

SKRIPSI

**ANALISIS SENTIMEN BERDASARKAN EKSPRESI WAJAH
PADA VIDEO REVIEW PRODUK MENGGUNAKAN
CONVOLUTIONAL NEURAL NETWORK**

Disusun dan diajukan oleh:

**AMIRUDDIN
D121171004**



**PROGRAM STUDI SARJANA TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

LEMBAR PENGESAHAN SKRIPSI

ANALISIS SENTIMEN BERDASARKAN EKSPRESI WAJAH PADA VIDEO REVIEW PRODUK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Disusun dan diajukan oleh


Amiruddin
D121171004


Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian
Studi Program Sarjana Program Studi Teknik Informatika
Fakultas Teknik Universitas Hasanuddin
Pada tanggal 26 Januari 2024
dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,


Pembimbing Utama,

Pembimbing Pendamping,


Prof. Dr. Ir. Indrabayu, S.T., M.T.
M.Bus.Sys., IPM, ASEAN. Eng.
NIP 19750716 200212 1 004


Anugravani Bustamin, S.T., M.T.
NIP 19901201 201807 4 001

Ketua Program Studi,


Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM, ASEAN. Eng.
NIP 19750716 200212 1 004



PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini ;

Nama : Amiruddin
NIM : D121171004
Program Studi : Teknik Informatika
Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

{Analisis Sentimen Berdasarkan Ekspresi Wajah pada Video Review Produk menggunakan Convolutional Neural Network}

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Semua informasi yang ditulis dalam skripsi yang berasal dari penulis lain telah diberi penghargaan, yakni dengan mengutip sumber dan tahun penerbitannya. Oleh karena itu semua tulisan dalam skripsi ini sepenuhnya menjadi tanggung jawab penulis. Apabila ada pihak manapun yang merasa ada kesamaan judul dan atau hasil temuan dalam skripsi ini, maka penulis siap untuk diklarifikasi dan mempertanggungjawabkan segala resiko.

Segala data dan informasi yang diperoleh selama proses pembuatan skripsi, yang akan dipublikasi oleh Penulis di masa depan harus mendapat persetujuan dari Dosen Pembimbing.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Makassar, 27 Januari 2024

Yang Menyatakan



Amiruddin

ABSTRAK

AMIRUDDIN. *Analisis Sentimen Berdasarkan Ekspresi Wajah Pada Video Review Produk Menggunakan Convolutional Neural Network* (dibimbing oleh Indrabayu dan Anugrayani Bustamin)

Analisis sentimen berbasis ekspresi wajah menjadi topik yang menarik dalam pengenalan pola dan kecerdasan buatan. Dalam penelitian ini, kami mengusulkan sebuah model berdasarkan arsitektur ResNet50 yang dilatih untuk mengenali ekspresi wajah dalam video review produk menggunakan Convolutional Neural Network (CNN). Tujuan dari penelitian ini adalah untuk mengembangkan sebuah model deep learning yang mampu mengidentifikasi sentimen positif, negatif, atau netral pada video review produk berdasarkan ekspresi wajah yang ditampilkan oleh reviewer.

Penelitian ini dimulai dengan pengumpulan dan pengolahan dataset yang berisi video review produk yang kemudian diekstrak dengan berbagai ekspresi wajah, seperti senang, kecewa, marah, netral, dan kaget. Selanjutnya, kami menggunakan ResNet50 sebagai basis model dan melakukan transfer learning dengan memuat bobot pra-pelatihan dari ImageNet. Kami menyesuaikan model dengan dataset kami dan melakukan pelatihan pada data tersebut.

Kami melakukan pelatihan model dengan 12 skenario berbeda, mengubah parameter seperti ukuran batch (8, 16, dan 32), learning rate (0.0001 dan 0.0004), serta menggunakan optimizer Adam dan Adamax. Evaluasi dilakukan dengan membagi dataset menjadi data pelatihan dan data validasi. Hasil pelatihan menunjukkan bahwa skenario dengan batch size 32, learning rate 0.0004, dan optimizer Adam menghasilkan akurasi pelatihan sebesar 99.83% dan akurasi validasi sebesar 95.00%, yang merupakan kinerja terbaik di antara skenario lainnya.

Hasil penelitian ini menunjukkan bahwa model kami berhasil mengenali ekspresi wajah dalam video review produk dengan baik. Hal ini menunjukkan bahwa ekspresi wajah dapat digunakan sebagai indikator sentimen pada video review produk, dan penggunaan CNN dalam pengolahan data wajah dapat meningkatkan kinerja klasifikasi sentimen secara signifikan. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi analisis sentimen pada video review produk yang lebih akurat dan efektif. Namun, perlu diperhatikan bahwa hasil pelatihan dapat dipengaruhi oleh ukuran dataset, variasi ekspresi, dan kompleksitas model. Penelitian lebih lanjut dapat menggali lebih dalam dengan memperluas dataset, menggunakan teknik data augmentation, atau mengeksplorasi kombinasi parameter lainnya untuk meningkatkan performa model.

Kata Kunci: Analisis sentimen, Ekspresi wajah, CNN, ResNet50, Video review produk

ABSTRACT

AMIRUDDIN. *SENTIMENT ANALYSIS BASED ON FACIAL EXPRESSIONS IN PRODUCT REVIEW VIDEOS USING CONVOLUTIONAL NEURAL NETWORK* (supervised by Indrabayu and Anugrayani Bustamin)

Sentiment analysis based on facial expressions has become an intriguing topic in pattern recognition and artificial intelligence. In this research, we propose a model based on the ResNet50 architecture, trained to recognize facial expressions in product review videos using Convolutional Neural Network (CNN). The objective of this study is to develop a deep learning model capable of identifying positive, negative, or neutral sentiments in product review videos based on the facial expressions displayed by the reviewers.

This research begins with the collection and preprocessing of a dataset containing product review videos, from which various facial expressions such as happiness, disappointment, anger, neutrality, and surprise are extracted. Subsequently, we employ ResNet50 as the base model and conduct transfer learning by loading pre-trained weights from ImageNet. The model is adapted to our dataset and trained on the collected data.

We perform the model training with 12 different scenarios, varying parameters such as batch size (8, 16, and 32), learning rate (0.0001 and 0.0004), and using optimizers Adam and Adamax. Evaluation is carried out by splitting the dataset into training and validation data. The training results show that the scenario with a batch size of 32, a learning rate of 0.0004, and Adam optimizer achieves a training accuracy of 99.83% and a validation accuracy of 95.00%, which represents the best performance among the other scenarios.

The results of this research demonstrate that our model successfully recognizes facial expressions in product review videos. This indicates that facial expressions can be used as sentiment indicators in product review videos, and the use of CNN in facial data processing significantly improves sentiment classification performance. This study is expected to contribute to the development of more accurate and effective sentiment analysis technology in product review videos. However, it should be noted that training outcomes may be influenced by the dataset size, expression variations, and model complexity. Further research could delve deeper by expanding the dataset, using data augmentation techniques, or exploring other parameter combinations to enhance the model's performance.

Keywords: Sentiment analysis, Facial expressions, CNN, ResNet50, Product review videos.

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI	i
PERNYATAAN KEASLIAN.....	ii
ABSTRAK	iii
ABSTRACT.....	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR.....	vii
DAFTAR TABEL	ix
DAFTAR SINGKATAN DAN ARTI SIMBOL	xi
DAFTAR LAMPIRAN	xii
KATA PENGANTAR.....	1
BAB I PENDAHULUAN.....	3
1.1 Latar Belakang	3
1.2 Rumusan Masalah	5
1.3 Tujuan Penelitian/Perancangan	5
1.4 Manfaat Penelitian/Perancangan	5
1.5 Ruang Lingkup/Asumsi perancangan	6
BAB II TINJAUAN PUSTAKA.....	7
2.1 Analisis Sentimen.....	7
2.2 Ekspresi Wajah dan Model Emosi	7
2.3 Visi Komputer.....	8
2.3.1 Pengolahan Citra	9
2.3.2 Augmentasi Gambar.....	9
2.3.3 Pengenalan Pola	10
2.4 <i>Face Detection</i>	10
2.5 <i>Convolutional Neural Network</i>	11
2.5.1 <i>Convolutional Layer</i>	11
2.5.2 <i>Pooling</i>	11
2.5.3 <i>Fully Connected Layer</i>	12
2.5.4 <i>Batch Size</i>	12
2.5.5 <i>Optimizer</i>	13
2.5.6 <i>Learning Rate</i>	14
2.5.7 ResNet50	15
2.5.7 <i>Confusion Matrix</i>	16
BAB 3 METODE PENELITIAN/PERANCANGAN	19
3.1 Tahap Penelitian.....	19
3.2 Waktu dan Lokasi Penelitian.....	20
3.3 Instrumen Penelitian.....	20
3.4 Teknik Pengambilan Data	20
3.5 Perancangan Sistem.....	22

3.6 Implementasi CNN Resnet50.....	23
3.7 Evaluasi Sistem	26
BAB 4 HASIL DAN PEMBAHASAN	29
4.1 Hasil Penelitian	29
4.1.1 Hasil Skenario Pertama	29
4.1.2 Hasil Skenario Kedua.....	34
4.1.3 Hasil Skenario Ketiga.....	38
4.1.4 Hasil Skenario Keempat.....	43
4.1.5 Hasil Skenario Kelima	47
4.1.6 Hasil Skenario Keenam.....	52
4.1.8 Hasil Skenario Ketujuh	56
4.1.8 Hasil Skenario Kedelapan	61
4.1.9 Hasil Skenario Kesembilan	65
4.1.10 Hasil Skenario Kesepuluh	69
4.1.11 Hasil Skenario Kesebelas.....	74
4.1.12 Hasil Skenario Keduabelas.....	78
4.2 Pembahasan	83
BAB 5 KESIMPULAN DAN SARAN	90
5.1 Kesimpulan.....	90
5.2 Saran.....	90
DAFTAR PUSTAKA	91

DAFTAR GAMBAR

Gambar 1. Model dimensional dua dimensi	8
Gambar 2. <i>Residual Block</i>	15
Gambar 3. <i>ResNet50 Model Architecture</i>	16
Gambar 4. <i>Multi-Class Confusion Matrix</i> (Sumber: Grandini, Bagli, & Visani, 2020).....	16
Gambar 5. Tahapan Penelitian	19
Gambar 6. Contoh hasil ekstrak <i>frame</i>	21
Gambar 7. Block Diagram Sistem	22
Gambar 8. Garis besar arsitektur <i>ResNet50</i> . (a) Lapisan input gambar dengan 3 layer. yaitu <i>channel</i> merah (<i>red</i>), hijau (<i>green</i>), dan biru (<i>blue</i>). (b) Gambaran keseluruhan struktur <i>ResNet50</i> . Simbol $\times 2$, $\times 3$, $\times 5$ dalam gambar adalah jumlah blok. (c) Struktur blok konvolusi di mana dimensi input bervariasi. (d) Struktur blok identitas di mana dimensi input tidak berubah.	24
Gambar 9. Grafik hasil <i>training</i> skenario pertama.....	29
Gambar 10. <i>Confusion matrix</i> skenario pertama	30
Gambar 11. Grafik hasil <i>training</i> dataset kombinasi skenario pertama.....	32
Gambar 12. <i>Confusion matrix</i> dataset kombinasi skenario pertama.....	32
Gambar 13. Grafik hasil <i>training</i> skenario kedua.....	34
Gambar 14. <i>Confusion matrix</i> skenario kedua.....	35
Gambar 15. Grafik hasil <i>training</i> dataset kombinasi skenario kedua	36
Gambar 16. <i>Confusion matrix</i> dataset kombinasi skenario kedua	37
Gambar 17. Grafik hasil <i>training</i> skenario ketiga.....	39
Gambar 18. <i>Confusion matrix</i> skenario ketiga.....	39
Gambar 19. Grafik hasil <i>training</i> dataset kombinasi skenario ketiga.....	41
Gambar 20. <i>Confusion matrix</i> dataset kombinasi skenario ketiga.....	41
Gambar 21. Grafik hasil <i>training</i> skenario keempat.....	43
Gambar 22. <i>Confusion matrix</i> skenario keempat.....	44
Gambar 23. Grafik hasil <i>training</i> dataset kombinasi skenario keempat	45
Gambar 24. <i>Confusion matrix</i> dataset kombinasi skenario keempat	46
Gambar 25. Grafik hasil <i>training</i> skenario kelima.....	48
Gambar 26. <i>Confusion matrix</i> skenario kelima	48
Gambar 27. Grafik hasil <i>training</i> skenario kelima.....	50
Gambar 28. <i>Confusion matrix</i> dataset kombinasi skenario kelima.....	50
Gambar 29. Grafik hasil <i>training</i> skenario keenam.....	52
Gambar 30. <i>Confusion matrix</i> skenario keenam	53
Gambar 31. Grafik hasil <i>training</i> dataset kombinasi skenario keenam	54
Gambar 32. <i>Confusion matrix</i> dataset kombinasi skenario keenam	55
Gambar 33. Grafik hasil <i>training</i> skenario ketujuh	56
Gambar 34. <i>Confusion matrix</i> skenario ketujuh	57
Gambar 35. Grafik hasil <i>training</i> dataset kombinasi skenario ketujuh.....	59
Gambar 36. <i>Confusion matrix</i> dataset kombinasi skenario ketujuh.....	59
Gambar 37. Grafik hasil <i>training</i> skenario kedelapan	61
Gambar 38. <i>Confusion matrix</i> skenario kedelapan	62
Gambar 39. Grafik hasil <i>training</i> dataset kombinasi skenario kedelapan	63

Gambar 40. <i>Confusion matrix</i> dataset kombinasi skenario kedelapan	64
Gambar 41. Grafik hasil <i>training</i> skenario kesembilan	65
Gambar 42. <i>Confusion matrix</i> skenario kesembilan	66
Gambar 43. Grafik hasil <i>training</i> dataset kombinasi skenario kesembilan	67
Gambar 44. <i>Confusion matrix</i> dataset kombinasi skenario kesembilan	68
Gambar 45. Grafik hasil <i>training</i> skenario kesepuluh	70
Gambar 46. <i>Confusion matrix</i> skenario kesepuluh	70
Gambar 47. Grafik hasil <i>training</i> dataset kombinasi skenario kesepuluh	72
Gambar 48. <i>Confusion matrix</i> dataset kombinasi skenario kesepuluh	73
Gambar 49. Grafik hasil <i>training</i> skenario kesebelas	74
Gambar 50. <i>Confusion matrix</i> skenario kesebelas	75
Gambar 51. Grafik hasil <i>training</i> dataset kombinasi skenario kesebelas	76
Gambar 52. <i>Confusion matrix</i> dataset kombinasi skenario kesebelas	77
Gambar 53. Grafik hasil <i>training</i> skenario keduabelas.....	78
Gambar 54. <i>Confusion matrix</i> skenario keduabelas.....	79
Gambar 55. Grafik hasil <i>training</i> skenario keduabelas.....	81
Gambar 56. <i>Confusion matrix</i> skenario keduabelas.....	81
Gambar 57. <i>Training</i> akurasi dari keseluruhan skenario	83
Gambar 58. <i>Validation</i> akurasi dari keseluruhan skenario	84
Gambar 59. <i>Training</i> akurasi dataset kombinasi dari keseluruhan skenario	85
Gambar 60. <i>Validation</i> akurasi dari keseluruhan skenario	86

DAFTAR TABEL

Tabel 1. Proporsi Data yang Digunakan	22
Tabel 2. Skenario Pelatihan.....	27
Tabel 3. Hasil Uji Skenario Pertama.....	31
Tabel 4. Persentase Analisis Sentimen Skenario Pertama	31
Tabel 5 . Hasil Uji Dataset Kombinasi Skenario Pertama	33
Tabel 6. Persentase Analisis Sentimen Dataset Kombinasi Skenario Pertama.....	34
Tabel 7. Hasil Uji Skenario Kedua	36
Tabel 8. Persentase Analisis Sentimen Skenario Kedua.....	36
Tabel 9. Hasil Uji Dataset Kombinasi Skenario Kedua.....	38
Tabel 10. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kedua	38
Tabel 11. Hasil Uji Skenario Ketiga	40
Tabel 12. Persentase Analisis Sentimen Skenario Ketiga.....	40
Tabel 13. Hasil Uji Dataset Kombinasi Skenario Ketiga.....	42
Tabel 14. Persentase Analisis Sentimen Dataset Kombinasi Skenario Ketiga	42
Tabel 15. Hasil Uji Skenario Keempat	44
Tabel 16. Persentase Analisis Sentimen Skenario Keempat.....	45
Tabel 17. Hasil Uji Dataset Kombinasi Skenario Keempat.....	47
Tabel 18. Persentase Analisis Sentimen Dataset Kombinasi Skenario Keempat	47
Tabel 19. Hasil Uji Skenario Kelima	49
Tabel 20. Persentase Analisis Sentimen Skenario Kelima.....	49
Tabel 21. Hasil Uji Dataset Kombinasi Skenario Kelima.....	51
Tabel 22. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kelima	51
Tabel 23. Hasil Uji Skenario Keenam	53
Tabel 24. Persentase Analisis Sentimen Skenario Keenam	54
Tabel 25. Hasil Uji Dataset Kombinasi Skenario Keenam	55
Tabel 26. Persentase Analisis Sentimen Dataset Kombinasi Skenario Keenam ..	56
Tabel 27. Hasil Uji Skenario Ketujuh.....	58
Tabel 28. Persentase Analisis Sentimen Skenario Ketujuh	58
Tabel 29 . Hasil Uji Dataset Kombinasi Skenario Ketujuh	60
Tabel 30. Persentase Analisis Sentimen Dataset Kombinasi Skenario Ketujuh ...	60
Tabel 31. Hasil Uji Skenario Kedelapan.....	62
Tabel 32. Persentase Analisis Sentimen Skenario Kedelapan	63
Tabel 33. Hasil Uji Dataset Kombinasi Skenario Kedelapan	65
Tabel 34. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kedelapan.....	65
Tabel 35. Hasil Uji Skenario Kesembilan.....	67
Tabel 36. Persentase Analisis Sentimen Skenario Kesembilan	67
Tabel 37. Hasil Uji Dataset Kombinasi Skenario Kesembilan	69
Tabel 38. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kesembilan.....	69
Tabel 39. Hasil Uji Skenario Kesepuluh.....	71
Tabel 40. Persentase Analisis Sentimen Skenario Kesepuluh	71
Tabel 41. Hasil Uji Dataset Kombinasi Skenario Kesepuluh	73

Tabel 42. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kesepuluh.....	74
Tabel 43. Hasil Uji Skenario Kesebelas.....	75
Tabel 44. Persentase Analisis Sentimen Skenario Kesebelas	76
Tabel 45. Hasil Uji Dataset Kombinasi Skenario Kesebelas	78
Tabel 46. Persentase Analisis Sentimen Dataset Kombinasi Skenario Kesebelas	78
Tabel 47. Hasil Uji Skenario Keduabelas	80
Tabel 48. Persentase Analisis Sentimen Skenario Keduabelas.....	80
Tabel 49. Hasil Uji Dataset Kombinasi Skenario Keduabelas.....	82
Tabel 50. Persentase Analisis Sentimen Dataset Kombinasi Skenario Keduabelas	82
Tabel 51. Catatan Hasil <i>Training</i> dengan Tiga Nilai Akurasi Tertinggi.....	84
Tabel 52. Metrik Evaluasi Hasil <i>Training</i> dengan Tiga Nilai Akurasi Tertinggi	85
Tabel 53. Catatan Hasil <i>Training</i> Dataset Kombinasi dengan Tiga Nilai Akurasi Tertinggi	87
Tabel 54. Metrik Evaluasi Hasil <i>Training</i> Dataset Kombinasi dengan Tiga Nilai Akurasi Tertinggi	87
Tabel 55. Hasil Pengujian Model Klasifikasi Ekspresi.....	88

DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
CNN	<i>Convolutional Neural Network</i>
ResNet	<i>Residual Network</i>
RGB	<i>Red Green Blue</i>
BGR	<i>Blue Green Red</i>
GAP	<i>Global Average Pooling</i>
FER	<i>Facial Emotion Recognition</i>
TP	<i>True Positive</i>
FP	<i>False Positive</i>
TN	<i>True Negative</i>
FN	<i>False Negative</i>
SGD	<i>Stochastic Gradient Descent</i>

DAFTAR LAMPIRAN

Lampiran 1: Contoh Dataset	94
Lampiran 2. <i>Source code project</i>	95
Lampiran 3. Lembar perbaikan skripsi.....	96

KATA PENGANTAR

Assalamu'alaikum Warahmatullahi Wabarakatuh.

Segala puji dan syukur kami panjatkan ke hadirat Allah SWT. Tuhan Yang Maha Esa yang dengan limpahan rahmat dan hidayah-Nya sehingga tugas akhir dengan judul “Analisis Sentimen Berdasarkan Ekspresi Wajah Pada Video *Review* Produk Menggunakan *Convolutional Neural Network*” ini dapat diselesaikan sebagai salah satu syarat dalam menyelesaikan jenjang Strata-1 pada Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin.

Dalam penyusunan penelitian ini disajikan hasil penelitian terkait judul yang telah diangkat dan telah melalui proses pencarian dari berbagai sumber baik jurnal penelitian, prosiding pada seminar-seminar nasional/internasional, buku maupun dari situs-situs di internet.

Penulis menyadari bahwa tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai dengan masa penyusunan Tugas Akhir, sangatlah sulit untuk menyelesaikan Tugas Akhir ini. Oleh karena itu, penulis berterima kasih kepada:

- 1) Kedua Orang tua dan saudara-saudara penulis, yang selalu memberikan dukungan, doa dan semangat;
- 2) Bapak Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM, ASEAN. Eng., selaku pembimbing I dan Ibu Anugrayani Bustamin, S.T., M.T. selaku pembimbing II, yang senantiasa menyediakan waktu, tenaga, pikiran, dan perhatian yang luar biasa dalam mengarahkan penulis untuk menyelesaikan tugas akhir;
- 3) Bapak Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM, ASEAN. Eng., selaku Ketua Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin atas bimbingannya selama masa perkuliahan penulis;
- 4) Andi Muh. Rizky dan Muh. Iqbal sebagai tim Multimodal Content yang membantu penulis dalam pengumpulan data dan pengujian sistem.
- 5) Para Sahabat, teman-teman yang telah memberikan begitu banyak bantuan, semangat, inspirasi, ilmu dan hiburan selama penelitian, pengambilan data dan diskusi *progress* penyusunan Tugas Akhir;

- 6) Segenap Staf Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin yang telah membantu penulis;
- 7) Seluruh teman-teman angkatan 2017 Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin;
- 8) Orang-orang berpengaruh lainnya yang tanpa sadar telah menjadi inspirasi penulis.

Akhir kata, penulis berharap semoga Allah SWT. berkenan membalas segala kebaikan dari semua pihak yang telah banyak membantu. Semoga Tugas Akhir ini dapat memberikan manfaat bagi pengembangan ilmu. Aamiin.

Wassalam

Makassar, Januari 2024

Penulis

BAB I PENDAHULUAN

1.1 Latar Belakang

Dengan berkembangnya jejaring sosial, orang cenderung menggunakan video daripada teks untuk mengekspresikan pendapat tentang produk atau layanan. Data suara dalam video mengekspresikan suasana hati pembicara, sementara visual data menyampaikan ekspresi wajah, yang semuanya membantu seseorang memahami keadaan emosi pengguna. Beberapa tahun ini, peneliti kecerdasan buatan telah berusaha memberdayakan mesin dengan kemampuan untuk merasakan dan mengenali emosi untuk mengidentifikasi dan mengekspresikannya, yang disebut analisis sentimen (Liu & Tang, 2021).

YouTube adalah sebuah situs web berbagi video yang dibuat oleh tiga mantan karyawan PayPal pada Februari 2005. Situs web ini memungkinkan pengguna mengunggah, menonton, dan berbagi video. Perusahaan ini berkantor pusat di San Bruno, California, dan memakai teknologi Adobe Flash Video dan HTML5 untuk menampilkan berbagai macam konten video buatan pengguna/kreator, termasuk klip film, klip TV, dan video musik. Selain itu, konten amatir seperti blog video, video orisinal pendek, video ulasan produk dan video pendidikan juga ada dalam situs ini. Melayani lebih dari dua miliar video setiap hari, telah menjadi pemimpin yang jelas dalam berbagi video daring. Sejak tahun 2010, youtube sudah menjadi salah satu alternatif menggali informasi bagi masyarakat Indonesia. Selain faktor keberagaman informasi, faktor menghibur sambil menggali informasi menjadi alasan masyarakat mulai beralih ke platform ini.

Tercatat pengguna aktif youtube selama tahun 2022 adalah 139 juta (Jemadu & Prastya, 2022). Salah satu teknik membagi informasi dalam bingkai hiburan adalah dengan mengulas, baik mengulas tempat wisata, makanan, hingga barang elektronik. Berdasarkan riset yang dilakukan oleh google dalam rentang waktu dari 2015 sampai 2017, total waktu yang dihabiskan orang dalam menonton video ulasan produk di youtube melalui perangkat mobile adalah 50.000+ tahun atau sekitar kurang lebih 438 juta jam (Think with Google, 2015-2017). Selain itu google juga melakukan riset terhadap 14.206 orang pembeli dan 87% mengatakan

bahwa penting untuk mengetahui bahwa mereka mendapat penawaran yang bagus saat memutuskan merek atau pengecer mana yang akan mereka beli (Think with Google, 2019).

Salah satu youtuber yang aktif mengulas barang elektronik adalah kanal GadgetIn. Tercatat per-Juni 2023 total *subscriber* youtuber ini sebanyak 11 juta, dengan rata-rata penonton sebanyak 43 juta berdasarkan 30 video terakhir dari 1371 video yang telah diunggah (Social Blade, 2023). Teknik mengulas yang interaktif dalam menjelaskan tiap kelebihan dan kekurangan barang yang diulas menjadi daya tarik tersendiri bagi penontonnya.

Namun, seringkali sebagian penonton dan pemilik produk yang murni ingin mengetahui kesimpulan ulasan dari suatu produk mengalami kendala dikarenakan kurang jelasnya penekanan terkait kesimpulan ulasan produk oleh pengulas atau tidak sesuainya ekspresi wajah yang ditampilkan dengan apa yang pengulas ucapkan. Analisis sentimen adalah tugas mengklasifikasikan keadaan pikiran dan perasaan seseorang ke dalam kategori seperti senang, sedih, dan marah dari suatu bentuk masukan tertentu. Estimasi sentimen otomatis memiliki potensi besar untuk digunakan dalam berbagai aplikasi (Cambria, Schuller, Xia, & Havasi, 2013). Analisis sentimen telah menjadi tren baru media sosial, yang dapat secara efektif memahami opini yang diungkapkan oleh pengguna di platform jejaring sosial. Visi komputer, sebagai salah satu cabang dari *artificial intelligence* yang digabungkan dengan keilmuan *forensic mimic* dan ekspresi wajah diharapkan dapat menjadi cara baru untuk menilai sebuah barang berdasarkan ekspresi wajah pengulas. *Facial Emotion Recognition* (FER) adalah teknologi yang menganalisis ekspresi wajah, baik dari gambar statis dan video untuk mengungkapkan informasi tentang keadaan emosional seseorang. Berdasarkan Latar belakang tersebut penulis mengajukan penelitian dengan judul “Analisis Sentimen berdasarkan ekspresi wajah pada video review produk menggunakan Convolutional Neural Network” yang diharapkan dapat menghemat waktu pengguna internet dan pemilik produk untuk mengetahui ulasan lugas suatu produk.

1.2 Rumusan Masalah

Rumusan masalah dari pengerjaan tugas akhir ini adalah:

- a. Bagaimana mengembangkan sistem analisis sentimen berdasarkan ekspresi wajah pada video menggunakan CNN?
- b. Bagaimana unjuk kinerja sistem analisis sentimen berdasarkan ekspresi wajah pada video menggunakan CNN?

1.3 Tujuan Penelitian/Perancangan

Tujuan dari pengerjaan tugas akhir ini adalah :

- a. Untuk Mengembangkan sistem analisis sentimen berdasarkan ekspresi wajah pada video menggunakan CNN.
- b. Untuk Mengukur performa CNN dalam menganalisis ekspresi wajah pada video.

1.4 Manfaat Penelitian/Perancangan

Manfaat dari pengerjaan tugas akhir ini adalah:

- a. Memberikan kontribusi pada bidang kecerdasan buatan; Penelitian ini dapat memberikan kontribusi pada pengembangan metode dan teknik analisis sentimen menggunakan teknologi kecerdasan buatan, khususnya dalam mengenali dan memahami ekspresi wajah dalam konteks video *review* produk. Hal ini dapat memperkaya pengetahuan dan pemahaman tentang penggunaan teknik *deep learning* seperti CNN dalam memproses dan menganalisis data visual.
- b. Efisiensi dalam menganalisis sentimen; Dengan mengembangkan model CNN yang efektif dan akurat dalam menganalisis sentimen berdasarkan ekspresi wajah dalam video *review* produk, penelitian ini dapat membantu menghemat waktu dan usaha yang diperlukan dalam menganalisis ulasan produk secara manual. Ini akan memudahkan produsen, perusahaan *e-commerce*, dan konsumen dalam memperoleh informasi penting tentang respon pengguna terhadap produk secara cepat dan efisien.
- c. Pengembangan penelitian masa depan; Penelitian ini dapat menjadi dasar dan kontribusi awal dalam pengembangan penelitian lebih lanjut yang melibatkan

multimodal content, seperti menggabungkan analisis sentimen dari teks, suara, dan ekspresi wajah. Melibatkan sumber informasi yang lebih beragam dapat memberikan pemahaman yang lebih komprehensif tentang sentimen pengguna dan membuka potensi penggunaan yang lebih luas di berbagai aplikasi.

1.5 Ruang Lingkup/Asumsi perancangan

Adapun batasan masalah pada penelitian ini yaitu :

- a. Penelitian ini akan fokus pada analisis sentimen berdasarkan ekspresi wajah dalam video *review* produk.
- b. Sumber video yang akan dianalisis berasal dari dataset primer dan sekunder. Dataset primer yang dibuat penulis bersumber dari video kanal youtube *GadgetIn* yang kemudian diekstrak dan dipilah kedalam 5 kelas ekspresi yaitu marah, kecewa, senang, netral dan kaget. Dataset sekunder yang digunakan adalah Indonesian Mixed Emotion Dataset (IMED).
- c. Arsitektur *Convolutional Neural Network* (CNN) yang digunakan adalah ResNet-50.

BAB II TINJAUAN PUSTAKA

2.1 Analisis Sentimen

Analisis sentimen adalah metode yang digunakan untuk mengidentifikasi, mengekstrak, dan menganalisis pendapat, sikap, atau emosi yang terkandung dalam teks, suara, atau gambar. Tujuan utama dari analisis sentimen adalah untuk memahami dan mengklasifikasikan apakah suatu pendapat atau ekspresi bersifat positif, negatif, atau netral (Liu B. , 2012). Metode analisis sentimen mencakup penggunaan teknik pemrosesan bahasa alami, pengenalan pola, dan pembelajaran mesin untuk mencapai pemahaman yang lebih baik tentang opini pengguna.


2.2 Ekspresi Wajah dan Model Emosi

Emosi dapat didefinisikan sebagai pengalaman subjektif yang terdiri dari perubahan fisiologis, ekspresi wajah, sikap tubuh dan kecenderungan untuk bertindak yang terjadi sebagai respons terhadap rangsangan tertentu (Ekman, 1992). Emosi melibatkan perasaan dan reaksi psikologis yang kompleks terhadap situasi, peristiwa atau stimulus tertentu. Emosi dapat bervariasi dalam intensitas, durasi dan jenisnya. Penelitian dalam bidang psikologi dan *neurosains* telah mengidentifikasi berbagai jenis emosi dasar yang universal di antara manusia, seperti kegembiraan, sedih, kemarahan, takut, jijik, dan kejutan. Emosi memiliki peran penting dalam kehidupan manusia, mempengaruhi persepsi, pengambilan keputusan, interaksi sosial, dan kesejahteraan psikologis. Studi tentang emosi melibatkan pengamatan perilaku, ekspresi wajah, dan respon fisiologis, serta penggunaan metode *neurosains* seperti pemindaian otak fungsional (fMRI) untuk memahami dasar *neurologis* dari emosi.

Ekspresi wajah merupakan salah satu cara utama bagi manusia untuk mengkomunikasikan emosi dan perasaan mereka. Kemampuan untuk mengenali dan memahami ekspresi wajah secara akurat dapat memberikan wawasan yang berharga tentang keadaan emosional seseorang (Ekman, 2007). Dalam konteks analisis sentimen pada video *review* produk, pengenalan ekspresi wajah menjadi

penting untuk memahami reaksi emosional pengulas terhadap produk yang sedang diulas.

Ada dua tipe utama dalam klasifikasi model emosi, yaitu model kategorikal dan model dimensional. Emosi dasar seperti marah, takut, sedih, bahagia, terkejut, dan jijik yang diajukan oleh Ekman dan Friesen disajikan dalam model kategorikal (Ekman, 1992). Model dimensional menggambarkan emosi dalam dua dimensi (*Arousal* dan *Valence*) atau tiga dimensi (*Power*, *Arousal*, dan *Valence*). *Valence* menentukan apakah emosi bersifat positif atau negatif, sedangkan *Arousal* mengukur tingkat kegembiraan ekspresi tersebut.



Gambar 1. Model dimensional dua dimensi

2.3 Visi Komputer

Visi komputer adalah bidang ilmu yang berfokus pada pengembangan sistem dan algoritma untuk mengizinkan komputer untuk memahami, menganalisis, dan menafsirkan informasi visual secara otomatis. Tujuannya adalah memberikan kemampuan kepada komputer agar dapat "melihat" dan "memahami" dunia seperti yang dilakukan oleh manusia. Visi komputer mencakup berbagai tugas dan aplikasi, seperti deteksi objek, pengenalan wajah, dan segmentasi gambar. Metode dalam visi komputer mencakup ekstraksi fitur, pengklasifikasian, dan pembelajaran mesin

(Szeliski, 2010). Visi komputer adalah ilmu yang mempelajari bagaimana komputer dapat mengenali objek yang akan diamati atau diobservasi. Hal ini dilakukan untuk dapat meniru visualisasi dari manusia yang diaplikasikan ke dalam komputer. Visi komputer merupakan kombinasi dari pengolahan citra (*image processing*) dan pengenalan pola (*pattern recognition*).

2.3.1 Pengolahan Citra

Pengolahan citra adalah bidang ilmu yang berkaitan dengan analisis dan manipulasi digital terhadap citra untuk meningkatkan kualitas, mengekstraksi informasi, dan memahami konten visual yang terkandung dalam citra tersebut. Tujuannya adalah untuk mengubah citra menjadi bentuk yang lebih berguna dan dapat dimengerti oleh manusia atau digunakan dalam aplikasi komputasi lainnya. Pengolahan citra melibatkan teknik dan algoritma seperti pra-pemrosesan, segmentasi, augmentasi, ekstraksi fitur, restorasi dan rekonstruksi, serta pemrosesan spasial dan frekuensi. Pengolahan citra memiliki banyak aplikasi praktis dalam berbagai bidang, termasuk pengenalan pola, pengolahan medis, pengenalan wajah, sistem pengawasan, dan pengolahan citra satelit (Gonzalez & Woods, 2008).

2.3.2 Augmentasi Gambar

Augmentasi gambar menghasilkan contoh pelatihan yang serupa tetapi berbeda setelah serangkaian perubahan acak pada gambar latih, sehingga memperluas ukuran training set. Sebagai alternatif, augmentasi gambar dapat dimotivasi oleh fakta bahwa perubahan acak dari contoh pelatihan memungkinkan model untuk tidak terlalu bergantung pada atribut tertentu, sehingga meningkatkan kemampuan generalisasinya. Misalnya, gambar dapat dipotong dengan cara yang berbeda untuk membuat objek yang diinginkan muncul di posisi yang berbeda, sehingga mengurangi ketergantungan model pada posisi objek. Augmentasi juga dapat menyesuaikan faktor seperti kecerahan dan warna untuk mengurangi sensitivitas model terhadap warna (Zhang, Lipton, Li, & Smola, 2022).

2.3.3 Pengenalan Pola

Pengenalan pola adalah studi metode-metode komputasional tentang pengambilan keputusan dan pengklasifikasian objek berdasarkan pengamatan terhadap sifat-sifatnya. Pengenalan pola melibatkan pengembangan metode dan algoritma untuk mengenali, mengklasifikasikan, dan memahami pola-pola dalam data. Proses pengenalan pola melibatkan ekstraksi fitur dan metode pengklasifikasian. Pengenalan pola memiliki berbagai aplikasi praktis dalam pengenalan karakter tulisan tangan, pengenalan wajah, deteksi objek, pengenalan suara, dan analisis data kompleks. Selain itu, pengenalan pola melibatkan pemodelan statistik, analisis probabilitas, dan teknik optimasi (Duda, Hart, & Stork, 2000).

2.4 *Face Detection*

Deteksi wajah adalah proses identifikasi dan lokalisasi wajah manusia dalam gambar atau video menggunakan model atau algoritma yang dilatih untuk mendeteksi fitur-fitur khas dari wajah manusia. Tujuan deteksi wajah adalah untuk secara otomatis mengenali dan memisahkan area wajah dari latar belakang atau objek lainnya dalam citra. Metode deteksi wajah mencari fitur-fitur khas seperti mata, hidung, dan mulut untuk mengenali pola-pola karakteristik wajah. Deteksi wajah melibatkan penggunaan algoritma atau model pembelajaran mesin yang telah dilatih dengan dataset gambar wajah. Beberapa metode yang umum digunakan dalam deteksi wajah adalah *Haar Cascade*, *Local Binary Patterns* (LBP), dan *Convolutional Neural Networks* (CNN). Metode-metode ini menganalisis piksel-piksel citra dengan menggunakan teknik pengklasifikasi berbasis fitur, jaringan saraf tiruan, atau kombinasi metode berbasis aturan. Deteksi wajah melibatkan serangkaian tahapan, termasuk ekstraksi fitur, pelatihan model dan proses pengklasifikasi untuk mengenali wajah manusia dengan tingkat akurasi yang tinggi. Aplikasi deteksi wajah meliputi pengenalan wajah, identifikasi keamanan, pengolahan video, dan pengenalan emosi (Viola & Jones, 2001).

2.5 Convolutional Neural Network

Convolutional Neural Network atau CNN adalah salah satu metode *deep learning* yang mempelajari fitur-fitur level hierarki dari citra menggunakan gambar dengan berbagai tingkat. Untuk melatih *deep network*, biasanya, ratusan gambar digunakan sebagai input untuk pembelajaran representatif yang lebih baik (El-Baz & Suri, 2021). Alex Krizhevsky berhasil menjuarai kompetisi ImageNet Large Scale Visual Recognition Challenge 2012, yang berhasil membuktikan bahwa metode CNN mengungguli metode *Machine Learning* lainnya pada kasus klasifikasi objek pada citra.

2.5.1 Convolutional Layer

Convolutional Layer merupakan lapisan yang paling fundamental namun penting dalam CNN. Lapisan ini melakukan konvolusi atau perkalian matriks piksel yang dihasilkan dari gambar atau objek yang diberikan untuk menghasilkan peta aktivasi. Peta aktivasi memiliki keunggulan utama yaitu menyimpan semua fitur khas dari gambar yang diberikan, sambil mengurangi jumlah data yang harus diproses. Matriks yang digunakan untuk konvolusi adalah detektor fitur, yang merupakan kumpulan nilai-nilai yang sesuai dengan mesin. Dengan menggunakan nilai-nilai detektor fitur yang berbeda, variasi gambar yang berbeda dapat dihasilkan. Model yang telah melalui proses konvolusi juga dilatih menggunakan metode *backpropagation* untuk meminimalkan kesalahan pada setiap lapisan (Ajit, Acharya, & Samanta, 2020).

2.5.2 Pooling

Pooling merupakan langkah penting untuk mengurangi dimensi peta aktivasi, sehingga hanya fitur-fitur penting yang dipertahankan, sambil juga mengurangi perubahan spasial. Hal ini berkontribusi pada pengurangan jumlah fitur yang dapat dipelajari oleh model dan membantu mengatasi masalah *overfitting*. Melalui *pooling*, CNN dapat menggabungkan berbagai dimensi dari sebuah gambar sehingga dapat mengenali objek yang diberikan, bahkan jika objek tersebut memiliki bentuk yang condong atau hadir dalam sudut yang berbeda. Terdapat berbagai jenis *pooling*, seperti *max pooling*, *average pooling*, *stochastic pooling*,

dan *spatial pyramid pooling*. Diantara semuanya, *max pooling* merupakan yang paling populer.

Max Pooling mengambil nilai terbesar dari setiap sub-matriks dalam peta aktivasi dan membentuk matriks terpisah dari nilai-nilai tersebut. Dengan melakukan ini, jumlah fitur yang dapat dipelajari tetap terbatas, sambil tetap mempertahankan fitur-fitur utama dari setiap gambar. *Max Pooling* umumnya dilakukan menggunakan filter berukuran 2×2 .

2.5.3 Fully Connected Layer

Ini merupakan lapisan akhir yang diberikan ke dalam jaringan saraf. Umumnya, matriks akan diubah menjadi bentuk datar sebelum diteruskan ke neuron-neuron. Setelah tahap ini, sulit untuk melacak data karena terdapat banyak lapisan tersembunyi dengan bobot yang bervariasi untuk keluaran setiap *neuron*. Di lapisan ini, semua pemikiran dan komputasi pada data dilakukan.

2.5.4 Batch Size

Batch size adalah *hyperparameter* yang menentukan jumlah sampel yang akan diproses sebelum memperbarui parameter model internal. Bayangkan sebuah *batch* sebagai *for-loop* yang mengulang satu atau lebih sampel dan membuat prediksi. Pada akhir *batch*, prediksi dibandingkan dengan variabel keluaran yang diharapkan, dan sebuah *error* dihitung. Dari *error* ini, algoritma pembaruan digunakan untuk meningkatkan model, misalnya, bergerak ke bawah sepanjang gradien *error*. Sebuah set data pelatihan dapat dibagi menjadi satu atau lebih *batch*.

Mini-batch gradient descent merupakan varian yang direkomendasikan dari *gradient descent* untuk sebagian besar aplikasi, terutama dalam *deep learning*. Ukuran *mini-batch*, sering disebut sebagai "*batch size*" untuk singkat, sering disesuaikan dengan salah satu aspek arsitektur komputasi di mana implementasi sedang dijalankan. Seperti pangkat dua yang sesuai dengan kebutuhan memori perangkat keras GPU atau CPU, seperti 8,16,32 dan sebagainya. *Batch size* adalah pengatur pada proses pembelajaran. Nilai-nilai kecil memberikan proses pembelajaran yang konvergen dengan cepat pada biaya *noise* dalam proses pelatihan. Nilai-nilai besar memberikan proses pembelajaran yang konvergen secara lambat dengan estimasi *gradient error* yang akurat (Brownlee, 2022).

2.5.5 *Optimizer*

Optimizer digunakan untuk mengurangi fungsi kesalahan, yaitu fungsi numerik yang tergantung pada parameter-parameter penting dalam model. Parameter-parameter ini digunakan untuk menghitung nilai tujuan dari sekumpulan prediktor yang diakses dalam model. Parameter pembelajaran internal termasuk nilai bias dan bobot jaringan saraf yang digunakan untuk menghitung nilai output. *Optimizer* memainkan peran penting dalam mengurangi kerugian yang terjadi selama proses pelatihan jaringan dan dalam model jaringan saraf selama pelatihan.

Optimizers dapat dijelaskan sebagai fungsi matematika untuk memodifikasi bobot jaringan berdasarkan gradien dan informasi tambahan, tergantung pada formulasi dari *optimizer* tersebut. *optimizer* dibangun berdasarkan ide dari *gradien descent*, pendekatan rakus yang secara iteratif mengurangi fungsi kerugian dengan mengikuti *gradien*. Fungsi-fungsi tersebut bisa semudah mengurangi gradien dari bobot, atau bisa juga sangat kompleks. *Optimizer* yang lebih baik umumnya difokuskan pada kecepatan dan efisiensi, namun juga sering dikenal karena kemampuannya untuk generalisasi yang baik dibandingkan dengan yang lain (Park, 2021). Adapun beberapa teknik optimasi sebagai berikut:

- a. *Adam* ; *Adam* adalah algoritma *adaptive learning rate optimization* yang dirancang khusus untuk pelatihan jaringan saraf mendalam. Pertama kali dipublikasikan pada tahun 2014, *Adam* diperkenalkan di konferensi yang sangat bergengsi bagi praktisi *deep learning*, yaitu ICLR 2015. Makalah ini memuat beberapa diagram yang sangat menjanjikan, menunjukkan peningkatan kinerja yang besar dalam hal kecepatan pelatihan. (Kingma & Ba, 2015)

Adam dapat dilihat sebagai kombinasi dari *RMSprop* dan *Stochastic Gradient Descent* (SGD) dengan momentum. Ini menggunakan gradien kuadrat untuk menyesuaikan laju pembelajaran seperti *RMSprop* dan memanfaatkan momentum dengan menggunakan rata-rata bergerak dari gradien daripada gradien itu sendiri, seperti pada SGD dengan momentum.

Adam adalah metode laju pembelajaran adaptif, yang berarti ia menghitung laju pembelajaran individu untuk setiap parameter. Namanya berasal dari *adaptive moment estimation*, dan alasan disebut demikian

adalah karena *Adam* menggunakan estimasi momen pertama dan kedua dari gradien untuk mengadaptasi laju pembelajaran untuk setiap bobot dalam jaringan saraf. (Bashaev, 2018)

b. *Adamax* ; Algoritma *adamax* merupakan perluasan dari algoritma optimisasi *Adaptive Movement Estimation (Adam)*. Secara lebih luas, ini juga merupakan perluasan dari algoritma optimisasi *gradient descent*. *Adamax* diperkenalkan oleh penulis *adam* dalam makalah yang sama. Ide di balik *adamax* adalah untuk memandang nilai v sebagai norma L2 dari gradien saat ini dan sebelumnya untuk setiap bobot secara individual. Kita dapat menggeneralisasinya ke aturan pembaruan L_p , tetapi menjadi cukup tidak stabil untuk nilai p yang besar. Namun, jika menggunakan kasus khusus norma *L-infinity*, ini menghasilkan algoritma yang mengejutkan stabil dan berkinerja baik. Secara umum, *adamax* secara otomatis menyesuaikan *learning rate* yang berbeda untuk setiap parameter dalam masalah optimisasi. (Bashaev, 2018)

2.5.6 Learning Rate

Learning rate adalah hiperparameter yang mengontrol ukuran langkah di mana algoritma optimisasi bergerak menuju minimum fungsi kerugian. Fungsi kerugian adalah fungsi matematika yang mengukur perbedaan antara keluaran yang diprediksi dan keluaran sebenarnya. Algoritma optimisasi digunakan untuk memperbarui bobot dan bias dari model pembelajaran mesin selama proses pelatihan.


Learning rate menentukan seberapa cepat atau lambat model belajar dari data. *Learning rate* yang tinggi dapat menyebabkan algoritma optimisasi melewati nilai minimum, menghasilkan osilasi atau divergensi. Di sisi lain, *learning rate* yang rendah dapat menyebabkan konvergensi yang lambat, yang dapat menyebabkan waktu pelatihan yang lebih lama atau bahkan terjebak dalam nilai minimum lokal.

Learning rate adalah hiperparameter kritis yang memengaruhi seberapa cepat model pembelajaran mesin belajar selama pelatihan. Ini dapat secara signifikan

memengaruhi jumlah *epoch* yang diperlukan agar model mencapai solusi yang memuaskan.

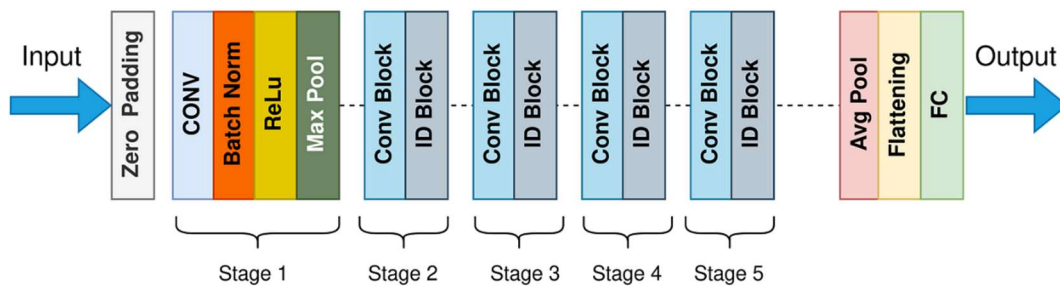
Sebuah *learning rate* yang terlalu rendah dapat menyebabkan konvergensi yang lambat, sementara *learning rate* yang terlalu tinggi dapat menyebabkan konvergensi yang tidak stabil atau bahkan divergensi. Penting untuk bereksperimen dengan *learning rate* yang berbeda untuk menemukan yang optimal, yang mungkin bergantung pada berbagai faktor seperti ukuran dan kompleksitas dataset, arsitektur model, dan algoritma optimisasi. (Soni, 2023)

2.5.7 ResNet50



Gambar 2. Residual Block

ResNet singkatan dari *Residual Network* adalah jaringan saraf klasik yang digunakan sebagai kerangka utama untuk banyak tugas *computer vision*. Seperti pada jaringan saraf konvolusi standar, arsitektur ini juga menggunakan lapisan konvolusi dan *pooling*. Model ini menjadi pemenang tantangan ImageNet pada tahun 2015. Jaringan ini memiliki kedalaman 50 lapisan. Inovasi utama dalam *ResNet50* adalah koneksi loncat (*skip connection*) dimana input asli ditambahkan ke output blok *Residual* seperti yang ditunjukkan pada Gambar 2. Hal ini menghilangkan masalah gradien yang menghilang yang terjadi selama *backpropagation* saat model sedang dilatih.



Gambar 3. *ResNet50 Model Architecture*

Arsitektur *ResNet50* terdiri dari lima tahap dengan blok konvolusi dan blok identitas. Ukuran input *ResNet50* adalah 224×224 dengan tiga saluran warna. Tahap awal terdiri dari lapisan konvolusi dengan ukuran kernel 7×7 dan lapisan *max-pooling* dengan ukuran kernel 3×3 . Setiap blok konvolusi terdiri dari tiga lapisan konvolusi, begitu pula dengan setiap blok identitas. Setelah melalui lima tahap tersebut, terdapat lapisan *average pooling*, dan lapisan terakhir berupa lapisan *fully connected* dengan 1000 *neuron*. Arsitektur *Resnet50* ditampilkan pada Gambar 3.

2.5.7 Confusion Matrix

		PREDICTED classification				Total
		Classes	a	b	c	
ACTUAL classification	a	6	0	1	2	9
	b	3	9	1	1	14
	c	1	0	10	2	13
	d	1	2	1	12	16
Total		11	11	13	17	52

Gambar 4. *Multi-Class Confusion Matrix* (Sumber: Grandini, Bagli, & Visani, 2020)

Confusion matrix adalah suatu matriks yang menampilkan klasifikasi prediksi dan kelas aktual. Sebuah *confusion matrix* memiliki ukuran $l \times l$, di mana l merupakan jumlah dari nilai label atau kelas yang berbeda (Kohavi & Provost, 1998). Dalam *confusion matrix* multi-kelas, kelas-kelas tersebut diurutkan dalam

urutan yang sama dalam baris dan kolom, seperti yang terlihat pada Gambar 4. Karena alasan ini, elemen-elemen yang terklasifikasi dengan benar (*True Positive*) terletak di sepanjang diagonal utama, dari sudut kiri atas ke sudut kanan bawah, dan merupakan titik-titik pertemuan antara prediksi dan aktual (Grandini, Bagli, & Visani, 2020)

Precision adalah hasil bagi antara jumlah elemen *True Positive* dan total unit yang diprediksi secara positif (jumlah kolom dari prediksi positif). Lebih rinci, *True Positive* mengacu pada elemen-elemen yang telah diberi label positif oleh model dan memang benar-benar positif, sedangkan *False Positive* merujuk pada elemen-elemen yang telah diberi label positif oleh model, tetapi pada kenyataannya sebenarnya negatif.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Dalam konteks klasifikasi, presisi memberikan gambaran mengenai seberapa sering model memprediksi kelas positif dengan benar, di antara semua prediksi positif yang dibuat oleh model. Nilai presisi akan menjawab pertanyaan sejauh mana model yang digunakan mampu memprediksi sentimen yang sebenarnya positif dengan benar. Dalam konteks analisis sentimen, presisi menggambarkan persentase prediksi positif yang benar (*True Positive*) dibandingkan dengan total jumlah prediksi positif (*True Positive* dan *False Positive*). Dengan menggunakan nilai presisi, kita bisa mengetahui seberapa baik model dalam mengidentifikasi sentimen sebagai positif tanpa salah mengklasifikasikan sentimen negatif sebagai positif (Rina, 2023)

Recall merupakan hasil bagi antara jumlah elemen *True Positive* dan total unit yang benar-benar bernilai positif dan diklasifikasikan sebagai positif (jumlah baris pada kelas aktual positif). Secara spesifik, *False Negative* adalah elemen yang telah diberi label negatif oleh model, namun pada kenyataannya sebenarnya positif.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

Recall adalah metrik evaluasi yang menggambarkan seberapa baik suatu model dalam mengidentifikasi kelas positif dengan benar. Dalam kasus analisis sentimen, *Recall* akan menunjukkan kemampuan model kita untuk mengenali sentimen positif yang sebenarnya. Sebagai analogi, bayangkan kita sedang mencari

jarum di tumpukan jerami. *Recall* menggambarkan seberapa baik kita menemukan semua jarum yang ada di tumpukan tersebut. Jika kita menemukan 6 dari 10 dari jarum ditumpukan Jerami tersebut, artinya kita masih melewatkan 4 jarum yang belum ditemukan. Nilai *Recall* akan menjawab pertanyaan sejauh mana model kita mampu mengenali dan mengklasifikasikan sentimen positif dengan benar (Rina, 2023).

F1-Score mengevaluasi performa model klasifikasi berdasarkan matriks konfusi. Formula *F1-Score* dapat diinterpretasikan sebagai rata-rata antara Presisi (*Precision*) dan *Recall*, di mana nilai *F1-Score* mencapai puncaknya pada 1 dan mencapai nilai terendah pada 0. Kontribusi relatif dari presisi dan *recall* adalah setara dalam *F1-Score*, dan rata-rata harmonik digunakan untuk mencari keseimbangan terbaik antara dua ukuran (Grandini, Bagli, & Visani, 2020).

$$F_1\text{Score} = 2 \times \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) \quad (3)$$

F1-Score merupakan metrik evaluasi yang mencerminkan keseimbangan antara Presisi (*Precision*) dan Sensitivitas (*Recall*). Dalam konteks analisis sentimen video review produk, *F1-Score* memberikan gambaran mengenai seberapa baik model kita dalam mengklasifikasikan baik sentimen positif maupun negatif secara akurat. Sebagai contoh, bayangkan kita ingin menilai kinerja seorang penjaga gawang dalam pertandingan sepak bola. *F1-Score* akan menggabungkan kemampuan penjaga gawang untuk melakukan penyelamatan (Presisi) dan mencegah gol (Sensitivitas) dalam satu angka yang mencerminkan kinerja keseluruhan. Nilai *F1-Score* akan memberikan informasi tentang seberapa baik model kita dalam menggabungkan kemampuan Presisi dan Sensitivitas, sehingga kita bisa memahami seberapa efektif model kita dalam mengklasifikasikan sentimen secara akurat. Dalam konteks analisis sentimen, ini penting karena kita ingin memastikan bahwa model kita efisien dalam mengidentifikasi sentimen positif dan negatif dengan benar, agar kita dapat memahami bagaimana produk yang direview tersebut diterima oleh orang yang mereview (Rina, 2023).