

**OPTIMASI ALGORITMA KNN DENGAN PARAMETER K DAN PSO UNTUK  
KLASIFIKASI STATUS GIZI BALITA DI KOTA SAMARINDA**

**SKRIPSI**

Diajukan Kepada Fakultas Sains dan Teknologi Universitas Muhammadiyah Kalimantan Timur untuk  
Memenuhi Sebagian Persyaratan guna Memperoleh Gelar Sarjana Komputer



**Disusun Oleh :**

**BAGUS FATHUR ROCHMAN**

**2011102441034**

**PROGRAM STUDI S1 TEKNIK INFORMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS MUHAMMADIYAH KALIMANTAN TIMUR  
JULI 2024**

**OPTIMASI ALGORITMA KNN DENGAN PARAMETER K DAN PSO UNTUK  
KLASIFIKASI STATUS GIZI BALITA DI KOTA SAMARINDA**

**SKRIPSI**

Diajukan Kepada Fakultas Sains dan Teknologi Universitas Muhammadiyah Kalimantan Timur untuk  
Memenuhi Sebagian Persyaratan guna Memperoleh Gelar Sarjana Komputer



**Disusun Oleh :**

**BAGUS FATHUR ROCHMAN**  
**2011102441034**

**PROGRAM STUDI S1 TEKNIK INFORMATIKA**  
**FAKULTAS SAINS DAN TEKNOLOGI**  
**UNIVERSITAS MUHAMMADIYAH KALIMANTAN TIMUR**  
**JULI 2024**

**LEMBAR PERSETUJUAN**

**OPTIMASI ALGORITMA KNN DENGAN PARAMETER K DAN PSO  
UNTUK KLASIFIKASI STATUS GIZI BALITA DI KOTA SAMARINDA**

**SKRIPSI**

**Diajukan oleh:**

**Bagus Fathur Rochman  
2011102441034**

**Disetujui untuk diujikan  
Pada tanggal 16 Juli 2024**

**Pembimbing**

  
**Abdul Rahim, S.Kom., M.Cs  
NIDN. 0009047901**

**Mengetahui, Koordinator Skripsi**

  
**Abdul Rahim, S.Kom., M.Cs  
NIDN. 0009047901**

LEMBAR PENGESAHAN SKRIPSI

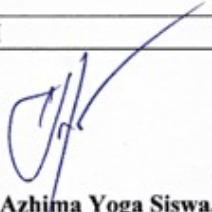
OPTIMASI ALGORITMA KNN DENGAN PARAMETER K DAN PSO  
UNTUK KLASIFIKASI STATUS GIZI BALITA DI KOTA SAMARINDA

SKRIPSI

Dipersiapkan dan disusun oleh :

**BAGUS FATHUR ROCHMAN**  
**2011102441034**

Diseminarkan dan Diujikan  
Pada tanggal 16 Juli 2024

Penguji I	Penguji II
 <b><u>Tagfirul Azhima Yoga Siswa, S.Kom, M.Kom</u></b> <b><u>NIDN. 1118038805</u></b>	 <b><u>Abdul Rahim, S.Kom., M.Cs.</u></b> <b><u>NIDN. 1115039601</u></b>

Mengetahui,



## **LEMBAR PERNYATAAN**

*Bismillahirrahmanirrahim*

Saya yang bertanda tangan di bawah ini :

Nama : Bagus Fathur Rochman  
Nim : 2011102441034  
Program Studi : SI Teknik Informatika  
Fakultas : Sains dan Teknologi

Dengan ini menyatakan bahwa :

1. Skripsi ini merupakan hasil karya asli saya yang diajukan untuk memenuhi salah satu persyaratan untuk memperoleh gelar Sarjana Komputer Strata (S1) di Universitas Muhammadiyah Kalimantan Timur..
2. Semua sumber yang saya gunakan dalam penulisan skripsi ini telah saya cantumkan sesuai dengan ketentuan yang berlaku di Universitas Muhammadiyah Kalimantan Timur.
3. Jika di kemudian hari terbukti karya ini bukan hasil karya asli saya atau merupakan hasil jiplakan dari karya orang lain, maka saya bersedia menerima sanksi yang berlaku di Universitas Muhammadiyah Kalimantan Timur.

Samarinda, 17 Juni 2024

Penulis



Bagus Fathur Rochman

2011102441034

## ABSTRAK

Masa balita merupakan fase krusial yang membutuhkan pemantauan gizi yang konstan, karena pertumbuhan dan perkembangan yang cepat memerlukan asupan gizi yang optimal. Masalah gizi pada balita dapat menghambat pertumbuhan fisik dan bahkan berpotensi fatal. Dalam menilai status gizi balita, penting untuk menggunakan metode yang efisien. Salah satu pendekatan yang bisa digunakan adalah *machine learning*, yang dapat membantu dalam penentuan status gizi balita. *K-Nearest Neighbors* (KNN) adalah salah satu algoritma yang umum digunakan dalam klasifikasi objek berdasarkan tetangga terdekat. Meskipun sederhana, penentuan nilai K yang tepat sangat penting karena dapat mempengaruhi performa KNN secara signifikan. Penelitian ini menekankan pentingnya pemilihan parameter yang tepat untuk meningkatkan akurasi model KNN dalam mengklasifikasikan status gizi balita. Hasil pengujian menunjukkan bahwa kombinasi optimal untuk KNN adalah pada K=4, dengan menggunakan bobot (*weight*) '*distance*' dan *distance metric* p=1, menghasilkan akurasi tertinggi sebesar 91,15% pada data uji. Selanjutnya, penelitian mengaplikasikan *Particle Swarm Optimization* (PSO) untuk mengoptimalkan parameter KNN, dan ditemukan bahwa kombinasi optimal adalah dengan K=6, *weight* '*distance*', dan *distance metric* p=1, mencapai *mean accuracy* sebesar 93,44% dan *test accuracy* sebesar 93,98%. PSO terbukti efektif dalam menemukan parameter terbaik yang meningkatkan generalisasi model terhadap data uji. Hasil uji dengan rasio data *training* 80% dan *testing* 20% menunjukkan akurasi terbaik sebesar 93,98%. Penggunaan PSO untuk optimasi parameter berhasil meningkatkan akurasi model sebesar 2,83% dibandingkan dengan model tanpa optimasi.

**Kata Kunci :** Status Gizi, K-Nearest Neighbor, Particle Swarm Optimization, Klasifikasi, Pemilihan Parameter

## ABSTRACT

*The toddler years are a crucial phase that requires constant nutritional monitoring, because rapid growth and development require optimal nutritional intake. Nutritional problems in toddlers can hinder physical growth and can even be fatal. In assessing the nutritional status of toddlers, it is important to use efficient methods. One approach that can be used is machine learning, which can help determine the nutritional status of toddlers. K-Nearest Neighbors (KNN) is an algorithm commonly used in object classification based on nearest neighbors. Even though it is simple, determining the correct K value is very important because it can significantly influence KNN performance. This research emphasizes the importance of choosing the right parameters to increase the accuracy of the KNN model in classifying the nutritional status of toddlers. The test results show that the optimal combination for KNN is at K=4, using the 'distance' weight and distance metric p=1, producing the highest accuracy of 91.15% on the test data. Furthermore, the research applied Particle Swarm Optimization (PSO) to optimize KNN parameters, and it was found that the optimal combination was with K=6, 'distance' weight, and distance metric p=1, achieving a mean accuracy of 93.44% and a test accuracy of 93.98%. PSO is proven to be effective in finding the best parameters that increase model generalization to test data. Test results with a training data ratio of 80% and testing 20% show the best accuracy of 93.98%. The use of PSO for parameter optimization succeeded in increasing model accuracy by 2.83% compared to the model without optimization.*

**Keywords:** *Nutritional Status, K-Nearest Neighbor, Particle Swarm Optimization, Accuracy*

## PRAKATA

Segala puji dan syukur peneliti panjatkan kepada Allah SWT Sang Tuhan Yang Maha Esa dan Maha Segalanya, atas berkah rahmah dan curahan hidayatNya sehingga penulis dapat menyelesaikan skripsi dengan judul “*Optimasi Algoritma KNN Dengan Parameter K Dan PSO Untuk Klasifikasi Status Gizi Balita Di Kota Samarinda*” ini tepat pada waktunya. Skripsi ini ditulis dalam rangka memenuhi syarat untuk mencapai gelar Sarjana Komputer pada Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Muhammadiyah Kalimantan Timur.

Penulis berupaya sebaik mungkin dalam menyelesaikan Skripsi ini yang menjadi sebuah karya yang dapat dipersembahkan. Dalam menyelesaikan studi dan penulisan skripsi ini, penulis banyak memberoleh bantuan baik pengajaran, bimbingan maupun arahan dari berbagai pihak baik secara langsung maupun tidak langsung. Untuk itu penulis menyampaikan penghargaan terbaik dan terima kasih yang tak terhingga kepada:

1. Allah SWT yang senantiasa memberikan jalan dan bantuan kepada hambanya.
2. Kedua orang tua penulis, Sri Julianto dan Yulisda saya persembahkan gelar sarjana ini kepada mereka berdua yang sudah memberikan banyak hal yang tidak bisa terbalaskan jasa budinya. Segala doa dan harapan mereka yang membuat saya dapat berdiri di titik ini dan semoga harapan mereka bisa terkabulkan dengan adanya saya di hidup mereka.
3. Saudara-saudara penulis, Fathussyfa, Zahrotus Syfa Lutfiah dan Abdulloh Yusuf Zakariya yang selalu menjadi ranjau kehidupan saya agar terus melangkah maju kedepan.
4. Bapak Ir. Sarjito sarjito, M.T., Ph.D selaku Dekan Fakultas Sains dan Teknologi Universitas Muhammadiyah Kalimantan Timur.
5. Bapak Arbansyah, S.Kom., M.TI selaku Kepala Program Studi Teknik Informatika yang senantiasa memberikan petunjuk dan nasehat kepada penulis.
6. Bapak Abdul Rahim, S.Kom., M.Cs selaku Dosen Pembimbing Skripsi yang senantiasa memberikan bantuan kepada penulis sehingga penulisan skripsi dapat selesai tepat waktu.
7. Bapak Taghfirul Azhima Yoga Siswa, S.Kom, M.Kom selaku Dosen Pembimbing Akademik yang sudah banyak membantu penulis terkait bimbingan selama masih menjadi mahasiswa.
8. Berinisial NEF terima kasih atas semangat, bantuan, dukungan, dan motivasi yang telah menjadi inspirasi bagi penulis
9. Tim RTA yang telah membantu dalam penggerjaan skripsi ini.
10. Staff Dosen dan Tenaga Kependidikan UMKT yang sudah banyak membantu penulis dalam menimba ilmu selama di bangku perkuliahan.

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL.....</b>	i
<b>LEMBAR PERSETUJUAN .....</b>	ii
<b>LEMBAR PENGESAHAN SKRIPSI.....</b>	iii
<b>LEMBAR PERNYATAAN .....</b>	iv
<b>ABSTRAK.....</b>	v
<b>ABSTRACT .....</b>	vi
<b>PRAKATA .....</b>	vii
<b>DAFTAR ISI.....</b>	viii
<b>DAFTAR TABEL.....</b>	x
<b>DAFTAR GAMBAR .....</b>	xi
<b>DAFTAR LAMPIRAN .....</b>	xii
<b>BAB I PENDAHULUAN .....</b>	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
<b>BAB II METODE PENELITIAN .....</b>	4
2.1    Objek Penelitian .....	4
2.2    Prosedur Penelitian.....	4
2.2.1    Metode Pengumpulan Data .....	5
2.2.2    Data <i>Pre-Processing</i> .....	5
2.2.3    Pembagian Data.....	7
2.2.4    Modeling .....	7
2.2.5    Evaluasi Model.....	9
<b>BAB III HASIL DAN PEMBAHASAN.....</b>	10
3.1    Hasil Penelitian.....	10

3.1.1	Data <i>Understanding</i> .....	10
3.1.2	Data <i>Pre-processing</i> .....	11
3.1.3	Pembagian Data.....	14
3.1.4	Implementasi <i>K-Nearest Neighbors</i> .....	14
3.1.5	Implementasi <i>K-Nearest Neighbors &amp; Particle Swarm Optimization</i> .....	15
3.1.6	Evaluasi Model.....	15
3.1.7	Pengujian Rasio.....	16
3.1.8	Hasil dan Validasi .....	17
3.1.9	Perbandingan Hasil.....	18
3.2	Pembahasan.....	18
<b>BAB IV PENUTUP .....</b>		19
4.1	Kesimpulan.....	19
4.2	Implikasi.....	19
<b>DAFTAR RUJUKAN.....</b>		20
<b>DAFTAR LAMPIRAN .....</b>		22
<b>RIWAYAT HIDUP .....</b>		44

## DAFTAR TABEL

	<b>Halaman</b>
<b>Tabel 2.1</b> Data status gizi balita.....	5
<b>Tabel 3.1</b> Informasi kelas berdasarkan kecamatan .....	11
<b>Tabel 3.2</b> Pengujian menggunakan KNN .....	14
<b>Tabel 3.3</b> Pengujian menggunakan KNN & PSO.....	15
<b>Tabel 3.4</b> Pengujian Rasio Data.....	16
<b>Tabel 3.5</b> Perbandingan Hasil akurasi pengujian KNN.....	18

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b> Desain Penelitian .....	4
<b>Gambar 2.2</b> Data <i>cleaning</i> .....	6
<b>Gambar 2.3</b> Data <i>transformation</i> .....	6
<b>Gambar 2.4</b> Pembagian data .....	7
<b>Gambar 2.5</b> Implementasi <i>K-Nearest Neighbors</i> .....	7
<b>Gambar 2.6</b> Fungsi <i>Optimize_Knn</i> .....	8
<b>Gambar 2.7</b> Batasan Parameter.....	9
<b>Gambar 2.8</b> Implementasi <i>Particle Swarm Optimization</i> .....	9
<b>Gambar 3.1</b> Informasi data .....	10
<b>Gambar 3.2</b> Data sebelum dibersihkan.....	11
<b>Gambar 3.3</b> Data setelah dibersihkan .....	12
<b>Gambar 3.4</b> Data sebelum ditransformasi.....	12
<b>Gambar 3.5</b> Data setelah ditransformasi.....	13
<b>Gambar 3.6</b> Korelasi data .....	13
<b>Gambar 3.7</b> <i>Confusion Matrix</i> .....	17

## DAFTAR LAMPIRAN

	Halaman
<b>Lampiran 1</b> Lembar Permohonan Data.....	22
<b>Lampiran 2</b> Lembar Fakta Integritas .....	23
<b>Lampiran 3</b> Lembar Kartu Kendali Bimbingan.....	24
<b>Lampiran 4</b> Data rekam medis status gizi balita di Kota Samarinda.....	25
<b>Lampiran 5</b> Proses data cleaning (mengubah format data dari objek menjadi numerik) .....	28
<b>Lampiran 6</b> Hasil Pengujian Parameter KNN .....	32
<b>Lampiran 7</b> Hasil Pengujian KNN&PSO .....	34
<b>Lampiran 8</b> Hasil Uji Turnitin .....	37
<b>Lampiran 9</b> Kode Pengujian KNN .....	39
<b>Lampiran 10</b> Kode pengujian KNN&PSO .....	41
<b>Lampiran 11</b> Hasil Pengujian dengan confusion matrix.....	43
<b>Lampiran 12</b> Daftar Riwayat Hidup .....	44

## BAB I

### PENDAHULUAN

#### 1.1 Latar Belakang

Balita merupakan anak yang telah menginjak usia diatas satu tahun atau lebih sering dikenal dengan pengertian anak dibawah lima tahun (Saleh et al., 2019). Balita masih bergantung penuh kepada orang tua untuk melakukan kegiatan penting seperti makan dan buang air. Masa balita merupakan periode yang sangat penting untuk dipantau terus gizinya, karena pertumbuhan dan perkembangan yang pesat membutuhkan asupan gizi yang optimal (Ramon et al., 2022). Balita yang mengalami masalah gizi akan mengalami gangguan pada tumbuh kembangnya bahkan menyebabkan kematian. Oleh karena itu untuk mendapatkan kesehatan balita yang baik, salah satunya adalah dengan cara mengkonsumsi gizi yang cukup sesuai kebutuhan pada tubuh balita, selain itu untuk mengetahui tingkat kesehatan balita dapat dilihat melalui status gizinya (Fitrianingsih et al., 2021).

Status gizi adalah sebuah ukuran keberhasilan pemberian nutrisi pada anak berdasarkan berat dan tinggi badan anak. Status gizi juga dapat diartikan sebagai keadaan kesehatan yang dihasilkan dari keseimbangan antara kebutuhan dan asupan zat gizi (Moch. Rizky Yuliansyah et al., 2022). Status gizi menentukan perkembangan dan pertumbuhan secara fisik, mental maupun emosional terhadap anak, dimana hal ini juga bergantung terhadap tingkat pengetahuan ibu dan orang tua serta lingkungan sekitar (Diah Putri Anggaraeningsih & Yuliati, 2022). Oleh karena itu peran status gizi menjadi indikator penting dalam terciptanya generasi unggul penerus bangsa di segala bidang.

Saat ini, Indonesia masih memiliki permasalahan gizi yang cukup serius, Masalah gangguan tumbuh kembang pada bayi usia di bawah dua tahun merupakan masalah yang perlu ditanggulangi dengan serius (Baiq Fitria Rahmiati, 2019). Kementerian Kesehatan mengumumkan hasil Survei Status Gizi di Indonesia (Liza Munira & Badan Kebijakan Pembangunan Kesehatan, 2023). Pada Rapat Kerja Nasional BKKBN di tahun 2022 menjelaskan bahwa balita yang mengalami *stunting* sebesar 21,6%, *wasting* sebesar 7,7%, *underweight* sebesar 17,1%, *overweight* sebesar 3,5%. Persentase angka pada *underweight* naik sebesar 0,1% dan *wasting* naik sebesar 0,6%, sedangkan *stunting* turun sebesar 2,8% dan *overweight* turun sebesar 0,3% dibandingkan dengan tahun 2021 (Liza Munira & Badan Kebijakan Pembangunan Kesehatan, 2023). Dalam menentukan status gizi balita, dibutuhkan metode untuk membantu proses penentuan status gizi agar lebih efisien (Lestari & Amalia, 2023) *Machine learning* dapat digunakan sebagai alat untuk membantu menentukan status gizi balita (Pratama & Darmawan, 2021).

Penelitian sebelumnya pada model klasifikasi status gizi balita dengan menerapkan algoritma *Naïve Bayes* menggunakan 412 data. Penelitian tersebut menghasilkan akurasi sebesar 80.60%, *recall* 80.60%, *precision* 79,66% (Setiawan et al., 2019). Penelitian lain menerapkan *K-Nearest Neighbors* dengan menggunakan 170 data pada klasifikasi status gizi balita, dengan 136 sebagai data *training* dan 34 sebagai data *testing*, Hasil pengujian pada  $k=3$ ,  $k=5$ ,  $k=7$ ,  $k=9$ ,  $k=11$ ,  $k=13$ ,  $k=15$  dan  $k=17$ , dengan hasil akurasi tertinggi diperoleh pada  $k=3$  dan  $k=5$  sebesar 73,53% (Fitrianingsih et al., 2021). Berdasarkan hasil yang didapat dari penelitian tersebut, peneliti ingin berusaha meningkatkan akurasi dengan menambahkan optimasi pada parameter  $k$  menggunakan PSO. Selain itu, peneliti juga ingin menambahkan lebih banyak data dalam penelitian ini guna mendapatkan hasil yang lebih baik.

Model klasifikasi terdapat beberapa model seperti *K-Nearest Neighbors*, *Naïve Bayes* dan *Support Vector Machine* (Argina, 2020). *K-Nearest Neighbors* (KNN) merupakan algoritma pengklasifikasian objek baru berdasarkan jumlah tetangga terdekat. Algoritma ini umum digunakan karena *relative* sederhana dan sangat mudah dipahami (Azizah et al., 2023). Penentuan nilai  $K$  pada KNN yang tidak akurat dapat mempengaruhi kinerja KNN (Widyatmoko et al., 2022). Beberapa penelitian telah menambahkan teknik optimasi untuk mencari parameter yang optimal guna meningkatkan hasil

akurasi yang diperoleh dengan algoritma KNN, dalam penelitian sebelumnya tentang klasifikasi tugas akhir mahasiswa, algoritma optimasi *Particle Swarm Optimization* (PSO) ditambahkan untuk mengoptimalkan parameter pada KNN. Pengujian yang dilakukan peneliti tersebut menghasilkan akurasi sebesar 89,86% dengan peningkatan akurasi terhadap metode KNN sebesar 17,4% (Sumarni & Rustam, 2020).

*Particle Swarm Optimization* (PSO) adalah algoritma optimasi berbasis populasi yang diperkenalkan oleh James Kennedy dan Russ Eberhart pada tahun 1995. Metode ini terinspirasi oleh pola perilaku sosial dalam kelompok burung dan ikan (Zulfia & Santi Wahyuni, 2020). PSO dikenal karena kemampuannya konvergensi yang cepat, kemudahan implementasi, dan aplikabilitasnya yang luas dalam berbagai bidang untuk menyelesaikan permasalahan optimasi (Putra, 2022). PSO memberikan pendekatan untuk mengoptimalkan bobot atribut terhadap seluruh atribut atau variabel yang digunakan, termasuk seleksi atribut dan fitur, yang menghubungkan setiap atribut satu sama lain (Arsi et al., 2021).

Berdasarkan permasalahan yang telah dijelaskan sebelumnya, penulis bermaksud untuk melakukan penelitian mengenai klasifikasi status gizi balita menggunakan algoritma *K-Nearest Neighbors* (KNN) dengan penambahan optimasi parameter K berbasis algoritma *Particle Swarm Optimization* (PSO). Penelitian ini diharapkan dapat meningkatkan akurasi model dengan menerapkan metode optimasi. Oleh karena itu, saya mengajukan penelitian dengan judul “Optimasi Algoritma KNN dengan Parameter K Dan Pso untuk Klasifikasi Status Gizi Balita di Kota Samarinda”.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang diatas, rumusan masalah yang diperoleh dari penelitian ini adalah seberapa pengaruh peningkatan akurasi dengan menggunakan *Particle Swarm Optimization* sebagai metode optimasi parameter K pada *K-Nearest Neighbors* di klasifikasi status gizi balita di Kota Samarinda?

## 1.3 Tujuan penelitian

Dari penelitian ini diharapkan bisa mencapai tujuan penelitian, yaitu mengetahui pengaruh peningkatan akurasi dengan menggunakan *Particle Swarm Optimization* sebagai metode optimasi parameter K pada *K-Nearest Neighbors* di klasifikasi status gizi balita di Kota Samarinda

## 1.4 Manfaat Penelitian

Berdasarkan tujuan penelitian yang ingin dicapai, penelitian ini diharapkan dapat membawa manfaat terkait klasifikasi status gizi balita dengan algoritma *K-Nearest Neighbors* berbasis optimasi parameter menggunakan algoritma *Particle Swarm Optimization*. Manfaat bagi (i) penulis adalah mengatasi kekurangan pada penelitian sebelumnya dan menjadi acuan bagi penelitian dan pengembangan selanjutnya. Penerapan model klasifikasi terhadap status gizi pada balita juga dapat memberikan alternatif pemahaman bagi peneliti yang lain. Manfaat selanjutnya bagi (ii) mahasiswa adalah dapat memperoleh pemahaman yang lebih baik tentang konsep status gizi balita dan teknik optimasi parameter dalam *machine learning*.

## 1.5 Batasan Masalah

Pembatasan masalah ini digunakan untuk menghindari terjadinya penyimpangan terhadap pokok masalah dalam penelitian supaya lebih terarah dan memudahkan dalam pembahasan agar tujuan penelitian bisa tercapai. Berikut batasan masalah penelitian adalah sebagai berikut: (i) Studi kasus dilakukan pengambilan data di Dinas Kesehatan Kota Samarinda pada tanggal 23 Januari 2024 dengan melampirkan surat permohonan data, (ii) Data berisi pemeriksaan status gizi dan *stunting* pada balita yang dilaksanakan di setiap Puskesmas wilayah Kota Samarinda. Data tersebut kemudian diinput dalam

server dan diserahkan kepada Dinas Kesehatan Kota Samarinda. (iii) Periode data yang digunakan dari tanggal 1 Januari 2023 sampai 31 Juli 2023, dengan total data sebanyak 9.494 data. (iv) Metode yang dipilih dalam melakukan penelitian ini adalah menggunakan metode algoritma *K-Nearest Neighbors* (KNN) sebagai tahapan dalam melakukan Analisa terhadap Klasifikasi Status Gizi pada Balita di Kota Samarinda. (v) Metode kombinasi *Particle Swarm Optimization* (PSO) ditambahkan untuk optimasi parameter K algoritma *K-Nearest Neighbors* dalam meningkatkan akurasi klasifikasi terhadap data.

## BAB II

### METODE PENELITIAN

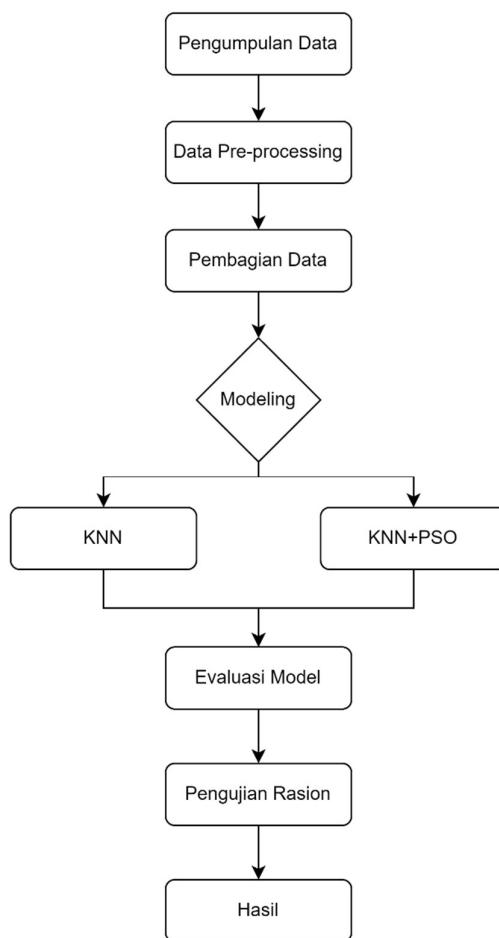
#### 2.1 Objek Penelitian

Objek penelitian ini adalah balita di Kota Samarinda yang memiliki beragam status gizi, yang terdiri dari berbagai parameter seperti tinggi, berat, lingkar kepala dan usia. Penelitian ini bertujuan untuk mengklasifikasikan status gizi balita menjadi kategori gizi buruk, gizi kurang, gizi baik atau gizi lebih berdasarkan data yang dikumpulkan.

Data yang digunakan dalam penelitian ini adalah rekam medis hasil pemeriksaan status gizi dan stunting pada balita di Puskesmas Kota Samarinda. Kota Samarinda terdiri dari 10 kecamatan, dengan total 26 puskesmas yang menyelenggarakan pemeriksaan kesehatan balita. Data yang diperoleh mencapai 15.593 data pada periode 3 Agustus 2022 hingga 31 Juli 2023. Data dikategorikan dalam beberapa klasifikasi yang mencakup enam kelas: gizi baik, gizi buruk, gizi kurang, gizi lebih, obesitas, dan makan berlebihan.

#### 2.2 Prosedur Penelitian

Penelitian ini melibatkan beberapa langkah untuk mencapai tujuan penelitian. Tahapan penelitian ini dimulai dari pengumpulan dan analisis data hingga tahap akhir. Berikut langkah prosedur penelitian:



Gambar 2.1 Desain Penelitian

### 2.2.1 Metode Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah rekam medis hasil pemeriksaan status gizi dan *stunting* pada balita di Puskesmas Kota Samarinda. Kota Samarinda terdiri dari 10 kecamatan, dengan total 26 puskesmas yang menyelenggarakan pemeriksaan kesehatan balita. Data yang diperoleh mencapai 15.593 data pada periode 3 Agustus 2022 hingga 31 Juli 2023 dan terdapat sebanyak 17 atribut dan 1 target yaitu “BB/TB”. Data target dikategorikan dalam beberapa klasifikasi yang mencakup enam kelas: gizi baik, gizi buruk, gizi kurang, gizi lebih, obesitas, dan resiko gizi lebih. Informasi atribut ditampilkan pada Tabel 2.1

**Tabel 2.1** Data status gizi balita

No	Atribut	Tipe Data	Keterangan
1	JK	<i>String</i>	Jenis Kelamin
2	Tgl Lahir	<i>String</i>	Tanggal Lahir
3	Provinsi	<i>String</i>	Provinsi
4	Kab/Kota	<i>String</i>	Kabupaten / Kota
5	Kec	<i>String</i>	Kecamatan
6	Puskesmas	<i>String</i>	Lokasi Puskesmas
7	Posyandu	<i>String</i>	Lokasi Posyandu
8	Usia saat diukur	<i>Integer</i>	Usia balita saat dilakukan pemeriksaan
9	Berat	<i>Integer</i>	Berat Badan
10	Tinggi	<i>Integer</i>	Tinggi Badan
11	BB/U	<i>Integer</i>	Berat Badan menurut Umur
12	ZS BB/U	<i>Integer</i>	Z Score Berat Badan menurut Umur
13	TB/U	<i>Integer</i>	Tinggi Badan menurut Umur (Stunting)
14	ZS TB/U	<i>Integer</i>	Z Score Tinggi Badan menurut Umur
15	BB/TB	<i>Integer</i>	Berat Badan menurut Tinggi Badan (Status Gizi)
16	ZS BB/TB	<i>Integer</i>	Z Score Berat Badan menurut Tinggi Badan
17	Naik Berat Badan	<i>Kategorikal</i>	Tinggi Badan Kenaikan berat badan dibandingkan pemeriksaan sebelumnya

### 2.2.2 Data Pre-Processing

Data dari Dinas Kesehatan Kota Samarinda harus diolah lebih dulu sebelum memasuki tahap pemodelan, yaitu dengan cara data *pre-processing*, tahap *pre-processing* mengacu pada langkah-langkah yang digunakan untuk membersihkan, mengubah dan menyiapkan data mentah sebelum digunakan untuk pemodelan (Mishra et al., 2020), sehingga menghasilkan sebuah data yang lebih relevan (A'yuniyah & Reza, 2023). Langkah-langkah pemrosesan data tersebut meliputi data *Cleaning*, tugas nya adalah menghapus data yang salah, rusak dan tidak lengkap. Jadi data *cleaning* digunakan untuk mengatasi nilai yang hilang. Pada proses ini bisa dilihat pada Gambar 2.2

```

1 missing_values = data.isna().sum()
2
3 # Menampilkan jumlah missing values untuk setiap kolom
4 print("Jumlah missing values untuk setiap kolom:")
5 print(missing_values)
6 data.dropna(inplace=True)
7 data.drop_duplicates(inplace=True)

```

**Gambar 2.2 Data cleaning**

Pada Gambar 2.2 menampilkan proses data *cleaning* menggunakan metode ‘.isna()’ untuk mengidentifikasi *missing values* dalam dataset. Setiap elemen dalam dataset yang bernilai ‘NaN’ atau ‘none’ akan dianggap sebagai *missing values*. Kemudian metode ‘.sum()’ digunakan untuk menghitung jumlah *missing* dalam setiap kolom. Selanjutnya pada metode penghapusan menggunakan ‘.dropna()’ dengan parameter ‘inplace=True’, yang menghapus semua baris yang mengandung *missing values* dan pada metode ‘.datadrop\_duplicates()’ menghapus semua baris duplikat pada dataframe

Langkah selanjutnya yaitu data *transformation*, adalah proses mengubah nilai pada data dari *string* menjadi *numerik*. Tujuannya untuk mempermudah proses pemodelan, pada tahap ini data yang akan ditransformasi adalah ‘Jenis Kelamin’, ‘BB/U’, ‘TB/U’, ‘BB/TB’, ‘Naik Berat Badan’. Seperti pada Gambar 2.3

```

1 from sklearn.preprocessing import LabelEncoder
2 le = LabelEncoder()
3
4 # Ubah Jenis Kelamin
5 data['JK'] = data['JK'].str.strip()
6 data['JK'] = le.fit_transform(data['JK'])
7
8 # Ubah BB/U
9 data['BB/U'] = le.fit_transform(data['BB/U'])
10
11 # Ubah TB/U
12 data['TB/U'] = le.fit_transform(data['TB/U'])
13
14 # Ubah BB/TB
15 data['BB/TB'] = le.fit_transform(data['BB/TB'])
16
17 # Ubah Naik Berat Badan
18 data['Naik Berat Badan'] = le.fit_transform(data['Naik Berat Badan'])

```

**Gambar 2.3 Data transformation**

Kode pada Gambar 2.3 merupakan serangkaian langkah untuk mengubah jenis data dalam beberapa kolom khusus dari dataset yang disimpan dalam variabel data. Pertama-tama, dilakukan pengolahan pada kolom 'JK' yang merupakan singkatan dari jenis kelamin. Langkah pertama dalam proses ini adalah menghilangkan spasi yang mungkin terdapat di sekitar nilai-nilai dalam kolom menggunakan metode .str.strip(). Kemudian, nilai-nilai dalam kolom tersebut diubah dari teks menjadi nilai numerik, di mana 'L' yang mewakili laki-laki diganti dengan angka 1, sedangkan 'P' yang mewakili perempuan diganti dengan angka 2. Selanjutnya, terdapat perubahan dalam kolom 'BB/U' yang merupakan kategori berat badan untuk umur. Nilai-nilai kategori teks seperti 'Berat Badan Normal', 'Kurang', 'Sangat Kurang', dan 'Risiko Lebih' diubah menjadi nilai numerik yang lebih mudah diinterpretasikan, yaitu 1, 2, 3, dan 4 secara berurutan. Langkah yang serupa dilakukan pada kolom 'TB/U', yang merupakan kategori tinggi badan untuk umur. Kategori teks seperti 'Pendek' dan 'Sangat Pendek' diubah menjadi nilai numerik 1 dan 2. Terakhir, dalam kolom 'BB/TB' yang mewakili indeks gizi berdasarkan berat badan dan tinggi badan, nilai-nilai teks seperti 'Gizi Baik', 'Gizi Buruk', 'Gizi

Kurang', 'Gizi Lebih', 'Obesitas', dan 'Risiko Gizi Lebih' diubah menjadi nilai *numerik* yang relevan, yaitu 1, 2, 3, 4, 5, dan 6 secara berurutan.

Semua perubahan ini bertujuan untuk menyederhanakan representasi data dan memungkinkan analisis lebih lanjut dengan menggunakan nilai numerik yang terstruktur.

### 2.2.3 Pembagian Data

```
1 from sklearn.model_selection import train_test_split  
2  
3 x_train, x_test, y_train, y_test = train_test_split(x,y, test_size = 0.2, random_state = 42)
```

Gambar 2.4 Pembagian data

Pada Gambar 2.4 adalah proses pembagian data dimana dataset dibagi menjadi dua subset eksklusif: data latih dan data uji. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk menguji kinerja model yang sudah dilatih. Pembagian jumlah data menjadi salah satu faktor yang menentukan hasil akurasi yang akan diperoleh (Musu et al., 2021). Proporsi pembagian adalah 80% untuk data latih dan 20% untuk data uji. Ini berarti 80% dari dataset akan digunakan untuk melatih model, sementara 20% sisanya akan digunakan untuk menguji model. Penggunaan nilai random\_state memastikan konsistensi dalam pembagian data setiap kali kode dijalankan, sehingga hasilnya dapat direproduksi dengan tepat.

### 2.2.4 Modeling

Pada penelitian ini, digunakan sebuah model klasifikasi yang menghubungkan *K-Nearest Neighbors* dengan *Particle Swarm Optimization* sebagai metode optimasi, sebelum proses pemrosesan dataset, data sebelumnya sudah di *pre-processing* terlebih dahulu agar tidak terjadi kesalahan dalam proses pemodelan. Berikut adalah rincian mengenai penggunaan model ini dalam penelitian, tahapan pertama. adalah mempersiapkan dataset status gizi balita.

Pada tahap kedua. melakukan pemodelan menggunakan KNN, dalam implementasi KNN menggunakan *scikit-learn*, langkah-langkah utama mencakup inisialisasi dan evaluasi model. KNN adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan regresi, yang bekerja dengan mengidentifikasi sejumlah k tetangga terdekat dari titik data yang ingin diklasifikasikan. Untuk proses implementasi bisa dilihat pada Gambar 2.5

```
for k in k_values:  
    for weight in weight_options:  
        for p in p_values:  
            knn = KNeighborsClassifier(n_neighbors=k, weights=weight, p=p)  
            scores = cross_val_score(knn, x_train, y_train, cv=cv_folds, scoring='accuracy')  
            mean_score = scores.mean()  
  
            knn.fit(x_train, y_train)  
            test_accuracy = knn.score(x_test, y_test)  
  
            results.append((k, weight, p, mean_score, test_accuracy))  
  
# Print hasil untuk setiap kombinasi parameter  
print(f'k: {k}, weight: {weight}, p: {p}, Cross-validated accuracy: {mean_score}, Test accuracy: {test_accuracy}')  
  
if mean_score > best_score:  
    best_score = mean_score  
    best_params = (k, weight, p)
```

Gambar 2.5 Implementasi *K-Nearest Neighbors*

Pada Gambar 2.5, dilakukan iterasi untuk mencoba setiap kombinasi parameter yang mungkin untuk model KNN. Pada setiap iterasi, sebuah model KNN baru dibangun dengan parameter-parameter yang sedang diuji. Kemudian, model tersebut dievaluasi menggunakan metode *cross-validation* dengan

menggunakan `cross_val_score`. Hasil evaluasi berupa akurasi dari setiap lipatan *cross-validation* dihitung, dan nilai rata-rata akurasi dari seluruh lipatan diambil.

Selama iterasi, nilai akurasi validasi silang yang paling baik (tertinggi) beserta parameter-parameter yang sesuai disimpan menggunakan variabel `best_score` dan `best_params`. Setelah iterasi selesai, parameter-parameter yang memberikan akurasi validasi silang tertinggi dipilih sebagai parameter optimal untuk model KNN.

Selanjutnya Tahapan ketiga. melakukan tahapan optimasi menggunakan PSO untuk mengoptimalkan parameter model KNN. PSO adalah metode optimasi berbasis populasi yang terinspirasi oleh perilaku sosial hewan, seperti kawanan burung dan digunakan untuk menemukan parameter optimal yang meminimalkan atau memaksimalkan suatu fungsi objektif. Proses implementasi bisa di lihat pada Gambar 2.6

```
def optimize_knn(params):
    k = int(params[0])
    weight = 'uniform' if params[1] < 0.5 else 'distance'
    algorithm = 'auto'
    p = int(params[2])

    knn = KNeighborsClassifier(n_neighbors=k, weights=weight, algorithm=algorithm, p=p)

    pipeline = Pipeline([
        ('scaler', StandardScaler()),
        ('knn', knn)
    ])

    # Menggunakan cross-validation untuk mendapatkan mean accuracy
    scores = cross_val_score(pipeline, x_train, y_train, cv=5, scoring='accuracy')
    penalty = 0 if k > 4 else (4 - k) * 0.01

    # Evaluasi model pada data uji
    pipeline.fit(x_train, y_train)
    test_accuracy = pipeline.score(x_test, y_test)

    # Simpan semua hasil yang dihitung
    all_results.append((k, weight, p, scores.mean(), penalty, test_accuracy))

return -scores.mean() + penalty
```

Gambar 2.6 Fungsi *Optimize\_Knn*

pada Gambar 2.6 adalah proses implementasi optimasi parameter untuk model *K-Nearest Neighbors* (KNN) menggunakan *Particle Swarm Optimization* (PSO). Fungsi ‘`optimize_knn`’ adalah fungsi tujuan yang akan dioptimalkan algoritma PSO.

Pertama, fungsi ini mengonversi nilai parameter yang diberikan oleh algoritma PSO menjadi nilai-nilai yang dapat digunakan dalam pembangunan model KNN. Parameter yang dioptimalkan meliputi jumlah tetangga (`k`), jenis bobot (uniform atau distance), dan parameter `p` untuk metrik jarak. Selanjutnya, model KNN dimasukan dalam pipeline dengan ‘`StandardScaler`’ dan dievaluasi menggunakan *cross-validation* untuk mendapatkan *mean accuracy*. Penalti diberikan jika nilai ‘`K`’ kurang dari 4 untuk menghindari *underfitting*. Hasil evaluasi disimpan dalam list ‘`all_results`’.

```
# Batasan untuk parameter  
lb = [1, 0, 1]  
ub = [50, 1, 2]
```

Gambar 2.7 Batasan Parameter

Pada Gambar 2.7, batasan nilai parameter didefinisikan sebagai ‘lb’ dan ‘ub’ yaitu jumlah tetangga terdekat ‘k’ dengan rentang 1 hingga 50, bobot (weight) yang berupa ‘uniform’ dan ‘distance’ serta metrik jarak (distance metric) dengan rentang 1 hingga 2.

```
optimal_params, optimal_score = pso(optimize_knn, lb, ub, swarmsize=20, maxiter=50)  
optimal_k = int(optimal_params[0])  
optimal_weight = 'uniform' if optimal_params[1] < 0.5 else 'distance'  
optimal_p = int(optimal_params[2])
```

Gambar 2.8 Implementasi *Particle Swarm Optimization*

Pada Gambar 2.8 menjelaskan implementasi dilakukan dengan menetapkan ukuran populasi partikel (*swarmsize*=20) dan jumlah iterasi maksimum (*maxiter*=50). Setiap partikel dalam populasi ini memiliki posisi dan kecepatan awal yang dipilih secara acak dalam ruang parameter yang telah ditentukan. Setelah proses optimasi selesai, parameter optimal yang ditemukan disimpan dalam variabel.

## 2.2.5 Evaluasi Model

Evaluasi model merupakan langkah krusial setelah pembentukan model, di tahap ini. Performa model akan diukur untuk mengevaluasi akurasi dan kualitas data pelatihan yang digunakan. Pengujian akan dilakukan dengan *Confusion Matrix* yang memberikan pemahaman kesalahan klasifikasi secara mendalam melalui kalkulasi nilai positif benar (TP), positif salah (FP), negatif benar (TN), negatif salah (FN).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

Keterangan:

TP : *True Positive*

TN : *True Negative*

FP : *False Positive*

FN : *False Negative*

Mengingat penelitian ini menggunakan berbagai metode, mulai dari algoritma klasifikasi *K-Nearest Neighbors* hingga metode optimasi *Particle Swarm Optimization*. Tahap evaluasi ini bertujuan untuk membandingkan keefektifan setiap algoritma yang digunakan.

## BAB III

### HASIL PEMBAHASAN

#### 3.1 Hasil Penelitian

Berdasarkan hasil penelitian yang telah dilakukan, untuk melihat pengaruh peningkatan akurasi dengan menggunakan Particle Swarm Optimization sebagai metode optimasi parameter K pada K-Nearest Neighbors di klasifikasi status gizi balita di Kota Samarinda.

##### 3.1.1 Data *Understanding*

Proses data *understanding* dimulai dengan pengumpulan dan analisis data rekam medis pemeriksaan status gizi balita di Kota Samarinda. Data dikumpulkan dari Dinas Kesehatan Kota Samarinda dengan melampirkan surat pengantar dari kampus. Data ini mencakup historis pemeriksaan status gizi dari tahun 2023 hingga 2023, terdiri dari 15.593 data dalam format file excel. Terdapat 17 atribut dan 1 kelas target yaitu “BB/TB”, dimana data target yang didapat tergolong *multi-classification*.

Proses yang dilakukan peneliti selanjutnya melakukan analisis data dengan menggabungkan data menjadi satu sheet agar mudah dilakukan analisa. Langkah-langkah analisis meliputi penelitian mendalam terhadap data yang digunakan, dengan fokus fitur-fitur yang relevan untuk membangun model yang akurat. Data tahun 2023 diprioritaskan untuk keperluan analisis.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 9494 entries, 0 to 9493
Data columns (total 19 columns):
 #   Column           Non-Null Count  Dtype  
 ---  --  
 0   No               9494 non-null    int64  
 1   Nama              9494 non-null    object  
 2   JK                9494 non-null    object  
 3   Kab/Kota          9494 non-null    object  
 4   Kec               9494 non-null    object  
 5   Pukesmas          9494 non-null    object  
 6   Desa/Kel          9484 non-null    object  
 7   Posyandu          9423 non-null    object  
 8   Usia Saat Ukur   9494 non-null    object  
 9   Tanggal Pengukuran 9494 non-null    object  
 10  Berat             9494 non-null    float64 
 11  Tinggi            9494 non-null    float64 
 12  BB/U              9494 non-null    object  
 13  ZS BB/U           9494 non-null    float64 
 14  TB/U              9494 non-null    object  
 15  ZS TB/U           9494 non-null    float64 
 16  BB/TB              9452 non-null    object  
 17  ZS BB/TB           9494 non-null    float64 
 18  Naik Berat Badan  9494 non-null    object  
dtypes: float64(5), int64(1), object(13)
memory usage: 1.4+ MB
```

**Gambar 3.1** Informasi data

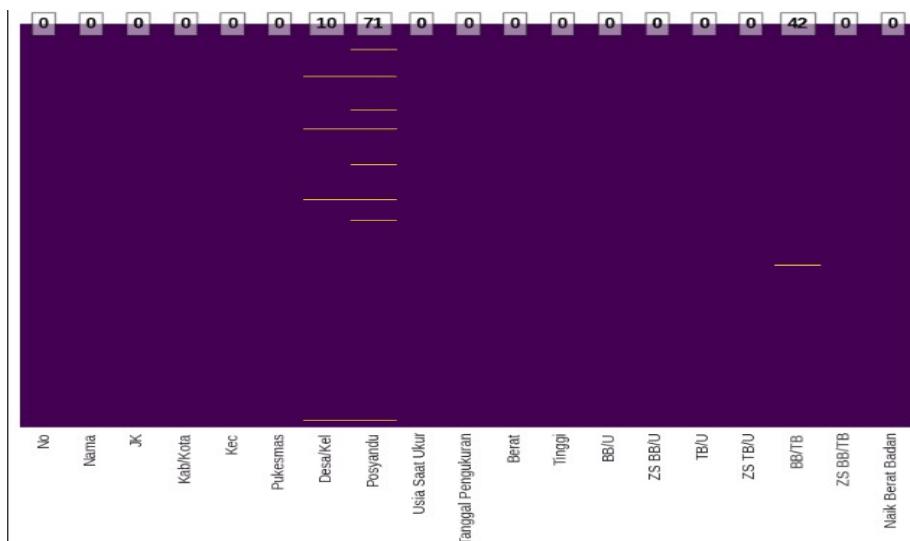
Berdasarkan Gambar 3.1, menjelaskan bahwa terdapat beberapa informasi terkait isi dan type dari setiap atribut. Dengan informasi ini, peneliti dapat melanjutkan dengan tahapan mengolah data agar siap digunakan untuk membuat model. Peneliti juga menampilkan sebaran data di setiap kecamatan yang berada di Kota Samarinda berdasarkan target / kelas status gizi dari data yang diperoleh. Distribusi kelas target ditampilkan dalam Tabel 3.1 berikut:

**Tabel 3.1** Informasi kelas berdasarkan kecamatan

No	Kecamatan	Gizi Baik	Gizi Buruk	Gizi Kurang	Gizi Lebih	Obesitas	Risiko Gizi Lebih	Blanks	Jumlah
1	LOA JANAN ILIR	1723	44	303	53	19	129	10	2281
2	PALARAN	665	8	87	18	14	55	1	848
3	SAMARINDA ILIR	270	14	104	19	9	38	4	458
4	SAMARINDA KOTA	270	11	53	6	4	17	1	362
5	SAMARINDA SEBERANG	565	15	84	19	7	52	8	750
6	SAMARINDA ULU	835	7	123	33	10	89	2	1099
7	SAMARINDA UTARA	494	4	46	12	5	30	3	594
8	SAMBUTAN	553	16	72	8	10	36	3	698
9	SUNGAI KUNJANG	1102	26	147	52	32	130	7	1496
10	SUNGAI PINANG	682	8	119	11	9	76	3	908
<b>Total</b>		<b>7159</b>	<b>153</b>	<b>1138</b>	<b>231</b>	<b>119</b>	<b>652</b>	<b>42</b>	<b>9494</b>

### 3.1.2 Data Pre-processing

Setelah mendapatkan gambaran analisis dari proses sebelumnya, peneliti melanjutkan dengan tahap *pre-processing* data. Salah satu langkah krusial dalam proses ini adalah data *cleaning*, dimana peneliti membersihkan data yang tidak diperlukan dan dapat mempengaruhi akurasi dari model yang akan dihasilkan. Langkah pertama yang dilakukan adalah pengecekan terhadap *missing value* atau nilai yang kosong dalam dataset. Data yang mengandung *missing value* dihapus agar tidak mengurangi hasil akurasi.



**Gambar 3.2** Data sebelum dibersihkan

Berdasarkan Gambar 3.2, data yang mengandung *missing value* dihapus agar tidak mengurangi hasil akurasi. atribut yang memiliki *missing value* adalah “Desa/Kel”, “Posyandu” dan “BB/TB”, selanjutnya dilakukan penghapusan dengan menggunakan perintah .dropna(inplace=True).

No	Nama	JK	Kab/Kota	Kec	Puskesmas	Desa/Kel	Posyandu	Usia Saat Ukur	Tanggal Pengukuran	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB	Naik Berat Badan
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

**Gambar 3.3** Data setelah dibersihkan

Pada Gambar 3.3 adalah hasil data yang sudah dibersihkan, data yang mengandung *missing value* sudah tidak ada. Peneliti juga melakukan penghapusan terhadap atribut yang tidak diperlukan seperti “No”, “Nama” dan “Tanggal Pengukuran”.

Setelah melakukan proses pembersihan data dari *missing value*, maka selanjutnya proses data transformasi, terdapat beberapa atribut yang akan ditransformasi yaitu, “Kec”, “Puskesmas”, “Des/Kel”, “Posyandu”, “JK”, “BB/U”, “TB/U”, “BB/TB” dan “Naik Berat Badan”.

JK	Kec	Puskesmas	Desa/Kel	Posyandu	Usia Saat Ukur	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB	Naik Berat Badan
0 P	SUNGAI KUNJANG	WONOREJO	KARANG ANYAR	HARAPAN KITA	0 Tahun - 0 Bulan - 0 Hari	3.2	45.0	Berat Badan Normal	-0.07	Pendek	-2.23	Gizi Lebih	2.77	-
1 P	SUNGAI PINANG	REMAJA	TEMINDUNG PERMAI	PULAU INDAH	4 Tahun - 0 Bulan - 16 Hari	12.8	94.0	Kurang	-2.25	Pendek	-2.09	Gizi Baik	-1.46	O
2 L	SAMBUTAN	SAMBUTAN	SAMBUTAN	AGLO NEMA	2 Tahun - 7 Bulan - 24 Hari	11.0	85.0	Berat Badan Normal	-1.81	Pendek	-2.35	Gizi Baik	-0.73	O
3 L	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	0 Tahun - 11 Bulan - 5 Hari	8.0	79.0	Berat Badan Normal	-1.52	Pendek	-2.03	Gizi Baik	-0.63	T
4 P	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	1 Tahun - 11 Bulan - 15 Hari	9.0	75.0	Berat Badan Normal	-1.96	Sangat Pendek	-3.43	Gizi Baik	-0.18	O
5 L	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	1 Tahun - 4 Bulan - 15 Hari	9.5	75.0	Berat Badan Normal	-1.01	Pendek	-2.19	Gizi Baik	0.00	O
6 L	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	2 Tahun - 9 Bulan - 20 Hari	10.4	81.3	Berat Badan Normal	-1.46	Pendek	-2.07	Gizi Baik	-0.50	O
7 P	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	2 Tahun - 10 Bulan - 29 Hari	10.5	83.7	Kurang	-2.13	Pendek	-2.82	Gizi Baik	-0.68	O
8 L	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	1 Tahun - 5 Bulan - 9 Hari	9.4	74.1	Berat Badan Normal	-1.25	Pendek	-2.81	Gizi Baik	0.11	O
9 P	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	3 Tahun - 8 Bulan - 4 Hari	11.4	91.5	Kurang	-2.32	Pendek	-2.14	Gizi Baik	-1.53	O

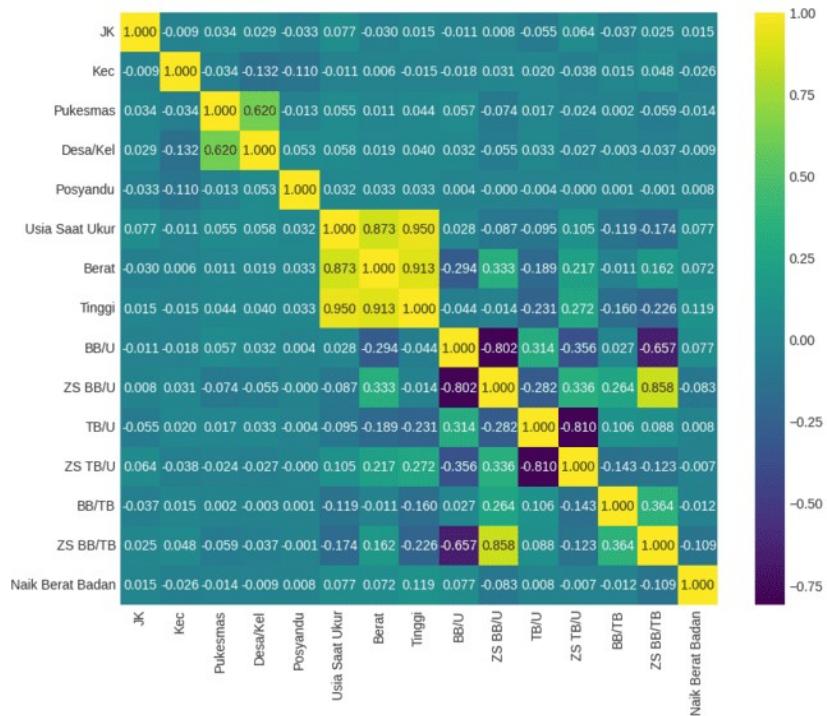
**Gambar 3.4** Data sebelum ditransformasi

JK	Kec	Pukesmas	Desa/Kel	Posyandu	Usia Saat Ukur	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB	Naik Berat Badan	
0	1	9	26	17	168	0	3.2	45.0	0	-0.07	0	-2.23	3	2.77	0
1	1	10	16	57	347	1476	12.0	94.0	1	-2.25	0	-2.09	0	-1.46	2
2	0	8	18	35	4	964	11.0	85.0	0	-1.81	0	-2.35	0	-0.73	2
3	0	8	18	35	205	335	8.0	70.0	0	-1.52	0	-2.03	0	-0.63	3
4	1	8	18	35	205	710	9.0	75.0	0	-1.96	1	-3.43	0	-0.18	2
5	0	7	3	40	5	500	9.5	75.0	0	-1.01	0	-2.19	0	0.00	2
6	0	7	3	40	5	750	10.4	81.3	0	-1.46	0	-2.07	0	-0.50	2
7	1	7	3	40	5	1059	10.5	83.7	1	-2.13	0	-2.82	0	-0.60	2
8	0	7	3	40	5	524	9.4	74.1	0	-1.25	0	-2.81	0	0.11	2
9	1	7	3	40	5	1339	11.4	91.5	1	-2.32	0	-2.14	0	-1.53	2

**Gambar 3.5** Data setelah ditransformasi

Berdasarkan Gambar 3.5, adalah proses hasil transformasi yang dilakukan pada atribut “Kec”, “Pukesmas”, “Des/Kel”, “Posyandu”, “JK”, “BB/U”, “TB/U”, “BB/TB” dan “Naik Berat Badan”, yang sebelumnya data berupa *string* diubah menjadi data berbentuk *numerik*. Hal ini bertujuan agar atribut data dapat diproses oleh algoritma KNN dan PSO untuk meningkatkan waktu dalam melakukan proses modeling data.

Selain dari atribut yang dihapus dan ditransformasi, peneliti juga melakukan perhitungan statistik dengan melihat hubungan antar atribut dengan menggunakan *correlation matrix*. Peneliti dapat melihat dan menganalisa hubungan korelasi kuat antar atribut. Dari hasil *correlation matrix*, peneliti akan menimbangkan beberapa atribut yang perlu dan tidak perlu yang digunakan untuk tahapan selanjutnya.



**Gambar 3.6** Korelasi data

Berdasarkan Gambar 3.4, menjelaskan terkait hasil dari tahapan *correlation matrix* yang menampilkan hubungan antara atribut dengan kelas target. Dari hubungan ini peneliti dapat melakukan analisis singkat terkait atribut yang kurang berpengaruh terhadap kelas target. Terdapat dua hasil

hubungan yang dihasilkan dari proses ini yaitu hubungan linear positif dan linear negatif. Semakin dekat dengan nilai 0 maka atribut tersebut memiliki korelasi rendah dengan kelas target. Beberapa atribut yang dihapus dalam tahapan ini adalah *Puskesmas* (0,002), *Desa/Kel* (-0,003), *Posyandu* (0,001), *dan Naik Berat Badan* (0,008).

### 3.1.3 Pembagian Data

Data yang sudah dilakukan proses data preprocessing selanjutnya mulai dilakukan pembagian data untuk dibagi menjadi data *training* dan data *testing*. Proses ini bertujuan untuk melakukan pengujian model terhadap data yang belum pernah dilihat sebelumnya. Rasio pembagian data yang digunakan dalam proses ini adalah sebesar 80% digunakan untuk data *training* dengan total data sebanyak 7505 dan 20% digunakan untuk data *testing* dengan total data sebanyak 1877. Pelatihan model akan diterapkan terlebih dahulu di data *training* sebelum diaplikasikan ke data *testing* maupun data baru yang ingin diuji.

### 3.1.4 Implementasi *K-Nearest Neighbors*

Algoritma *K-Nearest Neighbors* (KNN) merupakan kunci dalam pengembangan model untuk mengklasifikasikan status gizi balita. Dalam penelitian ini, KNN bekerja dengan cara mencari kelas mayoritas dari *k* tetangga terdekat dari sebuah data uji untuk menentukan label klasifikasi. Dalam mendapatkan model dengan akurasi terbaik, penting untuk melakukan pemilihan parameter yang optimal, seperti jumlah tetangga (*k*) dan metrik jarak yang digunakan

Untuk memperoleh konfigurasi parameter terbaik, berbagai kombinasi nilai *k*, *weight* (bobot), dan *distance metric* (metrik jarak) diuji. Kombinasi-kombinasi ini melibatkan nilai *k* yang berbeda (1 - 50), bobot ‘uniform’ dan ‘distance’, serta metrik jarak Manhattan (*p*=1) dan Euclidean (*p*=2). Tabel di bawah ini merangkum hasil pengujian berbagai kombinasi parameter tersebut, menunjukkan nilai akurasi yang diperoleh pada set pengujian (*testing set*). Dengan menganalisis tabel ini, kita dapat menentukan konfigurasi parameter KNN yang memberikan akurasi terbaik untuk tugas klasifikasi ini.

**Tabel 3.2** Pengujian menggunakan KNN

No	K	Weights	Distance Metric	Testing Accuracy (%)
1	1	uniform	<i>p</i> =1	89,93%
2	1	uniform	<i>p</i> =2	89,07%
3	1	distance	<i>p</i> =1	89,93%
4	1	distance	<i>p</i> =2	89,07%
5	2	uniform	<i>p</i> =1	88,59%
6	2	uniform	<i>p</i> =2	87,63%
7	2	distance	<i>p</i> =1	89,93%
8	2	distance	<i>p</i> =2	89,07%
9	3	uniform	<i>p</i> =1	90,25%
10	3	uniform	<i>p</i> =2	88,81%
11	3	distance	<i>p</i> =1	90,94%
12	3	distance	<i>p</i> =2	89,61%
13	4	uniform	<i>p</i> =1	89,61%
14	4	uniform	<i>p</i> =2	88,54%
15	4	distance	<i>p</i> =1	91,15%
16	4	distance	<i>p</i> =2	89,93%
...	...	...	...	...
198	50	uniform	<i>p</i> =2	81,67%
199	50	distance	<i>p</i> =1	84,76%
200	50	distance	<i>p</i> =2	83,16%

Dari Tabel 3.2, terlihat bahwa hasil pengujian menunjukkan beberapa pola penting. Pada nilai k yang lebih rendah, model cenderung memberikan akurasi yang lebih tinggi, misalnya pada K=3 dengan matrik jarak Manhattan ( $p=1$ ), akurasi mencapai 90,94%. Selain itu, penggunaan weight ‘distance’ menghasilkan akurasi yang lebih baik dibandingkan dengan ‘uniform’, contohnya pada K=4, ‘distance’ dengan metrik Manhattan ( $p=1$ ) mencapai akurasi 91,15%, sementara ‘uniform’ dengan metrik yang sama hanya mencapai 89,61%.

Metrik jarak (Distance Metric) juga berpengaruh signifikan terhadap akurasi. metrik Manhattan ( $p=1$ ) sering kali memberikan akurasi lebih tinggi dibandingkan Euclidean ( $p=2$ ). Contohnya pada K=4, penggunaan ‘distance’ dengan metrik Manhattan menghasilkan akurasi 91,15%, sedangkan matrik Euclidean hanya mencapai 89,93%.

### 3.1.5 Implementasi *K-Nearest Neighbors & Particle Swarm Optimization*

Pada penelitian ini, algoritma KNN diimplementasikan untuk mengklasifikasikan status gizi balita, agar dapat memperoleh model KNN dengan akurasi terbaik, peneliti menggunakan metode PSO untuk mengoptimalkan parameter KNN. Parameter yang dioptimalkan meliputi jumlah tetangga terdekat k (1 – 50), tipe *weight* dan *distance metric* ( $p$ ). dalam proses optimasi, PSO menjalankan iterasi untuk mengeksplorasi ruang parameter dan menemukan kombinasi parameter yang memberikan kinerja terbaik berdasarkan *cross-validated accuracy* pada data pelatihan.

**Tabel 3.3** Pengujian menggunakan KNN & PSO

No	K	Weight	Distance Metric	Mean Accuracy	Test Accuracy
1	4	Uniform	$p=1$	92,13%	93,71%
2	4	Distance	$P=1$	93,38%	94,19%
3	5	Uniform	$P=1$	92,47%	93,23%
4	5	Distance	$P=1$	93,10%	93,98%
5	6	Uniform	$P=1$	92,14%	92,91%
6	6	Distance	$P=1$	93,44%	93,98%
7	7	Uniform	$P=1$	92,35%	92,81%
8	7	Distance	$P=1$	93,10%	93,77%
9	8	Uniform	$P=1$	91,75%	92,75%
10	8	Distance	$P=1$	93,16%	93,93%

Pada Tabel 3.3, menunjukkan hasil optimasi dengan parameter optimal adalah k=6, *weight* ‘distance’, dan  $p=1$ . Dengan parameter ini, model KNN mencapai *mean Accuracy* sebesar 93,44%. Setelah model KNN dengan parameter optimal ini di-fit pada data pelatihan, model tersebut diuji pada data uji untuk mengukur performa sesungguhnya. Akurasi pada data *training* adalah 100%, sedangkan akurasi pada data *testing* adalah 93,98%. Nilai akurasi pengujian yang tinggi menunjukkan bahwa model KNN yang dioptimalkan dengan PSO dapat menggeneralisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

Selain itu, selama proses optimasi, hasil dari berbagai kombinasi parameter juga dicatat. Misalnya, iterasi dengan k=4, *weight* ‘distance’, dan  $p=1$  menghasilkan *mean accuracy* sebesar 93,38%, sedangkan iterasi dengan k=8, *weight* ‘distance’, dan  $p=1$  menghasilkan *mean accuracy* sebesar 93,16%. Analisis dari berbagai iterasi ini memberikan gambaran bahwa parameter k yang lebih rendah cenderung memberikan hasil yang lebih baik ketika menggunakan *weight* ‘distance’.

### 3.1.6 Evaluasi Model

Tahapan selanjutnya adalah melakukan evaluasi pada model KNN yang diterapkan untuk mengklasifikasi status gizi balita menunjukkan bahwa pemilihan parameter yang tepat sangat krusial

dalam meningkatkan akurasi model. Berdasarkan hasil pengujian berbagai kombinasi parameter KNN, ditemukan bahwa kombinasi terbaik adalah  $K=4$ , bobot 'distance', dan metrik jarak  $p=1$ , yang memberikan akurasi tertinggi pada data uji sebesar 91,15%. Tren dari hasil pengujian ini menunjukkan bahwa penggunaan bobot 'distance' secara konsisten menghasilkan performa yang lebih baik dibandingkan dengan bobot 'uniform', dan metrik jarak  $p=1$  cenderung lebih akurat daripada metrik jarak  $p=2$  untuk sebagian besar nilai  $k$  yang diuji.

Implementasi KNN dengan optimasi menggunakan Particle Swarm Optimization (PSO) menghasilkan parameter optimal dengan  $k=6$ , weight 'distance', dan  $p=1$ , yang memberikan mean accuracy 93,44% dan test accuracy 93,98%. Hasil optimasi ini menunjukkan kemampuan generalisasi yang baik terhadap data uji. Iterasi lain dengan  $k=4$  dan  $k=8$ , juga menunjukkan performa yang sangat baik, namun nilai  $k=6$  terbukti memberikan kombinasi terbaik. PSO terbukti efektif dalam mengeksplorasi ruang parameter dan menemukan kombinasi yang memberikan performa optimal.

### 3.1.7 Pengujian Rasio

Tahapan selanjutnya dengan melakukan pengujian terhadap rasio pembagian data *training* dan data *testing*. Tahap ini dilakukan untuk mengetahui rasio pembagian data terbaik terhadap model klasifikasi dan dataset yang digunakan. Pada pengujian rasio data total data yang digunakan sebanyak 9.382 data yang didapat dari hasil pengolahan data *preprocessing* yang sudah dilakukan pada tahap sebelumnya. Akurasi terbaik dari hasil pengujian sebesar 93,98%, dengan rasio pembagian data 80% : 20% dimana data *training* berjumlah 7.505 data dan data *testing* berjumlah 1.877 data. Hasil dari pengujian rasio data ditampilkan dalam Tabel 3.4, sebagai berikut:

**Tabel 3.4** Pengujian Rasio Data

Pengujian Rasio Data	Jumlah Data Training	Jumlah Data Testing	Akurasi
50% : 50%	4691	4691	92,84%
60% : 40%	5629	3753	92,94%
70% : 30%	6567	2851	92,93%
80% : 20%	7505	1877	93,98%
90% : 10%	8443	939	93,82%

### 3.1.8 Hasil dan Validasi

Hasil dan validasi merupakan tahap akhir dalam penelitian ini, yang dilakukan dengan menganalisis hasil dari *confusion matrix* untuk menentukan nilai TP (*True Positive*), FP (*False Positive*), FN (*False Negative*), dan TN (*True Negative*).

**Gambar 3.7 Confusion Matrix**

Confusion Matrix						
True Labels	0	1	2	3	4	5
	1421	0	15	0	0	9
	0	18	16	0	0	0
	27	0	187	0	0	0
	1	0	0	32	4	11
	0	0	0	3	21	0
	22	0	0	5	0	85
	0	1	2	3	4	5
	Predicted Labels					

Berdasarkan Gambar 3.5, nilai dari *confusion matrix* selanjutnya divalidasi kebenarannya untuk memastikan apakah hasil akurasi yang diperoleh sama dengan hasil perhitungan yang dilakukan menggunakan tabel *confusion matrix*. Perhitungan akurasi dilakukan dengan menjumlahkan semua prediksi yang benar (*True Positive*) dan membagi dengan total data. Perhitungan akurasi dari hasil *confusion matrix* adalah sebagai berikut :

$$\begin{aligned} \text{Accuracy} &= \frac{\text{Correct Prediction}}{\text{Total Instance}} \\ \text{Accuracy} &= \frac{(1421 + 18 + 187 + 32 + 21 + 85)}{1877} \\ \text{Accuracy} &= \frac{1.764}{1877} \\ \text{Accuracy} &= 0.9398 = 93.98\% \end{aligned}$$

Hasil perhitungan akurasi kemudian divalidasi kebenarannya terhadap akurasi terhadap model klasifikasi. Hal ini untuk memastikan bahwa akurasi memang sudah sesuai perhitungannya dan tidak ada manipulasi data didalamnya, sehingga penelitian ini dapat dianggap.

### 3.1.9 Perbandingan Hasil

Dalam melakukan perbandingan antara dua model *K-Nearest Neighbors*, di mana satu menggunakan optimasi *Particle Swarm Optimization* (PSO) dan satunya lagi tidak, fokus pada perbedaan akurasi memberikan pandangan yang penting dalam mengevaluasi efektivitas optimasi dalam meningkatkan kinerja model. Sehingga menghasilkan akurasi yang lebih akurat dan efisien

**Tabel 3.5** Perbandingan Hasil akurasi pengujian KNN

K	KNN	KNN+PSO	Status
4	91,15%	94,19%	Naik
5	90,88%	93,98%	Naik
6	90,88%	93,98%	Naik
7	90,72%	93,77%	Naik
8	90,41%	93,93%	Naik
9	90,03%	93,66%	Naik
10	89,98%	94,14%	Naik

Pada Tabel 3.5 menampilkan hasil perbandingan akurasi pengujian antara metode *K-Nearest Neighbors* (KNN) dan dengan optimasi *Particle Swarm Optimization* (PSO), terlihat bahwa metode dengan optimasi cenderung memberikan hasil akurasi yang lebih tinggi.

### 3.2 Pembahasan

Penelitian ini menunjukkan bahwa optimasi algoritma *K-Nearest Neighbors* (KNN) menggunakan *Particle Swarm Optimization* (PSO) menghasilkan peningkatan akurasi yang signifikan dalam klasifikasi status gizi balita di Kota Samarinda. Dengan parameter  $K = 6$ , *weight ‘distance’*, dan metrik jarak  $P = 1$ , diperoleh akurasi sebesar 93,98%, ini jauh lebih tinggi dibandingkan dengan penelitian yang dilakukan oleh Setiawan et al (2019) yang menggunakan *Naïve Bayes* dengan 412 data, yang mencapai akurasi 80,60%. Selain itu penelitian lain oleh Fitrianingsih et al (2021) yang menggunakan KNN tanpa optimasi hanya mencapai akurasi sebesar 73,53% pada  $K=3$  dan  $K=5$ .

Perbandingan ini menunjukkan bahwa optimasi KNN dengan PSO secara signifikan meningkatkan performa model dalam klasifikasi status gizi balita dibandingkan dengan metode sebelumnya. Hasil ini menunjukkan efektivitas PSO dalam menemukan konfigurasi parameter yang optimal dan memberikan akurasi yang lebih tinggi.

## **BAB IV**

### **PENUTUP**

#### **4.1 Kesimpulan**

Penelitian ini membuktikan bahwa *Particle Swarm Optimization* (PSO) efektif dalam mengeksplorasi ruang parameter dan menemukan kombinasi yang memberikan performa optimal untuk *K-Nearest Neighbors* (KNN). Dengan penerapan PSO, akurasi model KNN meningkat dari 91,15% menjadi 93,98%, menunjukkan peningkatan signifikan sebesar 2,83% dalam klasifikasi status gizi balita di Kota Samarinda.

#### **4.2 Implikasi**

Hasil pelaksanaan penelitian yang sudah dilakukan, peneliti menemukan beberapa kekurangan yang masih dialami saat melaksanakan penelitian, sehingga saran pengembangan diberikan kepada peneliti selanjutnya untuk menyempurnakan hasil dari penelitian menjadi lebih baik. Selain *K-Nearest Neighbors* (KNN), beberapa algoritma yang dapat dipertimbangkan digunakan adalah *Naïve Bayes*, *Support Vector Machine* (SVM).

## DAFTAR RUJUKAN

- A'yuniyah, Q. A., & Reza, M. (2023). Penerapan Algoritma K-Nearest Neighbor Untuk Klasifikasi Jurusan Siswa Di Sma Negeri 15 Pekanbaru. *Indonesian Journal of Informatic Research and Software Engineering (IJIRSE)*, 3(1), 39–45. <https://doi.org/10.57152/ijirse.v3i1.484>
- Argina, A. M. (2020). Penerapan Metode Klasifikasi K-Nearest Neigbor pada Dataset Penderita Penyakit Diabetes. *Indonesian Journal of Data and Science*, 1(2), 29–33. <https://doi.org/10.33096/ijodas.v1i2.11>
- Arsi, P., Wahyudi, R., & Waluyo, R. (2021). Optimasi SVM Berbasis PSO pada Analisis Sentimen Wacana Pindah Ibu Kota Indonesia. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 231–237. <https://doi.org/10.29207/resti.v5i2.2698>
- Azizah, N., Riyad Firdaus, M., Suyaningsih, R., & Indrayatna, F. (2023). Penerapan Algoritma Klasifikasi K-Nearest Neighbor pada Penyakit Diabetes. *Prosiding Seminar Nasional Statistika Aktuaria*, 2(1), 119–126. <http://prosiding.snsa.statistics.unpad.ac.id>
- Baiq Fitria Rahmiati. (2019). Upaya Perbaikan Status Gizi Balita Melalui Sosialisasi Menu Mp-Asi Sesuai Usia Balita Di Kecamatan Gunungsari. *JPMB : Jurnal Pemberdayaan Masyarakat Berkarakter*, 2(2). <https://doi.org/10.36765/jpmb.v2i2.8>
- Diah Putri Anggaraeningsih, N. L. M., & Yuliati, H. (2022). Hubungan Status Gizi Balita Dan Perkembangan Anak Balita Di Kelurahan Liliba Kecamatan Oebobo. *Jurnal Health Sains*, 3(7), 830–836. <https://doi.org/10.46799/jhs.v3i7.545>
- Fitrianingsih, D., Bettiza, M., & Uperiati, A. (2021). Klasifikasi Status Gizi Pada Pertumbuhan Balita Menggunakan K-Nearest Neighbor (Knn). *Student Online Journal*, 2(1), 106–111.
- Lestari, S., & Amalia, R. A. (2023). Penerapan Algoritma C. 45 Pada Klasifikasi Status Gizi Balita di Posyandu Desa Sukalilah Cibatu Kabupaten Garut Jawa Barat. *Jurnal Sains Dan Teknologi*, 5(1), 177–182.
- Liza Munira, S., & Badan Kebijakan Pembangunan Kesehatan, K. (2023). *Disampaikan pada Sosialisasi Kebijakan Intervensi Stunting Jakarta, 3 Februari 2023 Hasil Survei Status Gizi Indonesia (SSGI) 2022*.
- Mishra, P., Biancolillo, A., Roger, J. M., Marini, F., & Rutledge, D. N. (2020). New data preprocessing trends based on ensemble of multiple preprocessing techniques. *TrAC - Trends in Analytical Chemistry*, 132, 116045. <https://doi.org/10.1016/j.trac.2020.116045>
- Moch. Rizky Yuliansyah, B, M., & Franz, A. (2022). Perbandingan Metode K-Nearest Neighbors dan Naïve Bayes Classifier Pada Klasifikasi Status Gizi Balita di Puskesmas Muara Jawa Kota Samarinda. *Adopsi Teknologi Dan Sistem Informasi (ATASI)*, 1(1), 08–20. <https://doi.org/10.30872/atasi.v1i1.25>
- Musu, W., Ibrahim, A., & Heriadi. (2021). Pengaruh Komposisi Data Training dan Testing terhadap Akurasi Algoritma C4.5. *Prosiding Seminar Ilmiah Sistem Informasi Dan Teknologi Informasi*, X(1), 186–195.
- Pratama, E. R., & Darmawan, J. B. B. (2021). Klasifikasi Status Gizi Balita Menggunakan Jaringan Syaraf. *Riset Dan Teknologi Terapan (RITEKTRA)*, 1–10. <https://journal.unpar.ac.id/index.php/ritektra/article/view/4899>
- Putra, I. L. (2022). Implementasi Algoritma Particle Swarm Optimization(Pso) Dan K-Nearest Neighbor(K-Nn) Dalam Memprediksi Keberhasilan Anak Smk Mendapatkan Kerja. *Technologia : Jurnal Ilmiah*, 13(4), 339. <https://doi.org/10.31602/tji.v13i4.8167>
- Ramon, E., Nazir, A., Novriyanto, N., Yusra, Y., & Oktavia, L. (2022). Klasifikasi Status Gizi Bayi Posyandu Kecamatan Bangun Purba Menggunakan Algoritma Support Vector Machine (Svm).

*Jurnal Sistem Informasi Dan Informatika (Simika)*, 5(2), 143–150.  
<https://doi.org/10.47080/simika.v5i2.2185>

Saleh, H., Faisal, M., & Musa, R. I. (2019). Klasifikasi Status Gizi Balita Menggunakan Metode K-Nearest Neighbor. *Simtek : Jurnal Sistem Informasi Dan Teknik Komputer*, 4(2), 120–126. <https://doi.org/10.51876/simtek.v4i2.60>

Setiawan, A., Santoso, L. W., & Adipranata, R. (2019). Penerapan Algoritma Particle Swarm Optimization ( PSO ) untuk Optimisasi Pembangunan Negara dalam Turn Based Strategy Game. *Jurnal Infra*, 7(1), 249–255.

Sumarni, S., & Rustam, S. (2020). Klasifikasi Topik Tugas Akhir Mahasiswa menggunakan Algoritma Particle Swarm Optimization dan K-Nearest Neighbor. *ILKOM Jurnal Ilmiah*, 12(2), 168–175. <https://doi.org/10.33096/ilkom.v12i2.604.168-175>

Widyatmoko, K., Sugiarto, E., Muslih, M., & Budiman, F. (2022). Optimasi Metode K-Nearest Neighbor Dengan Particle Swarm Optimization Untuk Pengenalan Citra Batik Dengan Ragam Hias Geometris. *Jurnal Informatika Upgris*, 8(1). <https://doi.org/10.26877/jiu.v8i1.11705>

Zulfia, H., & Santi Wahyuni, F. (2020). Optimasi Particel Swarm Optimazation (PSO) Untuk Penentuan Base Tranciver Sistem (BTS). In *Jurnal MNEMONIC* (Vol. 3, Issue 1).

## DAFTAR LAMPIRAN

### Lampiran 1 Lembar Permohonan Data



Telp. 0541-748511 Fax. 0541-766832  
Website <http://informatika.umkt.ac.id>  
email: [informatika@umkt.ac.id](mailto:informatika@umkt.ac.id)

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِيْمِ

Nomor : 003-002/FST.1/D.3/C/2024

Lampiran : -

Perihal : **Permohonan Pengambilan Data**

Kepada Yth.

**Kepala Dinas Kesehatan Kota Samarinda**

di -

**Tempat**

*Assalamu 'alaikum Warrahmatullahi Wabarrakatuh*

Puji Syukur kepada Allah Subhanahu wa ta'ala yang senantiasa melimpahkan Rahmat-Nya kepada kita sekalian. Aamiin.

Sehubungan untuk memenuhi Tugas Akhir/Skripsi Tahun Akademik 2023/2024, maka dengan ini kami bermaksud untuk melakukan pengambilan data di Dinas Kesehatan Kota Samarinda. Adapun data yang diminta yaitu data Status Gizi pada Balita Kota Samarinda tahun 2022/2023, dengan nama mahasiswa sebagai berikut:

No	Nama	NIM
1	Melisa Nur Aini	2011102441122
2	Rita Yulfani	2011102441210
3	Hery Kurniawan	2011102441015
4	Bagus Fathur Rochman	2011102441034
5	Muhammad Wahyu Tirta	2011102441014

Demikian surat permohonan ini dibuat. Atas perhatiannya dan kerjasamanya kami mengucapkan terima kasih.

*Wassalamu 'alaikum Warrahmatullahi Wabarrakatuh*

Samarinda, 11 Rajab 1445 H  
23 Januari 2024 M



Ketua Program Studi S1 Teknik Informatika

*Burbansyah, S.Kom., M.TI*  
IDN. 1118019203

Kampus 1 : Jl. Ir. H. Juanda, No.15, Samarinda  
Kampus 2 : Jl. Pelita, Pesona Mahakam, Samarinda

Lampiran 2 Lembar Fakta Integritas

**FAKTA INTEGRITAS  
(PERNYATAAN TANGGUNG JAWAB MUTLAK)**

Yang bertanda tangan dibawah ini :

No	Nama	NIM	No. Telp	TTD
1	Melisa Nur Aini	2011102441122	+62 821-4855-6023	
2	Rita Yulfani	2011102441210	+62 823-5001-2295	
3	Hery Kurniawan	2011102441015	+62 812-3384-8740	
4	Bagus Fathur Rochman	2011102441034	+62 851-7411-7638	
5	Muhamad Wahyu Tirta	2011102441014	+62 858-0680-2134	

Menyatakan :

1. Bersedia mematuhi segala ketentuan terkait permohonan data yang diberlakukan di Dinas Kesehatan Kota Samarinda, Kalimantan Timur.
2. Data yang diberikan akan digunakan secara eksklusif untuk keperluan penelitian Skripsi. Tujuan penggunaan data ini terbatas pada topik permasalahan penelitian yang akan dilakukan nantinya.
3. Saya berkomitmen untuk menjaga kerahasiaan dan keamanan data yang diberikan. Data ini tidak akan diungkapkan kepada pihak ketiga tanpa izin resmi. Saya akan bertanggung jawab untuk menjaga privasi serta integritas informasi data yang diberikan.
4. Saya akan bertindak secara etis dalam semua aspek penelitian ini. Menghindari segala bentuk penyalahgunaan data dan berusaha sebaik mungkin untuk meminimalkan dampak negatif terhadap terhadap masyarakat.

Demikian Fakta Integritas atau Pernyataan Tanggung Jawab Mutlak ini saya buat dengan sebenarnya, dalam keadaan sehat jasmani/rohani dan tanpa ada paksaan dari pihak manapun.

Samarinda, 30 Januari 2024

Mengetahui,  
Pj. GiziKIA

Hormat Kami,  
Ketua Tim

Dr. Rudy Agus Riyanto  
NIP. 19770730 200502 1 003



Bagus Fathur Rochman  
2011102441034

**Lampiran 3** Lembar Kartu Kendali Bimbingan

**KARTU KENDALI BIMBINGAN LAPORAN KARYA ILMIAH**

Nama Mahasiswa : Bagus Fathur Rochman  
NIM : 2011102441034  
Nama Dosen Pembimbing : Abdul Rahim, S.Kom., M.Cs  
Judul Penelitian : OPTIMASI ALGORITMA KNN DENGAN PARAMETER K DAN PSO UNTUK KLASIFIKASI STATUS GIZI BALITA DI KOTA SAMARINDA

No	Tanggal	Uraian Pembimbing	Paraf Dosen
1	17 Jan, 2024	Diskusi permasalahan data	<i>Ar</i>
2	23 Jan, 2024	Diskusi permasalahan data dan penambahan anggota RTA	<i>Ar</i>
3	29 Jan, 2024	Diskusi informasi data yang didapatkan	<i>Ar</i>
4	7 Feb, 2024	Konsultasi terkait judul skripsi dan metode yang akan digunakan	<i>Ar</i>
5	20 Feb, 2024	Konsultasi terkait Outline judul skripsi	<i>Ar</i>
6	7 Mar, 2024	Informasi pemberian arahan dari dosen pembimbing terkait outline dan pengumpulan RTA	<i>Ar</i>
7	21 Mar, 2024	Bimbingan terkait pengumpulan proposal skripsi di website Simpel	<i>Ar</i>
8	26 Apr, 2024	Konsultasi terkait implementasi metode yang digunakan dalam pengujian skripsi	<i>Ar</i>
9	17 Mei, 2024	Konsultasi Bab III untuk alur penelitian	<i>Ar</i>
10	29 Mei, 2024	Pengarahan alur penelitian	<i>Ar</i>
11	30 Mei, 2024	Konsultasi Bab III dengan catatan menjelaskan secara mendetail tentang tahap penelitian pada bab 2	<i>Ar</i>
12	4 Jun, 2024	Konsultasi Bab III dan IV serta penulisan jurnal	<i>Ar</i>

Dosen Pembimbing

Abdul Rahim, S.Kom., M.Cs

NIDN. 0009047901



Albahayah, S.Kom., M.TI

NIDN. 1118019203

**Lampiran 4 Data rekam medis status gizi balita di Kota Samarinda**

No	Nama	JK	Kab/Kota	Kec	Pukesmas	Desa/Kel	Posyandu	Usia Saat Ukur	Tanggal Pengukuran	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB	Naik Berat Badan
1	JANUARSIH GORIA ELIORA	P	SAMARINDA	SUNGAI KUNJANG	WONOREJO	KARANG ANYAR	HARAPAN KITA	0 Tahun - 0 Bulan - 0 Hari	2023-01-01	3.2	45	Berat Badan Normal	-0.07	Pendek	-2.23	Gizi Lebih	2.77	-
2	SITI AISYAH	P	SAMARINDA	SUNGAI PINANG	REMAJA	TEMINDUNG PERMAI	PULAU INDAH	4 Tahun - 0 Bulan - 16 Hari	2023-01-02	12	94	Kurang	-2.25	Pendek	-2.09	Gizi Baik	-1.46	O
3	RAYYAN RAMADHAN	L	SAMARINDA	SAMBUTAN	SAMBUTAN	SAMBUTAN	AGLO NEMA	2 Tahun - 7 Bulan - 24 Hari	2023-01-02	11	85	Berat Badan Normal	-1.81	Pendek	-2.35	Gizi Baik	-0.73	O
4	MUHAMAD RAZZAN ARKANZA	L	SAMARINDA	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	0 Tahun - 11 Bulan - 5 Hari	2023-01-02	8	70	Berat Badan Normal	-1.52	Pendek	-2.03	Gizi Baik	-0.63	T
5	HAZZIMA RENNA QANITA ZIONATAN PARNINGOTA N S.	P	SAMARINDA	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	1 Tahun - 11 Bulan - 15 Hari	2023-01-02	9	75	Berat Badan Normal	-1.96	Sangat Pendek	-3.43	Gizi Baik	-0.18	O
6		L	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	1 Tahun - 4 Bulan - 15 Hari	2023-01-02	9.5	75	Berat Badan Normal	-1.01	Pendek	-2.19	Gizi Baik	0	O
7	M.DIAN PRATAMA	L	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	2 Tahun - 0 Bulan - 20 Hari	2023-01-02	10.4	81.3	Berat Badan Normal	-1.46	Pendek	-2.07	Gizi Baik	-0.5	O
8	FAYOLA ADISTIA J.	P	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	2 Tahun - 10 Bulan - 29 Hari	2023-01-02	10.5	83.7	Kurang	-2.13	Pendek	-2.82	Gizi Baik	-0.6	O
9	JUNAEDI EVRA.S	L	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	1 Tahun - 5 Bulan - 9 Hari	2023-01-02	9.4	74.1	Berat Badan Normal	-1.25	Pendek	-2.81	Gizi Baik	0.11	O
10	IVANA CALLRA PUTRI	P	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	3 Tahun - 8 Bulan - 4 Hari	2023-01-02	11.4	91.5	Kurang	-2.32	Pendek	-2.14	Gizi Baik	-1.53	O
11	IBRAHIM AL KAHFI	L	SAMARINDA	SAMARINDA UTARA	BENGKURING	SEMPAJA UTARA	AGLONEMA TERPADU	2 Tahun - 11 Bulan - 25 Hari	2023-01-02	10.3	84	Kurang	-2.75	Sangat Pendek	-3.24	Gizi Baik	-1.29	O
12	FATIMAH A ZAHRA	P	SAMARINDA	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	1 Tahun - 4 Bulan - 12 Hari	2023-01-02	8	72	Berat Badan Normal	-1.78	Pendek	-2.25	Gizi Baik	-0.95	O
13	SALMAN AL ILHAM	L	SAMARINDA	SAMBUTAN	SAMBUTAN	SAMBUTAN	KEMUNING	4 Tahun - 2 Bulan - 13 Hari	2023-01-02	13	96	Berat Badan Normal	-2	Pendek	-2.03	Gizi Baik	-1.2	O
14	LYANA BUKTI JASMINE	P	SAMARINDA	SAMARINDA ULU	JUANDA	GUNUNG KELUA	PERDANA 45	0 Tahun - 4 Bulan - 29 Hari	2023-01-02	8.6	65	Berat Badan Normal	0.41	Pendek	-2.04	Gizi Lebih	2.05	O

No	Nama	JK	Kab/Kota	Kec	Pukesmas	Desa/Kel	Posyandu	Usia Saat Ukur	Tanggal Pengukuran	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB	Naik Berat Badan
15	RAISA MAULIDA	P	SAMARINDA DA	SAMARINDA ULU	JUANDA	AIR HITAM	KUNJUNGAN PUSKESMAS	3 Tahun - 0 Bulan - 22 Hari	2023-01-02	7	75	Sangat Kurang	-5.23	Sangat Pendek	-5.35	Gizi Buruk	-3.29	O
16	YOGA ALFARIZKI	L	SAMARINDA DA	SAMBUTAN	MAKROMAN	sindang sari	KUTILANG 3	1 Tahun - 7 Bulan - 19 Hari	2023-01-02	9.3	78.1	Berat Badan Normal	-1.72	Pendek	-2.06	Gizi Baik	-1.01	N
17	ADERA ANINDRA P	P	SAMARINDA DA	PALARAN	PALARAN	HANDIL BAKTI	Harapan Sehat	1 Tahun - 3 Bulan - 18 Hari	2023-01-02	6.3	70	Sangat Kurang	-3.64	Pendek	-2.95	Gizi Kurang	-3	T
18	NUR HIYATUL AULIYA	P	SAMARINDA DA	PALARAN	PALARAN	HANDIL BAKTI	Harapan Sehat	1 Tahun - 1 Bulan - 14 Hari	2023-01-02	7.7	70	Berat Badan Normal	-1.54	Pendek	-2.17	Gizi Baik	-0.65	O
19	ABRISYAM	L	SAMARINDA DA	LOA JANAN ILIR	TRAUMA CENTER	TANI AMAN	PELANGI	2 Tahun - 8 Bulan - 3 Hari	2023-01-02	9.7	85.5	Kurang	-2.91	Pendek	-2.46	Gizi Kurang	-2.29	N
20	ADIBA FAIZAH	P	SAMARINDA DA	LOA JANAN ILIR	TRAUMA CENTER	TANI AMAN	PELANGI	2 Tahun - 5 Bulan - 3 Hari	2023-01-02	8.4	80.5	Sangat Kurang	-3.35	Pendek	-2.92	Gizi Kurang	-2.25	N
21	AINUN HUSNA	P	SAMARINDA DA	LOA JANAN ILIR	TRAUMA CENTER	TANI AMAN	PELANGI	2 Tahun - 3 Bulan - 18 Hari	2023-01-02	7.9	79.6	Sangat Kurang	-3.65	Pendek	-2.69	Gizi Kurang	-2.94	N
22	RATU KHUSNUL AZAHRA	P	SAMARINDA DA	LOA JANAN ILIR	TRAUMA CENTER	TANI AMAN	PELANGI	4 Tahun - 5 Bulan - 23 Hari	2023-01-02	11.1	96.5	Sangat Kurang	-3.23	Pendek	-2.11	Gizi Kurang	-2.93	N
23	M. GHIFARI MAHERZA	L	SAMARINDA DA	PALARAN	PALARAN	HANDIL BAKTI	Harapan Sehat	1 Tahun - 7 Bulan - 19 Hari	2023-01-02	8.7	78	Kurang	-2.31	Pendek	-2.1	Gizi Baik	-1.82	O
24	QUEENSHA AURA X	P	SAMARINDA DA	PALARAN	PALARAN	HANDIL BAKTI	Harapan Sehat	1 Tahun - 4 Bulan - 13 Hari	2023-01-02	6.9	70	Sangat Kurang	-3.07	Sangat Pendek	-3.22	Gizi Baik	-1.91	N
25	MUHAMMAD IRHAM PUTRA	L	SAMARINDA DA	SAMARINDA ULU	JUANDA	AIR HITAM	FAMILI PANDA	1 Tahun - 1 Bulan - 10 Hari	2023-01-02	7.1	70.5	Sangat Kurang	-3.05	Pendek	-2.79	Gizi Kurang	-2.31	N
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	
9490	Shanum Alesha S	P	SAMARINDA DA	SAMARINDA KOTA	SAMARINDA KOTA	BUGIS	BUGIS	3 Tahun - 0 Bulan - 28 Hari	2023-07-31	10.9	87.4	Kurang	-2.02	Pendek	-2.15	Gizi Baik	-1.1	T
9491	MUHAMMAD RAFASSYA HAFIZ	L	SAMARINDA DA	SAMARINDA SEBERANG	MANGKUPAL AS	MESJID	LAIS	1 Tahun - 0 Bulan - 28 Hari	2023-07-31	8.2	71.2	Berat Badan Normal	-1.68	Pendek	-2.33	Gizi Baik	-0.72	O
9492	ALVARENDRA FATHLANI	L	SAMARINDA DA	SAMARINDA SEBERANG	MANGKUPAL AS	MESJID		0 Tahun - 5 Bulan - 21 Hari	2023-07-31	6.32	62.7	Berat Badan Normal	-1.91	Pendek	-2.09	Gizi Baik	-0.72	O
9493	SHEIKA MAHRA SARADA	P	SAMARINDA DA	SAMARINDA SEBERANG	MANGKUPAL AS	TENUN SAMARINDA		0 Tahun - 4 Bulan - 24 Hari	2023-07-31	4	52.8	Sangat Kurang	-4.18	Sangat Pendek	-4.92	Gizi Baik	0.04	O



**Lampiran 5** Proses data cleaning (mengubah format data dari objek menjadi numerik)

No	Nama Atribut	Nilai (sebelum diubah)	Nilai (sesudah diubah)
1	JK	L	0
		P	1
2	Kec	LOA JANAN ILIR	0
		PALARAN	1
		SAMARINDA ILIR	2
		SAMARINDA KOTA	3
		SAMARINDA SEBERANG	4
		SAMARINDA ULU	5
		SAMARINDA UTARA	6
		SAMBUTAN	7
		SUNGAI KUNJANG	8
		SUNGAI PINANG	9
3	Pukesmas	AIR PUTIH	0
		BANTUAS	1
		BENGKURING	2
		BUKUAN	3
		HARAPAN BARU	4
		JUANDA	5
		KAMPUNG BAKA	6
		KARANG ASAM	7
		LEMPAKE	8
		LOA BAKUNG	9
		LOK BAHU	10
		MAKROMAN	11
		MANGKUPALAS	12
		PALARAN	13
		PASUNDAN	14
		REMAJA	15
		SAMARINDA KOTA	16
		SAMBUTAN	17
		SEGIRI	18
		SEI SIRING	19
		SEMPAJA	20
		SIDOMULYO	21
		SUNGAI KAPIH	22
		TEMINDUNG	23
		TRAUMA CENTER	24
		WONOREJO	25
4	Desa/Kel	AIR HITAM	0
		AIR PUTIH	1
		BANDARA	2
		BANTUAS	3
		BAQA	4

No	Nama Atribut	Nilai (sebelum diubah)	Nilai (sesudah diubah)
	BUDAYA PAMPANG	5	
	BUGIS	6	
	BUKIT PINANG	7	
	BUKUAN	8	
	DADI MULYA	9	
	GUNUNG KELUA	10	
	GUNUNG LINGAI	11	
	GUNUNG PANJANG	12	
	HANDIL BAKTI	13	
	HARAPAN BARU	14	
	JAWA	15	
	KARANG ANYAR	16	
	KARANG ASAM ILIR	17	
	KARANG ASAM ULU	18	
	KARANG MUMUS	19	
	LEMPAKE	20	
	LOA BAKUNG	21	
	LOA BUAH	22	
	LOK BAHU	23	
	MAKROMAN	24	
	MANGKUPALAS	25	
	MESJID	26	
	MUGIREJO	27	
	PASAR PAGI	28	
	PELABUHAN	29	
	PELITA	30	
	PULAU ATAS	31	
	RAPAK DALAM	32	
	RAWA MAKMUR	33	
	SAMBUTAN	34	
	SELILI	35	
	SEMPAJA BARAT	36	
	SEMPAJA SELATAN	37	
	SEMPAJA TIMUR	38	
	SEMPAJA UTARA	39	
	SENGKOTEK	40	
	SIDODADI	41	
	SIDODAMAI	42	
	SIDOMULYO	43	
	SIMPANG PASIR	44	
	SIMPANG TIGA	45	
	sindang sari	46	
	SUNGAI DAMA	47	
	SUNGAI KAPIH	48	
	SUNGAI KELEDANG	49	

No	Nama Atribut	Nilai (sebelum diubah)	Nilai (sesudah diubah)
	SUNGAI PINANG DALAM	50	
	SUNGAI PINANG LUAR	51	
	SUNGAI SIRING	52	
	TANAH MERAH	53	
	TANI AMAN	54	
	TELUK LERONG ILIR	55	
	TELUK LERONG ULU	56	
	TEMINDUNG PERMAI	57	
	TENUN SAMARINDA	58	
5	Posyandu	ABDI	0
	AGLO NEMA	1	
	AGLONEMA TERPADU	2	
	ANGGREK PUTIH	3	
	Angrek Hitam	4	
	Asoka	5	
	BALO TABA GOLO	6	
	BERKAT DOA IBU	7	
	BUGIS	8	
	BUNDA BAKTI	9	
	BUNGA SAKURA	10	
	CERRY	11	
	DELIMA	12	
	HARAPAN KITA	13	
	Harapan Sehat	14	
	JELAWAT	15	
	KAMBOJA	16	
	KARAMUNTING	17	
	KARTAR	18	
	KARTIKA I	19	
	KASIH IBU	20	
	KECUBUNG	21	
	KELAPA HIBRIDA	22	
	Kemangi	23	
	KENANGA 1	24	
	KEPODANG	25	
	KUNJUNGAN PUSKESMAS	26	
	KUTILANG 3	27	
	KUTILANG	28	
	LABU	29	
	LUBUK SAWA	30	
	MARKISA 2	31	
	mekar sari	32	
	MELATI II	33	
	MELATI PUTIH	34	
	melati	35	

No	Nama Atribut	Nilai (sebelum diubah)	Nilai (sesudah diubah)
	MELATI	36	
	MELON	37	
	MENUR B	38	
	MERAH DELIMA	39	
	MERPATI PUTIH	40	
	PELANGI	41	
	PELANGI	42	
	PERDANA 45	43	
	PERDANA	44	
	PERMATAHATI	45	
	PULAU INDAH	46	
	Rambutan	47	
	SEHAT	48	
	SEREI WANGI	49	
	serumi	50	
	SETIA	51	
	SPL	52	
	Sumber Waras	53	
	TERATAI SELILI	54	
	TERI	55	
	TULIP	56	
	TUNA A	57	
	WIJAYA KUSUMA	58	
6	BB/U	Berat Badan Normal	0
		Kurang	1
		Sangat Kurang	2
		Risiko Lebih	3
7	TB/U	Pendek	0
		Sangat Pendek	1
8	BB/TB	Gizi Baik	0
		Gizi Buruk	1
		Gizi Kurang	2
		Gizi Lebih	3
		Obesitas	4
		Risiko Gizi Lebih	5
9	Naik Berat Badan	-	0
		O	1
		T	2
		N	

**Lampiran 6** Hasil Pengujian Parameter KNN

No	K	Weight	Distance	Cross-validated accuracy	Test Accuracy
1	1	uniform	p: 1	89.25%	89.93%
2	1	uniform	p: 2	88.19%	89.08%
3	1	distance	p: 1	89.25%	89.93%
4	1	distance	p: 2	88.19%	89.08%
5	2	uniform	p: 1	87.48%	88.60%
6	2	uniform	p: 2	86.20%	87.64%
7	2	distance	p: 1	89.25%	89.93%
8	2	distance	p: 2	88.19%	89.08%
9	3	uniform	p: 1	88.99%	90.25%
10	3	uniform	p: 2	87.32%	88.81%
11	3	distance	p: 1	89.82%	90.94%
12	3	distance	p: 2	88.38%	89.61%
13	4	uniform	p: 1	87.81%	89.61%
14	4	uniform	p: 2	86.26%	88.55%
15	4	distance	p: 1	90.05%	91.15%
16	4	distance	p: 2	88.62%	89.93%
17	5	uniform	p: 1	88.29%	89.13%
18	5	uniform	p: 2	86.52%	87.64%
19	5	distance	p: 1	89.98%	90.89%
20	5	distance	p: 2	88.13%	89.29%
21	6	uniform	p: 1	87.77%	89.45%
22	6	uniform	p: 2	85.98%	87.48%
23	6	distance	p: 1	89.85%	90.89%
24	6	distance	p: 2	88.05%	89.08%
25	7	uniform	p: 1	87.82%	88.55%
26	7	uniform	p: 2	85.84%	87.32%
27	7	distance	p: 1	89.53%	90.73%
28	7	distance	p: 2	87.81%	89.08%
29	8	uniform	p: 1	87.06%	88.23%
30	8	uniform	p: 2	85.36%	86.73%
31	8	distance	p: 1	89.38%	90.41%
32	8	distance	p: 2	87.59%	88.65%
33	9	uniform	p: 1	86.98%	88.17%
34	9	uniform	p: 2	85.24%	86.79%
35	9	distance	p: 1	89.21%	90.04%
36	9	distance	p: 2	87.32%	88.65%
37	10	uniform	p: 1	86.45%	87.96%
38	10	uniform	p: 2	84.56%	85.99%
39	10	distance	p: 1	89.01%	89.98%
40	10	distance	p: 2	87.01%	88.65%
41	11	uniform	p: 1	86.34%	87.64%
42	11	uniform	p: 2	84.41%	86.25%
43	11	distance	p: 1	88.94%	89.56%
44	11	distance	p: 2	86.60%	88.55%
45	12	uniform	p: 1	85.80%	86.57%

No	K	Weight	Distance	Cross-validated accuracy	Test Accuracy
46	12	uniform	p: 2	83.98%	85.46%
47	12	distance	p: 1	88.49%	89.72%
48	12	distance	p: 2	86.40%	88.39%
49	13	uniform	p: 1	85.74%	87.11%
50	13	uniform	p: 2	83.93%	85.35%
51	13	distance	p: 1	88.29%	89.29%
52	13	distance	p: 2	86.12%	88.28%
53	14	uniform	p: 1	85.25%	86.47%
54	14	uniform	p: 2	83.49%	84.76%
55	14	distance	p: 1	88.03%	89.24%
56	14	distance	p: 2	85.97%	87.75%
57	15	uniform	p: 1	85.37%	86.20%
58	15	uniform	p: 2	83.42%	84.87%
59	15	distance	p: 1	88.11%	89.08%
60	15	distance	p: 2	85.85%	87.37%
61	16	uniform	p: 1	85.01%	85.83%
62	16	uniform	p: 2	83.21%	84.39%
63	16	distance	p: 1	87.73%	88.76%
64	16	distance	p: 2	85.61%	87.27%
65	17	uniform	p: 1	84.85%	85.67%
66	17	uniform	p: 2	83.28%	84.23%
67	17	distance	p: 1	87.61%	88.60%
68	17	distance	p: 2	85.40%	87.05%
69	18	uniform	p: 1	84.64%	85.30%
70	18	uniform	p: 2	83.09%	84.18%
71	18	distance	p: 1	87.41%	88.44%
72	18	distance	p: 2	85.08%	86.73%
73	19	uniform	p: 1	84.81%	85.46%
74	19	uniform	p: 2	83.10%	83.91%
75	19	distance	p: 1	87.26%	88.23%
76	19	distance	p: 2	84.97%	86.31%
77	20	uniform	p: 1	84.50%	84.87%
78	20	uniform	p: 2	82.82%	83.59%
79	20	distance	p: 1	86.92%	88.07%
80	20	distance	p: 2	84.80%	86.04%
...	...	...	...	...	...
197	50	uniform	p: 1	81.43%	82.42%
198	50	uniform	p: 2	80.57%	81.67%
199	50	distance	p: 1	82.90%	84.76%
200	50	distance	p: 2	81.55%	83.17%

**Lampiran 7 Hasil Pengujian KNN&PSO**

No	K	Weight	Distance Metric	Mean Accuracy	Test Accuracy
1	48	distance	p 1	89.62%	90.73%
2	18	uniform	p 1	90.54%	91.48%
3	32	distance	p 1	91.14%	91.85%
4	20	uniform	p 1	90.27%	91.26%
5	23	uniform	p 1	90.14%	90.89%
6	33	distance	p 1	90.97%	91.90%
7	24	uniform	p 1	89.90%	90.46%
8	6	uniform	p 1	92.14%	92.91%
9	32	distance	p 1	91.14%	91.85%
10	17	distance	p 1	92.47%	92.97%
11	17	uniform	p 1	90.94%	91.69%
12	33	uniform	p 1	88.89%	89.72%
13	47	distance	p 1	89.74%	90.73%
14	1	uniform	p 1	92.96%	93.55%
15	43	distance	p 1	90.09%	90.94%
16	48	uniform	p 1	87.20%	88.49%
17	49	distance	p 1	89.63%	90.73%
18	47	distance	p 1	89.74%	90.73%
19	14	distance	p 1	92.78%	93.23%
20	29	uniform	p 1	89.43%	89.88%
21	41	distance	p 1	90.23%	91.21%
22	2	uniform	p 1	91.61%	92.12%
23	40	distance	p 1	90.45%	91.05%
24	1	uniform	p 1	92.96%	93.55%
25	43	uniform	p 2	85.61%	86.31%
26	6	distance	p 1	93.44%	93.98%
27	10	uniform	p 1	91.45%	92.54%
28	11	distance	p 1	93.06%	93.93%
29	50	distance	p 1	89.50%	90.73%
30	4	uniform	p 1	92.13%	93.71%
31	1	distance	p 1	92.96%	93.55%
32	40	uniform	p 1	88.02%	89.03%
33	50	uniform	p 1	87.05%	88.44%
34	1	uniform	p 2	92.62%	92.70%
35	22	distance	p 1	92.10%	92.65%
36	6	uniform	p 1	92.14%	92.91%
37	41	uniform	p 1	88.06%	89.03%
38	29	distance	p 1	91.46%	91.85%
39	1	distance	p 1	92.96%	93.55%
40	2	distance	p 1	92.96%	93.55%
41	28	uniform	p 1	89.27%	90.14%
42	1	uniform	p 1	92.96%	93.55%
43	43	distance	p 2	87.86%	88.65%
44	1	uniform	p 1	92.96%	93.55%

No	K	Weight	Distance Metric	Mean Accuracy	Test Accuracy
45	35	uniform	p 2	86.66%	87.48%
46	1	uniform	p 1	92.96%	93.55%
47	3	uniform	p 1	92.96%	94.19%
48	12	distance	p 1	92.98%	93.66%
49	45	distance	p 1	89.89%	90.94%
50	1	uniform	p 1	92.96%	93.55%
51	1	distance	p 1	92.96%	93.55%
52	29	uniform	p 1	89.43%	89.88%
53	50	uniform	p 1	87.05%	88.44%
54	1	uniform	p 2	92.62%	92.70%
55	5	distance	p 1	93.10%	93.98%
56	1	uniform	p 1	92.96%	93.55%
57	30	uniform	p 1	89.13%	89.82%
58	17	distance	p 1	92.47%	92.97%
59	1	distance	p 1	92.96%	93.55%
60	1	distance	p 1	92.96%	93.55%
61	16	uniform	p 1	90.90%	91.74%
62	5	uniform	p 1	92.47%	93.23%
63	27	distance	p 1	91.65%	92.12%
64	2	uniform	p 1	91.61%	92.12%
65	27	uniform	p 1	89.73%	90.20%
66	1	uniform	p 1	92.96%	93.55%
67	1	uniform	p 1	92.96%	93.55%
68	11	distance	p 1	93.06%	93.93%
69	35	distance	p 1	90.82%	91.90%
70	1	uniform	p 1	92.96%	93.55%
71	2	uniform	p 1	91.61%	92.12%
72	19	uniform	p 1	90.65%	91.48%
73	33	uniform	p 1	88.89%	89.72%
74	2	uniform	p 2	91.18%	91.80%
75	1	distance	p 1	92.96%	93.55%
76	1	uniform	p 1	92.96%	93.55%
77	17	uniform	p 1	90.94%	91.69%
78	8	distance	p 1	93.16%	93.93%
79	4	distance	p 1	93.38%	94.19%
80	1	distance	p 1	92.96%	93.55%
81	10	uniform	p 1	91.45%	92.54%
82	8	uniform	p 1	91.75%	92.75%
83	11	distance	p 1	93.06%	93.93%
84	4	distance	p 1	93.38%	94.19%
85	18	uniform	p 1	90.54%	91.48%
86	1	uniform	p 1	92.96%	93.55%
87	2	uniform	p 1	91.61%	92.12%
88	9	distance	p 1	93.20%	93.66%
89	17	distance	p 1	92.47%	92.97%
90	4	distance	p 1	93.38%	94.19%

No	K	Weight	Distance Metric	Mean Accuracy	Test Accuracy
91	6	uniform	p 1	92.14%	92.91%
92	12	uniform	p 1	91.22%	91.85%
93	25	distance	p 1	91.78%	92.38%
94	4	uniform	p 1	92.13%	93.71%
95	1	distance	p 1	92.96%	93.55%
96	2	uniform	p 1	91.61%	92.12%
97	10	uniform	p 1	91.45%	92.54%
98	3	distance	p 1	93.27%	94.35%
99	6	distance	p 1	93.44%	93.98%
100	1	distance	p 1	92.96%	93.55%
...	...	...	...	...	...
1000	6	uniform	p 1	92.14%	92.91%
1001	5	uniform	p 1	92.47%	93.23%
1002	6	distance	p 1	93.44%	93.98%
1003	4	distance	p 1	93.38%	94.19%
1004	7	distance	p 1	93.10%	93.77%
1005	6	distance	p 1	93.44%	93.98%
1006	6	distance	p 1	93.44%	93.98%
1007	6	distance	p 1	93.44%	93.98%
1008	6	distance	p 1	93.44%	93.98%
1009	6	distance	p 1	93.44%	93.98%
1010	5	uniform	p 1	92.47%	93.23%
1011	6	uniform	p 1	92.14%	92.91%
1012	5	distance	p 1	93.10%	93.98%
1013	5	uniform	p 1	92.47%	93.23%
1014	6	distance	p 1	93.44%	93.98%
1015	6	uniform	p 1	92.14%	92.91%
1016	6	distance	p 1	93.44%	93.98%
1017	6	distance	p 1	93.44%	93.98%
1018	6	distance	p 1	93.44%	93.98%
1019	6	distance	p 1	93.44%	93.98%
1020	6	uniform	p 1	92.14%	92.91%

**Lampiran 8** Hasil Uji Turnitin

# SKRIPSI BAGUS FATHUR ROCHMAN

by Teknik Informatika Universitas Muhammadiyah Kalimantan Timur



---

**Submission date:** 25-Jul-2024 01:17PM (UTC+0800)  
**Submission ID:** 2422146393  
**File name:** SKRIPSI\_BAGUS\_FATHUR\_ROCHMAN.docx (951.87K)  
**Word count:** 5445  
**Character count:** 34220

---

## SKRIPSI BAGUS FATHUR ROCHMAN

### ORIGINALITY REPORT

<b>20%</b>	<b>16%</b>	<b>11%</b>	<b>7%</b>
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

### PRIMARY SOURCES

1	<a href="http://soj.umrah.ac.id">soj.umrah.ac.id</a> Internet Source	1 %
2	<a href="http://repository.its.ac.id">repository.its.ac.id</a> Internet Source	1 %
3	Emir Ramon, Alwis Nazir, Novriyanto Novriyanto, Yusra Yusra, Lola Oktavia. "KLASIFIKASI STATUS GIZI BAYI POSYANDU KECAMATAN BANGUN PURBA MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE (SVM)", Jurnal Sistem Informasi dan Informatika (Simika), 2022 Publication	1 %
4	<a href="http://dspace.umkt.ac.id">dspace.umkt.ac.id</a> Internet Source	1 %
5	<a href="http://repository.uin-suska.ac.id">repository.uin-suska.ac.id</a> Internet Source	1 %
6	<a href="http://core.ac.uk">core.ac.uk</a> Internet Source	1 %
7	<a href="http://mypertamina.id">mypertamina.id</a> Internet Source	<1 %

## Lampiran 9 Kode Pengujian KNN

```
from sklearn.model_selection import cross_val_score
from sklearn.neighbors import KNeighborsClassifier
import numpy as np

# Definisi parameter yang akan diuji
k_values = range(1, 51)
weight_options = ['uniform', 'distance']
p_values = [1, 2]

best_score = 0
best_params = None

results = []

# Jumlah lipatan dalam cross-validation
cv_folds = 5

# Loop untuk mencoba setiap kombinasi parameter
for k in k_values:
    for weight in weight_options:
        for p in p_values:
            knn = KNeighborsClassifier(n_neighbors=k, weights=weight,
p=p)
                scores = cross_val_score(knn, x_train, y_train,
cv=cv_folds, scoring='accuracy')
                mean_score = scores.mean()

                knn.fit(x_train, y_train)
                test_accuracy = knn.score(x_test, y_test)

                results.append((k, weight, p, mean_score, test_accuracy))

            # Print hasil untuk setiap kombinasi parameter
            print(f'k: {k}, weight: {weight}, p: {p}, Cross-validated
accuracy: {mean_score}, Test accuracy: {test_accuracy}')

            if mean_score > best_score:
                best_score = mean_score
                best_params = (k, weight, p)

# Hasil terbaik
optimal_k, optimal_weight, optimal_p = best_params
print('\nOptimal Parameters:')
print('Optimal k:', optimal_k)
print('Optimal weight:', optimal_weight)
print('Optimal p:', optimal_p)
print('Cross-validated accuracy:', best_score)
```

```
# Menggunakan parameter yang optimal
knn_optimal = KNeighborsClassifier(n_neighbors=optimal_k,
weights=optimal_weight, p=optimal_p)
knn_optimal.fit(x_train, y_train)
train_accuracy_optimal = knn_optimal.score(x_train, y_train)
test_accuracy_optimal = knn_optimal.score(x_test, y_test)

print('Optimal Train accuracy:', train_accuracy_optimal)
print('Optimal Test accuracy:', test_accuracy_optimal)
```

## Lampiran 10 Kode pengujian KNN&PSO

```
from pyswarm import pso
from sklearn.model_selection import cross_val_score
from sklearn.preprocessing import StandardScaler
from sklearn.pipeline import Pipeline
from sklearn.neighbors import KNeighborsClassifier
import numpy as np

# Definisi fungsi untuk mengoptimalkan
def optimize_knn(params):
    k = int(params[0])
    weight = 'uniform' if params[1] < 0.5 else 'distance'
    algorithm = 'auto'
    p = int(params[2])

    knn = KNeighborsClassifier(n_neighbors=k, weights=weight,
algorithm=algorithm, p=p)

    pipeline = Pipeline([
        ('scaler', StandardScaler()),
        ('knn', knn)
    ])

    # Menggunakan cross-validation untuk mendapatkan mean accuracy
    scores = cross_val_score(pipeline, x_train, y_train, cv=5,
scoring='accuracy')
    penalty = 0 if k > 4 else (4 - k) * 0.01

    # Evaluasi model pada data uji
    pipeline.fit(x_train, y_train)
    test_accuracy = pipeline.score(x_test, y_test)

    # Simpan semua hasil yang dihitung
    all_results.append((k, weight, p, scores.mean(), penalty,
test_accuracy))

    return -scores.mean() + penalty

# Batasan untuk parameter
lb = [1, 0, 1]
ub = [50, 1, 2]

# Inisialisasi list untuk menyimpan semua hasil yang dihitung
all_results = []

# Optimasi menggunakan PSO
optimal_params, optimal_score = pso(optimize_knn, lb, ub, swarmsize=20,
maxiter=50)
```

```

optimal_k = int(optimal_params[0])
optimal_weight = 'uniform' if optimal_params[1] < 0.5 else 'distance'
optimal_p = int(optimal_params[2])

# Menggunakan parameter yang optimal untuk model KNN
knn_optimal = KNeighborsClassifier(n_neighbors=optimal_k,
weights=optimal_weight, algorithm='auto', p=optimal_p)
pipeline_optimal = Pipeline([
    ('scaler', StandardScaler()),
    ('knn', knn_optimal)
])
pipeline_optimal.fit(x_train, y_train)

# Evaluasi model optimal
train_accuracy_optimal = pipeline_optimal.score(x_train, y_train)
test_accuracy_optimal = pipeline_optimal.score(x_test, y_test)

# Cetak semua hasil K yang dihitung
print("== Semua Hasil K yang Dihitung ==")
for result in all_results:
    print(f"K: {result[0]}, Weight: {result[1]}, p: {result[2]}, Mean
Accuracy: {result[3]:.4f}, Test Accuracy: {result[5]:.4f}")

# Cetak hasil terbaik
print("\n== Hasil Optimasi dan Evaluasi Model ==")
print(f"Optimal k: {optimal_k}")
print(f"Optimal weight: {optimal_weight}")
print(f"Optimal p: {optimal_p}")
print(f"Cross-validated accuracy: {-optimal_score:.4f}")
print(f"Optimal Train accuracy: {train_accuracy_optimal:.4f}")
print(f"Optimal Test accuracy: {test_accuracy_optimal:.4f}")

```

**Lampiran 11** Hasil Pengujian dengan *confusion matrix*

```
from sklearn.metrics import confusion_matrix
import matplotlib.pyplot as plt
import seaborn as sns

# Hitung confusion matrix
y_pred_test = pipeline_optimal.predict(x_test)
cm = confusion_matrix(y_test, y_pred_test)

# Plot confusion matrix
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', cmap='Blues', cbar=False)
plt.xlabel('Predicted Labels')
plt.ylabel('True Labels')
plt.title('Confusion Matrix')
plt.show()

from sklearn.metrics import classification_report

# Hasil Klasifikasi Report
report = classification_report(y_test, y_pred_test, digits=6)
print(report)
```

**Lampiran 12** Daftar Riwayat Hidup**RIWAYAT HIDUP**

Bagus Fathur Rochman, atau sering disapa Fathur lahir di Melak pada tanggal 06 Juli 2002. Penulis merupakan anak pertama dari empat bersaudara yang lahir dari keluarga Bapak Sri Julianto dan Ibu Yulisda. Saat ini saya tinggal di Jalan Jakarta, Gang PGRI No.23, Kelurahan Loa Bakung, Kecamatan Sungai Kunjang, Samarinda, [75126]. Saya menyelesaikan Pendidikan formal di SD Muhammadiyah 001 Melak tahun 2009-2014, MTsN Melak tahun 2014-2016 dan SMPN 38 Samarinda 2016-2017, dan SMK Terpadu Madina Samarinda jurusan Teknik Komputer dan Jaringan (TKJ) pada tahun 2017-2020, dan melanjutkan studi di Universitas Muhammadiyah Kalimantan Timur dengan Program Studi Teknik Informatika