypes: category(3), int64(2)
memory usage: 66.4 KB
```

Gambar 5.18 Mengubah Tipe Data Menjadi *Category*

Selanjutnya memulai untuk mengkonversi variabel dengan tipe data '*category*' menjadi numerik untuk beberapa variabel antara lain: produk, merek dan tipe. Hasil konversi akan disimpan ke dalam variabel yang diberi nama "produk_map", "merek_map" dan "tipe_map" sehingga didapatkan hasil konversinya yang ditampilkan pada Gambar 5.19 sebagai berikut:

```
def get_cat(col):
    return dict([(cat, code) for code, cat in enumerate(col.cat.categories)])

produk_map = get_cat(dataTV.produk)
merek_map = get_cat(dataTV.merek)
tipe_map = get_cat(dataTV.tipe)
```

Gambar 5.19 Konversi Variabel Produk, Merek dan Tipe

Secara *default* kategori diurutkan berdasarkan abjad, sehingga nama pertama akan diwakili oleh indeks nol. Hasil konversi menjadi data numerik untuk variabel produk, merek dan tipe yang ditampilkan pada Gambar 5.20 sebagai berikut:

```
produk_map
```

```
{'AKARI LE-19D88': 0,
 'AKARI LE-20D88': 1,
 'AKARI LE-20K88': 2,
 'AKARI LE-20V89': 3,
 'AKARI LE-23B88': 4,
 'AKARI LE-23K88': 5,
 'AKARI LE-24K88': 6,
 'AKARI LE-24V89': 7,
 'AKARI LE-25B88': 8,
 'AKARI LE-25V89': 9,
 'AKARI LE-29P57': 10,
 'AKARI LE-29V89': 11,
 'AKARI LE-3288T2': 12,
 'AKARI LE-3289T2': 13,
 'AKARI LE-32D88': 14,
 'AKARI LE-32K88': 15,
 'AKARI LE-32M88': 16,
 'AKARI LE-32P88': 17,
 'AKARI LE-32V90': 18,
 'AKARI LE-32V99': 19,
```

```
merek_map
```

```
{'AKARI': 0,
 'AQUA': 1,
 'ARISA': 2,
 'CHANGHONG': 3,
 'CooCaa': 4,
 'Daewoo': 5,
 'Hisense': 6,
 'ICHIKO': 7,
 'IKEDO': 8,
 'LG': 9,
 'Mito': 10,
 'NIKO': 11,
 'Panasonic': 12,
 'Philips': 13,
 'Polytron': 14,
 'SANYO': 15,
 'Samsung': 16,
 'Sanken': 17,
 'Sharp': 18,
 'Sony': 19,
 'TCL': 20,
 'Toshiba': 21,
 'Xiaomi': 22}
```

```
tipe_map
```

```
{'LCD': 0, 'LED': 1, 'NanoCell': 2, 'OLED': 3, 'Plasma': 4, 'QLED': 5}
```

Gambar 5.20 Hasil Konversi Variabel Produk, Merek, dan Tipe

Setelah dilakukan konversi dari data bertipe '*category*' menjadi data numerik, sehingga didapatkan hasil akhir data keseluruhan variabel telah berdata numerik yang ditampilkan pada Gambar 5.21 sebagai berikut:

```
dataTV.head()
```

	produk	merek	ukuran	tipe	harga
0	127	4	40	3	2225000
1	113	4	32	3	1870000
2	267	9	43	1	4490000
3	770	18	32	1	1648000
4	482	14	20	1	1090000

Gambar 5.21 Hasil Konversi dengan Metode *Label Encoder*

5.5 *Random Forest*

Pada tahapan analisis klasifikasi *Random Forest* dengan menentukan terlebih dahulu variabel independen dan dependennya. Dalam penelitian ini terdapat lima variabel yang terdiri dari empat variabel *independent* (x) antara lain: produk, merek, ukuran dan tipe, sedangkan terdapat satu variabel *dependent* (y) yaitu variabel harga. Pada langkah awal diperlukan untuk membagi data menjadi dua yaitu atribut sebagai variabel "x" dan label sebagai variabel "y". Diketahui bahwa sebagai label (y) hanya terdiri dari variabel harga dan sebagai atribut (x) adalah semua variabel independen kecuali variabel harga yang ditampilkan pada Gambar 5.22 sebagai berikut:

```
y = dataTV['harga']
x = dataTV.drop(['harga'], axis=1)
```

Gambar 5.22 Langkah Penentuan Atribut dan Label

Untuk melakukan analisis klasifikasi untuk membangun model *machine learning*, data perlu dibagi terlebih dahulu menjadi dua bagian yaitu data *training* dan data *testing*. Data *training* digunakan untuk melatih model dalam memprediksi variabel dependennya sehingga mampu mengenali pola yang ada, sedangkan data *testing* digunakan untuk menguji apakah hasil analisis dari data *training* untuk dapat mengetahui kebaikan model dan mengetahui seberapa besar tingkat ketepatan metode dalam melakukan klasifikasi data. Pada penelitian ini, perbandingan antara data *training* dan data *testing* dengan perbandingan 75% : 25% yang ditampilkan pada Gambar 5.23 sebagai berikut:

```
from sklearn.model_selection import train_test_split

X_train, X_test, y_train, y_test = train_test_split(x, y, test_size=0.25)
```

Gambar 5.23 Pembagian Data *Training* dan Data *Testing*

Tahapan selanjutnya memulai untuk membangun model *Random Forest* yang ditampilkan pada Gambar 5.24. Untuk langkah pengujian pembuatan model pertama, penulis ingin membuat model *Random Forest* dengan menggunakan parameter *default* dari *Random Forest Regressor*. Seperti diketahui bahwa jumlah pohon (*n_estimators*) yang akan dibangun berdasarkan hasil *default* yaitu sebanyak 10 pohon, sedangkan nilai banyaknya *feature random* yang akan dipilih untuk *split* (*max_features*) juga secara *default* adalah "*auto*" sebagai berikut:

```
from sklearn.ensemble import RandomForestRegressor

model = RandomForestRegressor()
model.fit(X_train, y_train)
```

Gambar 5.24 Pembuatan Model *Random Forest* dengan Parameter *Default*

Selanjutnya melihat hasil akurasi dengan menggunakan model prediksi *Random Forest* pertama dengan parameter *default*. Hasil prediksi dengan model *Random Forest* secara *default*, maka menghasilkan nilai RMSE sebesar 3.773.812 dan hasil nilai akurasi dari model pertama *Random Forest* dengan parameter *default* adalah sebesar 75,75% yang ditampilkan pada Gambar 5.25 sebagai berikut:

```
from sklearn import metrics
y_pred = model.predict(X_test)
print('Mean Absolute Error:', metrics.mean_absolute_error(y_test, y_pred))
print('Mean Squared Error:', metrics.mean_squared_error(y_test, y_pred))
print('Root Mean Squared Error:', np.sqrt(metrics.mean_squared_error(y_test, y_pred)))
print('MAPE :', np.mean(np.abs((y_test - y_pred) / y_test))*100)
print ('Nilai akurasi :', (1-(np.mean(np.abs((y_test - y_pred) / y_test))))*100)
```

```
Mean Absolute Error: 1739144.0238793103
Mean Squared Error: 14241657890072.396
Root Mean Squared Error: 3773812.116424504
MAPE : 24.245680884010053
Nilai akurasi : 75.75431911598996
```

Gambar 5.25 Hasil Model *Random Forest* dengan Parameter *Default*

Hasil evaluasi model prediksi *Random Forest* pertama dengan parameter *default* mendapatkan nilai akurasi sebesar 75,75%, sehingga masih dapat dioptimalkan dengan menggunakan metode *tuning hyperparameter* untuk mendapatkan parameter yang optimal.

5.5.1 *Tuning Hyperparameter*

Tuning hyperparameter adalah salah satu proses yang dilakukan untuk menemukan parameter yang optimal. Mengoptimalkan parameter untuk model *machine learning* adalah langkah solusi dalam membuat prediksi yang lebih baik dan akurat. *Hyperparameters* mendefinisikan karakteristik model yang dapat mempengaruhi akurasi model dan efisiensi komputasi.

Pada *Random Forest* terdapat dua parameter yang dapat disesuaikan dan dilakukan *tuning* yaitu jumlah pohon (n_{tree}) dan jumlah fitur acak untuk setiap *split* (m_{try}). Parameter yang akan dilakukan *tuning hyperparameter* pada penelitian ini adalah *n_estimators* (n_{tree}) dan *max_features* (m_{try}). Pendekatan metode untuk melakukan *tuning hyperparameter* terdapat dua metode antara lain: *grid search* dan *random search*. Dalam penelitian ini lebih mudah untuk menggunakan *random search* yang mengevaluasi hanya sejumlah kombinasi acak untuk setiap *hyperparameter* di setiap iterasi. Oleh karena itu, metode *random search* lebih efisien dalam mencari spesifikasi *hyperparameter* terbaik daripada menggunakan metode *grid search*.

Dengan menggunakan pendekatan metode *random search*, maka akan dicari parameter optimal antara lain: *n_estimators* (n_{tree}) dan *max_features* (m_{try}). Dalam menggunakan metode *RandomizedSearchCV*, maka diperlukan tahapan membuat *parameter grid* untuk mengambil sampel di masing-masing parameter yang dicari. Keuntungan dari *random search* adalah tidak perlu mencoba setiap kombinasi, tetapi dapat memilih dari hasil sampel yang didapatkan. Proses mencari sampel untuk parameter *n_estimators* dan *max_features* yang ditampilkan pada Gambar 5.26 sebagai berikut:

```
from sklearn.model_selection import RandomizedSearchCV
from pprint import pprint

# Number of trees in random forest (n_tree)
n_estimators = [int(x) for x in np.linspace(start = 100, stop = 1000, num = 10)]
#max_feature (m_try)
max_features = [1, 2, 3, 4]

# Create the random grid
random_grid = {'n_estimators': n_estimators,
               'max_features': max_features}

pprint(random_grid)
```

```
{'max_features': [1, 2, 3, 4],
 'n_estimators': [100, 200, 300, 400, 500, 600, 700, 800, 900, 1000]}
```

Gambar 5.26 Hasil Pemilihan Sampel Parameter

Untuk mengevaluasi jumlah total kombinasi yang mungkin dari masing-masing kandidat sampel *hyperparameter*. Argumen yang penting dalam *RandomizedSearchCV* adalah *cv* yang merupakan jumlah lipatan yang digunakan untuk validasi silang. Dalam penelitian ini, menggunakan *cv k-fold* adalah 10. Dalam menggunakan fungsi *scikit-learn RandomizedSearchCV*, perlu menyimpan hasil nilai-nilai kandidat sampel *hyperparameter* untuk *n_estimators* dan *max_features* ke dalam variabel yang diberi nama "param_dist". Selanjutnya, *RandomizedSearchCV* menggunakan objek model dalam hal ini adalah model *random forest regressor*, kandidat *hyperparameter*, dan jumlah validasi silang yang ditampilkan pada Gambar 5.27 sebagai berikut:

```
# specify parameters and distributions to sample from
param_dist = {'max_features': [1, 2, 3, 4],
              'n_estimators': [100, 200, 300, 400, 500, 600, 700, 800, 900, 1000]}

random_search = RandomizedSearchCV(model,param_dist,cv=10)
random_search.fit(X_train, y_train)
```

Gambar 5.27 *Tuning Hyperparameter*

Selanjutnya menggunakan perintah *random_grid.best_params_* untuk melihat nilai parameter terbaik dari hasil *tuning hyperparameter*. Menggunakan metode *RandomizedSearchCV* didapatkan hasil dari *tuning hyperparameter* bahwa nilai *n_estimators* optimal adalah 1.000 pohon dan nilai *max_features* optimal sebesar 4 variabel yang ditampilkan pada Gambar 5.28 sebagai berikut:

```
print(random_search.best_params_)
```

```
{'n_estimators': 1000, 'max_features': 4}
```

Gambar 5.28 Parameter Optimal Hasil *Tuning hyperparameter*

Berdasarkan hasil *tuning hyperparameter* yang telah dilakukan, diketahui bahwa didapatkan *n_estimators* (n_{tree}) optimal sebesar 1.000 pohon dan *max_features* (m_{try}) optimal sebesar 4 variabel. Dengan menggunakan parameter n_{tree} dan m_{try} optimal yang akan diaplikasikan ke dalam pelatihan model *random forest regressor* baru dengan tujuan untuk memprediksi harga penjualan televisi. Hasil prediksi model *random forest regressor* percobaan kedua dengan menggunakan nilai parameter optimal hasil *tuning hyperparameter* yang ditampilkan pada Gambar 5.29 sebagai berikut:

```
from sklearn.ensemble import RandomForestRegressor

model2 = RandomForestRegressor(n_estimators= 1000, max_features= 4)
model2.fit(X_train, y_train)
```

```
RandomForestRegressor(bootstrap=True, ccp_alpha=0.0, criterion='mse',
                      max_depth=None, max_features=4, max_leaf_nodes=None,
                      max_samples=None, min_impurity_decrease=0.0,
                      min_impurity_split=None, min_samples_leaf=1,
                      min_samples_split=2, min_weight_fraction_leaf=0.0,
                      n_estimators=1000, n_jobs=None, oob_score=False,
                      random_state=None, verbose=0, warm_start=False)
```

Gambar 5.29 Model *Random Forest* dengan Parameter Optimal

Hasil prediksi model dengan menggunakan parameter optimal hasil dari proses *tuning hyperparameter*, pada Gambar 5.30 diketahui bahwa didapatkan nilai RMSE sebesar 3.872.324. Sedangkan untuk hasil akurasi model kedua *random forest regressor* dengan menggunakan parameter optimal hasil dari proses *tuning hyperparameter* untuk memprediksi harga penjualan televisi sebesar 75,81% sebagai berikut:

```
from sklearn import metrics
y_pred = model2.predict(X_test)
print('Mean Absolute Error:', metrics.mean_absolute_error(y_test, y_pred))
print('Mean Squared Error:', metrics.mean_squared_error(y_test, y_pred))
print('Root Mean Squared Error:', np.sqrt(metrics.mean_squared_error(y_test, y_pred)))
print('MAPE :', np.mean(np.abs((y_test - y_pred) / y_test))*100)
print ('Nilai akurasi :', (1-(np.mean(np.abs((y_test - y_pred) / y_test))))*100)
```

```
Mean Absolute Error: 1733753.1585043103
Mean Squared Error: 14994900505453.293
Root Mean Squared Error: 3872324.9483292713
MAPE : 24.190034565932418
Nilai akurasi : 75.80996543406758
```

Gambar 5.30 Hasil Evaluasi Model *Random Forest* dengan Parameter Optimal Hasil *Tuning hyperparameter*

Di dalam *Python* terdapat sebuah modul yang berguna dapat menyimpan model yang disimpan di dalam memori yang diserialisasi ke dalam *file* berupa *pickle* dan dapat membaca obyek *Python* dari *file*. Model *random forest* yang telah dibuat dengan bahasa *python* akan melalui proses *serializing* untuk mengkonversi model *Random Forest* yang telah dilatih dan akan disimpan model hasil latih ke dalam *pickle* dengan nama "modelRF" dengan ekstensi `.pkl` dan disimpan di dalam *folder* yang digunakan untuk membangun *website.* Proses menyimpan model dengan *pickle* yang ditampilkan pada Gambar 5.31 sebagai berikut:

```
import pickle

# Saving model to disk
pickle.dump(model2, open('modelRF.pkl','wb'))
```

Gambar 5.31 Penyimpanan Model Menggunakan *Pickle*

Selanjutnya untuk mengetahui variabel apa saja yang memberikan pengaruh terhadap variabel harga dengan menggunakan metode *Variable Importance* sebagai berikut:

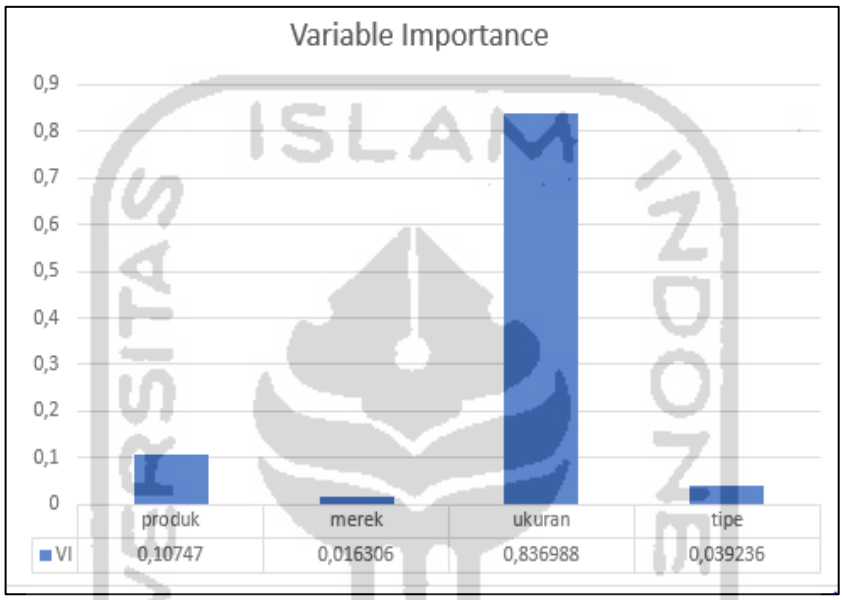

Gambar 5.32 *Variable Importance*

Berdasarkan hasil variabel *importance* pada Gambar 5.32 diketahui bahwa variabel ukuran memberikan pengaruh terbesar terhadap variabel harga penjualan televisi sebesar 0,836988. Berikutnya variabel produk di urutan kedua memberikan pengaruh sebesar 0,107470. Berikutnya variabel tipe di urutan ketiga memberikan pengaruh sebesar 0,039236. Selanjutnya di posisi terakhir terdapat variabel merek yang memberikan pengaruh sebesar 0.016306.

5.6 Tahapan Pembuatan *Website*

Selanjutnya memasuki tahapan pembuatan *website* dengan menggunakan *framework flask* dan bahasa pemrogramman *Python.* Flask adalah sebuah *web framework* dengan bahasa *python* yang menyediakan *library* dan kumpulan *code* yang dapat digunakan untuk membangun *website*. Untuk membuat *website* dengan menggunakan *Python* diperlukan *framework* pengembangan *web*. Pada *python framework* pengembangan *web* yang paling populer dan mudah dipelajari terdiri dari *Django* dan *Flask*. Sebagai pemula untuk membuat sebuah *website* dengan *python*, sebaiknya menggunakan *framework flask* karena dapat membuat *website* dengan lebih mudah. *Flask* adalah *framework* yang diterapkan untuk membuat *website* berskala kecil. Oleh karena itu, dalam penelitian ini diputuskan untuk menggunakan *framework flask* dengan bahasa pemrograman *Python* dalam mengaplikasikan model *machine learning* yang telah dilakukan pada tahapan sebelumnya menjadi sebuah *website* dan proses *deploy website* dengan menggunakan *Heroku*.

Dalam bahasa pemrograman *Python*, *package* seperti *Flask* tersedia di repositori publik sehingga semua orang dapat mengunduhnya. Dalam meng*install* sebuah *package* sangat mudah karena *Python* memiliki *tool* bernama *pip*. Oleh karena itu, dalam meng-*install flask* dapat menggunakan perintah `pip install flask`.

Dalam penelitian ini, tahapan untuk membangun sebuah model *machine learning* menjadi sebuah *website*, perlu dipersiapkan *file python* yang memuat model *Random Forest* yang telah dibuat sebelumnya dan disimpan dengan ekstensi `.pkl` yang diberi nama "`modelRF.pkl`".

Selanjutnya *file* yang diperlukan adalah *file HTML* yang berisi konten *website* yang akan dibangun. HTML menjadi bagian penting sebuah pondasi untuk membuat *website*. Elemen pada *HTML* membentuk sebuah struktur yang terdiri dari *tag* pembuka, konten, dan *tag* penutup. Dalam pembuatan *file html* dimulai dengan *tag* pembuka <html> dan diakhiri dengan *tag* penutup </html>. Dalam pembuatan *file HTML* menggunakan aplikasi editor teks yaitu *Notepad++*.

Dalam membuat *website* dibutuhkan *HTML* dan *CSS*. *HMTL* (*Hypertext Markup Language*) merupakan bahasa pemrograman yang menjadi standar untuk pembuatan struktur *website*. Sedangkan *CSS* (*Cascading Style Sheet*) digunakan untuk mendesain *layout* dari *website*. *File HTML* yang dibuat dalam penelitian ini diberi nama "`index.html`".

Layout dari *website* yang dibuat terdiri dari *header* dan *main Body*. Pada bagian *body* berisi konten yang ditampilkan pada *browser* seperti *form* untuk mengisi variabel produk, merek, tipe dan ukuran. *Form* untuk variabel produk, merek dan tipe menggunakan tampilan *drop down list* sedangkan untuk variabel ukuran menggunakan tampilan *input form* yang ditampilkan pada Gambar 5.33 sebagai berikut:

```
<!-- jenis produk -->
<div class="form-group">
  <label>Produk</label>
  <select name="produk" required class="form-control" id="produk_form_ex">
    <option value="" disabled selected>Produk</option>
  </select>
</div>

<!-- merek -->
<div class="form-group">
  <label for="exampleSelectGender">Merek</label>
  <select name="merek" required class="form-control" id="merek_form">
    <option value="" disabled selected>Merek</option>
  </select>
</div>

<!-- tipe -->
<div class="form-group">
  <label for="exampleSelectGender">Tipe</label>
  <select name="tipe" required class="form-control" id="tipe_form">
    <option value="" disabled selected>Tipe</option>
  </select>
</div>

<!-- ukuran -->
<div class="form-group">
  <label>Ukuran</label>
  <div class="input-group col-xs-12">
    <input name="ukuran" required type="text" id="ukuran_form" class="form-control"
      placeholder="Ukuran dalam Inch">
    <div class="input-group-append">
      <span class="input-group-text">Inch</span>
    </div>
  </div>
</div>
```

Gambar 5.33 Pembuatan *Form HTML* Variabel Spesifikasi

Tampilan setelah *form* untuk mengisi empat variabel tersebut, terdapat *tag button* berupa *submit* dan *clear*. Tombol *submit* digunakan untuk memproses data yang di*input* untuk *HTML* mengirimkan nilainya agar diproses ke model prediksi untuk memperoleh harga televisi hasil prediksi. Sedangkan tombol *clear* digunakan untuk mengosongkan nilai pada *form*.

Selanjutnya hasil prediksi harga televisi akan muncul pada *form* harga berdasarkan variabel spesifikasi yang di*input*kan pada masing-masing *form*. Pembuatan kolom *form* untuk menampilkan harga yang ditampilkan pada Gambar 5.34 sebagai berikut:

```
  <button onclick="kirim_form()" class="btn btn-gradient-primary mr-2">Submit</button>
  <button onclick="clear_form()" class="btn btn-light">Clear</button>


</div>
<div class="card-body">

  <h4 class="card-title">Hasil Predict Harga Tv : <div id="loader" style="visibility: hidden"
      class="spinner-border text-primary"></div>
  </h4>


  <div class="form-group">
    <label>Harga</label>
    <div class="input-group col-xs-12">
      <div class="input-group-prepend">
        <span class="input-group-text bg-gradient-primary text-white">Rp. </span>
      </div>
      <input readonly type="text" id="hasil_predict" class="form-control"
        aria-label="Amount (to the nearest dollar)">
      <div class="input-group-append">
        <span class="input-group-text">.00</span>
      </div>
    </div>
  </div>
```

Gambar 5.34 Pembuatan *Form HTML* Variabel Harga

Selanjutnya tahapan pembuatan *framework flask* dengan langkah pertama adalah melakukan inisialisasi *Flask API* dengan menggunakan "`app = Flask(__name__)`". Memuat ulang model dan variabel yang telah disimpan menggunakan *pickle* untuk memuat model dan *joblib* untuk memuat variabel. Mendefinisikan "`predict_harga`", dimana variabel data merupakan sebuah *data frame* yang menggabungkan empat variabel *independent* antara lain: produk, merek, tipe dan ukuran. Pada variabel harga merupakan hasil model prediksi dari data yang ditampilkan pada Gambar 5.31 sebagai berikut:

```
from flask import Flask, render_template, Response, jsonify, request
import os
import pandas as pd
import pickle
import joblib
import json

APP_ROOT = os.path.dirname(os.path.abspath(__file__))
app = Flask(__name__)

harga = 0
model = pickle.load(open('static/model/modelRF.pkl','rb'))
produk_map = joblib.load('static/var_cat/produk_map.pkl')
merek_map = joblib.load('static/var_cat/merek_map.pkl')
tipe_map = joblib.load('static/var_cat/tipe_map.pkl')

def predict_harga(produk, merek, tipe, ukuran):
    data = pd.DataFrame({"produk":[produk], "merek":[merek], "ukuran":[ukuran], "tipe":[tipe]})
    harga = model.predict(data)
    return harga
```

Gambar 5.35 Pembuatan *Framework Flask*

Selanjutnya terdapat perintah dengan `@app.route("/")`, simbol @ merupakan sebuah *decorator*. Suatu pola umum dengan *decorator* adalah untuk menggunakannya sebagai *callback* di perintah tertentu. Pada `@app.route` pertama terdapat URL yang akan memanggil "/" sedangkan URL yang kedua akan memanggil "`index`" yang masing-masing terhubung dengan fungsi di bawahnya. Sehingga setiap mengakses dari URL tersebut, *Flask* akan memanggil fungsi di bawahnya dan mengirimkan *response* (perintah *return*) ke fungsi `render_template()`. Operasi yang mengubah sebuah *template* menjadi halaman *HTML* disebut *rendering*. Fungsi ini meminta nama *file template* dan daftar variabel untuk diisi ke dalam *placeholder* yang ada di dalam *template* tersebut yaitu ke dalam *index.html*. Oleh karena itu, setiap mengakses alamat *URL* web *application* prediksi harga televisi ini akan diarahkan ke halaman tampilan utama *website* dan akan dapat menginput data spesifikasi televisi pada *form* masing-masing variabel.

Selanjutnya untuk mendefinisikan fungsi prediksi untuk melakukan proses prediksi harga, sehingga akan mengirimkan *URL* ke halaman *predict* `@app.route('/predict')`. Dalam proses menginput spesifikasi televisi terdapat proses permintaan (*request*) dari *form* dari data yang telah di*input*kan. Metode *request* dengan menggunakan `metode= ['POST']`, sehingga *input* data spesifikasi berdasarkan nama produk, merek, tipe dan ukuran akan merespon permintaan dan memberikan hasil berupa prediksi harga televisi. Selanjutnya *flask* disimpan dengan nama "app.py" yang ditampilkan pada Gambar 5.36 sebagai berikut:

```
@app.route('/')
def index():
    return render_template('index.html')

@app.route('/predict', methods = ['GET','POST'])
def predict():
    def pred():
        if request.method == 'POST':
            produk = request.form['produk']
            merek = request.form['merek']
            tipe = request.form['tipe']
            ukuran = request.form['ukuran']
            global harga
            harga = predict_harga(produk, merek, tipe, ukuran)[0]
        print(harga)
        return "data:"+str(harga)+"\n\n"

    return Response(pred(), mimetype='text/event-stream')
```

Gambar 5.36 Pembuatan *Flask* Prediksi

5.7 *Deploy Website* Menggunakan Heroku

Heroku adalah sebuah *cloud platform* yang menjalankan bahasa pemrograman tertentu seperti Phyton, Ruby, Java, PHP, Node.js dan lain-lain. Heroku adalah salah satu *web hosting* berbasis *cloud* yang merupakan contoh dari komputasi modern. *Cloud computing* ini berfungsi dalam hal *deployment* sebuah aplikasi *web*. Heroku termasuk ke dalam salah satu model layanan *cloud computing* yaitu *Platform As A Service* (PaaS), sehingga dalam melakukan *deploy* aplikasi *web* ke Heroku cukup dengan melakukan konfigurasi aplikasi yang ingin di*deploy*. Heroku dapat melakukan *deploy* secara otomatis terhadap aplikasi *web* yang di-*upload* menggunakan *git*.

Dalam tahapan *deploying web* menggunakan heroku, terdapat beberapa yang perlu dipersiapkan antara lain: meng*install git* karena *app* akan terhubung dengan Heroku, meng*install* Heroku CLI dan membuat akun terlebih dahulu pada *website* Heroku. Setelah pendukung untuk melakukan *deploy* ke Heroku selesai, maka tahapan meng*deploy* web *application* ke Heroku sebagai berikut:

1. Sambungkan dengan terminal *cmd, login* ke Heroku dengan menggunakan perintah "`heroku login`" seperti pada Gambar 5.37 sebagai berikut:

```
C:\SkripsiTV>heroku login
heroku: Press any key to open up the browser to login or q to exit:
Opening browser to https://cli-auth.heroku.com/auth/cli/browser/6a83e7e3-114f-46e8-9ddb-23678fdb833b
Logging in... done
Logged in as rismitawahyu@gmail.com
```

Gambar 5.37 Login Ke Heroku

2. Secara otomatis akan masuk ke URL Heroku, kemudian akan muncul tampilan "*Log In to the Heroku CLI*" dan klik *button log in.* Selanjutnya pada Gambar 5.38 akan terlihat bahwa telah melakukan *log in* ke akun heroku yang terdaftar di Heroku sebagai berikut:

Gambar 5.38 Tampilan *Log In to the Heroku CLI*

3. Selanjutnya membuat nama aplikasi dengan perintah "`heroku create nama-app`". Nama web *application* yang dibuat adalah "prediksihargatv", nama aplikasi tersebut akan menjadi *subdomain* dari URL *website* yang dibuat di Heroku seperti pada Gambar 5.39 sebagai berikut:

```
C:\SkripsiTV>heroku create prediksihargatv --buildpack heroku/python
Creating ⬚ prediksihargatv... done
Setting buildpack to heroku/python... done
https://prediksihargatv.herokuapp.com/ | https://git.heroku.com/prediksihargatv.git
```

Gambar 5.39 Pembuatan Nama Aplikasi

4. Jika berhasil nama aplikasi telah dibentuk, maka akan muncul di dalam akun Heroku seperti pada Gambar 5.40 sebagai berikut:

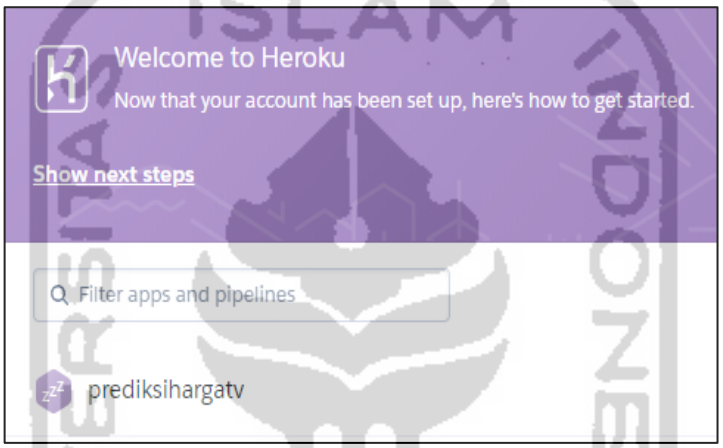

Gambar 5.40 Tampilan *Dashboard* Heroku

5. Selanjutnya menghubungkan *git* dengan Heroku untuk penghubung *web app* yang dibuat dengan *heroku cloud* dengan menjalankan perintah "`git init`" untuk menginisiasi repositori *git* seperti pada Gambar 5.41 sebagai berikut:

```
C:\SkripsiTV>heroku git init
manage local git repository for app

USAGE
  $ heroku git:COMMAND

COMMANDS
  git:clone   clones a heroku app to your local machine at DIRECTORY (defaults to app name)
  git:remote  adds a git remote to an app repo
```

Gambar 5.41 Proses *Git Init*

6. Dalam melakukan *push app* ke Heroku, dipastikan terlebih dahulu nama *remote* adalah Heroku dengan menggunakan "`git remote`" seperti pada Gambar 5.42 sebagai berikut:

```
C:\SkripsiTV>heroku git:remote -a prediksihargatv
set git remote heroku to https://git.heroku.com/prediksihargatv.git
```

Gambar 5.42 Proses *Git Remote*

7. Dalam men*deploy* aplikasi *web*nya, diperlukan untuk menambahkan *file* lokal aplikasinya menggunakan perintah "`git add .`" seperti pada Gambar 5.43 sebagai berikut:

```
C:\SkripsiTV>git add .
warning: LF will be replaced by CRLF in static/assets/css/style.css.
The file will have its original line endings in your working directory
warning: LF will be replaced by CRLF in static/assets/images/dashboard/circle.svg.
The file will have its original line endings in your working directory
warning: LF will be replaced by CRLF in static/assets/images/logo-mini.svg.
```

Gambar 5.43 Proses *Git Add*

8. Selanjutnya untuk merekam terjadinya perubahan yang terjadi dapat menggunakan perintah `git commit -m "komentar bebas"`. Sehingga setiap terdapat perubahan, selalu melakukan add dan commit dengan komentar bebas yang sama, dalam penelitian ini menggunakan komentar bebasnya adalah "rismita" seperti pada Gambar 5.44 sebagai berikut:

```
C:\SkripsiTV>git commit -am "rismita"
[master (root-commit) b9b13d3] rismita
 145 files changed, 41412 insertions(+)
 create mode 100644 .vscode/settings.json
 create mode 100644 Procfile
 create mode 100644 app.py
 create mode 100644 requirements.txt
 create mode 100644 static/assets/css/style.css
 create mode 100644 static/assets/css/style.css.map
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Bold.eot
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Bold.ttf
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Bold.woff
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Bold.woff2
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Light.eot
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Light.ttf
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Light.woff
 create mode 100644 static/assets/fonts/Ubuntu/Ubuntu-Light.woff2
```

Gambar 5.44 Proses *Git Commit*

9. Selanjutnya tahapan terakhir adalah proses *deploy* ke Heroku dengan mem-*push* aplikasi *web* ke master Heroku dengan perintah "`git push heroku master`" seperti pada Gambar 5.45 sebagai berikut:

```
C:\SkripsiTV>git push heroku master
Enumerating objects: 151, done.
Counting objects: 100% (151/151), done.
Delta compression using up to 8 threads
Compressing objects: 100% (142/142), done.
Writing objects: 100% (151/151), 10.34 MiB | 487.00 KiB/s, done.
Total 151 (delta 7), reused 0 (delta 0), pack-reused 0
remote: Compressing source files... done.
```

Gambar 5.45 Proses *Git Push Heroku Master*

Setelah melakukan langkah-langkah dalam proses *deploy* aplikasi *web* prediksi harga televisi yang telah dirancang dengan menggunakan Heroku,

maka dapat membuka *website* tersebut dengan mengakses alamat URL https://prediksihargatv.herokuapp.com/. Sehingga akan muncul tampilan halaman utama dari web *application* prediksi harga televisi yang telah dirancang. Selanjutnya dapat mlakukan uji coba pada *website* yang telah dibuat dengan mengisi *form* spesifikasi televisi antara lain: pada kolom produk memilih nama televisi Sharp LC-32LE179i, pada kolom merek memilih *Sharp*, pada kolom tipe memilih tipe layar LED dan pada kolom ukuran mengetikan ukuran layar sebesar 32 *inch* dan menekan *button submit*, maka akan muncul harga hasil prediksi televisi dengan spesifikasi yang telah di*input* sebelumnya yaitu sebesar Rp 1.300.744 yang ditampilkan pada Gambar 5.46 sebagai berikut:

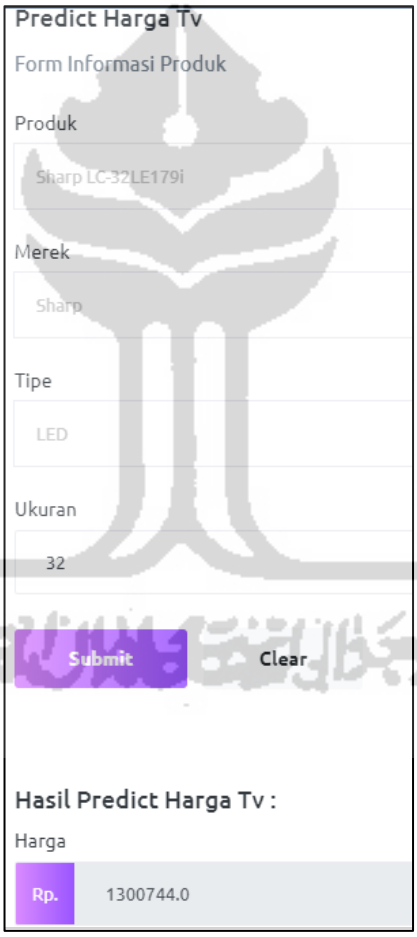

Gambar 5.46 Hasil Prediksi Harga Penjualan Televisi

BAB VI
KESIMPULAN

6.1 Kesimpulan

Berdasarkan hasil analisis dengan menggunakan *random forest* untuk memprediksi harga penjualan televisi yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut:

1. Berdasarkan data yang diperoleh dengan melakukan proses *scraping web* pada *website* Pricebook, maka didapatkan *dataset* yang terdiri dari variabel nama produk, merek, ukuran layar, tipe layar dan harga dengan total keseluruhan data sebanyak 925 data.
2. Dalam analisis *random forest* menggunakan data *training* dan data *testing* dengan perbandingan 75%:25%. Dilakukan percobaan pertama dengan membuat model *random forest regressor* menggunakan parameter *default* menghasilkan akurasi sebesar 75,75%. Dalam meningkatkan akurasi dilakukan *tuning hyperparameter* untuk mendapatkan parameter optimal antara lain: *n_estimators* (n_{tree}) optimal sebanyak 1.000 pohon dan parameter *max_features* (m_{try}) optimal sebanyak 4 variabel. Dilakukan pelatihan kedua dengan membuat model *random forest regressor* menggunakan parameter optimal hasil *tuning hyperparameter* sehingga didapatkan akurasi sebesar 75,81%.
3. Pada *variable importance* yang mempengaruhi dalam menentukan harga penjualan televisi berdasarkan urutan variabel yang memberikan pengaruh terbesar hingga terkecil sebagai berikut: ukuran, produk, tipe dan merek.
4. *Website application* yang telah berhasil dibuat dengan *framework flask* dan di*deploy* dengan menggunakan Heroku yang dapat diakses dengan menggunkan alamat URL sebagai berikut: https://prediksihargatv.herokuapp.com/.

6.2 Saran

Adapun saran yang dapat diberikan berdasarkan hasil penelitian saat ini untuk penelitian selanjutnya adalah:

1. Penelitian selanjutnya diharapkan menggunakan perbandingan dengan metode klasifikasi lainnya.
2. Penelitian selanjutnya diharapkan perlunya penggunaan *treatment* untuk mengatasi data *imbalanced*.
3. Penelitian selanjutnya diharapkan dapat memperluas dalam menggunakan parameter saat melakukan proses *tuning hyperparameter*.
4. Penelitian selanjutnya diharapkan dapat juga diaplikasikan untuk memprediksi harga televisi bekas.
5. Penelitian selanjutnya diharapkan terdapat tambahan fitur filter pada tampilan *website*.

LAMPIRAN

Lampiran 1 *Dataset* Penelitian

PRODUK	MEREK	UKURAN	TIPE	HARGA
CooCaa 40S5G	CooCaa	40	OLED	2225000
CooCaa 32S5C	CooCaa	32	OLED	1870000
LG 43UM7100	LG	43	LED	4490000
Sharp AQUOS LC-32LE180i	Sharp	32	LED	1648000
Polytron PLD 20D901	Polytron	20	LED	1090000
Toshiba 40PU200EJ	Toshiba	40	LED	4350000
Sharp AQUOS LC-24LE175i	Sharp	24	LED	1169000
Polytron PLD 43TV865	Polytron	43	LED	4250000
Polytron Cinemax Soundbar PLD-32B1550	Polytron	32	LED	1998000
Sharp LC-32SA4100	Sharp	32	LED	1670000
Sharp AQUOS LC-24LE170i	Sharp	24	LED	821300
Sharp 2TC45AD1X	Sharp	45	LED	3699000
Sharp AQUOS LC-32LE107	Sharp	32	LED	2600000
Sharp AQUOS LC-32LE265I	Sharp	32	LED	2099333
Samsung UA75NU800	Samsung	75	OLED	9575000
Polytron PLD 32D905	Polytron	32	LED	2750000
Samsung UA43M5100	Samsung	43	LED	3117000
Polytron Cinemax Soundbar PLD-40B150	Polytron	39	LED	2685000
Xiaomi Mi TV 4A 32 inch	Xiaomi	32	LED	1837000
Polytron Cinemax Soundbar PLD-43B150	Polytron	43	LED	3159000
Polytron PLD 24T8511	Polytron	24	LED	1299000
Samsung 32FH4003R	Samsung	32	LED	1782000
Polytron PLD 40T100	Polytron	40	LED	4099000
TCL 32B3	TCL	32	LED	1450000
Samsung UA32J4003	Samsung	32	LED	1830000
LG 43LM5500	LG	43	LED	3495000
Sharp AQUOS LC-24SA4000i	Sharp	24	LED	1099000
LG 32LJ500D	LG	32	LED	1849000
Polytron PLD 24D123	Polytron	24	LED	1349000
TCL 32A3	TCL	32	LED	1819000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Sharp 2T-C32BA1i	Sharp	32	LED	1640000
Samsung 43N5500	Samsung	43	LED	4235000
Panasonic TH-32G302G	Panasonic	32	LED	1675000
CooCaa 40D3A	CooCaa	40	LED	1995000
AQUA LE32AQT6100	AQUA	32	LED	1449000
LG 43UK6300	LG	43	LED	4799000
LG 32LM550	LG	32	LED	1790000
Panasonic TH-32F302G	Panasonic	32	LED	1650000
Polytron PLD 32T1550	Polytron	32	LED	1849900
LG 32LH510D	LG	32	LED	2199000
Samsung UA32N4300	Samsung	32	LED	1900000
Samsung UA43N5003	Samsung	43	LED	3124999
Sharp LC-32SA4200i	Sharp	32	LED	1850000
Samsung UA32N4001	Samsung	32	LED	1798000
Sharp AQUOS LC-32LE185i	Sharp	32	LED	1969000
LG 22LN4000	LG	22	LED	1950000
AQUA LE43AQT6000	AQUA	43	LED	2700000
TCL 40A3	TCL	40	LED	2613000
Samsung UA32J4303	Samsung	32	LED	2345000
CooCaa 50S5G	CooCaa	50	OLED	4499000
Polytron PLD 32T1500	Polytron	32	LED	1831500
Samsung UA40N5000	Samsung	40	LED	2347000
LG 32LM630BPTB	LG	32	LED	2325000
Polytron 43AS1558	Polytron	43	LED	3650000
Samsung UA24H4150	Samsung	24	LED	1169000
Toshiba 32L5650	Toshiba	32	LED	2318000
Samsung 43K5002	Samsung	43	LED	3899000
CooCaa 24W1900	CooCaa	24	LED	1100000
Samsung UA43J5100	Samsung	43	LED	3159000
LG 43LK5000	LG	43	LED	2950000
Philips 32PHT4002S	Philips	32	LED	1695000
CooCaa 32E20W	CooCaa	32	LED	1900000
Polytron PLD 32V7510	Polytron	32	LED	2331900
Polytron PLD 22D900	Polytron	22	LED	1125000
Samsung QLED Q7F QA65Q7FNAKPXD	Samsung	65	QLED	20400000
LG 22MT47AC	LG	22	LED	1715000
Samsung UA32J4005	Samsung	32	LED	1885000
TCL 32S62	TCL	32	LED	1750000
CHANGHONG L32H4	CHANGHONG	32	LED	1850000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Polytron 32T7511	Polytron	32	LED	1799000
Sharp LC-40SA5100	Sharp	40	LED	2584000
Samsung UA58RU7100KPXD	Samsung	58	LED	7999000
LG 24TL520A	LG	24	LED	1214000
Sony KDL-32R300B	Sony	32	LCD	2860000
LG 42LB550A	LG	42	LED	5250000
Polytron PLD 32D1500	Polytron	32	LED	1734000
Toshiba 32L1600	Toshiba	32	LED	1659000
CHANGHONG L32G3	CHANGHONG	32	LED	1374900
Sharp AQUOS LC-40LE185i	Sharp	40	LED	2224900
LG 42LF550A	LG	42	LED	4990000
Samsung UA50MU6100	Samsung	50	QLED	6498000
LG 43LF630T	LG	43	LED	3255000
Sharp AQUOS LC-23LE100M	Sharp	23	LED	1100000
Panasonic TH-32E305G	Panasonic	32	LED	1799000
Samsung 43j5202	Samsung	43	LED	3800000
Panasonic TH-32E302G	Panasonic	32	LED	1699990
Polytron PLD 32D710	Polytron	32	LED	1849000
LG 32LH500D	LG	32	LED	2599000
CooCaa 32A4	CooCaa	32	LED	1424900
Samsung UA20J4003	Samsung	20	LED	1650000
Sharp LC-32LE260I	Sharp	32	LED	1709000
Sharp AQUOS LC-19LE150M	Sharp	19	LED	1450000
LG 43LM5500PTA	LG	43	LED	2995000
LG 55UK6300	LG	55	OLED	6499000
TCL 32D2900	TCL	32	LED	1420000
LG OLED65C9	LG	65	OLED	46000000
Panasonic TH-32A402G	Panasonic	32	LED	421000
Sony KDL-48W650D	Sony	48	LED	5350000
Sharp AQUOS LC-32DX888I	Sharp	32	LED	3250000
Polytron PLD 32T710	Polytron	32	LED	1925000
Polytron PLD 24D9501	Polytron	24	LED	1190000
Sharp LC-32LE179i	Sharp	32	LED	1690000
CooCaa 50UB5100	CooCaa	50	LED	3854800
Samsung UA32F5105AR	Samsung	32	LED	3050000
Toshiba 24L1600	Toshiba	24	LED	1160000
Samsung UA24H4053	Samsung	24	LED	2100000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Polytron PLD 24D901	Polytron	24	LED	1325000
Toshiba 32L3750	Toshiba	32	LED	1725000
Polytron PLD 20D900	Polytron	20	LED	1289900
Panasonic TH-32F305G	Panasonic	32	LED	1800000
Xiaomi Mi TV 4A	Xiaomi	32	LED	2099000
Polytron PLD 29D700	Polytron	29	LED	2450000
LG 24MT48AF-PT	LG	24	LED	1248000
LG 32LM570BPTC	LG	32	LED	2150000
LG 43LH500T	LG	43	LED	5799000
LG 42LN5100	LG	42	LED	5450000
TCL 40S4900	TCL	40	LED	2150000
LG 43UM7300	LG	43	LED	4788000
CooCaa 24D3A	CooCaa	24	LED	989000
Panasonic TH-24F305G	Panasonic	24	LED	1199000
LG 49UJ652T	LG	49	QLED	6499000
Panasonic TH-43E302G	Panasonic	43	LED	2049000
LG 32LK500BPTA	LG	32	LED	1744000
ICHIKO S1998	ICHIKO	19	LED	849000
Philips 43PFT5250	Philips	43	LED	3099000
Polytron PLD 40TS153	Polytron	40	LED	2799000
CHANGHONG 32E6000	CHANGHONG	32	LED	1450000
AKARI LE-32V90	AKARI	32	LED	1536500
AKARI LE-55D88	AKARI	55	LED	5300000
LG 50UK6300PTE	LG	50	LED	5799000
AQUA LE32AQT6000	AQUA	32	LED	1549000
Sharp AQUOS LC-32LE347I	Sharp	32	LED	650000
LG 20MK400A-B	LG	20	LED	899000
LG 24TK425A	LG	24	LED	1327000
Samsung UA32N4003AKPXD	Samsung	32	LED	1798000
AKARI LE-32K88	AKARI	32	LED	1524000
LG 20MT45A	LG	20	LED	1475000
Sony KDL-50W800C	Sony	50	LED	5345000
LG 22TK420A	LG	22	LED	1200000
LG 20MT48AF-PT	LG	20	LED	1099000
Sony KDL-55W800C	Sony	55	LED	10500000
LG 29MT45A	LG	29	LED	2489000
Panasonic TH-22D305G	Panasonic	22	LED	1170000
LG 43LJ500T	LG	43	QLED	3485000
Sharp LC-40LE265M	Sharp	40	LED	2900000

PRODUK	MEREK	UKURAN	TIPE	HARGA
AKARI LE-50D88	AKARI	50	LED	4493000
LG 65UM7600	LG	65	LED	13860000
TCL 32D3000	TCL	32	LED	990000
Polytron PLD 32T100	Polytron	32	LED	2100000
Toshiba 24L2600	Toshiba	24	LED	1249000
Polytron PC52UV222	Polytron	21	LCD	1459000
Sharp AQUOS LC-32LE295i	Sharp	32	LED	2350000
Mito 4231	Mito	43	LED	2999000
Sharp LC-40SA5500i	Sharp	40	LED	3699000
Philips 32PHA4100S	Philips	32	LED	1639000
CooCaa 40E6	CooCaa	40	LED	3099000
CooCaa 39E20W	CooCaa	39	LED	3049000
CooCaa 55G7200	CooCaa	55	LED	5999000
Polytron PLD 24T810	Polytron	23	LED	1348000
Samsung UA60J6200	Samsung	60	LED	18000000
LG 32LF520A	LG	32	LED	2385000
Samsung UA50RU7400KPXD	Samsung	50	LED	7300000
Toshiba 40L1600	Toshiba	40	LED	2899000
Polytron PLD 24D8511	Polytron	24	LED	1245000
AKARI LE-29P57	AKARI	29	LED	1494000
LG 32LF550A	LG	32	LED	1792000
LG 39LN5100	LG	39	LED	4750000
Sharp LC-50SA5200X	Sharp	50	LED	5100000
Toshiba 40L5650	Toshiba	40	LED	3385000
LG 43LF540T	LG	43	LED	3400000
Sharp 2T-C32BA2i	Sharp	32	LED	1668000
Polytron PLD 22D901	Polytron	22	LED	1299000
CooCaa 32W4	CooCaa	32	LED	1485000
LG 32LJ550D	LG	32	LED	2345000
Sony KD-65X7000G	Sony	65	LED	12290000
IKEDO LT-22T1U	IKEDO	22	LED	1200000
Toshiba 43L3750	Toshiba	43	LED	3370000
CooCaa 32E3000T	CooCaa	32	LED	1930000
LG 24TL520	LG	24	LED	1080000
LG 49UK6300	LG	49	LED	5798000
Sharp LC-32SA4102I	Sharp	32	LED	1735000
SANYO LE40S7000	SANYO	49	LED	3198000
Polytron PLD 40D100	Polytron	40	LED	2649000
Samsung UA46F5000AM	Samsung	46	LED	10850000

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG OLED55C9	LG	55	OLED	26699000
Polytron PLD 32TS1503	Polytron	32	LED	1799000
Panasonic TH-43C305G	Panasonic	43	LED	3490000
Polytron PLD 50T555	Polytron	50	LED	4899000
Samsung UA23H4003	Samsung	23	LED	2050000
Samsung UA40EH5000	Samsung	40	LED	2848000
AQUA LE40AQT6900	AQUA	40	LED	2250000
Panasonic TH-22E302G	Panasonic	22	LED	990000
AKARI LE-43D99SBS	AKARI	43	LED	3498000
Panasonic TH-43F302G	Panasonic	43	LED	3019900
Toshiba 40L3750	Toshiba	40	LED	2920000
LG OLED77C9	LG	77	OLED	99999000
Mito A101	Mito	24	LED	1320000
Panasonic TH-40F305G	Panasonic	40	LED	2699000
Panasonic TH-49D305G	Panasonic	49	LED	5600000
Samsung UA32D5000	Samsung	32	LED	3350000
LG 19LN4050	LG	19	LED	1450000
ICHIKO S3258	ICHIKO	32	LED	1499000
AKARI LE-25B88	AKARI	24	LED	1389800
TCL 32S4900	TCL	32	LED	2199000
LG 55UM7100	LG	55	LED	7550000
LG 42LW5700	LG	42	LED	3440000
Sony KD-65X7000E	Sony	65	LED	12520000
CooCaa 40E39	CooCaa	40	LED	3399000
Hisense L32D50	Hisense	32	LED	1660000
Polytron PLD 32T711	Polytron	32	LED	300000
Toshiba 32P1400	Toshiba	32	LED	2500000
Polytron PLD-22D1150	Polytron	22	LED	1198000
Polytron PLD 24D810	Polytron	24	LED	1375000
LG 49LF540T	LG	49	LED	9850000
LG 65SK8500	LG	65	LED	14599000
Polytron PLD 24D900	Polytron	24	LED	1370000
Polytron PLD 20D9501	Polytron	20	LED	1010000
Toshiba 24P2300	Toshiba	24	LED	1750000
CooCaa 32E20	CooCaa	32	LED	1615000
Toshiba 23PU200	Toshiba	23	LED	2250000
Sharp AQUOS LC-32LE260M	Sharp	32	LED	2400000
LG 28MT49VF-PT	LG	28	LED	1799000
TCL 29D2900	TCL	29	LED	1137000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Samsung QLED Q7F QA75Q7FNAKPXD	Samsung	75	QLED	40000000
Panasonic TH-55E306G	Panasonic	55	LED	5000000
Polytron PLD 43V863	Polytron	40	LED	4075000
Polytron PLD 32D900	Polytron	32	LED	3250000
CooCaa 40E2000T	CooCaa	40	LED	2199000
Mito 3218	Mito	32	LED	1699000
Panasonic TH-32F306G	Panasonic	32	LED	1749000
Sharp AQUOS LC-50UE630X	Sharp	50	LED	8450000
LG 42LB561T	LG	42	LED	6250000
Sharp LC-24SA4100	Sharp	24	LED	1198000
Polytron PLD 50B880	Polytron	50	LED	4275000
CooCaa 32E2000T	CooCaa	32	LED	2300000
LG 43LM550	LG	43	LED	2900000
LG 50LN5400	LG	50	LED	11750000
LG 43LH511T	LG	43	LED	4150000
Sanken SLE-323HDB	Sanken	32	LED	2349000
CHANGHONG 32G4A	CHANGHONG	32	LED	1449000
Polytron PLD 32D700	Polytron	32	LED	2149000
Samsung UA40MU6103	Samsung	40	OLED	5750000
CHANGHONG L40G5i	CHANGHONG	40	LED	3897700
Samsung UA48JU6600	Samsung	48	LED	12000000
Polytron PLD 24T810W	Polytron	24	LED	1390000
CHANGHONG 32D2200	CHANGHONG	32	LED	2450000
Samsung UA40M5050AK	Samsung	40	LED	3250000
Toshiba 43L5650	Toshiba	43	LED	3983000
Sharp LC-50UA330X	Sharp	50	LED	9950000
Toshiba 40L2400VJ	Toshiba	40	LED	3599000
CHANGHONG 19D1000	CHANGHONG	19	LED	1045900
Panasonic TH-24E305G	Panasonic	24	LED	1250000
Sharp AQUOS LC-46LE840X	Sharp	46	LED	7699000
LG 49LJ510T	LG	49	QLED	4299000
LG 65UK6540PTD	LG	65	OLED	12499000
AQUA LE32AQT9100T	AQUA	32	LED	2429100
Sharp AQUOS LC-40LE355M	Sharp	40	LED	3749000
AKARI LE-40D88	AKARI	40	LED	2549000

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG 43UJ632T	LG	43	LED	4500000
Panasonic TH-43E306G	Panasonic	43	LED	3388000
LG 42UB820T	LG	42	LED	8950000
Samsung 55NU7300	Samsung	55	LED	8300000
LG 32LK540BPTA	LG	32	LED	2229000
Panasonic TH-32D302G	Panasonic	32	LED	2099000
Panasonic TH-43D306G	Panasonic	43	LED	4499000
Samsung UA48J5100	Samsung	48	LED	6300000
CHANGHONG 24D1000	CHANGHONG	24	LED	1598800
LG 24MT47A	LG	24	LED	1590000
Samsung S24D300HL	Samsung	24	LED	1400000
Sharp AQUOS LC-32LE150M	Sharp	32	LED	2600000
AKARI LE-23B88	AKARI	23	LED	1489000
LG 55SM8100	LG	55	LED	10000000
CHANGHONG 50D2200	CHANGHONG	50	LED	6899000
LG 28MT47A	LG	28	LED	2000000
Samsung UA40H5003	Samsung	40	LED	4499000
CooCaa 32S3A12G	CooCaa	32	LED	2299000
AKARI LE-32P88	AKARI	32	LED	1450000
Philips 24PHA4100S	Philips	24	LED	1479333
Sharp AQUOS LC-32DX288I	Sharp	32	LED	2850000
LG 43LK5400	LG	43	LED	3750000
LG 32LB561T	LG	32	LED	3100000
Samsung UA40J5100	Samsung	40	LED	3799000
NIKO NK-32ALPHA	NIKO	32	LED	1295000
Samsung UA65RU7300KPXD	Samsung	65	LED	16350000
AKARI LE-32M88	AKARI	32	LED	1650000
Sharp LC-60LE275X	Sharp	60	LED	10500000
Samsung UA65RU7400KPXD	Samsung	65	LED	14500000
ICHIKO S5568	ICHIKO	55	LED	6200000
Mito A120	Mito	17	LED	675000
CooCaa 50E2000T	CooCaa	50	LED	4599999
Philips 32PHT5853S	Philips	32	LED	2299000
Sharp 2T-C50AD1i	Sharp	50	LED	4675000
Sharp LC-40SA5200	Sharp	40	LED	2695000
LG 49LF550A	LG	49	LED	6299000

PRODUK	MEREK	UKURAN	TIPE	HARGA
AKARI LE-23K88	AKARI	32	LED	1399000
LG 22LN4100	LG	22	LED	1650000
LG 32LK5000	LG	32	LED	1744000
Panasonic TH-43D305G	Panasonic	43	LED	1869000
Philips 43PUT6002	Philips	43	LED	4690000
CooCaa 32A2A12	CooCaa	32	LED	1400000
LG 24TK42	LG	24	LED	1199000
AKARI SC-52V32	AKARI	32	LED	1800000
AQUA LE32AQT6900	AQUA	32	LED	1545000
Samsung UA32J6300	Samsung	32	LED	5850000
Philips 32PHA3052	Philips	32	LED	1690000
Panasonic TH-43E305G	Panasonic	43	LED	3175000
Samsung UA55M5500	Samsung	55	QLED	8999000
Sharp AQUOS LC-50LE275X	Sharp	50	LED	6499900
Samsung UA55K5100	Samsung	55	LED	8700000
Panasonic TH-24E302G	Panasonic	24	LED	1229000
Samsung UA43N5500	Samsung	43	LED	4198000
LG 55LB561T	LG	55	LED	16750000
Philips 40PFA4150S	Philips	40	LED	3499000
LG 60UF770T	LG	50	LED	18200000
Polytron PLD 22D9500	Polytron	22	LCD	1142500
Samsung UA32J4100	Samsung	32	LED	2820000
CooCaa 19E66B	CooCaa	19	LED	1350000
ICHIKO ST3976	ICHIKO	39	LED	3400000
LG M2241A	LG	22	LCD	200000
Sharp AQUOS LC-24LE155M	Sharp	24	LED	100000
Sharp LC-32SA4101I	Sharp	32	LED	1701000
Sony KD-55X8000G	Sony	55	LED	8729000
Samsung UA58H5200	Samsung	58	LED	13000000
Samsung UA50F6400AM	Samsung	50	LED	11550000
CHANGHONG 40C1600A	CHANGHONG	40	LED	3400000
Samsung UA50F5000AM	Samsung	50	LED	12850000
CooCaa 32E89	CooCaa	32	LED	1425000
Polytron PLD 40TS853	Polytron	40	LED	3149000
Toshiba 39L4300	Toshiba	39	LED	6499000
Samsung UA40J5000	Samsung	40	LED	3162000
LG 22MT45A	LG	22	LED	1719000

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG 65SK8000	LG	65	LED	15999000
Samsung UA43K5500	Samsung	43	LED	3950000
Sharp 2T-C40AE1	Sharp	40	LED	3199000
LG 55UH600T	LG	55	LED	10700000
Polytron PLD 40T851	Polytron	39	LED	2750000
LG 43UH6500	LG	43	LED	7360000
Toshiba 40L5400	Toshiba	32	LED	6850000
Samsung QA55Q7FAMKXXA	Samsung	55	QLED	18900000
Philips 50PUT6002	Philips	50	LED	5599000
Samsung 43NU7100	Samsung	43	OLED	4799000
LG 49LK5400	LG	49	LED	4750000
CooCaa 55E2000T	CooCaa	55	LED	7399000
AKARI LE-20D88	AKARI	20	LED	1099000
AKARI LE-20K88	AKARI	20	LED	1150000
AKARI LE-4399T2SB	AKARI	43	LED	2998000
AKARI SC-52V40	AKARI	40	LED	2699000
AQUA LE40AQT8300	AQUA	40	LED	3099000
LG 50UM7300	LG	50	LED	5940000
Toshiba 32L2900	Toshiba	32	LED	1685000
LG 49UH610T	LG	49	LED	7509000
Toshiba 47L2400	Toshiba	32	LED	6988000
LG 24MN33A	LG	24	LED	1750000
Polytron PLD-43TS153	Polytron	43	LED	3070000
IKEDO LT-15P1W	IKEDO	15	LED	631900
LG 43UH650T	LG	43	LED	6250000
IKEDO LT-20H1U	IKEDO	20	LED	850000
LG 43UK6500PLA	LG	43	OLED	4950000
LG 70UK6540PTA	LG	70	LED	15999000
LG 42LA6130	LG	42	LED	7650000
Toshiba 32P2400	Toshiba	32	LED	2595000
Polytron PLD 43TS156	Polytron	43	LED	4000000
Samsung UA24H4003	Samsung	24	LED	2150000
Toshiba 24P2301	Toshiba	24	LED	1800000
LG 22MT48AF-PT	LG	22	LED	1215000
Panasonic TH-22G302G	Panasonic	22	LED	1000000
LG 55UM7300	LG	55	LED	7590000
Panasonic TH-32E306G	Panasonic	32	LED	1999000
CHANGHONG L29G3	CHANGHONG	29	LED	1299000
CooCaa 32A2A11A	CooCaa	32	LED	1450000
LG 32LF630T	LG	32	LED	4550000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Polytron PLD 22D851	Polytron	22	LED	1750000
CooCaa 43E2A22G	CooCaa	43	LED	3300000
Sony KD-49X8000G	Sony	49	LED	7080000
LG 32LB582D	LG	32	LED	4350000
LG 32LN5400	LG	32	LED	3550000
Samsung UA32EH4003	Samsung	32	LED	1750000
Sony KD-55X7000E	Sony	55	LED	7570000
LG 24MT44A	LG	24	LED	1585000
LG 49SK8500	LG	49	OLED	6790000
Sony KDL-49W750D	Sony	49	LED	7999000
SANYO LE32S6500	SANYO	32	LED	1560000
CHANGHONG 50E2000	CHANGHONG	50	LED	4981100
ICHIKO S4088	ICHIKO	40	LED	3100000
LG 55SK9500	LG	55	LED	29837500
LG 65UM7300	LG	65	LED	12999000
TCL 48P1CFS	TCL	48	LED	5000000
AKARI LE-5099T2SB	AKARI	50	LED	4012000
AKARI LE-29V89	AKARI	29	LED	1275000
Philips 43PFT6100S	Philips	43	LED	3990000
Panasonic TH-40A403G	Panasonic	40	LED	750000
LG 42LM6200	LG	42	LED	10250000
Samsung QA88Q9F	Samsung	88	QLED	1,65E+08
CooCaa 40S5C	CooCaa	40	LED	2600000
LG 20LB450A	LG	20	LED	1500000
CHANGHONG 3D51C2000	CHANGHONG	51	LED	4900000
Sony KD-49X7000G	Sony	49	LED	6299000
Samsung UA40J5200	Samsung	40	LED	3900000
CHANGHONG L43H4	CHANGHONG	43	LED	3049000
Samsung UA50NU7100	Samsung	50	LED	6099000
LG 43UJ652T	LG	43	QLED	5199000
Polytron PLD 32D100	Polytron	32	LED	2725000
Polytron PLD 32V710	Polytron	32	LED	2699000
AKARI LE-24K88	AKARI	24	LED	1144000
Toshiba 65U9750VJ	Toshiba	65	LED	14995000
Samsung QA75Q8C	Samsung	75	OLED	42095000
Samsung UA32F6400AM	Samsung	32	LED	4950000
LG OLED55C8PTA	LG	55	OLED	19999000
Samsung UA65MU8000	Samsung	65	LED	14999000
Polytron PLD 50S883	Polytron	50	LED	4750000

PRODUK	MEREK	UKURAN	TIPE	HARGA
NIKO NK-24 Gamma	NIKO	24	LED	999000
LG 49UJ632T	LG	49	QLED	7088000
Sharp AQUOS LC-58UE630X	Sharp	50	LED	11499000
LG 32LM570	LG	32	LED	2140000
Samsung UA50KU6000	Samsung	50	LED	9000000
ICHIKO S1518	ICHIKO	15	LED	799000
Samsung UA40F6400AM	Samsung	40	LED	7350000
LG 28TK430V	LG	28	LED	1400000
CHANGHONG 32B2700	CHANGHONG	32	LED	1969500
LG OLED55B6T	LG	55	OLED	28450000
Sony KD-55X8500D	Sony	55	LED	11375000
LG 49UH650T	LG	49	LED	8000000
Sony KD-43X8000G	Sony	43	LED	5999000
Samsung UA55JU6600	Samsung	55	LED	25000000
Sony KD-43X7500F	Sony	43	OLED	6945000
LG 47LB561T	LG	47	LED	8250000
CooCaa 50E6000	CooCaa	50	LED	9299000
Sony KDL-48W700C	Sony	48	LED	7350000
Philips 22PFA5403S / 70	Philips	22	LED	1075700
CooCaa 24E100	CooCaa	24	LED	1050000
Polytron PLD 22D110	Polytron	22	LED	1130000
Sony KDL-40W650D	Sony	40	LED	4199000
AQUA LE24AQT8300	AQUA	25	LED	1375000
Samsung UA43RU7100KPXD	Samsung	43	LED	4565000
Sony KDL-40W660E	Sony	40	LED	5800000
Sony KLV-32R302C	Sony	32	LED	2499000
IKEDO LT-22P1U	IKEDO	22	LED	1125000
Polytron PLD 24D552	Polytron	24	LED	1850000
Sharp AQUOS LC-29LE440M	Sharp	29	LED	2450000
Sony KDL-49W660E	Sony	49	LED	7300000
Samsung UA55EH6000	Samsung	55	LED	4850000
LG 55UK6100	LG	55	OLED	7889000
Sony KD-75X9500G	Sony	75	LED	38700000
Polytron PLD 24D800	Polytron	24	LED	1549000
CHANGHONG L50G3	CHANGHONG	50	LED	3699000
LG 55UF680T	LG	55	LED	12995000
Panasonic TH-49E305G	Panasonic	49	LED	3899000
Samsung S32F351	Samsung	32	LED	3560001

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG 40UB800T	LG	40	LED	7350000
Philips 24PHA4110	Philips	24	LED	1479333
CooCaa 32E6000	CooCaa	40	LED	5499000
LG 65UK6300PTE	LG	65	LED	11000000
AKARI LE-32V99	AKARI	32	LED	1345000
Samsung UA43KU6000	Samsung	43	LED	5958000
TCL 29E4200	TCL	29	LED	1349000
Samsung QA55Q8C	Samsung	55	QLED	17500000
AKARI LE-25V89	AKARI	24	LED	1102000
Sony KD-55X8500C	Sony	55	LED	11230000
Samsung UA55MU6300	Samsung	55	LED	8900000
Toshiba 32L2550	Toshiba	32	LED	2850000
Hisense L40D50P	Hisense	40	LED	3190000
AKARI LE-32D88	AKARI	32	LED	1475000
Sony KD-65X7500F	Sony	65	OLED	11500000
LG 28MT48AF-PT	LG	28	LED	1890000
LG 43LM5700PTC	LG	43	LED	3996000
Samsung UA40F5105AR	Samsung	40	LED	5150000
Philips 39PHA4251	Philips	39	LED	2599000
Sony KDL-40R352C	Sony	40	LED	3750000
CooCaa 40S3A12G	CooCaa	40	LED	2865000
SANYO LE32S500	SANYO	32	LED	2990000
Samsung UE43NU7090	Samsung	43	LED	4399000
LG 32LM553	LG	32	LED	1799000
Panasonic TH-43F305G	Panasonic	43	LED	3199000
IKEDO LT-22T1AU	IKEDO	22	LED	1200000
CHANGHONG U58H7A	CHANGHONG	58	LED	6299000
Sony KD-49X8300C	Sony	49	LED	15888000
Polytron PLD 32V9500	Polytron	32	LED	2475000
Samsung UA40F5500AM	Samsung	40	LED	5500000
Samsung UA49M5100	Samsung	49	LED	4350000
Polytron PLD 32D715	Polytron	32	LED	1950000
CHANGHONG U65H7A	CHANGHONG	65	LED	9499000
CooCaa 55G2	CooCaa	55	OLED	5999000
Sony KD-49X8000E	Sony	49	LED	4999000
Sony KD-55X8000E	Sony	55	LED	8435000
Polytron PLD 28T655	Polytron	28	LED	2650000
LG 55UK6540PTD	LG	55	OLED	7789000
AQUA LE32AQT7000T	AQUA	32	LED	2150000
Polytron PLD 40D851	Polytron	39	LED	999000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Panasonic TH-40C304G	Panasonic	40	LED	2800000
Polytron MX 1503R	Polytron	15	LCD	1964000
LG 55UH615T	LG	55	LED	10225000
Sony KD-49X7000E	Sony	49	LED	6745000
Sony KD-43X7000E	Sony	43	LED	6499000
Toshiba 32L2800	Toshiba	32	LED	1725000
Samsung UA32F4510AM	Samsung	32	LED	2950000
Samsung UA43k5005	Samsung	43	LED	3123000
Samsung UA40MU6100	Samsung	40	LED	4200000
LG 50UK6540PTD	LG	50	OLED	6149000
CHANGHONG 29C2000	CHANGHONG	29	LED	1999000
LG OLED55C7T	LG	55	OLED	22999000
Polytron PLD 32D9505	Polytron	32	LED	1775500
Sony KDL-40R350C	Sony	40	LED	4085000
Daewoo DTV-49S1	Daewoo	49	LED	5249000
Panasonic TH-32C305G	Panasonic	32	LED	2450000
CHANGHONG 32C2000	CHANGHONG	32	LED	1800000
Sony KD-65A8F	Sony	65	OLED	37800000
Samsung UA49J5250	Samsung	49	LED	4999000
Samsung UA32F4105AR	Samsung	32	LED	2800000
Sony KD-65X8000G	Sony	65	LED	13215000
AQUA LE24AQT6500T	AQUA	24	LED	1820900
LG 49UM7290PTA	LG	49	LED	6175000
Polytron PLD 32D758	Polytron	32	LED	1728500
Samsung UA48JU6000	Samsung	48	LED	8900000
LG 55UM7600	LG	55	LED	7989000
Samsung UA43N5001	Samsung	43	LED	3097000
LG 49UB850T	LG	49	Plasma	7450000
Samsung QA65Q7FAMKXXA	Samsung	65	QLED	22540000
Toshiba 43U7750VJ	Toshiba	43	LED	6495000
CooCaa 32E21W	CooCaa	32	LED	1895000
Polytron PLD 43S883	Polytron	43	LED	3450000
Panasonic TH-32D400G	Panasonic	32	LED	2575000
Sony KD-55X7000D	Sony	55	LED	7575000
CHANGHONG 32D2000	CHANGHONG	32	LED	2002000
Samsung 55NU7090	Samsung	55	LED	6670000
Samsung UA49M5000	Samsung	49	LED	4408012
Samsung UA48JU7500	Samsung	48	LED	9900000
LG 55LH575T	LG	55	LED	10005000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Mito 5011	Mito	49	LED	3599000
Polytron PLD 32T451	Polytron	32	LED	2750000
ICHIKO S4998	ICHIKO	49	LED	4300000
LG 49LK5100	LG	49	LED	4105000
Samsung UA50JS7200	Samsung	50	LED	10500000
CHANGHONG 20E2000	CHANGHONG	20	LED	1050000
LG 60UH770T	LG	60	LED	22599000
CooCaa 50E700A	CooCaa	52	LED	6669100
ICHIKO ST3256	ICHIKO	32	LED	1899000
Mito 3255	Mito	32	LED	1395000
LG 43UF670T	LG	43	LED	5899000
LG 65UH850T	LG	65	LED	28600000
Panasonic VIERA TH-L24C28	Panasonic	24	LCD	1570000
Samsung UA55F6400AM	Samsung	55	LED	18500000
Sony KD-49X7000D	Sony	49	LED	10100000
Sharp AQUOS LC-40LE180i	Sharp	40	LED	3550000
Samsung UA55RU7100	Samsung	55	LED	7990000
Samsung UA55ES6220	Samsung	55	LED	10224000
Sony KDL-40R550C	Sony	40	LED	4990000
ICHIKO S4878	ICHIKO	48	LED	3799000
ICHIKO S4879	ICHIKO	48	LED	4699000
ICHIKO S6596	ICHIKO	65	LED	8250000
IKEDO LT-17L2U	IKEDO	17	LED	750000
CooCaa 50E3000T	CooCaa	50	LED	6599000
LG 55SK8500	LG	55	LED	9998000
LG 65UJ632T	LG	65	QLED	15495000
CooCaa 40E3000T	CooCaa	40	LED	3699000
Panasonic TH-32G306G	Panasonic	32	LED	1929000
Samsung S20D300HL	Samsung	20	LED	965000
Panasonic TH-49C305G	Panasonic	49	LED	3999000
CooCaa 19E88	CooCaa	19	LED	1395000
Sony KDL-32R300E	Sony	32	LED	2669500
TCL 29D2950	TCL	29	LED	1137000
Sony KD-65X8500C	Sony	65	LED	26500000
Toshiba 40L5550	Toshiba	40	LED	3799000
Samsung UA65KU6500	Samsung	65	LED	23000000
Samsung UA55K6300	Samsung	55	LED	10300000
LG 43LH570T	LG	43	LED	5000000
LG 55LF550T	LG	50	LED	12688000

PRODUK	MEREK	UKURAN	TIPE	HARGA
CHANGHONG 40E6000	CHANGHONG	40	LED	2699000
Panasonic TH-22G305G	Panasonic	22	LED	1175000
ICHIKO S2219	ICHIKO	22	LED	760000
AKARI LE-19D88	AKARI	19	LED	1277000
Samsung UA55KU6000	Samsung	55	LED	11000000
Sharp AQUOS LC-40LE830M	Sharp	40	LCD	4350000
Hisense L24D33	Hisense	24	LED	1479000
Polytron PLD 24T811	Polytron	24	LED	1375000
Sharp AQUOS LC-24LE107I	Sharp	24	LED	1079000
Sharp AQUOS LC-32LE155M	Sharp	32	LED	2198000
CHANGHONG 55D3000i	CHANGHONG	55	LED	6899000
Samsung LS19F350HNEX	Samsung	19	LED	908000
Sharp AQUOS LC-40LE295i	Sharp	40	LED	3298000
LG 49LF630T	LG	49	LED	9880000
Sharp LC-40UA330X	Sharp	40	LED	5390000
LG 32LB552A	LG	32	LED	3000000
Sharp AQUOS LC-50LE580X	Sharp	50	LED	8487900
LG 60LN5400	LG	60	LED	19750000
Sharp AQUOS LC-45LE280X	Sharp	45	QLED	5249000
Panasonic TH-49DS630G	Panasonic	49	LED	8298000
Samsung UA43MU6100	Samsung	43	LED	5650000
LG 49UH600T	LG	49	LED	7128000
CHANGHONG L39G3A	CHANGHONG	39	LED	2449000
AQUA LE32AQT6500	AQUA	32	LED	2009900
AQUA LE49AQT1000U	AQUA	49	LED	4499000
Philips 43PFT5853S / 70	Philips	43	LED	3880000
Samsung UA55MU6100	Samsung	55	LED	8448000
Mito 298	Mito	22	LED	1615000
AKARI LE-3288T2	AKARI	32	LED	2240000
Samsung QLED Q7F QA55Q7FNAKPXD	Samsung	55	QLED	14675000
Panasonic TH-55EX400G	Panasonic	55	LED	6999000
Samsung UA55J6300	Samsung	55	LED	14578000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Sony KD-65A9F	Sony	65	OLED	53145000
Toshiba 22L2800	Toshiba	22	LED	1265000
LG 65UH615T	LG	65	LED	17999000
Samsung UA55KU6500	Samsung	55	LED	13100000
Philips 49PFA4300S	Philips	49	LED	6126550
Sharp AQUOS LC-50LE570X	Sharp	32	LED	8997000
Polytron PLD-40TS156	Polytron	40	LED	3067000
Samsung UA40H5500	Samsung	40	LED	4499000
LG 65UH600T	LG	65	LED	20345000
AQUA LE32AQT1000U	AQUA	32	LED	1562500
Sony KD-75X8000G	Sony	75	LED	26460000
CooCaa 32E28W	CooCaa	32	LED	1449000
Panasonic TH-43F306G	Panasonic	43	LED	3498000
LG 55SJ800T	LG	55	QLED	13500000
Samsung 49NU7100	Samsung	49	LED	5799000
Sharp AQUOS LC-40LE835X	Sharp	40	LED	4650000
Samsung UA49K6300	Samsung	49	LED	7269000
AKARI LE-3289T2	AKARI	32	LED	2089000
LG 43LH540T	LG	43	LED	3666000
Samsung UA65NU800	Samsung	65	OLED	12400000
Hisense L20D50	Hisense	20	LED	1169000
CHANGHONG L43G3	CHANGHONG	43	LED	2599000
Sharp AQUOS LC-60LE380X	Sharp	60	LED	10500000
Samsung UA22H5003	Samsung	22	LED	1650000
LG 49LH570T	LG	49	LED	7088000
AQUA LE32AQT6500T	AQUA	32	LED	1565000
AKARI LE-20V89	AKARI	19	LED	1015000
AKARI LE-24V89	AKARI	24	LED	1129000
AKARI LE-43P88	AKARI	43	LED	2800000
AKARI SC-52V43	AKARI	43	LED	3799000
CHANGHONG 55D2200	CHANGHONG	55	LED	6399000
Toshiba 43L3650VJ	Toshiba	43	LED	3524000
Panasonic TH-40D305G	Panasonic	40	LED	3000000
Toshiba 50L4300	Toshiba	50	LED	11200000
LG 24LB452A	LG	24	LED	2100000
Panasonic TH-22F302G	Panasonic	22	LED	1080000
Samsung UA43J5500	Samsung	43	LED	3975000
Samsung UA55KS9000	Samsung	55	LED	22000000

PRODUK	MEREK	UKURAN	TIPE	HARGA
NIKO NK-1702	NIKO	17	LED	718900
Sony KDL-50W660G	Sony	50	LCD	5250000
Panasonic TH-49F306G	Panasonic	49	LED	4699000
LG 50UM7600	LG	50	LED	7350000
LG 29MT48AF-PT	LG	29	LED	2050000
Samsung UA49MU6300	Samsung	49	LED	6988000
Samsung UA55NU7100	Samsung	55	LED	6485000
CHANGHONG L24G3A	CHANGHONG	24	LED	1050000
AKARI LE-50D99SBS	AKARI	50	LED	4498000
ICHIKO S1798	ICHIKO	17	LED	675000
Philips 40PFT5063S / 70	Philips	40	LED	2489000
Philips 22PHA5403S	Philips	22	LED	999000
CHANGHONG 40D3000i	CHANGHONG	40	LED	4815200
ICHIKO S3998	ICHIKO	39	LED	2849000
Panasonic TH-32ES500G	Panasonic	32	LED	4888000
Samsung UA65RU7100	Samsung	65	LED	11700000
Sony KD-55X7500F	Sony	55	OLED	8475000
LG 65SM8100	LG	65	LED	18900000
Samsung UA32J5100	Samsung	32	LED	3750000
Sony KD-70X8300F	Sony	70	LED	25695000
Sharp 4T-C50AH1X	Sharp	50	LED	5887100
Samsung UA55NU800	Samsung	55	OLED	8250000
Polytron PLD 32D750	Polytron	32	LED	1734000
Samsung UA65NU7100	Samsung	65	LED	13590000
Panasonic TH-24E303G	Panasonic	24	LED	1315000
LG 24LF450A	LG	24	LED	2250000
Polytron PLD 40V853	Polytron	39	LED	4075000
Samsung QA55Q80R	Samsung	55	LED	22495000
Polytron PLD 32T106	Polytron	32	LED	1975000
ICHIKO S5588	ICHIKO	55	LED	5400000
Mito 3212	Mito	32	LED	1299400
CooCaa 39LF20	CooCaa	39	LED	3400000
LG OLED65C8PTA	LG	65	OLED	31998000
Sony KD-55X7000G	Sony	55	LED	7670000
AKARI LE-4289T2	AKARI	32	LED	3900000
Mito 1930	Mito	19	LED	1420000
LG 55SK8000	LG	55	LCD	8190000
CHANGHONG 50E6000	CHANGHONG	50	LED	4375000
Sony KD-65A9G	Sony	65	OLED	52900000
LG 39LN5400	LG	39	LED	4950000

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG 55UJ632T	LG	55	LED	9000000
LG 65SM9000PTA	LG	65	NanoCell	20000000
Polytron PLD 40TV853	Polytron	40	LED	3027900
LG 43UF690T	LG	43	LED	7280000
LG 55UH770T	LG	55	LED	11999000
Sony KDL-42W800B	Sony	42	LCD	7649100
Samsung QA55Q70R	Samsung	55	QLED	18875000
LG 20MT47A	LG	20	LED	1398000
ARISA AL32-S200	ARISA	32	LED	2025000
IKEDO LT-17L1H	IKEDO	17	LED	825000
Sony KD-55X9500G	Sony	55	LED	19990000
Samsung 65NU7300	Samsung	65	LED	13575000
LG 43UH610T	LG	43	LED	5600000
Polytron PLD 50T951	Polytron	50	LED	4950000
LG 49UF770T	LG	49	LED	11200000
CHANGHONG 40D2100T	CHANGHONG	40	LED	3175000
LG 86SJ957T	LG	86	LED	1,26E+08
Panasonic TH-55F306G	Panasonic	30	LED	6190000
Toshiba 29P2300	Toshiba	29	LED	2250000
Sony KLV-32R300B	Sony	32	LCD	3150000
Sony KD-49X7500F	Sony	49	OLED	5850000
LG 42LM6700	LG	42	LED	12250000
Samsung UA40F6100AM	Samsung	40	LED	7150000
Samsung UA46F6100AM	Samsung	46	LED	12500000
Samsung UA60F6300AM	Samsung	60	LED	21750000
Samsung UA65F6400AM	Samsung	65	LED	37500000
Toshiba 40PX200	Toshiba	40	LED	4550000
LG 32LN541B	LG	32	LED	2950000
Panasonic VIERA TH-L39B6G	Panasonic	39	LED	4250000
Samsung UA32H5100AW	Samsung	32	LED	3850000
Samsung UA48H5100AW	Samsung	48	LED	5925000
Samsung UA22H5000	Samsung	22	LED	1650000
Samsung UA40H6400AW	Samsung	40	LED	9950000
LG 55LN5400	LG	55	LED	13750000

PRODUK	MEREK	UKURAN	TIPE	HARGA
LG 55LB582T	LG	55	LED	18750000
LG 60LB561T	LG	60	LED	17500000
LG 60LB582T	LG	60	LED	19500000
Toshiba 32P1300	Toshiba	32	LED	2750000
Polytron PLD 40T555	Polytron	40	LED	650000
LG 42LB620T	LG	42	LED	8250000
LG 50LB561T	LG	50	LED	11750000
Samsung UA40H4200	Samsung	40	LED	4750000
Toshiba 23S2400	Toshiba	23	LED	1800000
LG 49LB620T	LG	49	LED	7888000
LG 22LB452A	LG	22	LED	1750000
LG 50LB582T	LG	50	LED	13750000
LG 55UB950T	LG	55	LED	20999000
LG 22MT44A	LG	22	LED	1830000
LG 47LN5710	LG	47	LED	11750000
LG 28MT45A	LG	28	LED	1800000
Polytron PLD 42T551	Polytron	42	LED	4850000
Toshiba 46WL700	Toshiba	46	LED	8750000
LG 65UF670T	LG	65	LED	18995000
LG 47LN5400	LG	47	LED	9150000
LG 29LN4510	LG	29	LED	2500000
Samsung UA65JS9000	Samsung	65	LED	35300000
Samsung UA75JU6400	Samsung	75	LED	38495000
Samsung UA55JS9000	Samsung	55	LED	29999000
Samsung UA65JU6600	Samsung	65	LED	27000000
Samsung UA55JU6400	Samsung	55	LED	18499000
Samsung UA48J6300	Samsung	48	LED	10200000
Samsung UA40J6300	Samsung	40	LED	7550000
Samsung UA40JU6600	Samsung	40	LED	9435000
Samsung UA40JU6400	Samsung	40	LED	8999000
CooCaa 24E88	CooCaa	24	LED	1430000
LG 55UF850T	LG	55	LED	17200000
LG 32LF561T	LG	32	LED	3950000
LG 42LF561T	LG	42	LED	6500000
Mito A868	Mito	32	LED	2299900
LG 24MT45A	LG	24	LED	1220000
Samsung S24D300HLR	Samsung	24	LED	2225000
CHANGHONG 40D1200	CHANGHONG	40	LED	2299000
Toshiba 50L5550	Toshiba	50	LED	10250000
LG 43LF510A	LG	43	LED	4725000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Samsung UA55JS7200	Samsung	55	LED	17994000
LG 58UF830T	LG	58	LED	15000000
Samsung UA40H5003AKXXD	Samsung	40	LED	5199000
SANYO LE24S8000	SANYO	24	LED	1529000
CooCaa 32E390	CooCaa	32	LED	2348000
Sanken SLE-50	Sanken	50	LED	5750000
Samsung UA48J5000	Samsung	48	LED	5899000
Panasonic TH-L32C304	Panasonic	32	LED	2050000
CHANGHONG 43D3000i	CHANGHONG	43	LED	2975000
Panasonic TH-40CS500G	Panasonic	40	LED	4999000
LG 49LF590	LG	49	LED	8475000
LG 49LH540T	LG	49	LED	6000000
LG 49LH511T	LG	49	LED	6579000
LG 55EG910T	LG	55	LED	14750000
LG 49LF510	LG	49	LED	7370000
LG 55UH650T	LG	55	LED	11380000
LG 60UH650T	LG	60	LED	17199000
LG 65UH650T	LG	65	LED	18900000
LG 49UH770T	LG	49	LED	11880000
LG 55UH850T	LG	55	LED	14000000
Sanken SLE-321HDJ	Sanken	32	LED	2399000
SANYO 24S6500T	SANYO	24	LED	1950000
Samsung UA65KU6000	Samsung	65	LED	19550000
Samsung UA40K6300	Samsung	40	LED	5800000
LG 43UF680T	LG	43	LED	7280000
Mito 3221	Mito	32	LED	2036000
Samsung UA78KS9000	Samsung	78	LED	50800000
Samsung UA43KU6300	Samsung	43	LED	9700000
Samsung UA60KS7000	Samsung	60	LED	21499000
Philips 39PHA4250S	Philips	39	LED	3200000
Samsung UA55K5500	Samsung	55	LED	11750000
Polytron PLD 32D106	Polytron	32	LED	2899000
LG 86UH955T	LG	86	LED	1,28E+08
CHANGHONG 50D3000i	CHANGHONG	50	LED	6174100
Panasonic TH-40DS500	Panasonic	40	LED	4385000
AQUA LE32AQT9000T	AQUA	32	LED	1800000
Samsung UA40KU6000	Samsung	40	LED	5850000

PRODUK	MEREK	UKURAN	TIPE	HARGA
CHANGHONG 24D2000	CHANGHONG	24	LED	1370000
Samsung UA49K5100	Samsung	49	LED	5999000
Samsung UA49KU6300	Samsung	49	LED	8998000
Polytron PLD 55UV5900	Polytron	55	LED	8300000
Polytron PLD 65UV5900	Polytron	65	LED	19309900
LG 65UF860T	LG	65	LED	17890000
Sony KD-65X9000E	Sony	65	LED	24495000
Panasonic TH-43ES630G	Panasonic	43	LED	5488000
ICHIKO S1788	ICHIKO	17	LED	650000
IKEDO LT-17L2H	IKEDO	17	LED	850000
IKEDO LT-24P1U1	IKEDO	24	LED	1389000
Samsung UA49MU6100	Samsung	49	LED	5599900
Samsung UA65MU6100	Samsung	65	LED	16899000
LG 49LJ550T	LG	49	QLED	5700000
LG 55UJ652T	LG	55	QLED	7750000
LG 65UJ652T	LG	65	QLED	13000000
LG 75UJ657T	LG	75	LED	35700000
LG 55SJ850T	LG	55	LCD	10050000
LG 65SJ850T	LG	65	LCD	19750000
LG OLED65B6T	LG	65	OLED	33369000
LG OLED65E6T	LG	65	OLED	57899000
Samsung UA40M5000	Samsung	40	LED	2900000
Samsung UA43M5500	Samsung	43	LED	2999000
Samsung UA49M6300	Samsung	49	LED	6750000
Samsung UA55M6300	Samsung	55	LED	8990000
Samsung UA49MU7000	Samsung	49	LED	5699000
Samsung UA49MU8000	Samsung	49	LED	10895000
Samsung UA55MU7000	Samsung	55	LED	14795000
Samsung UA55MU8000	Samsung	55	LED	11990000
Samsung UA65MU6500	Samsung	65	QLED	20000000
Samsung UA75MU6100	Samsung	75	QLED	32300000
Samsung QA65Q8C	Samsung	65	QLED	26895000
AQUA LE24AQT6550T	AQUA	24	LED	1550000
LG 49SJ800T	LG	49	LED	9500000
CooCaa 40E2100T	CooCaa	40	LED	3499000
TCL 49C2US	TCL	49	LED	7450000
CHANGHONG 50E2100	CHANGHONG	50	LED	3950000
CooCaa 50E2A12G	CooCaa	50	LED	4890000
CHANGHONG 55E6000	CHANGHONG	32	LED	5799900
ICHIKO S6558	ICHIKO	65	LED	10700000

PRODUK	MEREK	UKURAN	TIPE	HARGA
CooCaa 32E2A22G	CooCaa	32	LED	2249000
Polytron PLD 32T511	Polytron	32	LED	1800000
Samsung UA49J5200	Samsung	49	LED	5400000
Samsung UA40K5100	Samsung	40	LED	5360000
ICHIKO S5058	ICHIKO	50	LED	6000000
Toshiba 32L2605	Toshiba	32	LED	2259000
Philips 43PFA3002S	Philips	43	LED	4006700
AQUA LE40AQT1000U	AQUA	40	LED	2117600
CHANGHONG 24E2000	CHANGHONG	24	LED	999000
LG 65UK6100	LG	65	OLED	15500000
Philips 24PHA4003 / 70	Philips	24	LED	1325000
Philips 40PFA4160S	Philips	40	LED	3399000
Philips 55PUT6002	Philips	55	LED	7999000
Polytron PLD 40TS856	Polytron	40	LED	3823000
Polytron PLD 40TS865	Polytron	40	LED	4600000
LG 49UJ654V	LG	49	LED	7500000
Polytron PLD 43TS866	Polytron	43	LED	3300000
Polytron PLD 32D711	Polytron	32	LED	1776000
LG 49UH652V	LG	49	LED	8999000
Samsung UA55NU7300J	Samsung	55	LED	8750000
Samsung UA49NU7300J	Samsung	49	LED	4500000
Samsung UA75NU7100	Samsung	75	LED	24000000
Samsung UE50NU7090	Samsung	50	LED	5770000
Samsung 49NU7300	Samsung	49	LED	7050000
Samsung 40M5050	Samsung	40	LED	3999000
LG OLED65C7T	LG	65	OLED	30000000
LG OLED65C8	LG	65	OLED	49999000
Toshiba 24L2800	Toshiba	24	LED	1215000
CooCaa 24W3	CooCaa	24	LED	1049000
CooCaa 39W3	CooCaa	40	LED	1899000
CooCaa 32E2A12AG	CooCaa	32	LED	1515000
CooCaa 32E6	CooCaa	32	LED	2799000
TCL 49A3	TCL	49	LED	3999000
TCL 49P32	TCL	49	LED	5999000
LG OLED65E8PTA	LG	65	OLED	42180900
LG OLED55B8PTA	LG	55	OLED	14800000
Philips 43PFT5200	Philips	43	LED	3850000
Samsung 40M6100	Samsung	40	LED	4575000
Samsung UA40M5100	Samsung	40	LED	4900000
Samsung UA55MU6103	Samsung	55	LED	9749000
CooCaa 40E2A12G	CooCaa	40	LED	2499000

PRODUK	MEREK	UKURAN	TIPE	HARGA
CooCaa 50G2	CooCaa	50	OLED	5500000
LG 55EG9A7T	LG	55	LED	14420000
LG 32GK850G-B	LG	32	LED	10500000
CooCaa 24D1A	CooCaa	24	LED	989900
AKARI LE-40P88	AKARI	40	LED	2400000
Samsung 58NU7103	Samsung	58	LED	8425000
Samsung QA65Q6FNA	Samsung	65	LED	21300000
Samsung UA55LS003	Samsung	55	LED	22500000
Sony KD-55A8F	Sony	55	OLED	15999000
Sony KD-55A9F	Sony	55	OLED	38745000
Sony KD-55X8500G	Sony	55	LED	11235000
Sony KD-85X9000F	Sony	85	LED	75350000
Sony KDL-43W660F	Sony	43	LED	4750000
Polytron PLD 65UV5901	Polytron	65	LED	17803900
Polytron PLD 75UV5901	Polytron	75	LED	34652900
Polytron PLD 55UV6900	Polytron	55	LED	10189900
Panasonic LC-32SA4500I	Panasonic	32	LED	2704000
Samsung UA75RU7100KPXD	Samsung	75	LED	19800000
Sony KD-65X8500G	Sony	65	LED	17000000
Sony KD-65X9500G	Sony	65	LED	28350000
Polytron PLD 32D7511	Polytron	32	LED	1799000
Hisense 32N2170	Hisense	32	LED	2027400
Hisense 43N2170	Hisense	43	LED	3455000
Sony KD-55X8500F	Sony	55	LED	10165000
Sony KDL-40R350E	Sony	40	LED	4100000
Samsung QA82Q60R	Samsung	82	LED	64700000
LG 60UM7100	LG	60	LED	9499000
LG OLED65E7T	LG	65	OLED	32990000
Sony KD-49X8500G	Sony	49	LED	9750000
Sony KDL-43W660G	Sony	43	LED	4765000
Sony KD-65X9000F	Sony	65	LED	21999000
Samsung QA65Q70R	Samsung	65	QLED	25500000
Sony KD-55X9000F	Sony	55	LED	15995000
Sony KD-75X8500F	Sony	75	LED	29695000
LG 55SM8600	LG	55	LED	12495000
LG 49SM8600	LG	49	LED	9575000
LG 49SM8100	LG	49	LED	9499000
NIKO K-50 Omega	NIKO	50	LED	3129000
Sanken SL-40SN1950	Sanken	40	LED	1999000

PRODUK	MEREK	UKURAN	TIPE	HARGA
Mito 2922	Mito	22	LED	2300000
Samsung UA65NU8000	Samsung	65	LED	19300000
Samsung UA49N5000	Samsung	49	LED	4490000
Sony KDL-50W660F	Sony	50	LCD	5799000
Toshiba 49L3750	Toshiba	49	LED	4500000
Toshiba 55L3750	Toshiba	55	LED	6090000
NIKO NK-39BETA	NIKO	39	LED	1799000
Samsung UA82NU8000	Samsung	82	QLED	58900000
Polytron PLD 43D1500	Polytron	43	LED	3099000
Polytron PLD 43S153	Polytron	43	LED	3299000
Polytron PLD 40Y853	Polytron	40	LED	3699000
Toshiba 49L3650VJ	Toshiba	49	LED	5099000
Mito 3962E	Mito	40	LED	1999000
Samsung QA55Q60R	Samsung	55	QLED	13250000
Samsung QA75Q60R	Samsung	75	QLED	41500000
Samsung QA75Q70R	Samsung	75	QLED	62200000
Samsung UA55RU7300KPXD	Samsung	55	LED	8350000
Samsung UA55RU7400KPXD	Samsung	55	LED	8500000

Lampiran 2 *Syntax Scraping Web* dengan *BeautifulSoup*

```
from bs4 import BeautifulSoup
import requests
import pandas as pd
from string import *
import numpy
import re
from urllib.request import urlopen

print("Masukkan keyword : ")
keyword = input(" > ")
url = requests.get("https://www.pricebook.co.id/"+keyword)
url = url.text
url_base_page=
"https://www.pricebook.co.id/"+keyword+"?price=100000---
9999999999&page="
url_page = [url]
page_dicari = input (" Total Pencarian Page :  ")
page_dicari = int(page_dicari)

nama_produk = []
merek_produk = []
ukuran_produk = []
tipe _layar = []
harga_produk = []


for i in range(1,page_dicari) :
      i += 1
      prhalaman = requests.get(url_base_page + str(i))
      prhalaman = prhalaman.text
      url_page.append(prhalaman)

for halaman in url_page :
      soup = BeautifulSoup(halaman, "lxml")
      produk = soup.find_all("div", "feat-prod")
      for p in produk:
            nama = p.find("a", "link-inherit").get_text()
            merek            =            p.find('div','category-
breadcrumb').contents[1].contents[1].get_text()   #nanti  di  child
pas dimasukkin
            UnJ = p.find_all("span","pb-primary-specification")
            ukuran = UnJ[1].get_text()
            tipe = UnJ[0].get_text()
                  #ukuran     =     p.find("ul",     "prod-bycat-
spec").contents[2].find("div","inner_tittle_category_second").cont
ents[2].get_text() #cari childnya yang pertama
                  #     tipe     =     p.find("ul",     "prod-bycat-
spec").contents[1].find("div","inner_tittle_category_second").cont
ents[2].get_text()#cari childnya yg kedua
                  harga = p.find("h4", "title-price").get_text()
                  harga      =      re.sub("([\(\[]).*?([\)\]])",
"\g<1>\g<2>", harga)
                  harga = re.sub('[^0-9]','',harga)

                  ukuran      =      re.sub("([\(\[]).*?([\)\]])",
"\g<1>\g<2>", ukuran)
                  ukuran = re.sub('[^0-9]','',ukuran)
```

```
                ukuran = ukuran.replace("\n","")
                if ukuran == "" :
                      continue
                tipe = tipe.replace("Tipe :","")
                tipe = tipe.replace(" ","")
                if len(tipe) == 3 :
                      continue
                tipe = tipe.replace("\xa0","")
          nama_produk.append(nama.replace("\n","").encode('utf-
          8').decode('utf-8'))
          merek_produk.append(merek.replace("\n","").encode('utf
          -8').decode('utf-8'))
          ukuran_produk.append(int(ukuran.encode('utf-
          8').decode('utf-8')))
          tipe  _layar.append(tipe.replace("\n","").encode('utf-
          8').decode('utf-8'))
          harga_produk.append(harga.replace("\n","").encode('utf
          -8').decode('utf-8'))
##result disimpan pada file csv
produk_dict                                                    =
{"produk":nama_produk,"merek":merek_produk,"ukuran":ukuran_produk,
"tipe": tipe _layar, "harga":harga_produk,}
df = pd.DataFrame(produk_dict,columns = ["produk","merek","ukuran",
"tipe", "harga"])
df.sort_values('harga')
df.to_csv("dataTVnewfix.csv",sep=",")
```

Lampiran 3 *Syntax Random Forest* dengan Bahasa *Python*

```
import pandas as pd
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt

#load dataset
dataTV = pd.read_csv("C://SkripsiTV//dataTVnewfix.csv", sep=";")
dataTV.head()
dataTV.info()

#cek variabel
dataTV["merek"].value_counts()
dataTV["ukuran"].value_counts()
dataTV["tipe"].value_counts()
dataTV["harga"].describe()
dataTV.nunique()

#Konversi menjadi numerik
dataTV["produk"] = dataTV["produk"].astype('category')
dataTV["merek"] = dataTV["merek"].astype('category')
dataTV["tipe"] = dataTV["tipe"].astype('category')
dataTV.info()

def get_cat(col):
    return    dict([(cat,    code)    for    code,    cat    in
enumerate(col.cat.categories)])
produk_map = get_cat(dataTV.produk)
merek_map = get_cat(dataTV.merek)
tipe_map = get_cat(dataTV.tipe)
dataTV.produk = dataTV.produk.cat.codes
dataTV.merek = dataTV.merek.cat.codes
dataTV.tipe = dataTV.tipe.cat.codes
dataTV.head()

#Pembagian x dan y
y = dataTV['harga']
x = dataTV.drop(['harga'], axis=1)
x.head()

#pembagian data training dan data testing
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(x, y,
test_size=0.25)

#model random forest (parameter default)
from sklearn.ensemble import RandomForestRegressor
model = RandomForestRegressor()
model.fit(X_train, y_train)

#Akurasi model random forest (parameter default)
from sklearn import metrics
y_pred = model.predict(X_test)
print('Mean Absolute Error:', metrics.mean_absolute_error(y_test,
y_pred))
print('Mean Squared Error:', metrics.mean_squared_error(y_test,
y_pred))
```

```
print('Root Mean Squared Error:',
np.sqrt(metrics.mean_squared_error(y_test, y_pred)))
print('MAPE :', np.mean(np.abs((y_test - y_pred) / y_test))*100)
print ('Nilai akurasi :', (1-(np.mean(np.abs((y_test - y_pred) /
y_test))))*100)

#Tuning Hyperparameter
from sklearn.model_selection import RandomizedSearchCV
from pprint import pprint
### n_estimators (n_tree)
n_estimators = [int(x) for x in np.linspace(start = 100, stop =
1000, num = 10)]
### max_features (m_try)
max_features = [1, 2, 3, 4]
### Create the random grid
random_grid = {'n_estimators': n_estimators,
               'max_features': max_features}
pprint(random_grid)
###spesifikasi dari sampel parameter Tuning hyperparameter
param_dist = {'max_features': [1, 2, 3, 4],
              'n_estimators': [100, 200, 300, 400, 500, 600, 700,
800, 900, 1000]}
###Random Search
random_search = RandomizedSearchCV(model,param_dist,cv=10)
random_search.fit(X_train, y_train)
### Menentukan parameter optimal hasil tuning hyperparameter
print(random_search.best_params_)

#model   random   forest   (parameter   optimal   hasil   tuning
hyperparameter)
from sklearn.ensemble import RandomForestRegressor
model2 = RandomForestRegressor(n_estimators= 1.000, max_features=
4)
model2.fit(X_train, y_train)

#Akurasi model random forest (parameter optimal hasil tuning
hyperparameter)
from sklearn import metrics
y_pred = model2.predict(X_test)
print('Mean Absolute Error:', metrics.mean_absolute_error(y_test,
y_pred))
print('Mean Squared Error:', metrics.mean_squared_error(y_test,
y_pred))
print('Root Mean Squared Error:',
np.sqrt(metrics.mean_squared_error(y_test, y_pred)))
print('MAPE :', np.mean(np.abs((y_test - y_pred) / y_test))*100)
print ('Nilai akurasi :', (1-(np.mean(np.abs((y_test - y_pred) /
y_test))))*100)

import pickle
# Saving model pickle
pickle.dump(model2, open('modelRF.pkl','wb'))
import joblib
joblib.dump(produk_map, 'produk_map.pkl')
joblib.dump(merek_map, 'merek_map.pkl')
joblib.dump(tipe_map, 'tipe_map.pkl')
kode = []
produk = []
for i in produk_map:
```

```
        kode.append(produk_map[i])
        produk.append(i)
dict_produk  = {"kode":kode, "produk":produk}
kode = []
merek = []
for i in merek_map:
        kode.append(merek_map[i])
        merek.append(i)
dict_merek  = {"kode":kode, "merek":merek}
kode = []
tipe = []
for i in tipe_map:
        kode.append(tipe_map[i])
        tipe.append(i)
dict_tipe  = {"kode":kode, "tipe":tipe}
import joblib
joblib.dump(dict_produk, 'produk_map.pkl')
joblib.dump(dict_merek, 'merek_map.pkl')
joblib.dump(dict_tipe, 'tipe_map.pkl')

#variable importances
importances = model2.feature_importances_
std = np.std([tree.feature_importances_ for tree in
model2.estimators_], axis=0)
indices = np.argsort(importances)[::-1]
print("Feature ranking:")
for f in range(x.shape[1]):
    print("%d. feature %d (%f)" % (f + 1, indices[f],
importances[indices[f]]))
```

Lampiran 4 *Syntax Framework Flask*

```
from flask import Flask, render_template, Response, jsonify,
request
import os
import pandas as pd
import pickle
import joblib
import json

APP_ROOT = os.path.dirname(os.path.abspath(__file__))
app = Flask(__name__)

harga = 0
model = pickle.load(open('static/model/modelRF.pkl','rb'))
produk_map = joblib.load('static/var_cat/produk_map.pkl')
merek_map = joblib.load('static/var_cat/merek_map.pkl')
tipe_map = joblib.load('static/var_cat/tipe_map.pkl')

def predict_harga(produk, merek, ukuran, tipe):
    data   =   pd.DataFrame({"produk":[produk],   "merek":[merek],
"ukuran":[ukuran], "tipe":[tipe]})
    harga = model.predict(data)
    return harga

@app.route('/')
def index():
    return render_template('index.html')

@app.route('/predict', methods = ['GET','POST'])
def predict():
    def pred():
        if request.method == 'POST':
            produk = request.form['produk']
            merek = request.form['merek']
            tipe = request.form['tipe']
            ukuran = request.form['ukuran']
            global harga
            harga = predict_harga(produk, merek,ukuran, tipe)[0]
        print(harga)
        return "data:"+str(harga)+"\n\n"
    return Response(pred(), mimetype='text/event-stream')

@app.route('/harga')
def harga_():
    def get_harga():
        yield"data:"+str(harga)+"\n\n"
    return Response(get_harga(), mimetype='text/event-stream')

@app.route('/produk')
def produk():
    def load_produk():
        yield"data:"+str(produk_map)+"\n\n"
    return Response(load_produk(), mimetype='text/event-stream')
```

```
@app.route('/merek')
def merek():
    def load_merek():
        yield"data:"+str(merek_map)+"\n\n"
    return Response(load_merek(), mimetype='text/event-stream')

@app.route('/tipe')
def tipe():
    def load_tipe():
        yield"data:"+str(tipe_map)+"\n\n"
    return Response(load_tipe(), mimetype='text/event-stream')

if __name__ == '__main__':
    app.run(host='localhost', debug=True, threaded=True)
```

Lampiran 5 *Syntax File HTML*

```
<!DOCTYPE html>
<html lang="en">

<head>
  <!-- Required meta tags -->
  <meta charset="utf-8">
  <meta   name="viewport"   content="width=device-width,   initial-
scale=1, shrink-to-fit=no">
  <title>Predict Harga Tv</title>
  <!-- plugins:css -->
  <link rel="stylesheet"
href="../../static/assets/vendors/mdi/css/materialdesignicons.min.
css">
  <link rel="stylesheet"
href="../../static/assets/vendors/css/vendor.bundle.base.css">
  <!-- endinject -->
  <!-- Plugin css for this page -->
  <!-- End plugin css for this page -->
  <!-- inject:css -->
  <!-- endinject -->
  <!-- Layout styles -->
  <link rel="stylesheet" href="../../static/assets/css/style.css">
  <!-- End layout styles -->
  <link                    rel="shortcut                        icon"
href="../../static/assets/images/favicon.png" />
</head>
<script>
  var source_produk = new EventSource('/produk');
  source_produk.onmessage = function (event) {
    let produk = event.data;
    produk_str = produk.replace(/'/g, '"');
    produk_json = JSON.parse(produk_str);
    var kode_produk = produk_json.kode;
    var nama_produk = produk_json.produk;
    source_produk.close();

    for (let i = 0; i < kode_produk.length; i++) {
      const kode = kode_produk[i];
      const produk = nama_produk[i];
      produk_input(kode, produk);
    }

    function produk_input(kode, produk) {
      var markup = "<option value = " + kode + ">" + produk +
"</option>";
      $('#produk_form_ex').append(markup);
    }
  }
</script>

<script>
  var source_merek = new EventSource('/merek');
  source_merek.onmessage = function (event) {
    let merek = event.data;
    merek_str = merek.replace(/'/g, '"');
    merek_json = JSON.parse(merek_str);
    var kode_merek = merek_json.kode;
```

```
    var nama_merek = merek_json.merek;
    source_merek.close();

    for (let i = 0; i < kode_merek.length; i++) {
      const kode = kode_merek[i];
      const merek = nama_merek[i];
      merek_input(kode, merek);
    }

    function merek_input(kode, merek) {
      var markup = "<option value = " + kode + ">" + merek +
"</option>";
      $('#merek_form').append(markup);
    }
  }
</script>

<script>
  var source_tipe = new EventSource('/tipe');
  var count = 0;
  source_tipe.onmessage = function (event) {
    let tipe = event.data;
    tipe_str = tipe.replace(/'/g, '"');
    tipe_json = JSON.parse(tipe_str);
    var kode_tipe = tipe_json.kode;
    var nama_tipe = tipe_json.tipe;
    source_tipe.close();

    for (let i = 0; i < kode_tipe.length; i++) {
      const kode = kode_tipe[i];
      const tipe = nama_tipe[i];
      merek_input(kode, tipe);
    }

    function merek_input(kode, tipe) {
      var markup = "<option value = " + kode + ">" + tipe +
"</option>";
      $('#tipe_form').append(markup);
    }
  }
</script>

<script>
  function kirim_form() {
      count = 1;
    document.getElementById('loader').style.visibility          =
'visible';
    var produk = document.getElementById('produk_form_ex').value;
    var merek = document.getElementById('merek_form').value;
    var tipe = document.getElementById('tipe_form').value;
    var ukuran = document.getElementById('ukuran_form').value;
    console.log(produk, merek, tipe, ukuran);
    const data = { produk: produk, merek: merek, tipe: tipe, ukuran:
ukuran };
    url = '/predict';
    $.post(url, data);
  }
  function clear_form() {
    $('#kode_produk').val('');
```

```
    $('#merek_form').val('');
    $('#tipe_form').val('');
    $('#ukuran_form').val('');
    $('#nama_produk_form').val('');
      $('#hasil_predict').val('');
  }
</script>
<script>
  var source_harga = new EventSource('/harga');
  source_harga.onmessage = function (event) {
    let harga = event.data;
    console.log(harga);
      if (count == 1) {
    $('#hasil_predict').val(harga);
    document.getElementById('loader').style.visibility = 'hidden';
      count--;
      }
  }
</script>

<script>
   function stop_check(){
            source_harga.close();
   }
</script>

<body>
        <div class="content-wrapper">
          <div class="row">
            <div class="col-12 grid-margin stretch-card">
              <div class="card">
                <div class="card-body">
                  <h4 class="card-title">Predict Harga Tv</h4>
                    <p   class="card-description">  Form   Informasi
Produk </p>
                  <form class="forms-sample">

                    <!-- jenis produk -->
                    <div class="form-group">
                      <label>Produk</label>
                      <select name="produk" required class="form-
control" id="produk_form_ex">
                        <option          value=""          disabled
selected>Produk</option>
                      </select>
                    </div>

                    <!-- merek -->
                    <div class="form-group">
                      <label
for="exampleSelectGender">Merek</label>
                      <select  name="merek"  required  class="form-
control" id="merek_form">
                        <option          value=""          disabled
selected>Merek</option>
                      </select>
                    </div>

                    <!-- tipe -->
```

```
                    <div class="form-group">
                      <label
for="exampleSelectGender">Tipe</label>
                      <select name="tipe" required class="form-
control" id="tipe_form">
                        <option value="" disabled
selected>Tipe</option>
                      </select>
                    </div>

                    <!-- ukuran -->
                    <div class="form-group">
                      <label>Ukuran</label>
                      <div class="input-group col-xs-12">
                        <input name="ukuran" required type="text"
id="ukuran_form" class="form-control"
                          placeholder="Ukuran dalam Inch">
                        <div class="input-group-append">
                          <span class="input-group-
text">Inch</span>
                        </div>
                      </div>
                    </div>

                    <!-- btn -->

                  </form>
                  <button onclick="kirim_form()" class="btn btn-
gradient-primary mr-2">Submit</button>
                  <button onclick="clear_form()" class="btn btn-
light">Clear</button>


                </div>
                <div class="card-body">

                  <h4 class="card-title">Hasil Predict Harga Tv :
<div id="loader" style="visibility: hidden"
                      class="spinner-border text-primary"></div>
                  </h4>

                  <div class="form-group">
                    <label>Harga</label>
                    <div class="input-group col-xs-12">
                      <div class="input-group-prepend">
                        <span class="input-group-text bg-gradient-
primary text-white">Rp. </span>
                      </div>
                      <input readonly type="text"
id="hasil_predict" class="form-control"
                        aria-label="Amount (to the nearest
dollar)">
                      <div class="input-group-append">
                        <span class="input-group-text">.00</span>
                      </div>
                    </div>
                  </div>
                </div>
              </div>
```

```
            </div>
          </div>
        </div>
        <!-- content-wrapper ends -->
        <!-- partial:../../partials/_footer.html -->
        <!-- partial -->
        <!-- container-scroller -->
        <!-- plugins:js -->
  <script
src="../../static/assets/vendors/js/vendor.bundle.base.js"></scrip
t>
  <!-- endinject -->
  <!-- Plugin js for this page -->
  <!-- End plugin js for this page -->
  <!-- inject:js -->
  <script src="../../static/assets/js/off-canvas.js"></script>
  <script                    src="../../static/assets/js/hoverable-
collapse.js"></script>
  <script src="../../static/assets/js/misc.js"></script>
  <!-- endinject -->
  <!-- Custom js for this page -->
  <script src="../../static/assets/js/file-upload.js"></script>
  <!-- End custom js for this page -->
</body>
</html>
```

DAFTAR PUSTAKA

Adnyana, I. (2016). *PREDIKSI LAMA STUDI MAHASISWA DENGAN METODE RANDOM FOREST (STUDI KASUS : STIKOM BALI)*. *Csrid Journal*, Vol. 8 No. 3.

Alpaydin, E. (2010). *Introduction to Machine Learning.* The MIT Press.

Ardianto, E. (2007). *Komunikasi Massa Suatu Pengantar*. Bandung: Simbiosa Rekatama.

Azizah. (2019). *Masyarakat tak Lagi Menonton TV, Benarkah?*. Retrieved from Republika.co.id : https://www.republika.co.id/berita/gaya-hidup/trend/py4k9l463/trendtek/internet/19/09/20/py3y1f463-masyarakat-tak-lagi-menonton-tv-benarkah.

Bernard, S., Heutte, B., & Adam, S. (2009). *Influence of hyperparameters on random forest accuracy. Lecture Notes in Computer Science* (pp. 171-180). Springer.

Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 123-140.

Breiman, L. (2001). Random Forest. *Machine Learning*, 5-32.

Dewi , N., & Syafitri , U. (2011). *PENERAPAN METODE RANDOM FOREST DALAM DRIVER ANALYSIS*. Vol. 16 No. 1.

Dhawangkhara , M., & Riksakomara , E. (2017). *Prediksi Intensitas Hujan Kota Surabaya dengan Matlab menggunakan Teknik Random Forest dan CART (Studi Kasus Kota Surabaya)*. Vol. 6, No. 1.

Firmani, A. N. (2016). *PENYELESAIAN REGRESI SEMIPARAMETRIK DENGAN MENGGUNAKAN REGRESI RANDOM FOREST*. Yogyakarta: Universitas Gadjah Mada.

Hadi, D. A. (2016). *Ebook Belajar HTML dan CSS Dasar*. Retrieved January 18, 2020, from http://malasngoding.com

Han, J. (2001). *Data Mining : Concept and Techniques.* California: Morgan Kaufmann.

Hanjura , A. (2014). *Heroku Cloud Application Development.* Birmingham: Packt.

Haristu, R. A. (2019). *Penerapan Metode Random Forest Untu k Prediksi Win Ratio Pemain Player Unknown Battleground*. Yogyakarta: Universitas Sanata Dharma.

Heriyanti, A. (2018, Maret 9). *Penjualan Elektronik via Online Melonjak*. Retrieved from Kontan.co.id: https://industri.kontan.co.id/news/penjualan-elektronik-via-online-melonjak

Hermawati, F. (2013). *Data Mining.* Yogyakarta: Andi Offset.

J.B, Wahyudi. (1983). *Jurnalistik Radio dan Televisi.* Jakarta: PT Pustaka Utama.

Lewis, M. D., & J, R. (2000). *An Introduction to Classification and Regression Trees (CART) Analysis.* California: UCLA Medical Center.

Liaw, A., & Wiener, M. (2002). Classification and regression by Random Forest. *R News*, 18-22.

Putra, A. (2014. *KLASIFIKASI TULISAN TANGAN BERUPA ANGKA MENGGUNAKAN RANDOM FOREST DAN HISTOGRAM OF ORIENTED GRADIENT*. *e-Proceeding of Engineering*, Vol.1, No.1, Page 738.

Putra, M. (2019). *SISTEM REKOMENDASI KELAYAKAN KREDIT MENGGUNAKAN METODE RANDOM FOREST PADA BRI KANTOR CABANG PELAIHARI*. Surabaya: Universitas Islam Negeri Sunan Ampel.

Russel, S., & Norvig, P. (1995). *Artificial Intelligence: A Modern Approach.* Prentice Hall International.

Samudra, A. (2019). *Pendekatan Random Forest Untuk Model Peramalan Harga Tembakau Rajangan Di Kabupaten Temanggung.* Yogyakarta: Universitas Sanata Dharma.

Samuel, A. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal 3*, 535-554.

Schneider, J. (1997, Februari 7). *Cross Validation.* Retrieved from https://www.cs.cmu.edu/~schneide/tut5/node42.html

Siburian, V., & Mulyana, I. (2018). *Prediksi Harga Ponsel Menggunakan Metode Random Forest.* Palembang: Universitas Sriwijaya.

Sugiyono. (2009). *Metode Penelitian Kuantitatif, Kualitatif dan R&D.* Bandung: Alfabeta.

Sutisno. (1993). *Pedoman Praktis Penulisan Skenario Televisi Dan Video.* Jakarta: PT. Gramedia Widia Sarana Indonesia.

Turland, M. (2010). *Architect"s Guide to Web Scraping with PHP.* Toronto: Marco Tabini & Associates, Inc.

Ulwan, N. (2016). *Pattern Recognition Pada Unstructured Data Teks Menggunakan Support Vector Machine Dan Association.* Yogyakarta: Universitas Islam Indonesia.

Walpole, R. (1992). *Pengantar Statistika Edisi ke-3.* Gramedia Pustaka.

Wiryanto. (2004). *Pengantar Ilmu Komunikasi.* Jakarta: PT. Gramedia Widasarana.

Yahya, S. (2018). *Metode Support Vector Machine dan Random Forest (Studi Kasus: Data Lama Studi Alumni Universitas Islam Indonesia Tahun Kelulusan 2000-2017).* Yogyakarta: Universitas Islam Indonesia.