

Implementasi Klasifikasi Gambar Untuk Industri Pakaian Menggunakan *Image Search Engine* Berbasis Website

1st Rafi Fakhri Hidayat
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

rafi@student.telkomuniversity.ac.id

2nd Budhi Irawan
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

budhiirawan@telkomuniversity.ac.id

3rd Muhammad Nasrun
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

nasrun@telkomuniversity.ac.id

Abstrak— Seiring dengan perkembangan teknologi saat ini, teknologi banyak digunakan sebagai sarana memperoleh informasi. Pencarian informasi sudah sering dilakukan di kehidupan sehari-hari yaitu dengan menggunakan *search engine*. Contohnya pada industri pakaian saat mencari produk pakaian yang diinginkan melalui *search engine*, dengan mengharapkan hasil yang didapat dari pencarian *search engine* sesuai dengan detail lengkap mengenai referensi brand produk pakaian tersebut namun metode pencarian berbasis teks memiliki keterbatasan dan hasil yang didapat dari pencarian *search engine* tidak selalu akurat. Untuk itu penggunaan *Convolutional Neural Network* (CNN) digunakan untuk menyusun dataset dari produk pakaian berdasarkan klasifikasi gambar yang di inputkan. Penelitian ini bertujuan untuk dapat membuat sebuah sistem *image search engine* berbasis *website* dengan menggunakan arsitektur dari CNN yaitu *Deep Residual Network* (ResNet) khususnya pada ResNet50 yang dapat mengklasifikasi gambar dari produk- produk pakaian, dengan menginputkan gambar dan menghasilkan output berupa kategori lengkap referensi brand produk pada pakaian tersebut menggunakan *Long Short Term Memory* (LSTM) dalam memprediksi hasilnya. Didapatkan hasil pengujian 99.47% pada akurasi *train* dan 99.61% pada akurasi validasi yang akan digunakan pada saat di implementasikan pada *website*.

Kata kunci— *Convolutional Neural Network, ResNet50, Long ShortTerm Memory.*

Abstract— Along with current technological developments, technology is usually a means of obtaining information. Searching for information has often been done in everyday life, namely by using search engines. For example, in the clothing industry when searching for the desired clothing product through search engines, expecting the results obtained from search engine searches are under complete details regarding the reference to the clothing product brand. However, the text-based search method has limitations to the results obtained from search engine searches are not always accurate. For this reason, *Convolutional Neural Network* (CNN) is used to compile a dataset of clothing products based on the classification of the images entered.

This study aims to be able to create a website-based image search engine system using the architecture of CNN, namely the Deep Residual Network (ResNet) especially on ResNet50 which can classify images from clothing products, by inputting images and producing output in the form of complete categories of

product brand references on the clothes, using Long Short Term Memory (LSTM) in predicting the results. The test results obtained are 99.47% for train accuracy and 99.61% for validation which will be used when implemented on the website

Keywords— *Convolutional Neural Network, ResNet50, Long ShortTerm Memory.*

I. PENDAHULUAN

Pakaian merupakan kebutuhan dasar dengan beragam makna bagi manusia di kehidupan sehari-hari yang berfungsi sebagai identitas sosial dan ideologi setiap manusia. Pakaian juga merupakan gaya hidup dari setiap yang menggunakannya. Pada saat ini, teknologi dalam industri pakaian sangat banyak digunakan, salah satunya yaitu saat mencari produk pakaian yang diinginkan melalui *search engine* dengan harapan output yang dihasilkan di *search engine* sesuai dengan detail lengkap referensi brand produk pakaian tersebut. Namun, metode pencarian berbasis teks memiliki keterbatasan, untuk itu penggunaan CNN dalam mendeteksi objek pada gambar dengan output detail lengkap produk pakaian tersebut.

Dari sistem yang dibangun dalam penelitian ini diharapkan dapat mempermudah dalam mencari produk pakaian yang diinginkan melalui *image search engine* dengan output yang dihasilkan sesuai dengan detail lengkap referensi brand produk pakaian tersebut. Data yang dipergunakan adalah dataset yang diambil dari beberapa produk pakaian. Pada penelitian menggunakan ResNet50 yang memiliki cakupan data untuk mendeteksi objek pada gambar yang di inputkan dalam mengkategorikan item secara lengkap untuk mendapatkan hasil sesuai yang diharapkan. Selain itu penelitian ini akan dibuat sebuah *website* untuk implementasi dan klasifikasi gambar dan menggunakan *Long Short Term Memory* (LSTM) yang digunakan untuk memproses input yang dipanggil secara berulang kali dan melakukan hal yang sama pada setiap tahapan di sebuah urutan, kemudian memproses output yang mengacu pada tahapan komputasi sebelumnya secara berurutan.


II. KAJIAN TEORI

A. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis algoritma Deep Learning yang dapat menerima input berupa gambar, menentukan aspek atau obyek apa saja dalam sebuah gambar yang bisa digunakan mesin untuk “belajar” mengenali gambar, dan membedakan antara satu gambar dengan yang lainnya yang biasanya digunakan untuk menganalisis gambaran visual [9]. CNN saat ini merupakan pilihan terbaik dalam aplikasi pencitraan medis seperti deteksi dan klasifikasi pada gambar. Dalam banyak kasus, kumpulan data terbatas dan mungkin tidak cukup untuk melatih CNN dari awal. Meskipun CNN mencapai hasil terbaik pada kumpulan data yang besar, tapi CNN membutuhkan banyak data dan sumber daya komputasi untuk dilatih.

B. Deep Residual Network (ResNet)

Deep Residual Network (ResNet) adalah jenis deep network berbasis pembelajaran residual. Pembelajaran semacam ini dapat memfasilitasi pelatihan jaringan dengan mempertimbangkan input layer sebagai referensi [10].



GAMBAR 1
RESIDUAL BLOCK [24]

Pada GAMBAR 1 merupakan gambar residual block dari arsitektur ResNet [24] menjelaskan fungsi $f(x)$ sebagai identitas dan fungsi $f(x) + (x)$ sebagai skip connection. Pada arsitektur ResNet proses pemetaan identitas dilakukan dengan skip connection (melewati beberapa layer) tanpa menyebabkan kehilangan gradient. ResNet terdiri dari beberapa variasi layer diantaranya yaitu 18 layer (ResNet18), 34 layer (ResNet34), 50 layer (ResNet50), 101 layer (ResNet101), dan 152 layer (ResNet152). ResNet50 adalah salah satu varian ResNet yang memiliki 50-layer yang dapat memuat versi jaringan yang telah dilatih sebelumnya yang dilatih pada lebih dari satu juta gambar dari database *ImageNet*. Jaringan yang telah dilatih dapat mengklasifikasikan gambar ke dalam 1000 kategori objek, seperti pada pakaian yaitu kemeja, kaus, celana, jaket dan banyak lainnya. Akibatnya, jaringan telah mempelajari representasi fitur yang kaya untuk berbagai gambar yang memiliki ukuran input gambar 224×224 .

TABEL I
NILAI AKURASI ARSITEKTUR CNN


Arsitektur CNN	Nilai Akurasi (%)
AlexNet	80.09%
Vgg16	86.26%
ResNet18	87.47%
ResNet34	90.46%
ResNet50	95.23%

Pada TABEL I menjelaskan mengenai nilai akurasi dari arsitektur CNN yang telah peneliti rangkum dari hasil penelitian [22] yaitu melakukan penelitian tentang klasifikasi penyakit otak dengan gambar MRI. Arsitektur yang digunakan adalah AlexNet, Vgg16, ResNet18, ResNet34 dan ResNet50. Pada penelitian tersebut diketahui bahwa ResNet50 memberikan nilai akurasi terbaik dari pada dengan arsitektur CNN yang lainnya.

C. Long ShortTerm Memory (LSTM)

Long ShortTerm Memory (LSTM) adalah salah satu modifikasi dari *Recurrent Neural Network* (RNN). Banyak modifikasi dari RNN, tetapi LSTM merupakan salah satu yang populer di antara semua modifikasi RNN [11]. LSTM pertama kali dikembangkan oleh Hochreiter dan Schmidhuber. LSTM hadir untuk melengkapi kekurangan RNN yang tidak dapat memprediksi kata berdasarkan informasi lampau yang disimpan dalam jangka waktu lama. Dengan demikian, informasi pada LSTM dapat disimpan dalam memori untuk jangka waktu yang lebih lama, dengan kemampuan untuk secara selektif memanggil kembali atau menghapus informasi yang tidak lagi relevan. LSTM lebih efisien dalam memproses, memprediksi, sekaligus mengklasifikasikan data berdasarkan urutan waktu tertentu.

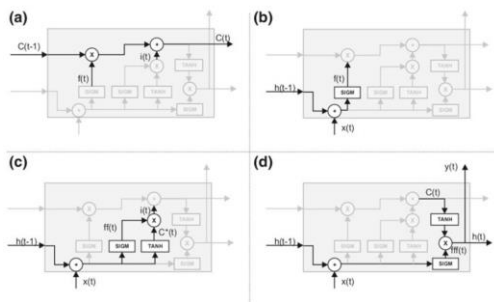
Perbedaan mendasar dari LSTM dan RNN adalah bahwa LSTM melengkapi kekurangan-kekurangan yang dimiliki oleh pendahulunya, recurrent neural network, yang tidak dapat memprediksi data berdasarkan informasi yang telah disimpan dalam waktu cukup lama. Dengan kata lain, persoalan jangka waktu penyimpanan tidak menjadi permasalahan dalam LSTM. Sistem yang menerapkan LSTM dapat memproses, memprediksi, dan mengklasifikasikan informasi berdasarkan data deret waktu. Sesuai dengan konsepnya, LSTM dapat mengingat dan menghapus data-data lawas yang sudah tidak relevan lagi.



GAMBAR 2
ARSITEKTUR LSTM [25]

Pada GAMBAR 2 merupakan arsitektur LSTM yang terdiri atas neural network dan beberapa blok memori yang berbeda. Blok memori ini disebut sebagai Cell state (C_t). State dari cell dan hidden state akan diteruskan ke cell berikutnya. Informasi yang dikumpulkan oleh algoritma LSTM kemudian akan disimpan oleh cell dan manipulasi memori dilakukan oleh komponen yang disebut dengan gate. Ada tiga jenis gate pada algoritma LSTM, di antaranya yaitu *Forget gate*, *Input gate*, dan *Output gate*. LSTM biasanya digunakan untuk klasifikasi dan prediksi berdasarkan data time-series seperti memberikan keterangan pada gambar dan video, translate Bahasa, dan Analisa Sentimen. Berdasarkan [25] LSTM dapat menambah atau menghapus informasi dari sel dengan menggunakan gate membuat sisa unit dalam LSTM. Sisa unit pada LSTM ini adalah kombinasi dari

penjumlahan, perkalian dan nonlinier. Sifat nonlinier digunakan hanya untuk memecah informasi. Kemudian fungsi aktivasi sigmoid (SIGM) digunakan untuk memecah informasi ke nilai antara 0 dan 1, dan fungsi aktivasi tangen hiperbolik (TANH) digunakan untuk memecah informasi ke nilai antara 1 dan 1.



GAMBAR 3

(A) CELL STATE, (B) FORGET GATE, (C) INPUT GATE, DAN (D) OUTPUT GATE [25]

Pada GAMBAR 3 merupakan gambar dari masing-masing gate pada LSTM yaitu (a) Cell state, (b) forget gate, (c) input gate, dan (d) output gate. Berdasarkan [25] LSTM dapat menambah atau menghapus informasi dari sel dengan menggunakan gate membuat sisa unit dalam LSTM. Sisa unit pada LSTM ini adalah kombinasi dari penjumlahan, perkalian dan nonlinier. Sifat nonlinier digunakan hanya untuk memecah informasi. Kemudian fungsi aktivasi sigmoid (SIGM) digunakan untuk memecah informasi ke nilai antara 0 dan 1, dan fungsi aktivasi tangen hiperbolik (TANH) digunakan untuk memecah informasi ke nilai antara 1 dan 1. Forget gate ($f(t)$) memiliki fungsi untuk mengontrol berapa banyak informasi dari input sebelumnya yang harus diingat. Secara matematis forget gate direpresentasikan pada persamaan (1).

$$f(t) = \sigma(\mathbf{w}f(x(t) + h(t-1))) \quad (1)$$

Kemudian pada *input gate* ($i(t)$) memiliki fungsi untuk memutuskan apa yang akan dimasukkan ke dalam *Cell state* ($C(t)$) yang terdiri dari *forget gate* ($f(t)$) tetapi dengan bobot yang berbeda $ff(t)$ merupakan salinan kedua dari forget gate yang dianggap sebagai mekanisme penghematan untuk mengontrol seberapa banyak dari input yang akan kita simpan ke Cell state ($C(t)$). Secara matematis input gate direpresentasikan pada persamaan (2) dan persamaan (3).

$$ff(t) = \sigma(\mathbf{w}ff(x(t) + h(t-1))) \quad (2)$$

$$i(t) = ff(t) \cdot C \ast (t) \quad (3)$$

Terakhir, pada *output gate* ($O(t)$) LSTM memiliki tiga keluaran: $C(t)$, $y(t)$ dan $h(t)$. Untuk menghitung $C(t)$ secara matematis direpresentasikan pada persamaan (4), kemudian untuk menghitung $y(t)$ secara matematis direpresentasikan pada persamaan (5), dan untuk menghitung $h(t)$ membutuhkan salinan ketiga dari *forget gate* ($fff(t)$) yang akan memiliki tugas memutuskan bagian mana dari input dan berapa banyak untuk memasukkannya ke dalam $h(t)$ yang secara matematis direpresentasikan pada persamaan (6).

$$C(t) = f(t) \cdot C(t-1) + i(t) \quad (4)$$

$$fff(t) = \sigma(\mathbf{w}fff(x(t) + h(t-1))) \quad (5)$$

$$h(t) = fff(t) \cdot \tau(C(t)) \quad (6)$$

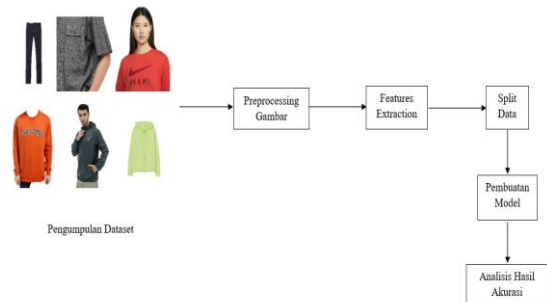
D. Image search engine

Image search engine saat ini sudah bisa untuk membantu pencarian media berupa gambar. Efektivitas dari sebuah pencarian bergantung pada kompleksitas waktu komputasi fitur dan struktur data sebuah gambar. Oleh sebab itu, semua perhitungan harus diminimalisir. Saat gambar pertama kali muncul di dalam sebuah web, semua nilai yang dibutuhkan dari fiturnya harus dihitung dan disimpan secara terstruktur bersama dengan elemen lain dari deskripsi sebuah gambar agar memaksimalkan efektivitas pencarian gambar [12]. Dengan berkembang pesatnya teknologi, sarana dalam memperoleh informasi pun lebih mudah diantaranya yaitu pada website sebagai saran untuk memperoleh informasi yang dapat diakses oleh setiap orang dengan menggunakan internet untuk mengaksesnya. Selain itu, website tidak hanya sebagai media untuk memperoleh informasi tetapi juga sebagai media komunikasi, media pendidikan, serta sebagai media promosi atau pemasaran dari suatu produk tertentu.

III. METODE

A. Gambaran Umum Sistem

Gambaran umum sistem dalam penelitian ini dibuat dalam bentuk diagram alir untuk perancangan sistem image search engine berbasis website secara keseluruhan.



GAMBAR 4

DIAGRAM ALIR GAMBARAN UMUM SISTEM.

Pada GAMBAR 4 merupakan alur kerja dari gambaran umum sistem. Pada tahapan pengumpulan dataset menggunakan dataset produk pakaian seperti kemeja, kaos, celana, dan jaket dari beberapa brand produk pakaian dengan jumlah sepuluh ribu gambar. Langkah selanjutnya adalah melakukan tahap *preprocessing* terhadap data gambar, tahapan ini dilakukan dengan menyiapkan dataset gambar. Kemudian pada tahapan *Features Extraction* menggunakan arsitektur yang berbasis *Convolutional Neural Network* (CNN) yaitu ResNet50. Selanjutnya pada tahap split data adalah membagi data menjadi data *training* dan testing yang masing-masing dengan beberapa variasi perbandingan seperti 80:20 sehingga sejumlah 8000 gambar adalah *training* dan 2000 gambar adalah *testing*, kemudian untuk data dipilih secara acak. Setelah itu, pada tahapan pembuatan model menggunakan LSTM yang cakupan data untuk mendeteksi objek pada gambar yang di inputkan untuk mendapatkan hasil sesuai yang diharapkan menghasilkan klasifikasi gambar yang akurat yang menghasilkan model yang akan digunakan pada saat di implementasikan pada *website*. Kemudian pada tahapan analisis hasil akurasi yaitu untuk mengetahui nilai akurasi tertinggi setiap parameter pengujian yang telah dilakukan pada tahapan pembuatan model.

B. Kebutuhan Data

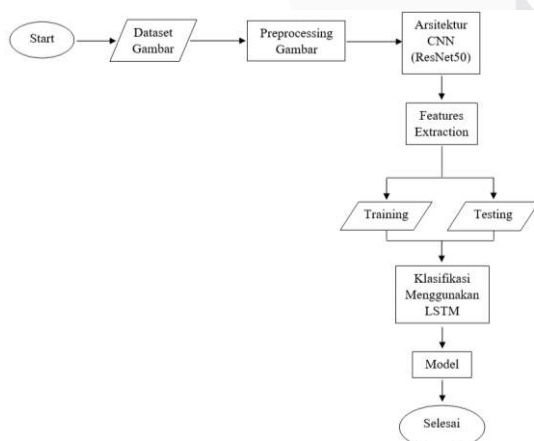
Dataset merupakan perwujudan data dalam memori yang memberikan model program relational yang konsisten tanpa memperhatikan asal dari sumber data [14]. Dataset juga merupakan kumpulan objek dan atribut - atributnya yang dapat memberikan pengaruh dalam melakukan proses pengklasifikasian gambar. Pada penelitian ini, dataset digunakan untuk mempersiapkan semua data yang dibutuhkan pada sistem image search engine berbasis website. Dataset sebagai input yang kemudian akan diproses pada tahap selanjutnya yaitu proses training dan testing klasifikasi gambar. Hasil akhir dari proses ini menghasilkan tingkat akurasi terkait kecocokan antara data input dengan data yang ada pada dataset.



GAMBAR 5
DATASET PRODUK PAKAIAN

Pada GAMBAR 5 merupakan gambar contoh dataset produk pakaian yang digunakan pada perancangan sistem image search engine berbasis website ini yaitu menggunakan dataset produk pakaian seperti kemeja, kaos, celana, dan jaket. Pada dataset yang telah diinputkan tersebut tetap memperhatikan garis, bentuk, siluet, ukuran, dan tekstur pada produk pakaian saat proses pengklasifikasian gambar. Untuk contoh dataset produk pakaian diambil dari beberapa website brand produk yang berjumlah sepuluh ribu dataset gambar, dengan diantaranya yaitu 3025 dataset gambar produk pakaian dari brand H&M [3], 1979 dataset gambar produk pakaian dari brand Nike [4], 2122 dataset gambar produk pakaian dari brand 3Second [5], 220 dataset gambar produk pakaian dari brand Uniqlo [6], 1412 dataset gambar produk pakaian dari brand Eiger [7], dan 1242 dataset gambar produk pakaian dari brand Levis [8].

C. Perancangan Sistem



GAMBAR 6
PERANCANGAN SISTEM

Pada GAMBAR 6 merupakan alur kerja dari perancangan sistem yang akan dilakukan dalam penelitian ini. Sistem dijalankan menggunakan Google Colab pada Google Chrome. Pada penelitian ini menggunakan sepuluh ribu dataset produk pakaian dan telah diperbanyak menjadi tiga

puluh ribu dataset gambar dengan dimodifikasi menggunakan software XnView dengan diantaranya yaitu 9075 dataset gambar produk pakaian dari brand H&M, 5937 dataset gambar produk pakaian dari brand Nike, 6366 dataset gambar produk pakaian dari brand 3Second, 660 dataset gambar produk pakaian dari brand Uniqlo, 4236 dataset gambar produk pakaian dari brand Eiger, dan 3726 dataset gambar produk pakaian dari brand Levis.



(a) (b) (c)
GAMBAR 7
HASIL MODIFIKASI DATASET MENGGUNAKAN XNVIEW

Pada GAMBAR 7 merupakan contoh hasil dataset yang telah dimodifikasi menggunakan software XnView yaitu (a) merupakan gambar asli, (b) merupakan modifikasi gambar dengan memutar gambar secara horizontal ke kanan, dan (c) merupakan modifikasi gambar dengan memutar gambar secara horizontal ke kiri. Kemudian dalam membuat dataset txt menggunakan Microsoft Excel seperti pada GAMBAR 8 pada kolom A di isi dengan keterangan nama dari gambar produk pakaian dan pada kolom B di isi dengan keterangan label dari gambar produk pakaian yang sama dengan kolom A, keterangan label tersebut diantaranya merupakan brand dan type dari produk pakaian tersebut.

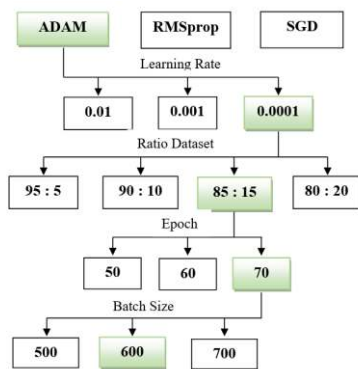
A	B
000ae15031b01f78cea15578c12271a94bee869b_xxl-1.jpg#0	H&M MEN'S RUNNING TIGHTS
000ae15031b01f78cea15578c12271a94bee869b_xxl-1.jpg#0	H&M MEN'S RUNNING TIGHTS
000ae15031b01f78cea15578c12271a94bee869b_xxl-1.jpg#0	H&M MEN'S RUNNING TIGHTS
001693e526ec9224907aea4429857990d5cbdac_xxl-1.jpg#0	H&M WOMEN'S PLEATED DRESS
001693e526ec9224907aea4429857990d5cbdac_xxl-1.jpg#0	H&M WOMEN'S PLEATED DRESS
001693e526ec9224907aea4429857990d5cbdac_xxl-1.jpg#0	H&M WOMEN'S PLEATED DRESS
0022e73716c254bda6e889ef6362801c27eb5c0_xxl-1.jpg#0	H&M MEN'S SLIM JEANS
0022e73716c254bda6e889ef6362801c27eb5c0_xxl-1.jpg#0	H&M MEN'S SLIM JEANS

GAMBAR 8
DATASET PELABELAN GAMBAR PRODUK PAKAIAN.

Preprocessing merupakan Komponen dasar dalam pengenalan pola gambar, Pada perancangan *image search engine* berbasis website ini, pertama-tama dilakukannya penyiapan dataset. Setelah dataset diperoleh, gambar diproses terlebih dahulu per dataset, setelah selesai maka proses berikutnya yaitu menggunakan arsitektur dari ResNet-50 pada *Features extraction*. *Features extraction* digunakan untuk membedakan suatu pola dengan pola lainnya yang diperoleh dari hasil pengukuran terhadap objek yang telah di uji. Pada perancangan image search engine berbasis website ini, *Features extraction* dilakukan setelah proses preprocessing selesai dan telah menggunakan arsitektur ResNet50 dimana dataset kemudian diubah menjadi fitur yang mewakili data asli yang terdefinisi dan dapat diidentifikasi melalui ciri-cirinya. Pola yang terdapat didalam gambar, bertujuan menentukan kelompok atau kategori berdasarkan ciri yang dimiliki oleh pola gambar tersebut seperti atribut yang menjadi ciri pada gambar produk pakaian. Maka, dalam membedakan pola gambar suatu objek dengan objek lainnya bisa dilakukan pengenalan pola gambar yaitu pada training dan testing model yang dapat dipelajari untuk menentukan ciri dalam menentukan klasifikasinya.

IV. HASIL DAN PEMBAHASAN

A. Skenario Pengujian



GAMBAR 9
ILUSTRASI SKENARIO PENGUJIAN


Pada GAMBAR 9 merupakan ilustrasi dari skenario pengujian yang telah dilakukan. Skenario pengujian ini dilakukan menggunakan arsitektur ResNet50 dan Algoritma LSTM pada pengujian pertama dilakukan dengan menguji tiga Optimizer yaitu Adam, RMSprop, dan SGD. Pengujian pada Optimizer dilakukan untuk mengetahui Optimizer dengan akurasi terbaik yang akan digunakan dalam merancang model. Kemudian pada pengujian selanjutnya dilakukan dengan menguji tiga learning rate yaitu pada nilai 0.0001, 0.001, dan 0.01 untuk mengetahui nilai learning rate terbaik yang akan digunakan dalam merancang model. Selanjutnya dilakukan pengujian dengan menguji pada empat parameter ratio dataset untuk merancang model dengan dibagi menjadi ratio training dataset dan testing dataset yaitu pada ratio 95:5, 90:10, 85:15, dan 80:20. Pengujian pada ratio dataset ini juga menggunakan beragam parameter pada tiga epoch yaitu 50, 60, dan 70 serta menggunakan beragam parameter pada tiga batch size yaitu 500, 600, dan 700. Pengujian pada ratio dataset ini dilakukan untuk mengetahui model dengan nilai akurasi terbaik yang akan digunakan pada saat di implementasikan pada website.

B. Hasil Pengujian Optimizer

Pada TABEL II menunjukkan hasil pengujian tiga Optimizer yang berbeda dilakukan pada tiga puluh ribu dataset gambar dengan menggunakan ratio 95:5 data training dan data testing serta menggunakan *epoch* = 70 dan *batchsize* = 700. Optimizer dengan nilai *accuracy* & *loss accuracy* terbaik yaitu pada Optimizer Adam dan Optimizer dengan nilai *accuracy* & *loss accuracy* terendah yaitu pada Optimizer SGD.

TABEL II
PENGUJIAN OPTIMIZER

Optimizer	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
RMSprop	98.77%	0.0764	99.05%	0.0671
Adam	98.98%	0.0600	98.73%	0.0664
SGD	16.65%	5.2585	16.65%	5.2511




GAMBAR 10
GRAFIK ACCURACY & LOSS ACCURACY OPTIMIZER

C. Hasil Pengujian Learning Rate

Pada TABEL III merupakan hasil dari pengujian pada learning rate yang dilakukan tiga nilai *learning rate* yang berbeda pada tiga puluh ribu dataset gambar dengan menggunakan ratio 95:5 data *training* dan data *testing* serta menggunakan *epoch* = 70 dan *batchsize* = 700. Learning rate dengan nilai *accuracy* & *loss accuracy* terbaik yaitu pada learning rate dengan nilai 0.0001 dan learning rate dengan nilai *accuracy* & *loss accuracy* terendah yaitu pada learning rate dengan nilai 0.01 hal ini terlihat pada nilai *accuracy* & *loss accuracy* learning rate dalam rentang nilai 0 sampai 1 bahwa semakin mendekati angka 1 maka nilai *accuracy* learning rate semakin kecil dan begitu juga sebaliknya semakin menjauhi angka 1 maka nilai *accuracy* learning rate semakin besar.

TABEL III
PENGUJIAN LEARNING RATE

Learning Rate	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
0.0001	98.98%	0.0600	98.73%	0.0664
0.001	98.93%	0.0336	98.71%	0.0396
0.01	16.65%	4.5599	16.65%	4.5545



GAMBAR 10
GRAFIK ACCURACY & LOSS ACCURACY LAEARNING RATE

D. Hasil Pengujian Ratio Dataset

Pada TABEL IV merupakan hasil pengujian ratio 95:5 data *training* dan data *testing* ini, didapatkan hasil pada Tabel pengujian menunjukkan besarnya nilai *accuracy* & *loss accuracy* yang telah dilakukan menggunakan *epoch* dan *batchsize* yang berbeda. Dari Nilai *accuracy* terbaik pada pengujian ratio 95:5 data *training* dan data *testing* ini yaitu pada *epoch* = 70 dan *batchsize* = 600 dengan *learning rate* = 0.0001.

TABEL IV
HASIL PENGUJIAN RATIO 95:5 DATA TRAINING DAN DATA TESTING.

Epoch	Batch Size	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
50	500	97.74%	0.1036	98.28%	0.0894
	600	96.35%	0.1529	96.37%	0.1534
	700	96.77%	0.1392	97.47%	0.1213
60	500	98.4%	0.0733	98.69%	0.0672
	600	98.23%	0.0841	98.52%	0.0749
	700	96.99%	0.1293	97.51%	0.1161
70	500	98.62%	0.0632	99.28%	0.0447
	600	98.97%	0.0559	99.29%	0.0465
	700	98.98%	0.0600	98.73%	0.0664

Pada TABEL V merupakan hasil pengujian ratio 90:10 data *training* dan data *testing* ini, didapatkan hasil pada Tabel 4.4 pengujian diatas menunjukkan besarnya nilai *accuracy* & *loss accuracy* yang telah dilakukan menggunakan *epoch* dan *batchsize* yang berbeda. Dari Nilai *accuracy* terbaik pada pengujian ratio 90:10 data *training* dan data *testing* ini yaitu pada *epoch* = 60 dan *batchsize* = 500 dengan *learning rate* = 0.0001.

TABEL V
HASIL PENGUJIAN RATIO 90:10 DATA TRAINING DAN DATA TESTING.

Epoch	Batch Size	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
50	500	97.72%	0.1076	98.37%	0.0903
	600	97.06%	0.1319	97.13%	0.1292
	700	95.9%	0.1722	96.58%	0.1559
60	500	98.8%	0.0599	99.04%	0.0544
	600	98.02%	0.0926	98.23%	0.0872
	700	97.24%	0.1260	97.7%	0.1142
70	500	98.74%	0.0592	99.5%	0.0351
	600	98.64%	0.0663	99.02%	0.0570
	700	98.73%	0.0688	98.72%	0.0665

Pada TABEL VI merupakan hasil pengujian ratio 85:15 data training dan data testing ini, didapatkan hasil pada Tabel 4.5 pengujian diatas menunjukkan besarnya nilai *accuracy* & *loss accuracy* yang telah dilakukan menggunakan *epoch* dan *batchsize* yang berbeda. Dari Nilai *accuracy* terbaik pada pengujian ratio 85:15 data training dan data testing ini yaitu pada *epoch* = 70 dan *batchsize* = 600 dengan *learning rate* = 0.0001.

TABEL VI
HASIL PENGUJIAN RATIO 85:15 DATA TRAINING DAN DATA TESTING.

Epoch	Batch Size	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
50	500	97.6%	0.1093	97.47%	0.1133
	600	95.99%	0.1635	96.01%	0.1677
	700	95.71%	0.1794	96.02%	0.1735
60	500	98.79%	0.0630	97.97%	0.0869
	600	97.86%	0.0977	98.54%	0.0797
	700	97.91%	0.0996	98.27%	0.0910
70	500	99.5%	0.0337	99.05%	0.0453
	600	99.47%	0.0381	99.61%	0.0344
	700	98.72%	0.0708	98.93%	0.0644

Pada TABEL VII merupakan hasil pengujian ratio 80:20 data training dan data testing ini, didapatkan hasil pada Tabel 4.6 pengujian diatas menunjukkan besarnya nilai *accuracy* & *loss accuracy* yang telah dilakukan menggunakan *epoch* dan *batchsize* yang berbeda. Dari Nilai *accuracy* terbaik pada pengujian ratio 80:20 data training dan data testing ini yaitu pada *epoch* = 70 dan *batchsize* = 500 dengan *learning rate* = 0.0001.


TABEL VII
HASIL PENGUJIAN RATIO 80:20 DATA TRAINING DAN DATA TESTING.

Epoch	Batch Size	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
50	500	97.18%	0.1208	98.17%	0.0977
	600	97.37%	0.1169	98.02%	0.1001
	700	95.92%	0.1704	96.62%	0.1527
60	500	98.73%	0.0640	98.09%	0.0827
	600	98.13%	0.0909	98.22%	0.0896
	700	97.49%	0.1142	97.92%	0.1049
70	500	99.26%	0.0419	99.21%	0.0434
	600	98.99%	0.0571	98.87%	0.0601
	700	98.21%	0.0862	98.25%	0.0877

Berdasarkan TABEL VIII merupakan hasil pengujian dengan akurasi terbaik dari setiap pengujian ratio dataset yang telah dilakukan, ditemukan bahwa pengujian model dengan menggunakan ratio data 85:15 data training dan data testing yaitu pada *epoch* = 70 dan *batchsize* = 600 dengan *learning rate* = 0.0001 memiliki nilai *accuracy* terbaik yang akan digunakan pada saat di implementasikan pada *website*.

TABEL VII Hasil Pengujian terbaik setiap ratio pada data training dan data testing

Ratio	Train Accuracy (%)	Train Loss	Validation Accuracy (%)	Validation Loss
95:5	98.97%	0.0559	99.29%	0.0465
90:10	98.8%	0.0599	99.04%	0.0544
85:15	99.47%	0.0381	99.61%	0.0344
80:20	99.26%	0.0419	99.21%	0.0434



GAMBAR 11
GRAFIK ACCURACY & LOSS ACCURACY TERBAIK

V. KESIMPULAN

Berdasarkan hasil dari semua pengujian yang telah dilakukan, parameter uji dengan akurasi terbaik yaitu menggunakan ratio data 85:15 data training dan data testing yaitu pada *epoch* = 70 dan *batchsize* = 600 dengan *learning rate* = 0.0001 memiliki nilai akurasi terbaik yaitu 99.47% pada akurasi train dan 99.61% pada akurasi validasi yang akan digunakan pada saat di implementasikan pada *website*.

REFERENSI

- [1] I. Melfianora and M. Si, "PENULISAN KARYA TULIS ILMIAH DENGAN STUDI LITERATUR." [Online]. Available: <http://banjirembun.blogspot.co.id/2012/04/penelitian-kepuustakaan.html>
- [2] Jaedun, A. (2011). Metodologi penelitian eksperimen. Fakultas Teknik UNY, 12.
- [3] "H&M Indonesia" https://id.hm.com/id_id/ [Diakses pada 14 Maret 2022, 14:11:07 WIB]
- [4] "Nike Indonesia" <https://www.nike.com/id/> [Diakses pada 16 Maret 2022, 06:47:27 WIB]
- [5] "3Second" <https://3second.co.id/> [Diakses pada 16 Maret 2022, 11:33:19 WIB]
- [6] "Uniqlo Indonesia" <https://www.uniqlo.com/id/id/> [Diakses pada 22 Maret 2022, 02:44:16 WIB]
- [7] "Eiger" <https://eigeradventure.com/> [Diakses pada 12 April 2022, 22:14:29 WIB]

- [8] "Levis Indonesia"
<https://www.levi.co.id/>
[Diakses pada 20 April 2022, 09:28:11 WIB]
- [9] Wonohadidjojo, D. M. (2021). Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih. *Ultimatics: Jurnal Teknik Informatika*, 13(1), 51-57.
- [10] Hendra, S. B. H., Azizah, A. S. N., & Akbar, F. (2020). Perbandingan Kinerja Arsitektur Inception-V4 dan ResNet-50 Dalam Mengklasifikasikan Citra Paru-Paru Terinfeksi Covid-19. *Digilib Unhas*.
- [11] Sharma, N., Jain, V., & Mishra, A. (2018). An analysis of convolutional neural networks for image classification. *Procedia computer science*, 132, 377-384.
- [12] "Image Search Engine: Teknologi Review"
[Image Search Engine: Teknologi Review – MTI \(binus.ac.id\)](https://www.binus.ac.id/)
[Diakses pada 18 Desember 2021, 16:19:22 WIB]
- [13] Enterprise, J. (2013). *Trik Cepat Menguasai Google Chrome*. Elex Media Komputindo.
- [14] Khaeriyah, R. (2019). Implementasi Metode Convolutional Neural Network Menggunakan Tensorflow Dalam Mendeteksi Sebuah Objek.
[15] "Google Colab"
https://colab.research.google.com/?hl=id#scrollTo=5fCEDCU_qrC0 [Diakses pada 18 Desember 2021, 13:09:47 WIB]
- [16] Grinberg, M. (2018). *Flask web development: developing web applications with python*. "O'Reilly Media, Inc."
- [17] Malhotra, R., Raj, T., & Gupta, V. (2022, March). Image Captioning and Identification of Dangerous Situations using Transfer Learning. In *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 909-915). IEEE.
- [18] Bird, J. J., Faria, D. R., Premevida, C., Ekárt, A., & Ayrosa, P. P. (2020, April). Overcoming data scarcity in speaker identification: Dataset augmentation with synthetic mfccs via character-level rnn. In *2020 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)* (pp. 146-151). IEEE.
- [19] Yuvaraj, G., & Anand Kumar, R. IMAGE CAPTION GENERATOR USING IMAGE FEATURES AND LSTM NETWORKS.
- [20] Vinyals, O., Toshev, A., Bengio, S., & Erhan, D. (2015). Show and tell: A neural image caption generator. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3156-3164).
- [21] Tanti, M., Gatt, A., & Camilleri, K. P. (2017). What is the role of recurrent neural networks (rnns) in an image caption generator?. *arXiv preprint arXiv:1708.02043*.
- [22] Talo, M., Yildirim, O., Baloglu, U. B., Aydin, G., & Acharya, U. R. (2019). Convolutional neural networks for multi-class brain disease detection using MRI images. *Computerized Medical Imaging and Graphics*, 78, 101673.
- [23] <https://www.niagahoster.co.id/blog/tutorial-bootstrap-5/#:~:text=Bootstrap%20adalah%20versi%20terbaru%20dari%20salah%20satu%20front%20end,semua%20elemen%20yang%20disediakan%20Bootstrap>
[Diakses pada 14 Agustus 2022, 09:43:47 WIB]
- [24] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [25] Skansi, S. (2018). *Introduction to Deep Learning: from logical calculus to artificial intelligence*. Springer.