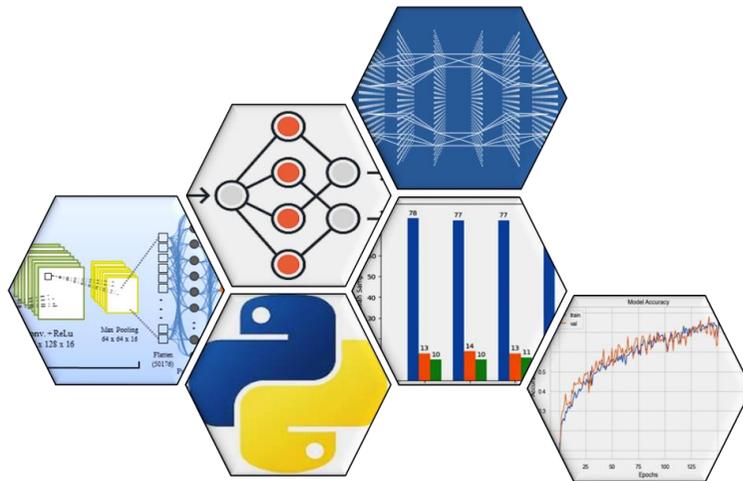


KLASIFIKASI CITRA MAKANAN KHAS SULAWESI SELATAN MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

SKRIPSI



FUTIKHA RAHMA PUSPITADEWI
H011191063

PROGRAM STUDI MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2024



**KLASIFIKASI CITRA MAKANAN KHAS SULAWESI SELATAN
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK**

**FUTIKHA RAHMA PUSPITADEWI
H011191063**



**PROGRAM STUDI MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2024**

**KLASIFIKASI CITRA MAKANAN KHAS SULAWESI SELATAN
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK**

FUTIKHA RAHMA PUSPITADEWI
H011191063

Skripsi

sebagai salah satu syarat untuk mencapai gelar sarjana

Program Studi Matematika

pada

**PROGRAM STUDI MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN
MAKASSAR
2024**

SKRIPSI

KLASIFIKASI CITRA MAKANAN KHAS SULAWESI SELATAN MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

FUTIKHA RAHMA PUSPITADEWI
H011191063

Skripsi,

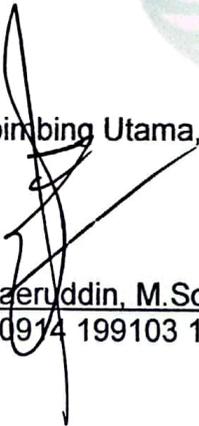
Telah dipertahankan di depan Panitia Ujian Sarjana Sains pada tanggal 13 September 2024
dan dinyatakan telah memenuhi syarat kelulusan
pada

Program Studi Matematika
Departemen Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Hasanuddin
Makassar

Mengesahkan:

Pembimbing Utama,

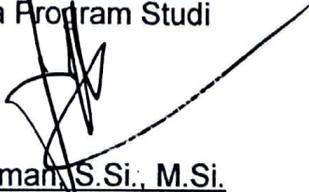
Pembimbing Pendamping


Dr. Khaeruddin, M.Sc.
NIP. 19650914 199103 1 003


A. Muhsin Amil Siddik, S.Si., M.Si.
NIP. 19911003 201903 1 015

Mengetahui:

Ketua Program Studi


Dr. Firman, S.Si., M.Si.
NIP. 19680429 200212 1 001



PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa, skripsi berjudul “Klasifikasi Citra Makanan Khas Sulawesi Selatan Menggunakan *Convolutional Neural Network*” adalah benar karya saya dengan arahan dari pembimbing (Dr. Khaeruddin, M.Sc sebagai Pembimbing Utama dan A. Muh. Amil Siddik, S.Si., M.Si sebagai Pembimbing Pendamping). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka skripsi ini. Apabila di kemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini adalah karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut berdasarkan aturan yang berlaku.

Dengan ini saya melimpahkan hak cipta (hak ekonomis) dari karya tulis saya berupa skripsi ini kepada Universitas Hasanuddin.

Makassar, 13 September 2024



Futikha Rahma Puspitadewi
NIM. H011191063

Ucapan Terima Kasih

Bismillahirrahmanirrahim,

Segala puji dan syukur kita panjatkan ke hadirat Allah *Subhanahu Wa ta'ala.* yang telah memberikan rahmat, hidayah, dan kesehatan sehingga penulisan skripsi ini dapat terselesaikan dengan baik. Tidak lupa, shalawat serta salam semoga senantiasa tercurah kepada junjungan kita, Nabi Muhammad *Shallallahu 'alaihi wa sallam*, beserta keluarga, sahabat, dan para pengikutnya hingga akhir zaman.

Alhamdulillah, penyusunan skripsi dengan judul “Klasifikasi Citra Makanan Khas Sulawesi Selatan Menggunakan *Convolutional Neural Network*” dapat terselesaikan dengan baik sebagai syarat untuk memperoleh gelar Sarjana Sains pada Program Studi Matematika Departemen Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

Penulis menyadari bahwa penyusunan skripsi ini tidak akan terwujud tanpa bantuan, bimbingan, dan dukungan dari berbagai pihak. Penulis ingin menyampaikan rasa terima kasih yang tak terhingga kepada kedua orangtua penulis Ibu Endang Purnomowati dan Bapak Moh. Ali Nurdin yang selalu memberikan doa, dukungan moral, serta motivasi yang tiada henti sehingga penulis dapat menyelesaikan pendidikan di Universitas Hasanuddin. Penulis juga berterima kasih kepada saudara penulis Moh. Fatkhurohman Romadhoni serta kepada keluarga penulis yang telah memberikan banyak bantuan serta dukungan dan motivasi kepada penulis. Pada kesempatan ini tidak lupa penulis menyampaikan ucapan terima kasih yang tulus kepada:

1. Bapak/Ibu Prof. Dr. Ir. Jamaluddin Jompa, M.Sc. selaku rector Universitas Hasanuddin beserta seluruh jajarannya, serta Bapak Dr. Eng. Amiruddin, M.Si. selaku dekan Fakultas Matematika dan Ilmu Pengetahuan Alam beserta seluruh jajarannya.
2. Bapak Dr. Firman, S.Si. M.Si sebagai Ketua Departemen Matematika FMIPA Unhas. Penulis juga berterima kasih atas dedikasi dosen-dosen pengajar, serta staf Departemen atas ilmu dan bantuan yang bermanfaat,
3. Bapak Dr. Khaeruddin, M.Sc sebagai dosen pembimbing utama sekaligus ketua tim penguji, yang telah meluangkan waktu serta memberikan bimbingan dan pengarahan selama penyelesaian skripsi ini.
4. Bapak A. Muh. Amil Siddik, S.Si., M.Si sebagai dosen pembimbing pertama sekaligus sekretaris tim penguji, yang telah meluangkan waktu bimbingan dan pengarahan selama proses penyelesaian skripsi ini.
5. Bapak Dr. Agustinus Ribal, S.Si., M.Sc., Ph.D. sebagai anggota tim penguji, atas ilmu yang beliau bagikan selama masa perkuliahan serta kritik dan saran yang membangun selama penulisan skripsi ini.
6. Ibu Naimah Aris S.Si., M.Math sebagai anggota tim penguji, atas ilmu yang beliau berikan selama masa perkuliahan, serta kritik dan saran yang membangun selama penulisan skripsi ini.
7. Teman-teman prodi Matematika 2019 dan teman-teman seperjuangan, yang telah memberikan bantuan, dukungan dan semangat, selama masa studi hingga penyusunan skripsi ini.
8. Kepada semua pihak yang Namanya tidak dapat disebutkan satu per satu, terimakasih atas segala bentuk bantuan dan dukungan yang telah diberikan kepada

penulis selama ini. Semoga apa yang kita berikan dilipatgandakan oleh Allah *Subhanahu Wa ta'ala*.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang membangun untuk kesempurnaan skripsi ini di masa mendatang.

Akhir kata, penulis berharap semoga skripsi ini dapat bermanfaat bagi semua pihak yang membutuhkan.

Penulis,

Futikha Rahma Puspitadewi

ABSTRAK

FUTIKHA RAHMA PUSPITADEWI. **Klasifikasi Citra Makanan Khas Sulawesi Selatan Menggunakan *Convolutional Neural Network*** (Dr. Khaeruddin, M.Sc dan A. Muh. Amil Siddik, S.Si., M.Si)

Latar belakang. Indonesia dikenal sebagai negara dengan keanekaragaman budayanya, termasuk dalam kuliner tradisionalnya. Setiap daerah memiliki makanan khas yang mencerminkan identitas dan kearifan lokalnya. Sulawesi Selatan, salah satu provinsi di Indonesia, terkenal dengan berbagai makanan tradisional seperti coto makassar, sop konro, pallubasa, dan pallu butung. Namun, pengenalan makanan khas melalui citra digital seringkali mengalami kesulitan akibat variasi pencahayaan, perbedaan sudut pengambilan gambar, serta kemiripan visual antara beberapa jenis makanan. **Tujuan.** Penelitian ini bertujuan untuk mengklasifikasikan citra digital makanan khas Sulawesi Selatan menggunakan metode Convolutional Neural Network (CNN). Metode CNN dipilih karena kemampuannya dalam melakukan ekstraksi fitur dan klasifikasi gambar secara efektif. Penelitian ini diharapkan dapat mengukur kinerja model CNN dalam mengenali dan mengklasifikasikan beberapa jenis makanan khas Sulawesi Selatan. **Metode.** Penelitian dibagi lima tahap, yakni: 1) pengumpulan dataset; 2) preprocessing data; 3) Perancangan arsitektur CNN 4) pelatihan data; 5) Evaluasi Akhir. **Hasil.** Diperoleh nilai akurasi pelatihan sebesar 78,12% dan loss 0,5519. Nilai akurasi validasi yaitu 78,05% dan loss 0,6341. Sementara itu pada hasil evaluasi akhir menggunakan data pengujian diperoleh nilai akurasi sebesar 77%. Pada evaluasi akhir menggunakan data uji diperoleh rata-rata nilai precision sebesar 0.79, recall sebesar 0.77, F1-Score sebesar 0.77, dan akurasi keseluruhan mencapai 77%. Beberapa kelas seperti "Pisang Ijo" dan "Pallubutung" memiliki performa yang sangat baik, dengan F1-Score masing-masing sebesar 0.95 dan 0.91. Namun, terdapat pula beberapa kelas dengan performa yang lebih rendah, seperti "Coto Makassar" yang memiliki F1-Score sebesar 0.58. **Kesimpulan.** Model CNN ini efektif dalam mengklasifikasikan makanan khas Sulawesi Selatan, meskipun masih ada ruang untuk peningkatan pada beberapa kelas tertentu.

Kata kunci: citra digital, Convolutional Neural Network (CNN), ekstraksi fitur, klasifikasi citra digital, confusion matrix, precision, recall, F1-Score, akurasi

ABSTRACT

FUTIKHA RAHMA PUSPITADEWI. **Classification of Traditional South Sulawesi Foods Using Convolutional Neural Network** (Dr. Khaeruddin, M.Sc and A. Muh. Amil Siddik, S.Si., M.Si)

Background. Indonesia is known as a country rich in cultural diversity, including its traditional cuisine. Each region has its unique dishes that reflect local identity and wisdom. South Sulawesi, one of Indonesia's provinces, is renowned for its traditional foods such as coto makassar, sop konro, pallubasa, and pallu butung. However, the recognition of traditional foods through digital images often faces challenges due to variations in lighting, differences in camera angles, and visual similarities between certain types of food. **Aim.** This study aims to classify digital images of traditional South Sulawesi foods using the Convolutional Neural Network (CNN) method. The CNN method was chosen for its ability to effectively extract features and classify images. This research is expected to measure the performance of the CNN model in recognizing and classifying several types of traditional South Sulawesi foods. **Method.** The study is divided into five stages: 1) dataset collection; 2) data preprocessing; 3) CNN architecture design; 4) data training; 5) final evaluation. **Results.** The training accuracy was 78.12% with a loss of 0.5519. The validation accuracy was 78.05% with a loss of 0.6341. Meanwhile, in the final evaluation using test data, the accuracy reached 77%. The final evaluation with test data showed an average precision score of 0.79, recall of 0.77, F1-Score of 0.77, and an overall accuracy of 77%. Some classes like "Pisang Ijo" and "Pallubutung" performed very well, with F1-Scores of 0.95 and 0.91, respectively. However, some classes had lower performance, such as "Coto Makassar" with an F1-Score of 0.58. **Conclusion.** This CNN model is effective in classifying traditional South Sulawesi foods, although there is room for improvement in certain classes.

Keywords: digital image, Convolutional Neural Network (CNN), feature extraction, digital image classification, confusion matrix, precision, recall, F1-Score, accuracy.

DAFTAR ISI

HALAMAN JUDUL	i
PERNYATAAN PENGAJUAN	iii
HALAMAN PENGESAHAN	v
PERNYATAAN KEASLIAN SKRIPSI	vii
UCAPAN TERIMA KASIH	ix
ABSTRAK.....	xi
DAFTAR ISI.....	xv
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	2
1.3 Tujuan Penelitian.....	2
1.4 Manfaat Penelitian.....	2
1.5 Batasan Masalah.....	2
1.6 Landasan Teori	3
1.6.1 Makanan Tradisional.....	3
1.6.2 Citra Digital.....	8
1.6.3 Artificial Neural Network.....	9
1.6.4 Deep Learning.....	14
1.6.5 Convolutional Neural Network.....	17
1.6.6 Confusion Matrix.....	22
1.6.7 Dropout	23
BAB II METODOLOGI PENELITIAN	25
2.1 Rancangan Penelitian.....	25
2.2 Alur Penelitian	26
BAB III HASIL DAN PEMBAHASAN	31
3.1 Pengumpulan Data.....	31
3.2 Preprocessing Data	31
3.3 Perancangan Model Arsitektur CNN	36
3.4 Pelatihan dan Pengujian Dataset	40
3.5 Evaluasi Akhir.....	42
BAB IV KESIMPULAN DAN SARAN	49
4.1 Kesimpulan	49

4.2 Saran.....	49
DAFTAR PUSTAKA	51
LAMPIRAN.....	55

DAFTAR GAMBAR

Gambar 1. Coto Makassar	3
Gambar 2. Kapurung.....	4
Gambar 3. Pallu Basa	4
Gambar 4. Sop Konro	5
Gambar 5. Pallu Butung.....	5
Gambar 6. Pisang Epe	5
Gambar 7. Pisang Ijo	6
Gambar 8. Mie Titi	6
Gambar 9. Nasu Palekko	6
Gambar 10. Barongko.....	7
Gambar 11. Burasa.....	7
Gambar 12. Pallu Mara	8
Gambar 13. Representasi Nilai Piksel Dari Citra RGB	9
Gambar 14. Struktur Artificial Neural Network.....	9
Gambar 15. Ilustrasi ANN	10
Gambar 16. Neural Network dengan 2 Lapisan	11
Gambar 17. Neural Network Tanpa Fungsi Aktivasi.....	12
Gambar 18. Grafik Fungsi ReLu.....	13
Gambar 19. Grafik Fungsi Softmax	13
Gambar 20. Ilustrasi Feed Forward dan Backpropagation	14
Gambar 21. Arsitektur CNN.....	18
Gambar 22. Ilustrasi proses konvolusi pada input 5x5 dengan kernel 3x3.....	20
Gambar 23. Ilustrasi Teknik Stride Dengan Nilai Stride 1	20
Gambar 24. Ilustrasi Teknik Padding.....	21
Gambar 25. Pooling layer dengan kernel 2x2 dan stride 2x2	21
Gambar 26. (a) Confusion Matrix pada <i>binaryclass</i> , (b) Confusion Matrix pada <i>multiclass</i>	23
Gambar 27. Rancangan Penelitian.....	25
Gambar 28. Diagram alir preprocessing data.....	27
Gambar 29. Diagram alir perancangan arsitektur CNN dan contoh arsitektur CNN	28
Gambar 30. Diagram alir proses pelatihan data.....	29
Gambar 31. Diagram alir proses evaluasi akhir	29
Gambar 32. Folder Dataset Citra.....	31
Gambar 33. Citra berukuran 850 x 550 diresize ke ukuran 256 x 256	32
Gambar 34. Kode untuk pelabelan data	32
Gambar 35. Kode untuk menormalisasi nilai piksel citra	33
Gambar 36. Kode untuk pembagian data latih, validasi, dan uji	33
Gambar 37. Distribusi jumlah data latih, data uji, dan data validasi pada setiap kelas.....	34
Gambar 38. Augmentasi data menggunakan ImageDataGenerator	35
Gambar 39. Perancangan model arsitektur CNN pada tahap feature learning.....	37
Gambar 40. Perancangan model arsitektur CNN pada tahap classification.....	39

Gambar 41. Ringkasan Arsitektur CNN.....	39
Gambar 42. Tahapan feature learning dan classification dalam CNN.....	40
Gambar 43. Ilustrasi arsitektur CNN	40
Gambar 44. Kode untuk melakukan pelatihan pada dataset.....	40
Gambar 45. Proses Pelatihan pada Dataset	41
Gambar 46. Grafik Model Akurasi dan Model Loss	42
Gambar 47. Confusion Matrix dan Nilai Metrik Evaluasi pada Data Uji	42
Gambar 48. Kurva RO C-AUC.....	47

DAFTAR TABEL

Tabel 1. Spesifikasi Perangkat Keras dan Perangkat Lunak lunak	25
Tabel 2. Penjelasan Kode Resize Citra	32
Tabel 3. Hasil pelabelan data.....	32
Tabel 4. Penjelasan Kode Pelabelan Data	33
Tabel 5. Penjelasan Kode Pembagian Dataset	34
Tabel 6. Hasil Augmentasi Citra.....	35
Tabel 7. Inisialisasi Hyperparameter	36
Tabel 8. Penjelasan Kode pelatihan Dataset.....	40
Tabel 9. Nilai <i>true positive</i> (TP), <i>true negative</i> (TF), <i>false positive</i> (FP) dan <i>false negative</i> (FN).....	43
Tabel 10. Nilai Metrik <i>Precision</i> , <i>Recall</i> , <i>F1-Score</i> , dan <i>Accuracy</i>	43
Tabel 11. Nilai Luas Area AUC	47

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara yang kaya akan keberagaman adat, budaya, suku, dan bahasa. Selain itu, kuliner Indonesia juga sangat beragam. Setiap wilayah di Indonesia memiliki makanan khas dengan keunikan dan keberagamannya masing-masing, yang mencerminkan kekayaan alam dan kearifan lokal daerahnya. Makanan tradisional atau makanan khas adalah makanan dan masakan yang diwariskan dari satu generasi ke generasi lainnya (Harsana,2020). Makanan tradisional merupakan warisan budaya yang harus dilestarikan sebab memiliki nilai sejarah bagi bangsa atau daerah asal makanan tersebut. Makanan khas dapat dikatakan sebagai identitas suatu daerah karena keberadaannya yang menjadi bagian dari budaya masyarakat seperti tata cara tertentu dalam proses pengolahan serta resep yang terjaga secara turun temurun.

Sulawesi Selatan merupakan salah satu provinsi yang terletak di Indonesia Timur dan memiliki 24 Kabupaten/Kota di dalamnya serta memiliki luas wilayah 45.717,48 km². Tiga populasi ternak paling banyak di Sulawesi Selatan ialah sapi potong 1.461.457 ekor dan 826.675 ekor kambing. Produksi daging unggas untuk ayam kampung 5.736.750 ton; ayam petelur 5.122.176 ton; ayam pedaging 90.029.428 ton; dan itik 1.991.522 ton. (Badan Pusat Statistik, 2022).

Besarnya potensi Sulawesi Selatan dalam sektor pangan membuat daerah ini memiliki sumber daya pangan yang melimpah di setiap daerahnya, sehingga setiap daerahnya memiliki makanan tradisionalnya masing-masing. Beberapa makanan tradisional khas Sulawesi Selatan yang terkenal adalah coto makassar, sop konro, pallubasa dan pallu butung.

Seiring dengan perkembangan teknologi digital, gambar-gambar makanan digital semakin populer di media sosial. Banyak orang yang mengambil gambar makanan dan membagikannya ke berbagai media sosial dengan berbagai tujuan salah satunya yaitu sebagai media dalam memberikan informasi dan mempromosikan makanan khas Sulawesi Selatan. Namun, dalam penggunaan gambar digital makanan khas Sulawesi Selatan, seringkali terdapat beberapa kendala dalam pengenalan makanan. Hal ini dapat disebabkan oleh variasi dalam pencahayaan, perbedaan sudut pengambilan gambar, atau bahkan variasi dalam penyajian makanan, serta kemiripan visual antara jenis makanan.

Dalam mengatasi masalah tersebut, *Convolutional Neural Network* (CNN) menjadi solusi yang digunakan dalam pemrosesan data citra. CNN memiliki kedalaman jaringan yang tinggi dan dirancang khusus untuk mengolah data dua dimensi. Algoritma CNN melakukan ekstraksi fitur dan klasifikasi citra dalam satu proses, dengan melibatkan pembelajaran dalam proses ekstraksi fitur (Juliansyah & Laksito, 2021).

CNN merupakan metode yang populer untuk tugas klasifikasi gambar, dimana telah dilakukan oleh beberapa peneliti seperti Tohidul Islam dkk pada tahun 2018 melakukan penelitian yang berjudul *food image classification with*

convolutional neural network pada dataset the food-11 dengan akurasi evaluasi 92.86%. Pada tahun 2020, Isna Wulandari dkk melakukan klasifikasi pada citra bumbu dan rempah dari kategori ginseng, jahe, dan lengkuas menghasilkan akurasi evaluasi sebesar 88.89%. Tahun 2021, Dandi Darajat dkk melakukan klasifikasi pada citra makanan khas Indonesia yang terdiri dari 9 kelas yaitu gudeg, gado-gado, nasi goreng, nasi kuning, sate, soto, rendang, pempek, dan kerak telur kemudian menghasilkan akurasi evaluasi 91%. Tahun 2020, Assyifa Ramdani dkk melakukan penelitian berjudul *food detection with image processing using convolutional neural network (CNN) methode* dengan akurasi sebesar 100%. Tahun 2020, Zeduo Yuan dkk melakukan penelitian berjudul *breast cancer image classification based on CNN classifier* dan memperoleh akurasi sebesar 91,1%.

Setiap citra digital makanan memiliki perbedaan pada warna, bentuk, tekstur, pencahayaan, ataupun sudut pengambilan gambar. Hal tersebut menjadi tantangan tersendiri dalam melakukan klasifikasi pada data citra makanan menggunakan CNN. Penelitian ini berfokus pada penerapan metode CNN untuk data citra makanan khas Sulawesi Selatan. Oleh karena itu, penulis tertarik untuk melakukan penelitian dengan judul "**Klasifikasi Citra Makanan Khas Sulawesi Selatan Menggunakan Metode Convolutional Neural Network**"

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang diatas, maka rumusan masalah dalam penelitian ini yaitu:

1. Bagaimana cara mengklasifikasi citra digital makanan khas Sulawesi Selatan dengan menggunakan metode CNN?
2. Bagaimana kinerja sistem dan akurasinya dalam klasifikasi citra digital makanan khas Sulawesi Selatan dengan menggunakan metode CNN?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang ada, maka tujuan yang ingin dicapai dalam penelitian ini yaitu:

1. Untuk mengimplementasikan metode CNN pada proses klasifikasi citra digital makanan khas Sulawesi Selatan.
2. Untuk mengukur kinerja model dalam proses klasifikasi citra digital makanan khas Sulawesi Selatan.

1.4 Manfaat Penelitian

Adapun manfaat dalam penelitian ini yaitu:

1. Penelitian ini dapat digunakan sebagai referensi untuk pengembangan ilmu pengetahuan dan teknologi kedepannya.
2. Penelitian ini dapat digunakan sebagai alat bantu untuk mengklasifikasikan citra digital makanan khas Sulawesi Selatan.

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini adalah:

1. Dataset yang digunakan dalam penelitian ini didapatkan secara *open-source* dan diambil secara manual melalui *search engine google*.
2. Dataset yang digunakan berupa citra digital makanan khas Sulawesi Selatan.
3. Jenis makanan khas Sulawesi Selatan yang akan diteliti ada 12 kelas, yaitu coto Makassar, kapurung, pallu basa, sop konro, pallu butung, pisang epe, pisang ijo, mi titi, nasu palekko, barongko, burasa, dan pallu mara.
4. Jumlah data perkelas yaitu 101 gambar.

1.6 Landasan Teori

1.6.1 Makanan Tradisional

Keberagaman etnik dan wilayah multikultural Indonesia sejalan dengan ragam makanan tradisionalnya. Berbagai macam rempah-rempah terkandung dalam makanan tradisional Indonesia dengan beraneka teknik memasak dan bahan-bahan lokal yang sebagian dipengaruhi oleh negara Timur Tengah, India, Eropa dan China. Keberagaman makanan tradisional juga terpengaruh oleh ragam bahan baku yang tersedia di masing-masing daerah (Harsana, 2020).

Makanan tradisional atau makanan khas adalah makanan dan masakan yang memiliki cita rasa yang khas dan diwariskan dari satu generasi ke generasi berikutnya. Makanan tradisional pada awalnya memiliki peran penting dalam ritual dan upacara adat serta diwariskan secara turun-temurun. Resep dan teknik pengolahan makanan terus diwariskan dari generasi ke generasi. Makanan khas juga mencerminkan perpaduan budaya yang melibatkan lebih dari satu aspek (Harsana, 2020).

Sulawesi Selatan yang memiliki potensi besar dalam sektor pangan membuat daerah ini memiliki sumber daya pangan yang melimpah di setiap daerahnya, sehingga setiap daerahnya memiliki makanan tradisionalnya masing-masing. Beberapa makanan tradisional khas Sulawesi selatan yang terkenal adalah coto Makassar, sop konro, pallubasa, pallu butung dan sebagainya.

a) Coto Makassar

Kota Makassar memiliki beragam makanan tradisional salah satunya yaitu coto makassar. Makanan ini telah menjadi bagian dari warisan kuliner sejak abad ke-16. Hidangan ini memiliki ciri khas penggunaan 40 jenis rempah-rempah dalam bahan-bahannya dan kuah yang terbuat dari gilingan kacang tanah. Coto makassar terbuat dari daging dan jeroan sapi yang direbus dalam waktu lama dengan berbagai macam rempah-rempah seperti bawang merah, bawang putih, cabai, ketumbar, jintan, serai, lengkuas, jahe dan lainnya (Lestari dkk., 2023).



Gambar 1. Coto Makassar

Sumber: <https://budaya-indonesia.org/Coto-Makasar>

b) Kapurung

Kapurung merupakan makanan yang berasal dari daerah Luwu (Kabupaten Luwu, Kota Palopo, Luwu Utara, Luwu Timur). Makanan ini dibuat menggunakan sari atau tepung sagu dan dimasak dengan campuran ikan atau daging ayam beserta berbagai jenis sayuran. Di Kota Makassar, terdapat Rumah Makan Kapurung yang menyajikan hidangan tradisional Kapurung dari Daerah Luwu dengan cita rasa dan aroma khas, karena menggunakan bumbu khas yang hanya terdapat di daerah tersebut, seperti asam patikala (Musniar, 2008).



Gambar 2. Kapurung

Sumber: <https://budaya-indonesia.org/Kapurung-4>

c) Pallu Basa

Nama "Pallu Basa" berasal dari bahasa Makassar, di mana "Pallu" berarti masakan dan "Basa" berarti berkuah. Jadi, Pallu Basa dapat diartikan sebagai masakan berkuah. Pallu Basa memiliki kesamaan dengan hidangan coto Makassar atau sup daging, namun perbedaannya terletak pada kekentalan kuah yang berasal dari campuran berbagai rempah-rempah khas seperti lengkuas, serai, jintan, bawang merah, pala, bawang putih, jahe, asam, kayu manis, gula merah, dan cabe keriting yang dihaluskan, kemudian ditumis hingga harum dan dicampurkan ke dalam air yang sudah mendidih. Daging sapi atau jeroan sapi yang telah direbus kemudian dipotong-potong dan dicampur dengan kuah rempah tersebut. Sebagai sentuhan akhir dan juga sebagai ciri khas dari Pallu Basa, daging dan kuah rempah disajikan dengan penambahan kalapa parut yang telah disangrai (serundeng), sehingga kuahnya menjadi kental dan gurih. Tambahkan lain yang membuat Pallu Basa lebih istimewa adalah penambahan telur ayam yang dimasak setengah matang (Nurchintyawati, 2018).



Gambar 3. Pallu Basa

Sumber: <https://budaya-indonesia.org/Pallubasa>

d) Sop Konro

Sop konro adalah masakan berkuah dengan bahan dasar tulang iga berbalut daging dan berbumbu rempah-rempah. Biasanya disajikan dengan nasi putih. Warna kuah yang hitam kecoklatan berasal dari buah kluwek yang berwarna hitam dan beraroma khas. Kuah sop ini berasal dari bumbu yang dibuat dari campuran

rempah-rempah, seperti ketumbar, kluwek, pala, kunyit, kencur, kayu manis, asam, daun lemon, cengkih, dan daun salabagi, membuat rasa sup semakin tajam (Portal Informasi Indonesia, 2019).



Gambar 4. Sop Konro

Sumber: <https://budaya-indonesia.org/Sup-Konro-2>

e) Pallubutung

Pallu butung merupakan kuliner yang berbahan dasar buah pisang. Makanan ini terbuat dari adonan berbahan tepung beras, santan, gula pasir, vanili, daun pandan, dan garam yang dimasak hingga matang dan mengental. Kemudian potongan pisang raja yang telah dikukus ataupun direbus dimasukkan ke adonan yang sudah matang tadi lalu diaduk. Pallu butung dapat disajikan dalam kondisi hangat ataupun dingin dengan ditambahkan parutan es di atasnya (wikipedia).



Gambar 5. Pallu Butung

Sumber: <https://cookpad.com/id/resep/16860059-es-pallu-butung-khas-makassar-tanpa-santan>

f) Pisang Epe

Pisang epe banyak dijumpai di pesisir Pantai Losari, Makassar. Pisang epe terbuat dari pisang kepok yang dibakar di atas arang kemudian dipipihkan menggunakan alat khusus yang terbuat dari kayu. Pisang ini disajikan dengan gula merah cair dan dapat diberi toping tambahan seperti coklat, kacang dan keju (Toemon, 2017).



Gambar 6. Pisang Epe

Sumber: https://cookpad.com/id/resep/16857330-pisang-epe-khas-pantai-losari?ref=search&search_term=pisang%20epe

g) Pisang Ijo

Pisang ijo berasal dari daerah Makassar, Sulawesi Selatan. Kuliner ini terbuat dari jenis pisang raja, ambon, atau kepok yang sudah matang. Pisang kemudian dibalut dengan adonan yang terdiri dari campuran tepung beras, santan, dan air

daun pandan sebagai pewarna alami dan penambah aroma. Setelah itu, diberi tambahan bubur sum-sum atau tepung terigu rebus yang kenyal, dan diberi sirup DHT serta susu kental manis (Indonesia Kaya, 2022).



Gambar 7. Pisang Ijo

Sumber: <https://budaya-indonesia.org/Es-Pisang-Ijo>

h) Mie Titi

Mie Titi merupakan salah satu makanan khas Makassar. Berbeda dengan mie-mie lainnya seperti mie ayam, mie kuah, mie bakso, mie goreng, dan sejenisnya, Mie Titi menggunakan mie berukuran kecil yang dipanggang atau digoreng hingga kering. Kemudian, mie tersebut disajikan dengan kuah bumbu yang kental dan diberi tambahan irisan daging ayam, jamur, hati, udang, cumi, serta sayuran sawi hijau (Nurchintyawati, 2018).



Gambar 8. Mie Titi

Sumber: https://cookpad.com/id/resep/22658091-resep-mie-titi-bihun-mie?ref=search&search_term=mi%20titi

i) Nasu Palekko

Kuliner itik palekko juga dikenal dengan sebutan Nasu Palekko. Nama makanan ini memiliki asal-usul dari dua kata dalam bahasa Bugis, yaitu "Nasu" yang berarti memasak dan "Palekko" yang merujuk pada wajan yang terbuat dari tanah. Nasu Palekko secara harfiah berarti memasak menggunakan wajan tanah. Nasu Palekko merupakan hidangan khas Bugis yang dibuat dari daging itik muda yang dipotong kecil-kecil seperti cincangan. Rasa pedas yang khas muncul dari kombinasi rempah-rempah yang digunakan dalam proses pengolahan (Fatmawaty, 2019).



Gambar 9. Nasu Palekko

Sumber: <https://budaya-indonesia.org/Nau-palekko>

j) Barongko

Barongko adalah salah satu kue tradisional yang sangat terkenal di kalangan masyarakat Bugis dan Makassar. Kue ini memiliki rasa manis dan gurih yang khas. Barongko dibuat dari pisang kepok yang sudah matang, yang kemudian dihaluskan. Adonan pisang tersebut kemudian dicampur dengan gula, santan, dan telur ayam. Untuk memberikan tambahan cita rasa, irisan nangka juga dicampurkan ke dalam adonan. Setelah itu, adonan dibungkus dengan menggunakan daun pisang, dengan membentuk polanya terlebih dahulu sebelum adonan dituangkan ke dalamnya. Selanjutnya, kue dikukus hingga matang (Hafid, 2020).



Gambar 10. Barongko

Sumber: <https://budaya-indonesia.org/Barongko-2>

k) Burasa

Burasa merupakan kuliner tradisional khas Makassar, makanan ini sangat cocok disantap bersama hampir semua jenis makanan yang berkuah, seperti hidangan Coto Makassar yang juga merupakan hidangan khas Makassar. Burasa yang dibungkus dengan daun pisang sudah merupakan ciri khas dari kuliner ini.

Burasa terbuat dari beras yang dicampur dengan santan dan sedikit garam. Adonan tersebut kemudian dibungkus dengan daun pisang dan diikat dengan cara khusus. Setelah itu, burasa dikukus hingga matang. Kuliner ini merupakan hidangan wajib di antara hidangan-hidangan lain seperti ketupat, nasu likku, dan lainnya yang biasa disajikan saat hari raya kepada tamu yang datang berkunjung di kalangan masyarakat Bugis dan Makassar (Rabiah dkk.,2016).



Gambar 11. Burasa

Sumber: <https://budaya-indonesia.org/burasa>

l) Pallu Mara

Pallu Mara merupakan makanan khas Sulawesi Selatan yang menggunakan ikan sebagai bahan utamanya. Nama Pallu Mara sendiri berasal dari kata "Pallu" yang berarti masakan, dan "Mara" yang berarti kuah asam. Dengan demikian, Pallu Mara dapat diartikan sebagai masakan dengan kuah asam. Masyarakat setempat menggunakan ikan sebagai bahan utama dalam pembuatan Pallu Mara,

karena ikan mudah ditemukan di sekitar mereka. Proses pembuatan Pallu Mara cukup sederhana, dimulai dengan membersihkan ikan dan melumuri dengan kunyit dan garam untuk menghilangkan bau amis. Selanjutnya, asam diperas dengan air hingga kental. Irisan bawang merah dan bawang putih ditumis dengan minyak, kemudian ditambahkan air asam beserta ikan yang telah dilumuri kunyit dan tunggu hingga mendidih dan matang (Arfan, 2018).



Gambar 12. Pallu Mara

Sumber: <https://budaya-indonesia.org/Pallumara-Ikan-Tenggiri>

1.6.2 Citra Digital

Citra merupakan suatu representasi (gambar) pada bidang dua dimensi dari suatu objek. Citra digital umumnya diwakili dalam bentuk matriks dua dimensi dimana setiap elemen matriks mewakili satu piksel pada citra yang menyimpan informasi warna dan intensitas cahaya (Yafis & Rijal, 2023).

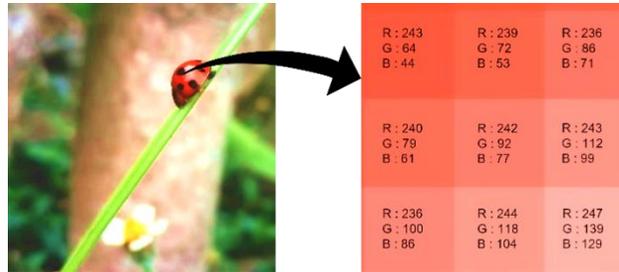
Dalam penelitian ini, digunakan citra berwarna yang terdiri dari tiga warna primer, yaitu *Red* (R), *Green* (G), dan *Blue* (B). Sebuah citra berwarna dengan ukuran $i \times j$ piksel dapat diwakili oleh tiga matriks, masing-masing terdiri dari i baris dan j kolom. Setiap komponen dalam matriks tersebut merepresentasikan nilai derajat keabuan pada masing-masing kanal RGB. Citra berwarna dapat direpresentasikan oleh matriks I_p , di mana I_1 adalah matriks yang mewakili derajat keabuan pada kanal Merah (*Red*), I_2 adalah matriks yang mewakili derajat keabuan pada kanal Hijau (*Green*), dan I_3 adalah matriks yang mewakili derajat keabuan pada kanal Biru (*Blue*).

$$I_p = \begin{bmatrix} (a_{11})_p & (a_{12})_p & \dots & (a_{1j})_p \\ (a_{21})_p & (a_{22})_p & \dots & (a_{2j})_p \\ \vdots & \vdots & \ddots & \vdots \\ (a_{i1})_p & (a_{i2})_p & \dots & (a_{ij})_p \end{bmatrix}$$

Nilai untuk masing-masing komponen matriks I_p adalah sebagai

$$(a_{ij})_p = \frac{d_p}{255} \quad (1)$$

Nilai d_p menggambarkan derajat keabuan pada kanal ke- p . Nilai d_p bersifat diskrit dan memiliki rentang antara 0 hingga 255 (Wulandari dkk., 2020).



Gambar 13. Representasi Nilai Pixel Dari Citra RGB

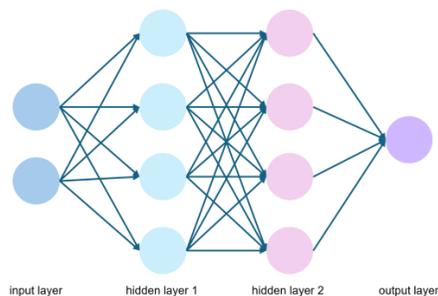
Persamaan (1) digunakan untuk memetakan nilai derajat keabuan d_p pada rentang 0 hingga 1. Hal ini disebut juga dengan proses normalisasi data. Nilai pixel dalam citra yang tidak dinormalisasi dapat memiliki rentang nilai yang berbeda-beda, yang dapat mempengaruhi hasil pengolahan citra. Proses normalisasi data membuat data tersebut menjadi seragam dengan nilai yang memiliki rentang sama.

1.6.3 Artificial Neural Network

Artificial Neural Network (ANN) adalah sistem pemrosesan informasi yang meniru prinsip kerja jaringan saraf (neuron) dalam otak manusia. ANN terdiri dari neuron yang terhubung dan mengubah informasi melalui koneksi menuju neuron lain. Tujuan dari pembuatan ANN adalah untuk menggeneralisasi model matematika pemahaman manusia.

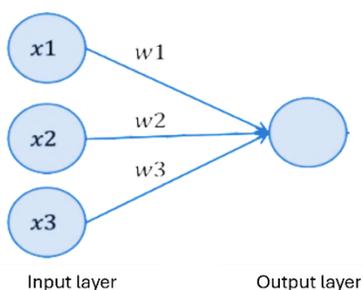
ANN terdiri dari beberapa proses yang sederhana namun saling terhubung yang disebut neuron. Proses ini meliputi pengumpulan data, analisis dan pemrosesan data, desain struktur jaringan, jumlah lapisan tersembunyi (*hidden layer*), inisialisasi bobot, pelatihan jaringan, simulasi jaringan, penyesuaian bobot, dan pengujian jaringan. ANN umumnya digunakan untuk memproses kumpulan data yang besar, dengan tujuan memberikan informasi analisis yang dapat digunakan untuk prediksi dan klasifikasi data (Sutoyo & Fadlurrahman, 2020).

Setiap pola informasi input dan output yang dimasukkan ke dalam ANN akan diproses oleh neuron. Neuron-neuron ini terorganisir dalam tiga lapisan seperti yang terlihat pada gambar berikut:



Gambar 14. Struktur Artificial Neural Network

1. *Input layer*, Lapisan ini terdiri dari neuron-neuron yang menerima input untuk proses pembelajaran dan pengenalan oleh ANN. Pada penelitian ini input layer berisi data citra yang akan diproses, seperti ukuran dimensi citra, kanal warna citra, dan nilai piksel.
2. *Hidden Layer*, pada lapisan ini berisikan neuron - neuron yang digunakan untuk melakukan komputasi dan ekstraksi fitur terhadap data input. Dalam penelitian ini *hidden layer* terdiri dari *convolutional layer*, *pooling layer*, dan *fully connected layer*.
3. *Output Layer*, pada lapisan ini berisikan neuron - neuron yang akan memberikan respons terhadap data input yang diberikan. *Output layer* merupakan bagian akhir dari jaringan saraf dan memberikan hasil atau prediksi yang dihasilkan oleh ANN.



Gambar 15. Ilustrasi ANN

Dari gambar 15, data input akan masuk ke *hidden layer*. Sebelum masuk, setiap input akan diberi bobot khusus. Kemudian, setiap input yang telah diberi bobot akan dijumlahkan. Sehingga, hasil penjumlahan tersebut adalah:

$$y = w_1x_1 + w_2x_2 + w_3x_3 + b \quad (2)$$

Keterangan:

- y : hasil output
- w_i : bobot
- x_i : fitur (*feature*)
- b : bias

Bobot merupakan parameter yang digunakan oleh jaringan untuk belajar. Bobot memainkan peran yang sangat penting dalam ANN. Bobot dapat merepresentasikan fitur-fitur yang ada dalam dataset. Selain itu, bobot juga memiliki kemampuan untuk mengubah orientasi atau kemiringan garis pemisah antara dua kelas, sehingga dapat mempengaruhi keputusan prediksi. Bobot juga dapat menunjukkan sejauh mana suatu fitur berkontribusi dalam memprediksi nilai target, serta memberikan informasi tentang hubungan antara fitur-fitur dengan nilai target yang ingin diprediksi (Saputra & Kristiyanti, 2022).

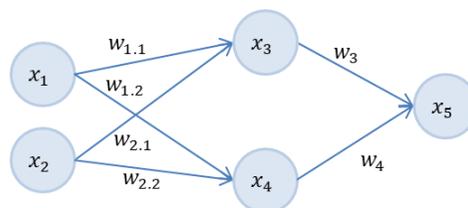
Fitur adalah nilai-nilai yang mewakili data yang dimasukkan kedalam jaringan. Setiap fitur mewakili karakteristik unik yang dimiliki oleh suatu objek. Fitur dibedakan menjadi dua yaitu fitur alami merupakan bagian dari gambar, seperti

kecerahan dan tepi objek. Sedangkan fitur buatan merupakan fitur yang diperoleh dengan operasi tertentu pada gambar, seperti histogram tingkat keabuan (Noak, 2020).

Pada persamaan (2), Bias adalah konstanta yang diatur secara bebas dan dapat diubah selama pelatihan model. Bias memberikan fleksibilitas dan kemampuan model untuk belajar pola yang lebih kompleks dan membuat keputusan yang lebih baik. Peran bias adalah menggeser garis atau fungsi yang dihasilkan oleh hasil penjumlahan bobot dan input ke atas atau ke bawah pada sumbu y . Dengan adanya bias, model dapat menghasilkan prediksi yang lebih fleksibel dan sesuai dengan data yang diberikan. Bias juga membantu model untuk menangani ketidakseimbangan dalam data atau situasi dimana pola yang ingin dipelajari tidak melalui titik $(0, 0)$.

a) Fungsi Aktivasi

Fungsi aktivasi dalam konteks jaringan saraf merujuk pada fitur-fitur dari neuron yang dapat diaktifkan dan dipetakan oleh fungsi non-linear. Fungsi aktivasi ini digunakan untuk mengatasi masalah non-linear dalam pemodelan data. Fungsi aktivasi yang tepat memiliki kemampuan yang lebih baik dalam memetakan data dalam dimensi yang lebih kompleks. Ketika jaringan saraf memiliki sifat linear, artinya persamaan linear dan kombinasinya hanya memiliki kemampuan untuk mengekspresikan hubungan linear antara input dan output. Hal ini akan membuat lapisan-lapisan dalam jaringan saraf kehilangan makna atau tidak memberikan keuntungan dalam memodelkan data yang lebih kompleks, artinya model tidak dapat menyelesaikan masalah non-linear dan kemampuan jaringan untuk belajar dan memodelkan data yang kompleks menjadi terbatas, lapisan-lapisan dalam jaringan akan kehilangan kemampuan untuk membedakan pola-pola yang rumit dan membuat keputusan yang lebih akurat. Oleh karena itu, fungsi aktivasi digunakan untuk meningkatkan kemampuan ekspresif dari model jaringan saraf, sehingga jaringan saraf dapat memiliki makna dan mampu mempelajari pola yang lebih kompleks, mirip dengan kecerdasan buatan (Wang dkk., 2020).



Gambar 16. Neural Network dengan 2 Lapisan

Pada gambar 16 merupakan contoh neural network dengan dua lapisan, hasil output x_5 tanpa menggunakan fungsi aktivasi yaitu:

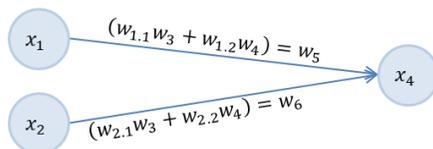
$$x_5 = x_3 w_3 + x_4 w_4$$

$$x_3 = x_1 w_{1.1} + x_2 w_{2.1}$$

$$x_4 = x_1 w_{1.2} + x_2 w_{2.2}$$

Sehingga, output x_5 dapat dijabarkan menjadi

$$\begin{aligned} x_5 &= (x_1 w_{1.1} + x_2 w_{2.1})w_3 + (x_1 w_{1.2} + x_2 w_{2.2})w_4 \\ &= x_1 w_{1.1} w_3 + x_2 w_{2.1} w_3 + x_1 w_{1.2} w_4 + x_2 w_{2.2} w_4 \\ &= x_1 (w_{1.1} w_3 + w_{1.2} w_4) + x_2 (w_{2.1} w_3 + w_{2.2} w_4) \\ &= x_1 w_5 + x_2 w_6 \end{aligned}$$



Gambar 17. Neural Network Tanpa Fungsi Aktivasi

Dapat dilihat bahwa neural network dengan dua lapisan sebelumnya menjadi setara dengan neural network dengan satu lapisan saja seperti ditunjukkan pada gambar 17. Hal ini menyebabkan proses pembelajaran menjadi terhambat dan kemampuan pengenalan pola-pola yang rumit dapat menghilang.

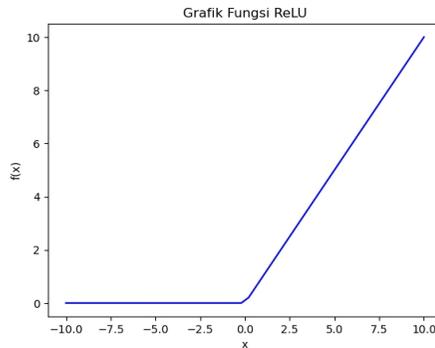
Terdapat beberapa fungsi aktivasi yang umum digunakan yaitu:

1) *Rectified Linear Unit* (ReLU)

ReLU adalah salah satu fungsi aktivasi yang sangat populer dan sering digunakan dalam *hidden layer* dari ANN terutama dalam hampir semua *Convolutional Neural Networks* (CNN) atau *Deep Learning*. ReLU didefinisikan oleh persamaan berikut:

$$f(x_i) = \max(0, x_i) = \begin{cases} x_i, & x_i > 0 \\ 0, & x_i < 0 \end{cases} \quad (3)$$

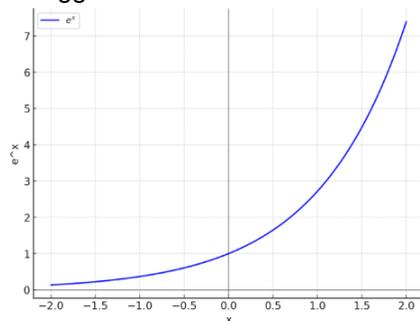
Dari Gambar 1.18, terlihat bahwa ReLU memiliki bentuk yang mirip dengan fungsi linear, namun sebenarnya itu adalah fungsi non-linier. Hal ini karena outputnya adalah 0 ketika inputnya kurang dari 0 ($x_i < 0$), dan fungsi ini mengatasi masalah gradien yang menghilang (*vanishing gradient*). Selain itu, ReLU memiliki komputasi yang lebih efisien dibandingkan dengan fungsi Sigmoid dan Tanh (Feng & Lu, 2019). Keunggulan dari fungsi aktivasi ReLU yaitu dapat mempercepat proses konfigurasi yang dilakukan dengan Stochastic Gradient Descent (SGD) jika dibandingkan dengan fungsi sigmoid dan tanh (Wahyuni & Sulaeman, 2022).



Gambar 18. Grafik Fungsi ReLU

2) Softmax

Softmax adalah sebuah fungsi aktivasi yang digunakan dalam perhitungan probabilitas untuk menentukan klasifikasi, terutama pada masalah klasifikasi multikelas. Fungsi aktivasi ini diterapkan pada output layer dari model jaringan saraf tiruan (*Neural Network*). Secara matematis, softmax mengubah nilai logit (nilai keluaran dari output layer) menjadi distribusi probabilitas dengan rentang antara 0 hingga 1, yang dijumlahkan menjadi 1. Softmax menghitung nilai eksponensial dari setiap logit menggunakan bilangan Euler ($e \approx 2.718$), yang merupakan dasar dari logaritma natural (\ln). Eksponensial sendiri adalah salah satu fungsi dasar matematika yang menunjukkan pertumbuhan yang sangat cepat seiring bertambahnya nilai input seperti yang ditunjukkan pada Gambar 19. Dalam softmax, penggunaan eksponensial memastikan bahwa perbedaan kecil antara logit dapat diperbesar, sehingga kelas dengan nilai logit lebih besar akan memiliki probabilitas yang lebih tinggi.

Gambar 19. Grafik Fungsi e^x

Fungsi aktivasi softmax dirumuskan pada persamaan (4) dan divisualisasikan pada Gambar 19.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad \text{for } i = 1, 2, 3, \dots, k \quad (4)$$

x_i merupakan nilai logit (nilai output pada neuron ke- i), nilai k merupakan jumlah kategori yang diklasifikasikan. Nilai $f(x_i)$ merupakan nilai probabilitas untuk setiap kategori. Semua nilai $f(x_i)$ jika dijumlahkan akan

bernilai satu (Wulandari dkk., 2020). Fungsi aktivasi softmax memiliki keunggulan pada rentang probabilitas output. Rentang output adalah 0 sampai 1, dan jumlah semua probabilitas dalam satu objek output adalah 1 (Kholik, 2021).

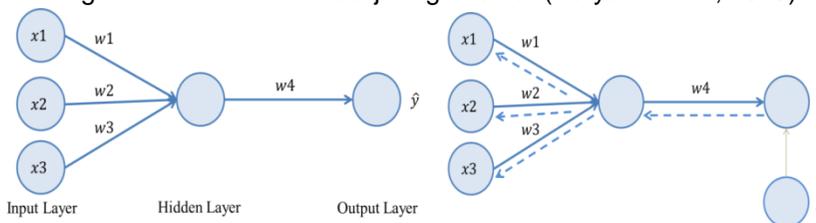
1.6.4 Deep Learning

Deep learning adalah salah satu cabang dalam bidang kecerdasan buatan (*artificial intelligence*) yang awalnya terinspirasi oleh model komputasi dan kognisi biologis dalam otak manusia. Teknik *deep learning* memungkinkan analisis data yang tidak terstruktur dan identifikasi fitur secara otomatis. Salah satu keunggulan utama dari *deep learning* adalah kemampuannya untuk mengekstraksi fitur-fitur tingkat tinggi dari data input mentah. Dengan menggunakan arsitektur jaringan saraf yang dalam (*deep*) dan kompleks, *deep learning* mampu mengenali pola-pola yang kompleks dan menghasilkan representasi-fitur yang lebih abstrak dari data tersebut. Hal ini memungkinkan *deep learning* untuk menjadi sangat efektif dalam berbagai tugas seperti pengenalan gambar, pengenalan suara, dan pemrosesan bahasa alami (Choudary et al, 2022).

Model-model *deep learning* memiliki kemampuan untuk secara langsung belajar representasi-fitur dari data asli, seperti gambar dan teks, tanpa memerlukan teknik rekayasa fitur manual. Hal ini memungkinkan metode *deep learning* untuk bekerja secara *end-to-end*, yaitu langsung dari input hingga output yang diinginkan. Dalam konteks dataset yang besar, metode *deep learning* memiliki keunggulan yang signifikan dibandingkan dengan model-model dangkal atau tradisional. Dalam studi tentang *deep learning*, fokus utamanya adalah pada pengembangan arsitektur jaringan yang efektif, penyetelan *hiperparameter* yang tepat, dan strategi optimisasi yang baik (Liu & Lang, 2019).

a) **Feed Forward, Backpropagation and Loss Function**

Dalam *deep learning*, *feedforward*, *backpropagation*, dan fungsi kerugian (*loss function*) adalah konsep yang saling terkait dan digunakan dalam proses pelatihan jaringan saraf tiruan. Proses *feedforward* dimulai setelah dataset diproses. Pada tahap ini, vektor *input* (misalnya gambar) melewati serangkaian langkah, seperti konvolusi dan *max pooling*, untuk mereduksi ukuran gambar dan meningkatkan jumlah neuron. Hal ini membentuk banyak fitur-fitur yang berbeda yang akan dipelajari oleh jaringan. Hasil dari proses *feedforward* ini adalah bobot yang akan digunakan dalam evaluasi jaringan saraf (Peryanto dkk., 2019).



Gambar 20. Ilustrasi Feed Forward dan Backpropagation

Fungsi kerugian (*loss function*) adalah sebuah fungsi yang menggambarkan kesalahan(error) yang terkait dengan prediksi yang dihasilkan oleh model. Fungsi kerugian dianggap baik ketika menghasilkan kesalahan yang paling rendah. Cross-entropy loss merupakan fungsi kerugian yang digunakan untuk menghitung kinerja dari suatu model yaitu dengan menghitung error yang dihasilkan dari model tersebut. Biasanya, cross-entropy loss ini digunakan setelah fungsi softmax (Pangestu dkk., 2020). Rumus yang digunakan untuk menghitung cross entropy yaitu

$$L = -\frac{1}{N} \sum_{n=1}^N \sum_{m=1}^M y_{m,n} \log(f(x_i)_n) \quad (5)$$

Nilai N menunjukkan jumlah data citra dan nilai M menunjukkan jumlah kategori. $f(x_i)$ merupakan fungsi aktivasi. $y_{m,n}$ merupakan indikator biner, nilainya 1 untuk kelas yang sesuai dan 0 untuk kelas yang tidak sesuai. Jika gambaran umum cross-entropy loss function adalah meminimalkan kemungkinan log negatif dari dataset, yang merupakan ukuran langsung dari performa prediksi model. Kinerja suatu model semakin baik apabila nilai L semakin mendekati nol (Wulandari dkk., 2020).

Backpropagation adalah suatu pendekatan sistematis dalam jaringan saraf tiruan yang menggunakan algoritma pembelajaran ter-awasi. Metode ini umumnya digunakan oleh perceptron dengan banyak lapisan tersembunyi untuk memperbarui nilai bobot-bobot yang ada pada lapisan tersebut (Rohayani & Umam, 2022). Dalam prosesnya, backpropagation menghitung turunan dari fungsi kerugian (*loss function*) untuk mengetahui seberapa besar perubahan bobot dan bias yang diperlukan agar kesalahan prediksi berkurang. Secara matematis, misalkan L adalah fungsi kerugian yang tergantung pada output prediksi \hat{y} dan target y , serta W adalah bobot jaringan. Tujuan dari backpropagation adalah meminimalkan L dengan menghitung gradien dari L terhadap bobot W , yang diberikan oleh:

$$\frac{\partial L}{\partial W}$$

Dengan menggunakan aturan rantai, turunan ini dihitung secara berjenjang dari lapisan output ke lapisan input. Misalkan fungsi aktivasi di suatu neuron adalah $f(z)$, di mana z adalah :

$$z = W \cdot X + b$$

Gradien dari fungsi kerugian L terhadap bobot W dihitung sebagai:

$$\frac{\partial L}{\partial W} = \frac{\partial L}{\partial \hat{y}} \cdot \frac{\partial \hat{y}}{\partial z} \cdot \frac{\partial z}{\partial W}$$

Dalam hal ini:

- $\frac{\partial L}{\partial \hat{y}}$ adalah turunan dari fungsi kerugian terhadap output prediksi.
- $\frac{\partial \hat{y}}{\partial z}$ adalah turunan dari fungsi aktivasi neuron.
- $\frac{\partial z}{\partial W}$ adalah turunan dari masukan tertimbang terhadap bobot.

Algoritma backpropagation menggunakan gradien ini untuk memperbarui bobot dengan persamaan berikut:

$$W_{new} = W_{old} - \eta \cdot \frac{\partial L}{\partial W}$$

Di mana η adalah laju pembelajaran (learning rate) yang mengontrol seberapa besar pembaruan dilakukan pada bobot. Dengan menggunakan turunan dan gradien ini, jaringan saraf dapat belajar secara efisien melalui iterasi berulang, sehingga model lebih mampu menangkap pola dalam data.

b) Penyetelan *Hyperparameter*

Hyperparameter merupakan karakteristik dari algoritma pembelajaran yang umumnya memiliki nilai numerik yang mempengaruhi cara kerja algoritma. Nilai-nilai ini tidak diperoleh oleh algoritma itu sendiri melalui proses pembelajaran dari data, melainkan harus ditentukan sebelum menjalankan algoritma. Proses penyetelan hyperparameter, yang dikenal sebagai hyperparameter tuning, dilakukan untuk memilih nilai-nilai hyperparameter yang optimal agar model dapat memberikan hasil dan waktu komputasi yang optimal.

Penyetelan hyperparameter bertujuan untuk memastikan bahwa model tidak mengalami underfitting atau overfitting terhadap dataset pelatihan, sambil mempelajari struktur data dengan secepat mungkin. Dalam penelitian ini, terdapat beberapa hyperparameter yang digunakan dan diatur melalui proses hyperparameter tuning (Hariz dkk., 2022). Beberapa hyperparameter yang digunakan dalam penelitian ini contohnya yaitu jumlah *epoch*, *batch size*, fungsi aktivasi dan *learning rate*.

Jumlah epoch merupakan hyperparameter yang menentukan berapa kali algoritma pembelajaran akan bekerja melalui seluruh dataset pelatihan. Dalam satu epoch setiap sampel dataset pelatihan memiliki kesempatan untuk memperbarui parameter model internal. Dalam satu kali feed forward dan backpropagation disebut dengan satu epoch (Saputra & Kristiyanti, 2022).

Batch size mengacu pada jumlah sampel data yang digunakan antara pembaruan bobot model pada satu kali batch. Pemilihan ukuran batch dapat memiliki dampak signifikan terhadap performa model dan waktu pelatihan. Jika ukuran batch lebih besar, konvergensi model yang dihasilkan cenderung lebih cepat, namun menghasilkan bobot akhir yang kurang optimal. Sebaliknya, jika ukuran batch terlalu kecil, algoritma dapat mengabaikan variasi sebenarnya dalam distribusi sampel, yang dapat menyebabkan pelatihan yang tidak stabil. Umumnya, ukuran batch biasanya menggunakan nilai pangkat dua, seperti 32 hingga 256 atau lebih. Hal ini disebabkan karena akses memori dan desain perangkat keras lebih dioptimalkan untuk operasi pada array dengan dimensi yang berpangkat dua, dibandingkan dengan ukuran lainnya (Hariz dkk, 2022).

c) Pengoptimalan (*Optimizer*)

Optimizer dalam neural network adalah algoritma yang digunakan untuk mengoptimalkan parameter dalam proses training neural network. Tujuan utama dari *optimizer* adalah untuk menemukan nilai-nilai parameter yang optimal yang dapat meminimalkan fungsi kerugian atau maksimalkan kinerja model pada tugas

yang diberikan. *Optimizer* yang paling umum digunakan yaitu *stochastic gradient descent* (SGD) dan Adam.

1. *Stochastic Gradient Descent* (SGD)

Stochastic Gradient Descent (SGD) adalah algoritma optimasi yang paling sering digunakan dalam pembelajaran mesin. Pada dasarnya, SGD menggunakan pendekatan stokastik dalam menghitung gradien dan memperbarui bobot dalam proses pelatihan. Istilah "stokastik" mengacu pada penggunaan subset acak dari data pelatihan untuk menghitung gradien dan memperbarui bobot. Algoritma SGD bekerja dengan mengambil salah satu data dan menghitung gradien data tersebut kemudian nilai gradiennya akan diperbarui menggunakan learning rate, proses update nilai ini berlangsung hingga nilai mencapai titik terendah.

Pada regresi linier sederhana dengan data set kecil yang terdiri dari beberapa pasangan data (x, y)

(x, y)
$(a, 1)$
$(b, 2)$
$(c, 3)$
$(d, 4)$

Langkah awal pada algoritma SGD yaitu melakukan inialisasi parameter w, b dan learning rate dengan nilai acak. Selanjutnya melakukan update untuk setiap data dengan memilih satu sampel data secara acak misalnya (x_i, y_i) , lalu menghitung prediksi $y_{pred} = wx_i + b$, menghitung nilai loss dan gradien, serta memperbarui parameter w dan b . Proses ini diulangi beberapakali untuk semua sampel dalam dataset sesuai epoch yang ditentukan.

2. Adam (*Adaptive moment estimation*)

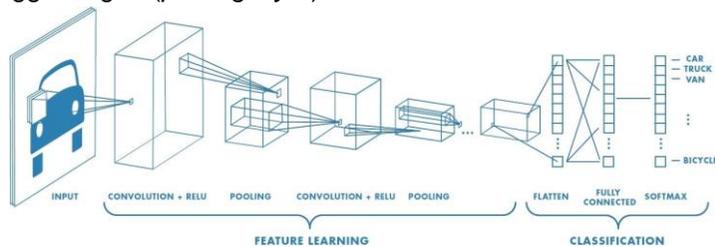
Teknik optimasi dengan Adam merupakan yang paling populer karena memberikan hasil yang bagus dengan cepat. Teknik ini bekerja dengan mempertahankan learning rate untuk setiap bobot dan disesuaikan ketika pembelajaran model semakin membaik (Saputra & Kristiyanti, 2022). Adam merupakan kombinasi antara RMSprop dan Stochastic Gradient Descent dengan momentum. Adam berbeda dengan SGD, pada SGD digunakan learning rate yang konstan dari awal hingga akhir, sedangkan Adam menggunakan learning rate yang sudah ditentukan diawal tetapi learning rate tersebut akan beradaptasi menyesuaikan parameter yang ada seiring berjalannya waktu, dengan menggunakan momentum pertama dan momentum kedua yang akan mengubah learning rate yang telah ditentukan.

1.6.5 Convolutional Neural Network

Convolutional Neural Network (CNN) termasuk dalam jenis *Deep Neural Network* karena memiliki kedalaman jaringan yang tinggi dan sering digunakan dalam pemrosesan data citra. Algoritma CNN dirancang khusus untuk mengolah data dua dimensi. Algoritma ini dalam satu proses akan mengekstraksi fitur dari

citra dan kemudian mengklasifikasikannya. Dalam algoritma CNN, proses ekstraksi fitur juga melibatkan proses pembelajaran (Juliansyah & Laksito, 2021). Secara teknis, CNN adalah sebuah arsitektur yang dapat dilatih dan terdiri dari beberapa tahap. Kemampuannya untuk menggambarkan citra menjadi fitur yang dapat dimengerti oleh jaringan ini menjadi salah satu perbedaan utama antara CNN dan jenis jaringan saraf lainnya (Wulandari, 2020).

Arsitektur CNN terdiri dari dua komponen utama, yaitu *feature learning* dan *fully connected layer*. Tahap *feature learning* bertanggung jawab untuk mengubah matriks *input* citra menjadi peta fitur (*feature maps*) yang merepresentasikan fitur-fitur yang ada pada gambar. Pada tahap *feature learning*, terdapat dua jenis lapisan yang sering digunakan, yaitu lapisan konvolusi (*Convolution Layer*) dan lapisan penggabungan (*pooling layer*).



Gambar 21. Arsitektur CNN

Sumber: <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>

Langkah pertama dalam arsitektur CNN adalah melakukan konvolusi, di mana digunakan sebuah filter yang terdiri atas beberapa matriks bobot atau biasa disebut dengan kernel. Banyaknya filter yang digunakan merupakan hyperparameter, jumlah filter ini akan menentukan jumlah peta fitur yang dihasilkan. Setelah itu, keluaran dari tahap konvolusi melewati fungsi aktivasi dan kemudian melalui proses *pooling*. Tahap ini diulang beberapa kali hingga peta fitur yang memadai diperoleh untuk diteruskan ke lapisan *fully connected layer* dan akhirnya menghasilkan kelas *output* (Wahyuni & Sulaeman, 2022).

a) **Convolutional Layer**

Operasi konvolusi adalah operasi matematika yang diterapkan pada dua fungsi dengan argumen bernilai riil. Misal $x(t)$ dan $w(t)$ adalah fungsi yang terdefinisi pada $t \geq 0$. Konvolusi x dan w dinotasikan dengan $x * w$ dan didefinisikan oleh:

$$s(t) = (x * w)(t) = \int x(a)w(t - a) da \quad (6)$$

Dalam konteks CNN, fungsi $s(t)$ menghasilkan suatu *feature map* sebagai output tunggal. Argumen pertama adalah input x , yang merupakan citra dua dimensi dengan a yang merepresentasikan koordinat pixel dalam citra tersebut, sedangkan argumen kedua adalah w , yang merupakan kernel atau filter yang akan digeser berdasarkan nilai t . Jika input berupa citra dua dimensi, t dapat

dianggap sebagai piksel dan menggantinya dengan i dan j . Operasi konvolusi pada input dengan lebih dari satu dimensi dapat dituliskan sebagai berikut:

$$S(i, j) = (K * I)(i, j) = \sum_m \sum_n I(i - m, j - n)K(m, n) \quad (7)$$

Persamaan di atas merupakan dasar perhitungan dalam operasi konvolusi, di mana i dan j mewakili posisi piksel dalam citra, $I(i - m, j - n)$ adalah nilai pixel dari citra input yang berada pada posisi yang tergeser berdasarkan kernel, dan $K(m, n)$ adalah nilai kernel pada posisi (m, n) . Perhitungannya bersifat komutatif dan muncul ketika K adalah kernel, I adalah input, dan kernel dapat dibalik relatif terhadap input. Sebagai alternatif, operasi konvolusi dapat diinterpretasikan sebagai perkalian matriks antara citra input dan kernel, di mana keluarannya dapat dihitung menggunakan *dot product* (Prasmatio dkk., 2020).

Sebagai contoh perhitungan konvolusi pada matriks $I = [1 \ -2 \ 3 \ 4 \ -1]$ dan $K = [1 \ -1]$ diperoleh sebagai berikut

Nilai $S(i, j)$ untuk posisi $(0,0)$ yaitu

$$S(0,0) = I(0,0)K(0,0) + I(0,1)K(0,1) = 1 \cdot 1 + (-2) \cdot (-1) = 3$$

Nilai $S(i, j)$ untuk posisi $(0,1)$ yaitu

$$S(0,1) = I(0,1)K(0,0) + I(0,2)K(0,1) = (-2) \cdot 1 + 3 \cdot (-1) = -5$$

Nilai $S(i, j)$ untuk posisi $(0,2)$ yaitu

$$S(0,1) = I(0,2)K(0,0) + I(0,3)K(0,1) = 3 \cdot 1 + 4 \cdot (-1) = -1$$

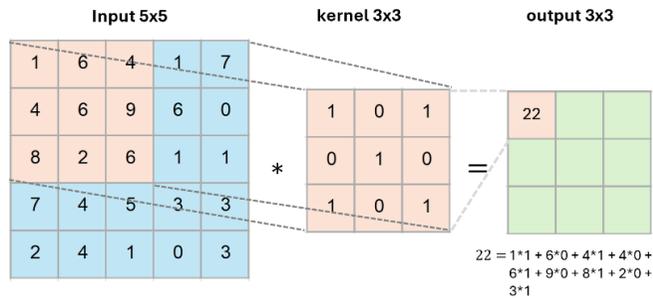
Nilai $S(i, j)$ untuk posisi $(0,3)$ yaitu

$$S(0,1) = I(0,3)K(0,0) + I(0,4)K(0,1) = 4 \cdot 1 + (-1) \cdot (-1) = 5$$

Sehingga diperoleh matriks hasil konvolusinya yaitu

$$S = [3 \ -5 \ -1 \ 5]$$

Karakteristik penting dari CNN adalah operasi yang disebut sebagai konvolusi. Operasi konvolusi adalah operasi perkalian dot antara matriks bobot dan input dari lapisan sebelumnya. Dalam konteks pengolahan citra, operasi konvolusi menerapkan sebuah kernel pada citra dengan memindahkannya secara bertahap ke semua posisi yang mungkin. Matriks input secara keseluruhan adalah citra yang akan dikonvolusi. Kernel bergerak dari sudut kiri atas ke sudut kanan bawah, memproses setiap wilayah citra dengan menggunakan aturan konvolusi yang telah ditentukan. Kernel biasanya berbentuk persegi dengan ukuran yang lebih kecil dari ukuran dimensi spasial inputnya. Kedalaman (*depth*) dari kernel selalu sama dengan kedalaman dari inputnya. Misalkan input di lapisan ke- q memiliki ukuran $L_q \times B_q \times d_q$. Disini, L_q mengacu pada tinggi, B_q mengacu pada lebar, dan d_q adalah kedalaman. Dimensi dari kernel di lapisan ke- q adalah $F_q \times F_q \times d_q$ (Aggarwal, 2018).

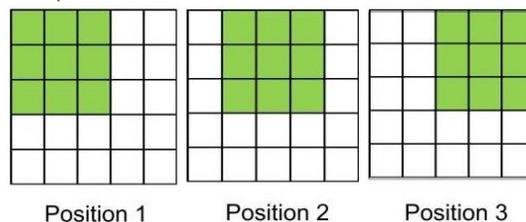


Gambar 22. Ilustrasi proses konvolusi pada input 5x5 dengan kernel 3x3

Tujuan dari melakukan konvolusi pada data citra adalah untuk mengekstraksi fitur-fitur dari citra input. Melalui konvolusi, transformasi linier dari data input dilakukan dengan memperhatikan informasi spasial yang terkandung dalam data tersebut. Bobot-bobot yang ada pada lapisan ini menggambarkan kernel konvolusi yang digunakan, sehingga kernel tersebut dapat diadaptasi melalui pelatihan pada CNN berdasarkan input yang diberikan. Pada lapisan ini, fungsi aktivasi diterapkan pada setiap neuron untuk menentukan apakah neuron tersebut akan aktif atau tidak aktif sesuai dengan aturan yang ditentukan (Suta dkk., 2019).

b) **Stride dan Padding**

Stride adalah sebuah parameter yang menentukan seberapa banyak filter konvolusi bergeser. Jika nilai stride adalah 1, maka filter konvolusi akan bergeser sebanyak 1 piksel secara horizontal dan vertikal. Semakin kecil nilai *stride*, informasi yang diperoleh dari *input* akan lebih detail, tetapi memerlukan komputasi yang lebih besar dibandingkan dengan *stride* yang lebih besar. Namun, penggunaan *stride* yang kecil tidak selalu menghasilkan performa yang baik. (Gerald & Lubis, 2020).

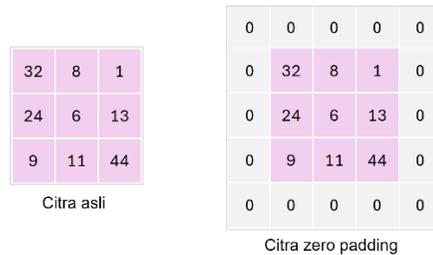


Gambar 23. Ilustrasi Teknik Stride Dengan Nilai Stride 1

Sumber: https://www.researchgate.net/figure/Gambar-54-Perhitungan-Proses-Konvolusi-Gambar-54-menunjukkan-proses-konvolusi-dengan_fig9_325578703

Operasi konvolusi yang dilakukan akan menyebabkan ukuran output berkurang, sehingga menyebabkan input untuk lapisan berikutnya menjadi lebih kecil. Masalah ini dapat diatasi dengan memanipulasi dimensi output dari peta fitur menggunakan teknik *padding*. Dalam teknik ini, di sekeliling citra akan ditambahkan piksel 0 sebanyak $(F_q - 1)/2$. Sehingga ukuran citra diperluas tanpa

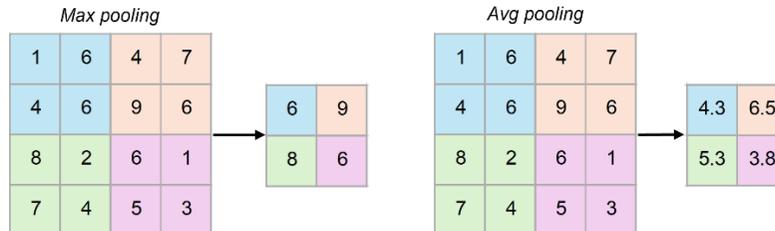
mempengaruhi informasi visual utama dalam citra tersebut. Dengan menggunakan teknik ini ukuran citra input akan menjadi berukuran $L_q + 2(F_q - 1)$ dan $B_q + 2(F_q - 1)$ (Aggarwal, 2018).



Gambar 24. Ilustrasi Teknik Padding

c) Pooling Layer

Pooling layer terdiri dari filter dan stride dengan ukuran tertentu. Fungsinya adalah untuk mengurangi dimensi *feature map*, sehingga proses komputasi menjadi lebih cepat dengan jumlah parameter yang lebih sedikit, serta untuk mengatasi masalah *overfitting*. Layer ini juga digunakan untuk mengurangi data menggunakan metode *Max Pooling* atau *Average Pooling*. Pada *Max Pooling*, nilai maksimum diambil dari area filter saat pergeseran dilakukan, sedangkan pada *Average Pooling*, nilai rata-rata diambil dari area filter tersebut. (Sheptyan dkk., 2022).



Gambar 25. Pooling layer dengan kernel 2x2 dan stride 2x2

d) Fully Connected Layer

Feature map, yang merupakan keluaran dari proses ekstraksi fitur, memiliki bentuk sebagai array multidimensi sehingga perlu dilakukan proses *reshape* untuk mengubahnya menjadi vektor. Vektor ini kemudian digunakan sebagai input pada lapisan *fully connected*. Lapisan ini terdiri dari neuron aktivasi yang saling terhubung dengan neuron di lapisan sebelumnya. Semua aktivasi dari lapisan sebelumnya diubah menjadi dimensi tunggal sebelum dihubungkan ke semua neuron pada lapisan *fully connected*. Tujuan dari lapisan ini adalah untuk mengolah data agar dapat diklasifikasikan. Neuron dalam lapisan konvolusi hanya terhubung ke area tertentu pada input, sedangkan neuron dalam lapisan *fully connected layer* terhubung secara keseluruhan dengan input. (Magdalena dkk, 2021).

Pada lapisan *connected layer*, cara kerjanya mirip dengan *Multi Layer Perceptron* (MLP) dan memiliki komponen yang serupa, yaitu beberapa lapisan input, lapisan tersembunyi, fungsi aktivasi, dan lapisan output. Fungsi dari lapisan ini adalah untuk mengklasifikasikan data agar dapat dibedakan.

Algoritma yang digunakan pada layer ini adalah *feed forward* dan *backpropagation*. Prosesnya dimulai dengan melakukan *feed-forward* terlebih dahulu, di mana setiap neuron diaktifkan menggunakan fungsi aktivasi yang dapat diturunkan. Kemudian, dilakukan perhitungan nilai kesalahan (*error*) untuk mengevaluasi seberapa akurat prediksi yang dilakukan oleh jaringan. Setelah itu, dilakukan penyesuaian bobot (*weights*) menggunakan algoritma *backpropagation*. Dengan *backpropagation*, bobot-bobot dalam jaringan akan diperbarui berdasarkan error yang terjadi, sehingga jaringan dapat belajar dan meningkatkan kualitas prediksinya (Qudsi dkk, 2019).

1.6.6 Confusion Matrix

Dalam bidang *machine learning*, terutama dalam permasalahan klasifikasi, digunakan *Confusion Matrix* atau dikenal juga sebagai matriks kesalahan. *Confusion Matrix* adalah tabel yang menggambarkan performa sebuah algoritma, terutama dalam melakukan klasifikasi. Tabel ini juga menyajikan tingkat akurasi dari algoritma tersebut. Dalam penelitian ini, *Confusion Matrix* digunakan sebagai ukuran seberapa baik model yang diuji berdasarkan beberapa parameter, seperti presisi (*precision*), *recall*, *F1-score*, akurasi, dan kurva ROC-AUC (Darojat, 2021).

$$precision = \frac{TP}{TP + FP} \quad (8)$$

Presisi mengindikasikan tingkat akurasi antara data yang diminta dengan hasil prediksi sistem. Presisi adalah rasio prediksi yang benar (positif) dibandingkan dengan total prediksi positif (benar dan salah).

$$recall = \frac{TP}{TP + FN} \quad (9)$$

Recall menggambarkan keberhasilan sistem dalam menemukan informasi kembali. *Recall* adalah rasio prediksi yang benar (positif) dibandingkan dengan prediksi benar (positif) dan salah (negatif).

$$F1_{score} = 2 \times \frac{precision \times recall}{Precision + recall} \quad (10)$$

F1-score digunakan untuk mencapai keseimbangan antara presisi yang rendah dan *recall* yang tinggi, atau sebaliknya. *F1-score* membantu dalam menghitung presisi dan *recall* secara bersamaan.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

Akurasi menggambarkan seberapa akurat sistem yang telah dirancang dalam melakukan pengklasifikasian. Akurasi adalah rasio prediksi yang benar (positif dan negatif) terhadap total data. Dengan kata lain, akurasi mengukur sejauh mana nilai prediksi mendekati nilai sebenarnya (Sheptyan dkk., 2022).

$$TPR (Sensitivity) = \frac{TP}{TP + FN} \quad (12)$$

$$FPR = \frac{FP}{FP + TN}$$

ROC AUC (Receiver Operating Characteristic - Area Under Curve) adalah metrik yang digunakan untuk mengevaluasi kinerja model klasifikasi. Metrik ini memberikan gambaran tentang kemampuan model untuk membedakan antara kelas positif dan negatif. Kurva ROC adalah grafik yang menggambarkan kinerja model klasifikasi dengan menampilkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai ambang batas (*threshold*) klasifikasi. TPR merupakan hasil dari *sensitivity* dan FPR merupakan $(1 - \text{sensitivity})$. Sehingga diperoleh nilai AUC dari luas area dibawah kurva ROC yang menggambarkan probabilitas dengan batas 0 hingga 1 dan juga memberikan gambaran tentang keseluruhan hasil pengukuran atas kesesuaian dari sistem yang digunakan.

		Nilai Prediksi	
		Positif	Negatif
Nilai Aktual	Positif	TP	FN
	Negatif	FP	TN

(a)

		Estimate		
		$C_0 \dots C_{k-1}$	C_k	$C_{k+1} \dots C_n$
annotated ground truth	$C_{k+1} \dots C_n$	TN	FP	TN
	C_k	FN	TP	FN
	$C_0 \dots C_{k-1}$	TN	FP	TN

(b)

Gambar 26. (a) Confusion Matrix pada *binaryclass*, (b) Confusion Matrix pada *multiclass*

Sumber (gambar 26 b) : https://www.researchgate.net/figure/Confusion-matrix-for-multi-class-classification-The-confusion-matrix-of-a_fig7_314116591

Keterangan:

- TP = Nilai *True Positive*
- FP = Nilai *False Positive*
- TN = Nilai *True Negative*
- FN = Nilai *False Negative*
- C_n = label kelas ke-n

Informasi yang diberikan oleh *True Positive* dan *True Negative* adalah ketika model berhasil dalam mengklasifikasikan data dengan benar. Di sisi lain, *False Positive* dan *False Negative* memberikan informasi ketika model melakukan kesalahan dalam mengklasifikasikan data (Suharni dkk, 2021).

1.6.7 Dropout

Dropout merupakan metode regularisasi jaringan syaraf dimana beberapa neuron akan dipilih secara acak dan tidak digunakan selama pelatihan. Neuron-neuron ini dapat dianggap dibuang secara acak. Artinya, kontribusi neuron yang dibuang akan diberhentikan sementara dalam jaringan, dan bobot baru juga tidak diterapkan pada neuron-neuron tersebut saat proses backpropagation dilakukan.

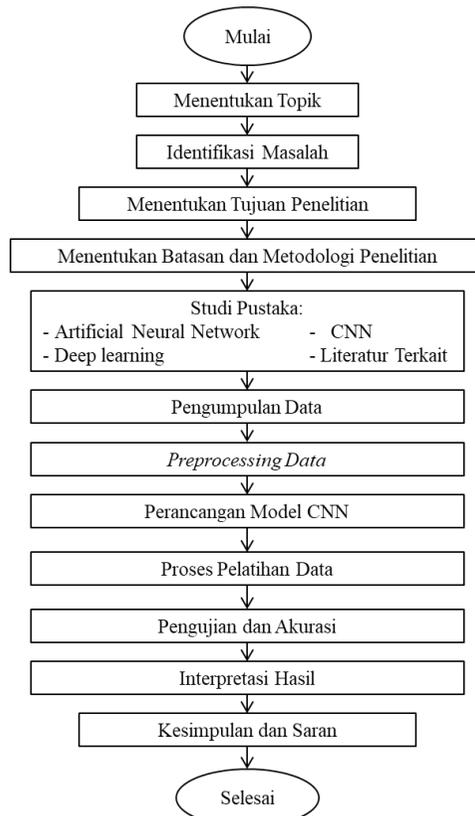
Dropout merupakan metode yang digunakan untuk mencegah terjadinya overfitting dan juga mempercepat proses learning. Metode ini melibatkan penghilangan neuron yang berupa hidden maupun layer yang visible didalam jaringan. Dengan menghilangkan suatu neuron, berarti neuron tersebut dihilangkan secara sementara dari jaringan yang ada. Proses pemilihan neuron yang akan dihapus dilakukan secara acak. Setiap neuron diberikan probabilitas antara nol dan satu, yang menentukan kemungkinan neuron tersebut dihilangkan selama pelatihan jaringan (Peryanto dkk., 2019).

BAB II

METODOLOGI PENELITIAN

2.1 Rancangan Penelitian

Adapun rancangan penelitian ini secara keseluruhan dapat dilihat pada gambar di bawah ini:



Gambar 27. Rancangan Penelitian

Penelitian ini menggunakan algoritma *Convolutional Neural Network* yang banyak digunakan untuk penelitian berupa data citra digital. Penelitian ini menggunakan perangkat keras dan perangkat lunak dengan spesifikasi seperti pada tabel 1 berikut.

Tabel 1. Spesifikasi Perangkat Keras dan Perangkat Lunak

Perangkat keras	Prosesor amd ryzen 5 5600g, Ram 16GB, GPU gx 1660s, Memory 256gb
Perangkat lunak	Windows 10 Jupyter notebook Python 3.10

Dataset yang digunakan berupa gambar citra makanan khas Sulawesi Selatan yang terdiri dari 12 jenis makanan berbeda. Tahapan metode Penelitian ini

terdiri dari pengumpulan data citra, *preprocessing data* citra, pembangunan model CNN, serta pengujian dan evaluasi model.

2.2 Alur Penelitian

Penelitian ini dilakukan dengan beberapa tahapan, yaitu:

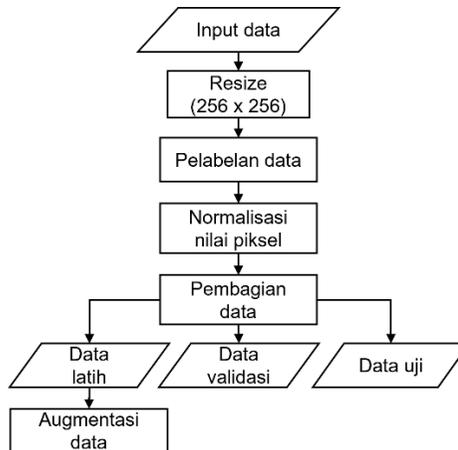
1. Pengumpulan Data

Dataset yang digunakan berupa gambar citra digital makanan khas Sulawesi Selatan. Dataset yang digunakan dalam penelitian ini didapatkan secara *open-source* dan diambil melalui *search engine Google*. Proses pengumpulan data dilakukan secara manual dengan memperhatikan kualitas dari citra digital yang akan diunduh.

Dataset yang diambil terdiri dari 12 jenis makanan khas Sulawesi Selatan yaitu yaitu coto makassar, kapurung, pallubasa, sop konro, pallu butung, pisang epe, pisang ijo, mie titi, nasu palekko, barongko, burasa, dan pallu mara. Setiap kategori makanan terdiri dari 101 gambar sehingga total gambar dalam dataset ini adalah 1.212. Dataset tersebut kemudian dikelompokkan sesuai dengan jenis makanannya lalu disimpan kedalam subfolder yang diberi nama sesuai jenis makanan tersebut. Sehingga akan terdapat 12 subfolder yang selanjutnya akan di satukan ke sebuah folder bernama 'Makanan Khas Sulsel'.

2. *Preprocessing Data*

Tahap selanjutnya setelah melakukan pengumpulan data yaitu, melakukan *preprocessing* terhadap citra di dataset. *Preprocessing data* penting dilakukan untuk mempersiapkan data yang baik sebelum dimasukkan ke model CNN. Dalam dataset seringkali terdapat berbagai masalah yang dapat menghambat kinerja model misalnya seperti ukuran citra yang beragam dan kurangnya variasi dalam citra. Permasalahan seperti itu dapat diatasi dengan melakukan tahap *preprocessing* pada dataset. Pada tahap ini, dilakukan analisis terhadap data input sebelum masuk ke tahap klasifikasi, dengan tujuan untuk menghilangkan hambatan-hambatan yang dapat mempengaruhi kinerja model. Adapun tahapan *preprocessing* yang dilakukan dalam penelitian ini yaitu; *resize* citra; pelabelan data; normalisasi data; pembagian data latih, data uji, dan data validasi; dan augmentasi data.



Gambar 28. Diagram alir preprocessing data

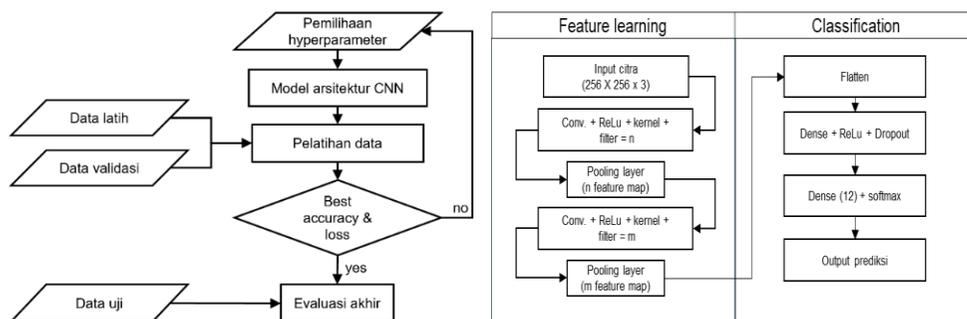
Diagram alir tersebut menunjukkan proses yang sistematis dari pengumpulan data mentah hingga siap digunakan untuk melatih model CNN dalam tugas klasifikasi gambar. Berikut adalah penjelasan setiap langkah:

- a) **Input Data:** Langkah pertama adalah memasukkan data gambar yang akan digunakan untuk melatih dan menguji model.
- b) **Resize (256 x 256):** Data gambar yang dimasukkan kemudian diubah ukurannya menjadi 256x256 piksel. Ini adalah langkah penting untuk memastikan semua gambar memiliki ukuran yang seragam sebelum diproses lebih lanjut.
- c) **Pelabelan Data:** Setelah gambar di-resize, label data yang sebelumnya berbentuk string (misalnya, "coto makassar", "kapurung", dll.) kemudian ditransformasikan ke bentuk numerik (misalnya, 0, 1, 2, dst.). Namun karena output dari metode CNN ini berupa vector probabilitas untuk setiap kelas maka label numerik tadi di transformasikan lagi ke bentuk one-hot encode (misalnya, 100000000000, 010000000000, 001000000000, dst.).
- d) **Normalisasi Nilai Piksel:** Nilai piksel dari gambar kemudian dinormalisasi, biasanya ke dalam rentang 0 hingga 1, untuk memudahkan proses pelatihan model. Normalisasi ini dapat membantu mempercepat konvergensi model selama pelatihan.
- e) **Pembagian Data:** Data yang telah diproses kemudian dibagi menjadi beberapa bagian, yaitu data latih, data validasi, dan data uji.
 - Data latih digunakan untuk melatih model.
 - Data validasi digunakan untuk mengevaluasi model selama pelatihan untuk memantau overfitting.
 - Data uji digunakan untuk menguji model setelah pelatihan selesai, guna mengukur performa sebenarnya.
- f) **Augmentasi Data (Hanya pada Data Latih):** Pada tahap ini, augmentasi data diterapkan hanya pada data latih. Augmentasi data adalah teknik untuk memperluas dataset dengan membuat variasi dari gambar yang sudah ada, seperti *rotation_range*, *zoom_range*, *widht_shift_range*, *height_shift_range*,

horizontal_flip, dan *vertical_flip* untuk meningkatkan kemampuan generalisasi model.

3. Perancangan Model Arsitektur CNN

Pada tahap ini dilakukan perancangan model arsitektur CNN yang sesuai untuk data yang akan digunakan, mencakup berbagai aspek seperti jumlah layer yang digunakan, jenis fungsi aktivasi, jumlah *batch*, jumlah *epoch*, dan sejumlah parameter lain yang diperlukan. Setelah menentukan arsitektur yang akan digunakan, kemudian dilakukan proses pelatihan data. Jika hasil dari pelatihan data belum mendapatkan akurasi dan loss yang baik, maka dilakukan kembali pemilihan hyperparameter hingga diperoleh nilai akurasi yang terbaik.



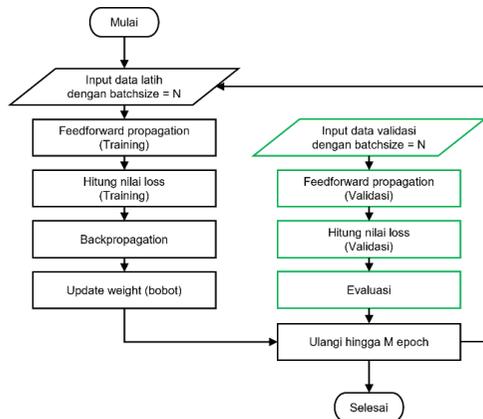
Gambar 29. Diagram alir perancangan arsitektur CNN dan contoh arsitektur CNN

Berikut adalah penjelasan dari setiap langkah dalam flowchart:

- Data Latih:** Ini adalah dataset yang digunakan untuk melatih model. Data latih berfungsi agar model dapat mempelajari fitur-fitur yang relevan dari gambar sehingga model dapat melakukan prediksi dengan baik.
- Data Validasi:** Setelah model dilatih dengan data latih, data validasi digunakan untuk mengevaluasi kinerja model selama proses pelatihan. Data ini membantu dalam menghindari overfitting dengan memastikan bahwa model tidak hanya menghafal data latih tetapi juga mampu menggeneralisasi ke data yang belum pernah dilihat sebelumnya.
- Pemilihan Hyperparameter:** Pada tahap ini, hyperparameter model CNN, seperti jumlah layer konvolusi, ukuran kernel, jumlah neuron di layer fully connected, dan lain-lain, dipilih. Pemilihan hyperparameter yang tepat sangat penting untuk mendapatkan model yang optimal.
- Model Arsitektur CNN:** Ini mengacu pada desain arsitektur model CNN yang akan digunakan untuk klasifikasi gambar. Arsitektur mencakup berbagai layer konvolusi, pooling, dan fully connected yang membentuk struktur dasar model.
- Pelatihan Data:** Pada tahap ini, model dilatih menggunakan data latih yang tersedia, dan performanya dievaluasi pada data validasi untuk mengoptimalkan parameter model.
- Best Accuracy & Loss:** Selama proses pelatihan, model terus dievaluasi berdasarkan metrik seperti akurasi dan loss. Model dengan akurasi terbaik dan loss terkecil dari hasil evaluasi di data validasi dipilih sebagai model final.

- g) Data Uji: Setelah model terbaik dipilih, model tersebut dievaluasi dengan data uji. Data uji merupakan dataset yang sama sekali belum pernah dilihat oleh model dan digunakan untuk mengukur kinerja model dalam kondisi nyata.
- h) Evaluasi Akhir: Ini adalah tahap akhir di mana performa model diukur berdasarkan data uji. Hasil evaluasi akhir ini digunakan untuk menentukan seberapa baik model dapat diharapkan bekerja di dunia nyata atau pada data yang belum pernah dilihat sebelumnya.

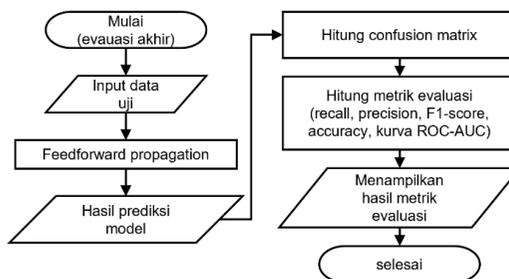
4. Pelatihan Dataset



Gambar 30. Diagram alir proses pelatihan data

Tahap pelatihan model CNN memiliki beberapa langkah penting. Pertama, bobot awal diinisialisasi pada setiap lapisan CNN. Selanjutnya, dilakukan iterasi berulang melalui dataset pelatihan menggunakan algoritma pelatihan seperti *Adam*. Selama iterasi, dilakukan *forward propagation* untuk menghasilkan prediksi kelas citra. Kemudian, nilai loss dihitung menggunakan *loss function* seperti *crossentropy loss*. Selanjutnya dilakukan *backpropagation* untuk menghitung *gradien loss* dan memperbarui bobot menggunakan *optimizer*. Pada tahap ini data validasi digunakan untuk memvalidasi model selama proses pelatihan untuk mengevaluasi kinerja model pada data yang tidak dilatih serta membantu dalam memantau overfitting. Proses ini diulangi sampai mencapai jumlah epoch dan iterasi yang ditentukan.

5. Evaluasi Akhir



Gambar 31. Diagram alir proses evaluasi akhir

Setelah model CNN dilatih, evaluasi akhir dilakukan menggunakan data uji. Evaluasi akhir melibatkan pengujian model terhadap data yang belum dilihat sebelumnya untuk mengukur performa model. Data uji akan memberikan evaluasi akhir dari kinerja model setelah pelatihan selesai yang akan memberikan estimasi kinerja model pada data yang benar-benar tidak pernah terlihat sebelumnya. Metrik evaluasi seperti akurasi, presisi, *recall*, *F1-score* serta kurva ROC-AUC digunakan untuk mengukur kinerja model dalam mengklasifikasikan citra dengan benar.