

**KLASIFIKASI PENEMPATAN BARANG PADA ALAT ANGKUT
MENGUNAKAN *K-NEAREST NEIGHBOR* DAN
*SUPPORT VECTOR MACHINE***

THESIS

**MOH. HUSNUS SYAWAB
NIM. 210605220003**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**KLASIFIKASI PENEMPATAN BARANG PADA ALAT ANGKUT
MENGUNAKAN *K-NEAREST NEIGHBOR* DAN
*SUPPORT VECTOR MACHINE***

THESIS

**Diajukan kepada:
Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh :
MOH. HUSNUS SYAWAB
NIM. 210605220003**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

LEMBAR PERSETUJUAN

**KLASIFIKASI PENEMPATAN BARANG PADA ALAT ANGKUT
MENGUNAKAN *K-NEAREST NEIGHBOR* DAN
*SUPPORT VECTOR MACHINE***

THESIS

**MOH. HUSNUS SYAWAB
NIM. 210605220003**

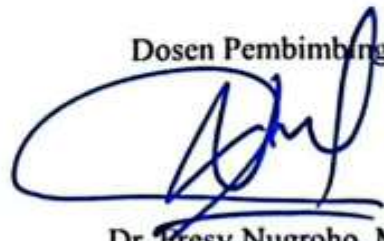
Telah Diperiksa dan Disetujui untuk Diuji
Tanggal: 9 Desember 2024

Dosen Pembimbing I



Dr. Yunifa Miftachul Arif, M. T
NIP. 19830616 201101 1 004

Dosen Pembimbing II



Dr. Presy Nugroho, M. T
NIP. 19710722 201101 1 001

Mengetahui,

Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi

Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Cahyo Crysdian

NIP. 19740424 200901 1 008

LEMBAR PENGESAHAN

KLASIFIKASI PENEMPATAN BARANG PADA ALAT ANGKUT MENGUNAKAN *K-NEAREST NEIGHBOR* DAN *SUPPORT VECTOR MACHINE*





THESIS

Oleh:

MOH. HUSNUS SYAWAB
NIM. 210605220003

Telah Dipertahankan Di depan Dewan Penguji
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
untuk Memperoleh Gelar Magister Komputer (M.Kom)
Pada Tanggal 9 Desember 2024

Susunan Penguji

- | | | | |
|------------------|---|---|---|
| 1. Penguji I | : | <u>Dr. Ririen Kusumawati, S.Si, M.Kom</u>
NIP. 19720309 200501 2 002 |  |
| 2. Penguji II | : | <u>Dr. Cahyo Crysdiان</u>
NIP. 19740424 200901 1 008 |  |
| 3. Pembimbing I | : | <u>Dr. Yunifa Miftachul Arif, M. T</u>
NIP. 19830616 201101 1 004 |  |
| 4. Pembimbing II | : | <u>Dr. Fresy Nugroho, M.T</u>
NIP. 19710722 201101 1 001 |  |

Mengetahui,

Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Cahyo Crysdiان
NIP. 19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Moh. Husnus Syawah

NIM : 210605220003

Fakultas / Prodi : Sains dan Teknologi/Magister Informatika

Judul Thesis : Klasifikasi Penempatan Barang Pada Alat Angkut
Menggunakan *K-Nearest Neighbor* Dan
Support Vector Machine

Menyatakan dengan sebenarnya bahwa thesis yang saya tulis ini benar-benar merupakan hasil karya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila di kemudian hari terbukti atau dapat dibuktikan thesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 23 Desember 2024

Yang Membuat Pernyataan,

A handwritten signature in black ink is written over a pink and green 3000 Rupiah meter stamp. The stamp features the Garuda Pancasila logo and the text 'METERAN TEMPEL' and '3000'. The serial number '7A.X315 41330' is visible at the bottom of the stamp.

Moh. Husnus Syawah
NIM. 210605220003

MOTTO

“Teruslah berbuat kebaikan.”

HALAMAN PERSEMBAHAN

أَلْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ

Puji syukur kepada Allah SWT penulis persembahkan hasil karya ini kepada:

Ayah, almarhum Dimjati, yang telah berjasa mendidik dan membimbing hingga saya bisa sampai pada titik pencapaian sekarang ini.

Ibu dan kakak, Umi Sulistiany, M. Aruman Hasmi, yang selalu memanjatkan do'a dan memberikan motivasi untuk segera menyelesaikan thesis ini.

Bapak Dr. Cahyo Crysdiyan, selaku Ketua program studi magister Informatika, Fakultas Sains dan Teknologi UIN Maliki Malang.

Dosen pembimbing, Bapak Dr. Yunifa Miftachul Arif, M. T dan Bapak Dr. Fresy Nugroho, M. T, yang telah memberikan bimbingan dan saran sehingga penelitian ini bisa berjalan dengan lancar.

Dosen penguji, Bapak Dr. Cahyo Crysdiyan & Ibu Dr. Ririen Kusumawati, S.Si, M.Kom, yang telah sabar dalam menguji penulis

Seluruh dosen magister Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang, yang telah dengan ikhlas membagi ilmu dan berbagai pengalamannya.

Mbak Citra Fidya Atmalia, S.H, yang telah membantu dalam urusan administrasi.

Support system yang telah banyak membantu dalam menyelesaikan thesis ini.

Sahabat-sahabat saya yang begitu banyak dan tidak bisa disebutkan namanya satu per satu, saudara Angkatan 5 mahasiswa magister informatika, keluarga besar Asosiasi mahasiswa magister informatika UIN Maulana Malik Ibrahim Malang, yang tiada hentinya memberikan semangat untuk menyelesaikan thesis ini.

KATA PENGANTAR

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Puji syukur penulis panjatkan kehadiran Tuhan yang Maha Esa yang telah memberikan berkat dan rahmat-Nya sehingga penulis dapat menyelesaikan thesis yang berjudul “Klasifikasi Penempatan Barang Pada Alat Angkut Menggunakan *K-Nearest Neighbor* Dan *Support Vector Machine*”. Tujuan dari penyusunan thesis ini guna memenuhi salah satu syarat untuk bisa menempuh ujian magister informatika pada Fakultas Sains dan Teknologi Program Studi Magister Informatika di Universitas Islam Negeri Maulana Malik Ibrahim Malang. Dalam penyusunan thesis, penulis banyak mendapatkan bantuan ataupun masukan dari berbagai pihak. Oleh sebab itu, penulis mengungkapkan rasa terima kasih kepada:

1. Bapak Prof. Dr. H. M. Zainuddin, M.A, selaku Rektor Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang.
2. Ibu Dr. Sri Harini, M.Si, selaku Dekan Fakultas Sains dan Teknologi.
3. Bapak Dr. Cahyo Crysdiyan, selaku Ketua Program Studi Magister Informatika, Fakultas Sains dan Teknologi UIN Maliki Malang.
4. Ibu Dr. Ririen Kusumawati, S.Si, selaku Wali Dosen yang telah memberikan saran dan masukan serta dukungan semangat hingga saya bisa menyelesaikan perkuliahan dengan baik.
5. Bapak Dr. Yunifa Miftachul Arif, M. T, selaku pembimbing I, yang telah memberikan bimbingan dan masukan dengan sangat sabar sehingga penulis dapat menyelesaikan penelitian ini.
6. Bapak Dr. Fresy Nugroho, M. T, selaku pembimbing II, yang telah memberikan bimbingan dan masukan sehingga penulis dapat menyelesaikan penelitian ini.
7. Mbak Citra Fidya Atmalia, S.H dan para staff laboran, yang telah membantu dalam urusan administrasi.
8. Orang tua dan keluarga penulis yang telah memanjatkan do’a dan memberikan suntikan motivasi.
9. Sahabat-sahabat tercinta, teman-teman angkatan 5 mahasiswa magister informatika, dan teman-teman asosiasi mahasiswa Magister Informatika UIN Maulana Malik Ibrahim Malang.

10. Bapak Fajar Rohman Hariri dan keluarga yang telah memberikan beasiswa kepada saya sehingga saya mampu menempuh pendidikan S2 ini

11. Semua pihak yang terlibat dalam penyusunan thesis.

Penulis menyadari bahwa thesis ini masih terdapat banyak kekurangan, namun penulis berharap thesis ini dapat bermanfaat khususnya bagi penulis secara pribadi.

Malang, 23 Desember 2024

Penulis

DAFTAR ISI

LEMBAR PERSETUJUAN	ii
LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN TULISAN	iv
MOTTO	v
HALAMAN PERSEMBAHAN	vi
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xi
DAFTAR TABEL	xii
ABSTRAK	xiv
ABSTRACT.....	xv
المخلص.....	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Pernyataan Masalah	3
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Batasan Masalah	3
BAB II STUDI PUSTAKA.....	5
2.1 Klasifikasi Penempatan.....	5
2.2 Kerangka Teori	10
BAB III METODE PENELITIAN	14
3.1 Desain Penelitian	14
3.2 <i>Data Collection</i>	14
3.3 Desain Sistem.....	16
3.3.1 Preprocessing Data.....	16
3.3.2 Normalisasi	17
3.3.3 Split Data	17
3.3.4 Model <i>K-Nearest Neighbor</i>	18
3.3.5 Model <i>Support Vector Machine</i>	18
3.4 Eksperimen	21
3.5 Evaluasi.....	22
BAB IV ANALISIS DAN PEMBAHASAN	23
4.1 Desain <i>K-Nearest Neighbor</i>	23
4.2 Uji Coba Model KNN.....	23

4.2.1	Pengujian 1.....	24
4.2.2	Pengujian 2.....	30
4.2.3	Pengujian 3.....	35
4.2.4	Pengujian 4.....	40
4.2.5	Pengujian 5.....	44
4.3	Desain <i>Support Vector Machine</i>	49
4.4	Uji Coba Model SVM.....	50
4.4.1	Pengujian 1.....	50
4.4.2	Pengujian 2.....	52
4.4.3	Pengujian 3.....	53
4.4.4	Pengujian 4.....	54
4.4.5	Pengujian 5.....	55
4.5	Evaluasi Hasil	56
4.5.1	Komparasi Akurasi Pengujian Model KNN dan SVM.....	56
4.5.2	Komparasi Presisi Pengujian Model KNN dan SVM.....	58
4.5.3	Komparasi <i>Recall</i> Pengujian Model KNN dan SVM	59
4.6	Klasifikasi Penempatan Barang Pada Alat Angkut dalam Pandangan Islam....	60
BAB V KESIMPULAN		64
5.1	Kesimpulan	64
5.2	Saran	66
DAFTAR PUSTAKA.....		68

DAFTAR GAMBAR

Gambar 2.1. Kerangka Teori	10
Gambar 3.1. Prosedur Penelitian	14
Gambar 3.2. Desain Sistem Penempatan Barang pada Alat Angkut.....	16
Gambar 4.1. Flowchart proses klasifikasi model KNN.....	23
Gambar 4.2. Flowchart proses klasifikasi model SVM.....	50
Gambar 4.3. Grafik akurasi KNN dan SVM	57
Gambar 4.4. Grafik presisi KNN dan SVM	58
Gambar 4.5. Grafik presisi KNN dan SVM	59

DAFTAR TABEL

Tabel 3.1 Data Barang 10 November 2022 – 17 November 2022	15
Tabel 3.2 Atribut Data Barang	15
Tabel 4.1. Nama Pengujian dan Rasio Split Data	24
Tabel 4.2. Hasil klasifikasi pengujian 1 KNN nilai $k=3$	24
Tabel 4.3. Hasil confusion matrix pengujian 1 KNN nilai $k=3$	24
Tabel 4.4. Hasil klasifikasi pengujian 1 KNN nilai $k=5$	25
Tabel 4.5. Hasil confusion matrix pengujian 1 KNN nilai $k=5$	25
Tabel 4.6. Hasil klasifikasi pengujian 1 KNN nilai $k=7$	26
Tabel 4.7. Hasil confusion matrix pengujian 1 KNN nilai $k=7$	27
Tabel 4.8. Hasil klasifikasi pengujian 1 KNN nilai $k=9$	28
Tabel 4.9. Hasil confusion matrix pengujian 1 KNN nilai $k=9$	28
Tabel 4.10. Komparasi evaluasi pengujian 1 KNN.....	29
Tabel 4.11. Hasil klasifikasi pengujian 2 KNN nilai $k=3$	30
Tabel 4.12. Hasil confusion matrix pengujian 2 KNN nilai $k=3$	30
Tabel 4.13. Hasil klasifikasi pengujian 2 KNN nilai $k=5$	31
Tabel 4.14. Hasil confusion matrix pengujian 2 KNN nilai $k=5$	31
Tabel 4.15. Hasil klasifikasi pengujian 2 KNN nilai $k=7$	32
Tabel 4.16. Hasil confusion matrix pengujian 2 KNN nilai $k=7$	32
Tabel 4.17. Hasil klasifikasi pengujian 2 KNN nilai $k=9$	33
Tabel 4.18. Hasil confusion matrix pengujian 2 KNN nilai $k=9$	33
Tabel 4.19. Komparasi evaluasi pengujian 2 KNN.....	34
Tabel 4.20. Hasil klasifikasi pengujian 3 KNN nilai $k=3$	35
Tabel 4.21. Hasil confusion matrix pengujian 3 KNN nilai $k=3$	35
Tabel 4.22. Hasil klasifikasi pengujian 3 KNN nilai $k=5$	36
Tabel 4.23. Hasil confusion matrix pengujian 3 KNN nilai $k=5$	36
Tabel 4.24. Hasil klasifikasi pengujian 3 KNN nilai $k=7$	37
Tabel 4.25. Hasil confusion matrix pengujian 3 KNN nilai $k=7$	37
Tabel 4.26. Hasil klasifikasi pengujian 3 KNN nilai $k=9$	38
Tabel 4.27. Hasil confusion matrix pengujian 3 KNN nilai $k=9$	38
Tabel 4.28. Komparasi evaluasi pengujian 3 KNN.....	40
Tabel 4.29. Hasil klasifikasi pengujian 4 KNN nilai $k=3$	40
Tabel 4.30. Hasil confusion matrix pengujian 4 KNN nilai $k=3$	40
Tabel 4.31. Hasil klasifikasi pengujian 4 KNN nilai $k=5$	41
Tabel 4.32. Hasil confusion matrix pengujian 4 KNN nilai $k=5$	41
Tabel 4.33. Hasil klasifikasi pengujian 4 KNN nilai $k=7$	42
Tabel 4.34. Hasil confusion matrix pengujian 4 KNN nilai $k=7$	42
Tabel 4.35. Hasil klasifikasi pengujian 4 KNN nilai $k=9$	43
Tabel 4.36. Hasil confusion matrix pengujian 4 KNN nilai $k=9$	43
Tabel 4.37. Komparasi Evaluasi pengujian 4 KNN	44
Tabel 4.38. Hasil klasifikasi pengujian 5 KNN nilai $k=3$	45

Tabel 4.39. Hasil confusion matrix pengujian 5 KNN nilai k=3	45
Tabel 4.40. Hasil klasifikasi pengujian 5 KNN nilai k=5	46
Tabel 4.41. Hasil confusion matrix pengujian 5 KNN nilai k=5	46
Tabel 4.42. Hasil klasifikasi pengujian 5 KNN nilai k=7	47
Tabel 4.43. Hasil confusion matrix pengujian 5 KNN nilai k=7	47
Tabel 4.44. Hasil klasifikasi pengujian 5 KNN nilai k=9	48
Tabel 4.45. Hasil confusion matrix pengujian 5 KNN nilai k=9	48
Tabel 4.46. Komparasi evaluasi pengujian 5 KNN.....	49
Tabel 4.47. Nama Pengujian dan Rasio Split Data	50
Tabel 4.48. Hasil klasifikasi pengujian 1 SVM.....	51
Tabel 4.49. Hasil confusion matrix pengujian 1 SVM.....	51
Tabel 4.50. Hasil klasifikasi pengujian 2 SVM.....	52
Tabel 4.51. Hasil confusion matrix pengujian 2 SVM.....	52
Tabel 4.52. Hasil klasifikasi pengujian 3 SVM.....	53
Tabel 4.53. Hasil confusion matrix pengujian 3 SVM.....	53
Tabel 4.54. Hasil klasifikasi pengujian 4 SVM.....	54
Tabel 4.55. Hasil confusion matrix pengujian 4 SVM.....	54
Tabel 4.56. Hasil klasifikasi pengujian 5 SVM.....	55
Tabel 4.57. Hasil confusion matrix pengujian 5 SVM.....	55
Tabel 4.58. Komparasi Akurasi model KNN dan SVM.....	57
Tabel 4.59. Komparasi presisi model KNN dan SVM.....	58
Tabel 4.60. Komparasi recall model KNN dan SVM	59

ABSTRAK

Syawab, Moh. Husnus. 2024. *Klasifikasi Penempatan Barang Pada Alat Angkut Menggunakan K-Nearest Neighbor Dan Support Vector Machine*. Thesis. Program Studi Magister Informatika Fakultas Sains Dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing : (I) Dr. Yunifa Miftachul Arif, M. T. (II) Dr. Fresy Nugroho, M.T.

Kata Kunci: Klasifikasi, KNN, SVM, Logistik, Penempatan Barang.

Penelitian ini membahas klasifikasi penempatan barang pada alat angkut menggunakan metode K-Nearest Neighbor (KNN) dan Support Vector Machine (SVM). Data yang digunakan berasal dari pengiriman Kantor Pos Malang pada 10–17 November 2022 untuk membandingkan akurasi kedua metode pada berbagai rasio split data. Hasil menunjukkan bahwa KNN dengan $k=9$ mencapai akurasi tertinggi, sebesar 84,3%, pada rasio 50:50. Sementara itu, SVM menunjukkan performa optimal pada rasio 70:30 dengan akurasi 83,57%. Penelitian ini menyoroti pentingnya efisiensi dalam logistik untuk meminimalkan risiko keterlambatan, kerusakan barang, dan meningkatkan kepuasan pelanggan. Prinsip-prinsip efisiensi ini juga selaras dengan ajaran Islam, seperti dalam Surat Al-Baqarah ayat 269 dan Al-Isra' ayat 7, yang menekankan penggunaan hikmah dalam tindakan. Penerapan metode klasifikasi yang tepat diharapkan dapat membantu perusahaan logistik meningkatkan efektivitas operasional dan tanggung jawab dalam pengelolaan barang. Penelitian ini sekaligus membuktikan relevansi penggunaan teknologi dan ilmu pengetahuan untuk menyelesaikan permasalahan logistik secara praktis dan terarah.

ABSTRACT

Syawab, Moh. Husnus. 2024. *Classification of Placement of Goods on Transportation Using K-Nearest Neighbor and Support Vector Machine*. Thesis. Master of Informatics Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Supervisor : (I) Dr. Yunifa Miftachul Arif, M. T. (II) Dr. Fresy Nugroho, M.T.

Keywords: Classification, KNN, SVM, Logistics, Placement of Goods.

This study discusses the classification of the placement of goods on means of transportation using the K-Nearest Neighbor (KNN) and Support Vector Machine (SVM) methods. The data used came from the Malang Post Office delivery on November 10–17, 2022 to compare the accuracy of the two methods on various data split ratios. The results showed that KNN with $k=9$ achieved the highest accuracy, at 84.3%, at a ratio of 50:50. Meanwhile, SVM showed optimal performance at a ratio of 70:30 with an accuracy of 83.57%. This research highlights the importance of efficiency in logistics to minimize the risk of delays, damage to goods, and improve customer satisfaction. These principles of efficiency are also in line with Islamic teachings, such as in Surah Al-Baqarah verse 269 and Al-Isra' verse 7, which emphasizes the use of wisdom in action. The application of the right classification method is expected to help logistics companies increase operational effectiveness and responsibility in managing goods. This research also proves the relevance of using technology and science to solve logistics problems in a practical and targeted manner.

المخلص

سياو اب ، موه. حسنوس. 2024. *تصنيف وضع البضائع في النقل باستخدام آلة ناقلات K-أقرب جار وداعم*.
اطروحه. برنامج دراسة ماجستير المعلوماتية ، كلية العلوم والتكنولوجيا ، جامعة مولانا مالك إبراهيم
الإسلامية الحكومية ، ملانج. المشرف: (I) د. يونيفة مفتاح العارف ، (II) M. T. د. فريسي نوغرو هو
، M.T.

الكلمات المفتاحية: التصنيف ، SVM ، KNN ، الخدمات اللوجستية ، وضع البضائع.

تناقش هذه الدراسة تصنيف وضع البضائع على وسائل النقل باستخدام طريقتي K-Nearest Neighbor (KNN) وآلة ناقلات الدعم (SVM). جاءت البيانات المستخدمة من تسليم مكتب بريد مالانج في الفترة من 10 إلى 17 نوفمبر 2022 لمقارنة دقة الطريقتين على نسب تقسيم البيانات المختلفة. أظهرت النتائج أن KNN مع $k = 9$ حقق أعلى دقة بنسبة 84.3% بنسبة 50:50. وفي الوقت نفسه ، أظهر SVM الأداء الأمثل بنسبة 70:30 بدقة 83.57%. يسلط هذا البحث الضوء على أهمية الكفاءة في الخدمات اللوجستية لتقليل مخاطر التأخير والأضرار التي تلحق بالبضائع وتحسين رضا العملاء. تتماشى مبادئ الكفاءة هذه أيضا مع التعاليم الإسلامية ، كما هو الحال في سورة البقرة الآية 269 والإسراء الآية 7 ، التي تؤكد على استخدام الحكمة في العمل. من المتوقع أن يساعد تطبيق طريقة التصنيف الصحيحة شركات الخدمات اللوجستية على زيادة الفعالية التشغيلية والمسؤولية في إدارة البضائع. يثبت هذا البحث أيضا أهمية استخدام التكنولوجيا والعلوم لحل المشكلات اللوجستية بطريقة عملية ومستهدفة.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Proses pengiriman barang pada jasa ekspedisi memerlukan penempatan barang yang dilakukan pada alat angkut ekspedisi agar pengiriman tersebut dapat dilakukan dengan efektif. Hal itu menyesuaikan dengan berat, jenis, dan tujuan dari barang yang dikirimkan. Namun dalam praktiknya, menurut Kurnia & Mahmudy (2018), beberapa perusahaan ekspedisi masih menggunakan metode tradisional dalam proses penempatan barang pada alat angkut sehingga akan menyebabkan penggunaan waktu yang tidak efektif.

Masalah-masalah yang akan terjadi ke depannya disebabkan oleh penempatan yang tidak efektif seperti keterlambatan pengiriman, kerusakan barang, biaya lebih tinggi, serta barang yang tercampur dengan barang-barang lainnya. Jika tidak ada jalan keluar terhadap masalah tersebut, mempengaruhi kepercayaan dan kepuasan pelanggan, serta eksistensi ekspedisi tersebut.

Kusdiby (2022), menjelaskan bahwa perusahaan ekspedisi mempercayakan penempatan barang kepada pegawai yang sudah berpengalaman, karena lebih banyak akan mendukung kesuksesan dalam pengerjaan tugas. Namun, pergantian atau penambahan pegawai akan selalu dilakukan dalam perusahaan jika dibutuhkan. Jika pegawai yang sudah mempunyai pengalaman pensiun ataupun keluar dari perusahaan, maka pegawai baru yang akan melakukan pekerjaan.

Metode klasifikasi juga dapat membantu dalam proses penempatan barang pada alat angkut sehingga optimal hasilnya. Metode ini sesuai dengan konsep ilmu

pengetahuan dalam islam yang dijelaskan dalam Al-Qur'an surat Al-Baqarah ayat 269, yang berbunyi:

يُؤْتِي الْحِكْمَةَ مَنْ يَشَاءُ وَمَنْ يُؤْتَ الْحِكْمَةَ فَقَدْ أُوتِيَ خَيْرًا كَثِيرًا وَمَا يَدَّكُرُ إِلَّا أُولُو الْأَلْبَابِ ﴿٣٦٩﴾

“Allah menganugerahkan al hikmah (kefahaman yang dalam tentang Al Quran dan As Sunnah) kepada siapa yang dikehendaki-Nya. Dan barangsiapa yang dianugerahi hikmah, ia benar-benar telah dianugerahi karunia yang banyak. Dan hanya orang-orang yang berakallah yang dapat mengambil pelajaran (dari firman Allah).” (QS. Al-Baqarah/ 2 : 269)

Dengan cara ini, perusahaan dapat mengoptimasi biaya operasional (Rahayu et al., 2019), proses pengiriman barang, dan kapasitas alat angkut. Hal ini sesuai dalam Al-Qur'an surat Al-Isra' ayat 7, yang berbunyi:

إِنْ أَحْسَنْتُمْ أَحْسَنْتُمْ لِأَنْفُسِكُمْ وَإِنْ أَسَأْتُمْ فَلَهَا...

“Jika kamu berbuat baik (berarti) kamu berbuat baik bagi dirimu sendiri dan jika kamu berbuat jahat maka kejahatan itu bagi dirimu sendiri.” (QS. Al-Isra'/ 17 : 7)

Maksud dari ayat tersebut adalah sebagai umat manusia seharusnya saling berbuat baik (*hablum minannas*). Apabila dapat mempermudah pekerjaan orang lain, maka segala bentuk pekerjaan akan dimudahkan oleh Allah Subhanahu Wa Ta'ala.

Penggunaan metode klasifikasi yang akurat diharapkan dapat menjaga kualitas layanan serta menciptakan lingkungan kerja yang lebih efisien dan efektif di perusahaan. Penelitian ini membandingkan dua metode klasifikasi, yaitu *K-Nearest Neighbour* (KNN) dan *Support Vector Machine* (SVM), untuk menentukan metode yang paling akurat dalam penempatan barang pada alat angkut.

K-Nearest Neighbour (KNN) adalah metode klasifikasi yang bekerja dengan cara mencari data yang paling mirip (terdekat) dengan data yang ingin diprediksi. Dalam KNN, "K" mengacu pada jumlah tetangga terdekat yang akan

dipertimbangkan untuk menentukan kategori data tersebut. *Support Vector Machine* (SVM) adalah metode klasifikasi yang mencoba memisahkan data ke dalam kategori yang berbeda dengan cara mencari garis (atau lebih tinggi dalam dimensi lebih tinggi) yang paling optimal, yang disebut sebagai *hyperplane*, untuk membedakan kelas-kelas tersebut. Melalui perbandingan ini, diharapkan dapat ditemukan metode yang paling optimal dalam meningkatkan efisiensi dan akurasi penempatan barang pada alat angkut.

1.2 Pernyataan Masalah

Berdasarkan latar belakang, masalah yang menjadi fokus dalam penelitian ini adalah bagaimana mendapatkan model klasifikasi KNN dan SVM penempatan barang pada alat angkut dengan performa terbaik?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mengetahui model klasifikasi KNN dan SVM yang digunakan untuk penempatan barang pada alat angkut dengan performa terbaik.

1.4 Manfaat Penelitian

Manfaat dari penelitian ini adalah:

1. Mengetahui penempatan barang yang paling optimal
2. Mendukung pengambilan keputusan yang lebih baik dalam penempatan barang
3. Bahan kajian untuk mengembangkan penempatan barang

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini diantaranya:

1. Data yang digunakan merupakan data pengiriman barang kantor pos dari kota Malang ke seluruh Indonesia dengan rentang waktu 10 November 2022 – 17 November 2022.
2. Barang yang digunakan dalam penelitian ini tanpa melihat dari dimensi atau volume nya.

BAB II STUDI PUSTAKA

2.1 Klasifikasi Penempatan

Animesh Giri (2021) melakukan penelitian pada tahun 2016 tentang mencari probabilitas siswa ditempatkan pada *IT Company*, berdasarkan penelitian tersebut, menunjukkan bahwa dalam perbandingan metode *K-Nearest Neighbour* (KNN), Regresi logistik, dan *Support Vector Machine* (SVM) menunjukkan bahwa nilai akurasi KNN paling tinggi di antara regresi logistik dan SVM, yaitu 78,57% akurasi untuk KNN, 75% untuk regresi logistik dan 77,38% untuk SVM.

Shao, *et al.* (2009), melakukan penelitian yang mengusulkan 2 kombinasi sistem *Fuzzy Neural Network* dan *Genetic Algorithm* sebagai evaluasi lokasi utama distribusi logistik yang dibandingkan dengan *Fuzzy Neural Network* biasa. Hasilnya menunjukkan bahwa Fuzzy NN yang sudah dikombinasi dengan GA nilai akurasi lebih tinggi daripada Fuzzy NN biasa dengan masing-masing nilainya sebesar 85% untuk Fuzzy NN yang dikombinasikan dengan GA, sedangkan Fuzzy NN saja nilainya sebesar 82%.

Fan, *et al.* (2019), dalam penelitiannya menjelaskan bahwa *Weighted-KNN* (W-KNN) dapat melakukan klasifikasi beban short-term pada histori data beban daya National *Electricity Market* di Australia untuk mendapatkan akurasi tinggi, W-KNN yang akan digunakan juga melakukan perbandingan dengan model ARMA dan juga model BPNN dengan hasil menunjukkan bahwa model W-KNN nilai errornya jauh lebih kecil dibandingkan ARMA dan BPNN.

Menurut B. Sheng, *et al.* (2020), studi mereka mengklasifikasikan aktivitas fisik menggunakan algoritma supervised machine learning (SML) berdasarkan data akselerometer. Empat algoritma SML yang berbeda digunakan dan dievaluasi dalam klasifikasi aktivitas fisik, yaitu Support Vector Machine (SVM), Decision Tree, K-Nearest Neighbor (KNN), dan Ensemble Method (EM). Hasil percobaan menunjukkan bahwa kinerja algoritma SML tidak dipengaruhi oleh perbedaan penempatan dan modalitas monitor. SVM dan EM menunjukkan performa yang memuaskan di semua modalitas monitor dengan akurasi sekitar 89%, diikuti oleh K-Nearest Neighbor (80%), dan Decision Tree (71%). Sementara itu, akurasi keseluruhan GT9X tidak lebih baik dari GT3X+ baik pada penempatan di pinggul maupun paha, dan akurasi keseluruhan mode gabungan (dua monitor bersamaan) tidak lebih baik dari mode tunggal (satu monitor).

B. Cancela, *et al.* (2021) telah melakukan penelitian tentang efektivitas penempatan data pada tugas klasifikasi menggunakan Neural Network (NN). Mereka memperkenalkan seperangkat fungsi loss yang mampu melatih klasifikator dengan memaksa fitur-fitur dalam (input lapisan terakhir) untuk diproyeksikan pada basis ortogonal yang telah ditentukan sebelumnya. Fungsi loss "penempatan data" ini bertujuan untuk meminimalkan jarak antara sampel yang berasal dari kelas yang sama, sekaligus memaksimalkan jarak ke kelas-kelas lainnya. Hasil eksperimen menunjukkan bahwa fungsi loss "penempatan data" ini dapat melampaui akurasi pelatihan yang diberikan oleh fungsi loss cross-entropy klasik, dengan peningkatan akurasi mencapai 5% pada beberapa kasus.

Menurut A. Faza, *et al.*(2024), algoritma *machine learning* (ML) semakin banyak digunakan dalam aplikasi *power systems*, salah satunya untuk klasifikasi

dan lokalisasi berbagai jenis gangguan saluran transmisi. Penelitian ini mengusulkan teknik untuk menemukan jumlah dan penempatan PMU yang optimal dengan melakukan pemilihan fitur yang menyeluruh, di mana fitur dipilih untuk memaksimalkan akurasi algoritma klasifikasi dan regresi ML. Hasil menunjukkan bahwa untuk sistem IEEE 14 bus, penggunaan hanya lima PMU sudah cukup untuk memperoleh tingkat akurasi yang tinggi, yaitu akurasi pengujian 99,0% untuk jenis gangguan dan 97,1% untuk lokasi saluran gangguan, serta MAE 3,1% dan skor R2 94,4% untuk jarak gangguan di sepanjang saluran. Penambahan lebih banyak PMU tidak memberikan nilai tambah dalam hal akurasi.

K. Taunk, *et al.* (2019) menyatakan bahwa algoritma *K-Nearest Neighbor* (KNN) efektif dalam berbagai tugas klasifikasi dan regresi karena kesederhanaannya, kemampuan adaptasi, dan kekuatannya dalam menangani data non-linear. KNN membutuhkan waktu komputasi yang lebih lama dibandingkan dengan algoritma lainnya. KNN lebih baik jika data pelatihan lebih besar dari jumlah fitur, sedangkan SVM lebih baik jika jumlah fitur lebih banyak dari data pelatihan. KNN mendukung solusi non-linear, sedangkan regresi logistik hanya mendukung solusi linear, namun regresi logistik lebih cepat daripada KNN.

E. Y. Boateng, *et al* (2020) melakukan penelitian untuk mengevaluasi algoritma klasifikasi, KNN efektif untuk data dengan tetangga terdekat yang sangat informatif, sementara SVM unggul dalam menangani noise dan outlier. Penelitian ini mengkaji dan membandingkan empat algoritma klasifikasi non-parametrik: K-Nearest Neighbor (KNN), Support Vector Machine (SVM), Random Forest (RF), dan Neural Network (NN). RF sensitif terhadap perubahan data pelatihan dan cenderung overfitting, sedangkan KNN mudah diimplementasikan tetapi lambat

untuk data besar. SVM dan RF tidak sensitif terhadap noise, sehingga baik untuk data tidak seimbang. Data input besar memperlambat klasifikasi NN dan KNN dibanding SVM dan RF.

Menurut R. Andrian, *et al.*(2019), algoritma K-Nearest Neighbors (KNN) sangat efektif dalam mengklasifikasikan motif Batik Lampung berdasarkan fitur visual RGB. Citra motif batik diubah ukuran menjadi 50 x 50 piksel dan dikonversi menjadi grayscale. Fitur Gray Level Co-Occurrence Matrix (GLCM) diekstraksi, kemudian KNN dengan nilai $k = 3, 5, 7, 9, 11$ dan sudut orientasi $0^\circ, 45^\circ, 90^\circ, 135^\circ$ diaplikasikan untuk klasifikasi motif. Akurasi terbaik 97,96% dicapai pada $k = 7$ dan sudut 135° . Keunggulan KNN adalah sederhana, tanpa asumsi data, serta efektif untuk kasus non-linear dengan jumlah data pelatihan kecil.

Menurut I. N. Yulita, *et al.* (2019) bahwa dalam klasifikasi posisi tubuh berdasarkan data sensor smartphone, SVM sedikit mengungguli KNN dalam akurasi keseluruhan, namun KNN lebih baik dalam menangani transisi postur yang cepat. Hasil metode KNN untuk semua variasi menunjukkan akurasi di sekitar 85,3% - 85,7% dengan menggunakan validasi silang 10 lipatan. Untuk SVM dengan kernel RBF (Radial Basis Function), akurasi hasil validasi silang juga sekitar 86%. Dari hasil tersebut dapat disimpulkan bahwa baik *K-Nearest Neighbor* maupun *Support Vector Machine* dengan kernel RBF memberikan performa yang memuaskan.

Penelitian dari J. Cao, *et al.* (2020) mengusulkan model klasifikasi lalu lintas jaringan yang ditingkatkan berbasis *Support Vector Machine* (SVM). Metode pemilihan fitur hibrida dan algoritma optimasi parameter yang disempurnakan

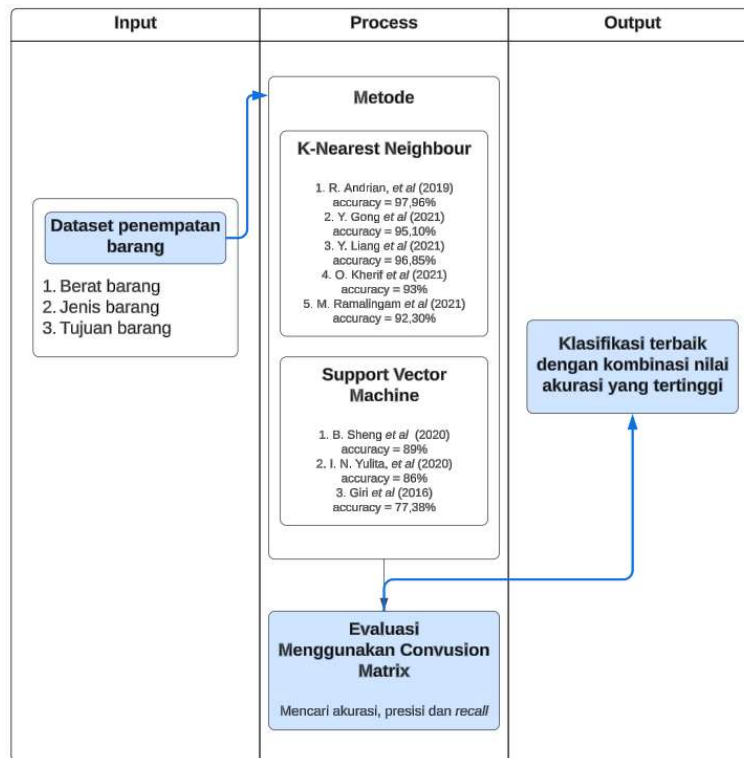
diperkenalkan untuk mengatasi tantangan dalam menentukan fitur optimal, kombinasi karakteristik efektif, serta menyeimbangkan risiko empiris dan kemampuan generalisasi. Model SVM yang ditingkatkan ini unggul dengan akurasi klasifikasi lebih tinggi, dimensi lebih rendah, waktu komputasi lebih singkat, serta mampu mencegah overfitting saat optimasi parameter.

Menurut P. Visutsak (2021), sistem pengenalan aktivitas untuk orang lanjut usia membantu mereka tinggal sendiri di rumah dengan aman dan meningkatkan kualitas hidup. Penelitian ini menggunakan metode *Backpropagation Neural Networks* untuk mendeteksi dan mengklasifikasikan aktivitas harian orang lanjut usia seperti berbaring, berdiri, duduk, berjalan, dan makan. Model yang diusulkan dilatih untuk mengonstruksi model Neural Networks dan digunakan untuk mengklasifikasikan aktivitas harian dasar orang lanjut usia. Hasilnya, model mencapai presisi 0,78, recall 0,72, dan skor F1 0,74.

A. Almomani, *et al* (2023) melakukan penelitian dengan menyajikan sistem *Classifying Voice Gender, Age, and Accent (CVGAA)* dengan algoritma *Backpropagation Neural Network (BPNN)* dan bagging untuk mengklasifikasikan jenis kelamin, usia, dan aksen suara. BPNN adaptif menunjukkan akurasi tinggi 98% dalam identifikasi gender, melebihi algoritma lain yang digunakan untuk masalah ini. Meski bagging memiliki akurasi terbaik 98,10% untuk gender, 55,39% untuk dataset suara umum, dan 78,94% untuk klasifikasi usia dan aksen, BPNN merupakan algoritma unggul untuk klasifikasi suara berkat kemampuannya memanfaatkan fitur sensorik seperti fitur berbasis ritme untuk membedakan kategori gender.

2.2 Kerangka Teori

Penelitian ini merujuk dari beberapa penelitian yang sudah terlebih dahulu dilakukan sehingga penelitian terdahulu menjadi kerangka teori dari adanya penelitian tentang prediksi penempatan seperti pada gambar 2.1.



Gambar 2.1. Kerangka Teori

Gambar 2.1 merupakan ringkasan penelitian yang menggunakan metode *K-Nearest Neighbour* dan *Support Vector Machine* untuk menentukan model klasifikasi penempatan barang pada alat angkut dengan performa terbaik.

Beberapa penelitian lain menggunakan metode yang berbeda seperti Paul *et al* (2022) yang menggunakan metode *Multiple Logistic Regression* dengan nilai akurasi sebesar 68,13%. Untuk penelitian terdahulu lainnya lebih jelasnya bisa dilihat pada tabel 2.1.

Tabel 2.1. Daftar Referensi Kerangka Teori Prediksi Penempatan Barang

No	Referensi	Metode	Judul	Subyek
1	R. Andrian, <i>et al.</i> (2019)	KNN	k-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs	Klasifikasi motif-motif Batik Lampung berdasarkan sampel gambar dalam format RGB
2	Y. Gong & P. Zhang (2021)	KNN	Research and Realization of Air Quality Grade Prediction Based on KNN	Pengembangan model prediksi kualitas udara
3	Y. Liang <i>et al</i> (2021)	KNN	Multilabel Classification Model for Type Recognition of Single-Phase-to-Ground Fault Based on KNN-Bayesian Method	Klasifikasi multilabel untuk mengenali jenis-jenis kesalahan satu fasa-ke-tanah pada jaringan distribusi listrik
4	O. Kherif <i>et al</i> (2021)	KNN	Accuracy Improvement of Power Transformer Faults Diagnostic Using KNN Classifier With Decision Tree Principle	Pengembangan metode diagnostik gangguan transformator daya
5	M. Ramalingam <i>et al</i> (2021)	KNN	Data Mining Algorithms(KNN & DT) Based Predictive Analysis on Selected Candidates in Academic Performance	Analisis dan prediksi kinerja akademik serta penempatan mahasiswa
6	B. Sheng <i>et al.</i> (2020)	<ul style="list-style-type: none"> - SVM - Decision Tree - KNN - EM 	A comparison of different machine learning algorithms, types and placements of activity monitors for physical activity classification	Mengklasifikasikan aktivitas fisik menggunakan algoritma supervised machine learning (SML) berdasarkan data akselerometer
7	I. N. Yulita, <i>et al.</i> (2019)	<ul style="list-style-type: none"> - SVM - KNN 	Human Activities and Postural Transitions Classification using Support Vector Machine and K-	Klasifikasi penentuan posisi tubuh berdasarkan data sensor pada smartphone

No	Referensi	Metode	Judul	Subyek
			Nearest Neighbor Methods	
8	Shao <i>et al.</i> (2009)	FNN Optimized by GA, FNN	Logistics Distribution Center Location Evaluation Based on Genetic Algorithm and Fuzzy Neural Network	Pengembangan sistem evaluasi penempatan pusat distribusi logistik
9	Sharma <i>et al.</i> (2014)	Gradient Descent Algorithm	Placement prediction system using logistic regression	Pengembangan sistem prediktor penempatan mahasiswa
10	Giri <i>et al.</i> (2016)	- Support Vector Machine (SVM) - KNN	A Placement Prediction System using K-nearest Neighbors Classifier	Memperkirakan penempatan mahasiswa di perusahaan IT
11	Paul <i>et al.</i> (2022)	Multiple Logistic Regression	Placement Prediction Using Multiple Logistic Regression Method	Prediksi penempatan mahasiswa menggunakan metode regresi logistik berganda
12	Fan, <i>et al.</i> (2019)	- Auto-Regressive Moving Average (ARMA) - BPNN - KNN	Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting	Pengusulan <i>load forecasting</i> untuk menganalisis karakteristik dan regulasi ketenagalistrikan
13	B. Cancela <i>et al.</i> (2021)	Neural Network	Can data placement be effective for Neural Networks classification tasks? Introducing the Orthogonal Loss	Efektivitas penempatan data (data placement) untuk tugas klasifikasi menggunakan Neural Network (NN)
14	A. Faza <i>et al.</i> (2024)	Machine Learning	Optimal PMU Placement for Fault Classification and Localization Using Enhanced Feature Selection in Machine Learning Algorithms	Penempatan optimal dari Phasor Measurement Unit (PMU) untuk tugas klasifikasi dan lokalisasi gangguan pada aplikasi <i>power systems</i>
15	K. Taunk, <i>et al.</i> (2019)	- KNN - SVM	A Brief Review of Nearest Neighbor Algorithm for Learning and Classification	Efektivitas algoritma KNN untuk klasifikasi dan regresi

Pada tabel 2.2, merupakan tabel yang menunjukkan akurasi tertinggi dalam penggunaan prediksi penempatan. Metode KNN pada penelitian R. Andrian *et al* tahun 2019 menunjukkan bahwa akurasi yang dihasilkan adalah 97,96%.

Tabel 2.2. *Ranking Performance Accuracy* untuk Prediksi Penempatan

No	Referensi	Tahun	Metode	Akurasi
1	R. Andrian, <i>et al</i>	2019	KNN	97,96%
2	Y. Gong <i>et al</i>	2021	KNN	95,10%
3	Y. Liang <i>et al</i>	2021	KNN	96,85%
4	O. Kherif <i>et al</i>	2021	KNN	93%
5	M. Ramalingam <i>et al</i>	2021	KNN	92,30%
6	B. Sheng <i>et al</i>	2020	SVM	89%
7	B. Sheng <i>et al</i>	2020	Ensemble Method	89%
8	I. N. Yulita, <i>et al</i>	2019	SVM	86%
9	I. N. Yulita, <i>et al</i>	2019	KNN	85,70%
10	Shao <i>et al</i>	2009	FNN Optimized by GA	85%
11	Sharma <i>et al</i>	2014	Gradient Descent Algorithm	83,33%
12	Shao <i>et al</i>	2009	FNN	82%
13	B. Sheng <i>et al</i>	2020	KNN	80%
14	Giri <i>et al</i>	2016	KNN	78,57%
15	Giri <i>et al</i>	2016	SVM	77,38%
16	Giri <i>et al</i>	2016	Logistic Regression	75%
17	B. Sheng <i>et al</i>	2020	Decision Tree	70%
18	Paul <i>et al</i>	2022	Multiple Logistic Regression	68,13%


Berdasarkan dari nilai *performance accuracy* pada tabel 2.2, penelitian ini akan menentukan model klasifikasi KNN penempatan barang pada alat angkut dengan performa terbaik.

BAB III

METODE PENELITIAN

3.1 Desain Penelitian

Pada penelitian ini ada beberapa prosedur penelitian dalam memprediksi penempatan barang pada alat angkut yaitu *data collection*, desain sistem, eksperimen, evaluasi dan kesimpulan.



Gambar 3.1. Prosedur Penelitian

(Sumber: Diolah Peneliti)

Gambar 3.1 menjelaskan rancangan prosedur penelitian dimulai dari pengumpulan data, kemudian merancang desain sistem dan melakukan eksperimen dengan model algoritma KNN. Selanjutnya melakukan evaluasi dari hasil eksperimen dan melakukan analisa. Setelah mendapatkan analisa dari penelitian, proses selanjutnya adalah memberikan kesimpulan dari penelitian yang telah dilakukan.

3.2 *Data Collection*

Pengumpulan data pada penelitian kali ini menggunakan data barang dari kantor pos Indonesia. Data penelitian mengambil dari data pengiriman barang kantor pos pada tanggal 10 November 2022 – 17 November 2022. Data tersebut menjadi acuan data untuk melakukan klasifikasi penempatan barang pada alat angkut di kantor pos. Tabel 3.1 menunjukkan *sample dataset* yang digunakan pada penelitian kali ini.

Tabel 3.1 Data Barang 10 November 2022 – 17 November 2022

No	Kota Tujuan	Berat (Kg)	Jenis Barang	Tempat
1	Kota Pasuruan, Panggungrejo, Bangilan	0.02	Dokumen	Belakang Atas
2	Kota Pasuruan, Panggungrejo, Bangilan	0.02	Dokumen	Belakang Atas
3	Kota Pasuruan, Panggungrejo, Bangilan	0.1	Dokumen	Belakang Atas
4	Kota Pasuruan, Panggungrejo, Bangilan	0.1	Dokumen	Belakang Atas
5	Kota Pasuruan, Panggungrejo, Bangilan	0.1	Paket	Belakang Bawah
6	Kota Pasuruan, Panggungrejo, Bangilan	0.01	Dokumen	Belakang Atas
7	Kota Pasuruan, Panggungrejo, Bangilan	0.01	Paket	Belakang Bawah
8	Kota Pasuruan, Panggungrejo, Bangilan	0.01	Dokumen	Belakang Atas
9	Kota Pasuruan, Panggungrejo, Bangilan	0.03	Dokumen	Belakang Atas
10	Kota Pasuruan, Panggungrejo, Bangilan	0.02	Dokumen	Belakang Atas
...				
7021	Kota Bandung, Arcamanik, Cisaranten Kulon	0.5	Paket	Tengah Bawah
7022	Kota Bekasi, Bekasi Selatan, Kayuringin Jaya	0.6	Paket	Tengah Bawah
7023	Kota Bekasi, Bekasi Selatan, Kayuringin Jaya	0.25	Paket	Tengah Bawah
7024	Kota Bekasi, Bekasi Selatan, Kayuringin Jaya	0.4	Paket	Tengah Bawah
7025	Kota Bekasi, Bekasi Selatan, Kayuringin Jaya	0.8	Paket	Tengah Atas
7026	Kota Bekasi, Bekasi Selatan, Kayuringin Jaya	2.6	Paket	Tengah Bawah
7027	Kota Bekasi, Mustika Jaya, Cimuning	1	Dokumen	Tengah Bawah
7028	Kota Bekasi, Mustika Jaya, Cimuning	1	Paket	Tengah Atas
7029	Kota Bekasi, Mustika Jaya, Cimuning	0.1	Paket	Tengah Bawah
7030	Kota Bekasi, Mustika Jaya, Cimuning	0.11	Dokumen	Tengah Bawah

(Sumber: Data Pengiriman Barang Kantor Pos tanggal 10 November 2022 – 17 November 2022)

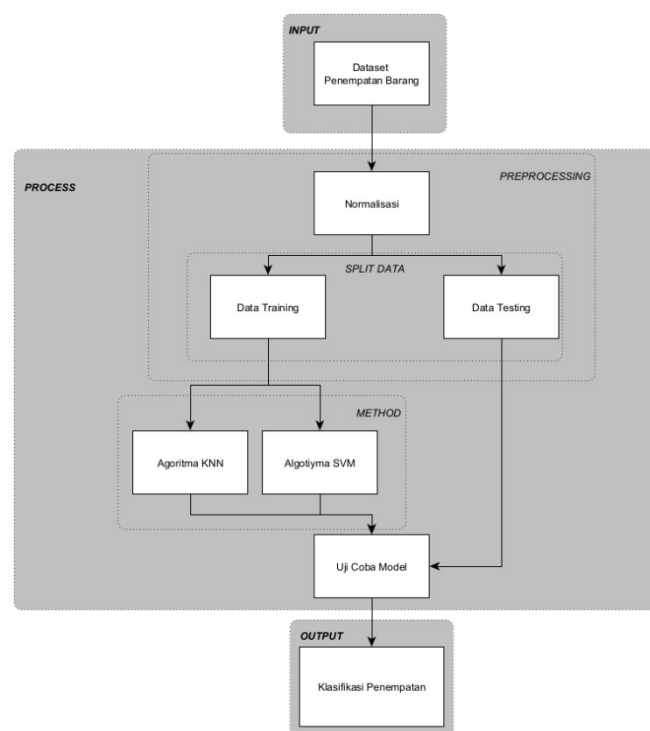
Dalam tabel tersebut, terdapat kota tujuan, berat dalam bentuk kilogram, jenis barang dan tempat. Data-data tersebut mempunyai beberapa atribut dalam setiap data pada barang yang akan dikirimkan. Atribut-atribut tersebut ditunjukkan pada tabel 3.2.

Tabel 3.2 Atribut Data Barang

Data	Atribut
Kota Tujuan	Tujuan Seluruh Indonesia
Berat	Berat (Kg)
Jenis Barang	1. Paket 2. Dokumen
Tempat	1. Depan Atas (DA) 2. Depan Bawah (DB) 3. Tengah Atas (TA) 4. Tengah Bawah (TB) 5. Belakang Atas (BA) 6. Belakang Bawah (BB)

3.3 Desain Sistem

Penelitian ini menggunakan desain sistem seperti yang ditunjukkan pada gambar 3.2. Input yang merupakan dataset dari penempatan barang. Kemudian data tersebut akan melewati tahap *preprocessing data* kemudian akan melukan proses klasifikasi sesuai dengan metodenya. Setelah perhitungan tersebut, di-evaluasi hasilnya dan menghasilkan output berupa model dengan performa terbaik.



Gambar 3.2. Desain Sistem Penempatan Barang pada Alat Angkut

(Sumber: Diolah Peneliti)

3.3.1 Preprocessing Data

Tahap *preprocessing data* ini membuat pengumpulan data pada proses sebelumnya yang akan mengalami pengolahan sehingga data tersebut menjadi data yang berguna dan efisien. Tahapan ini mengalami 2 kali tahap pemrosesan, yakni

tahap normalisasi sehingga data menjadi seragam, serta tahap *split data* supaya data terbagi menjadi *data testing* dan *data training*.

3.3.2 Normalisasi

Normalisasi merupakan suatu cara untuk merubah nilai *dataset* yang nilainya sangat besar ragam variasinya, menjadi nilai yang lebih kecil (Patro & sahu, 2015). Pada penelitian kali ini, normalisasi nilainya berkisar antara 0 sampai dengan 1 sehingga untuk mencapai nilai yang seragam tersebut, penggunaan metode normalisasi *min-max* yang digunakan pada penelitian ini.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.1)$$

x' = data baru

x = data lama

x_{min} = nilai minimum data

x_{max} = nilai maksimum data

3.3.3 Split Data

Setelah tahapan normalisasi data, data yang nilainya sudah seragam tersebut akan mengalami tahapan *split data*. Tahapan ini merupakan cara untuk membagi data yang ada menjadi lebih dari 1 yang penggunaannya biasanya untuk membagi menjadi data *testing* dan data *training* yang berfungsi sebagai evaluasi dari performa suatu *machine learning*.

Data *training* adalah data yang diuji dengan suatu metode sehingga hasil dari data yang sudah mengalami pengolahan, dapat digunakan sebagai acuan untuk data *testing*. Sedangkan data *testing* merupakan data awal yang tidak diberikan suatu

metode terlebih dahulu agar data tersebut dapat dievaluasi performanya dari suatu model *machine learning*.

3.3.4 Model *K-Nearest Neighbor*

Model KNN dalam penelitian ini menggunakan perhitungan jarak euclidean untuk menentukan kelas dari data penempatan barang berdasarkan k tetangga terdekatnya. Berikut adalah tahapan dan rumus yang digunakan:

1. Perhitungan jarak menggunakan *Euclidean Distance*:

$$d(x, y) = \sqrt{\sum (x_i - y_i)^2}$$

Dimana:

- $d(x,y)$ = jarak antara data x dan y

- x_i = nilai fitur ke-i dari data x (data uji)

- y_i = nilai fitur ke-i dari data y (data latih)

- n = jumlah fitur

2. Pengurutan jarak dari yang terkecil ke terbesar

3. Pemilihan k tetangga terdekat dari hasil pengurutan

4. Penentuan kelas berdasarkan mayoritas kelas dari k tetangga terdekat

3.3.5 Model *Support Vector Machine*

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang bertujuan untuk memisahkan data ke dalam dua kelas dengan menggunakan batas *hyperplane* optimal. Model ini mencari margin terbesar antara data dari kedua kelas untuk memaksimalkan generalisasi pada data baru. Dengan menggunakan kernel dot (linear kernel), SVM tidak memetakan data ke ruang fitur yang lebih tinggi, melainkan tetap bekerja dalam ruang dimensi asli. Dalam metode SVM ini, persamaan yang dilakukan adalah sebagai berikut:

1. Fungsi *Hyperplane* Optimal

Model SVM menggunakan *hyperplane* yang didefinisikan sebagai berikut:

$$f(x) = w \cdot x + b$$

Di mana:

- w adalah vektor bobot yang menentukan orientasi *hyperplane*.
- b adalah bias untuk memindahkan *hyperplane*.
- x adalah data *input* (vektor fitur).

Hyperplane optimal memisahkan data dari dua kelas (+1 dan -1) dengan *margin* terbesar, sehingga memenuhi:

$$y_i(w \cdot x_i + b) \geq 1, \forall i$$

Di mana:

- y_i adalah label kelas (+1 atau -1).
- x_i adalah data pelatihan.

2. Fungsi Objektif untuk Optimasi

SVM meminimalkan fungsi objektif untuk mengoptimalkan margin:

$$\text{Minimalkan } \frac{1}{2} \|w\|^2$$

Dengan batasan kendala:

$$y_i(w \cdot x_i + b) \geq 1, \forall i$$

Pemecahan masalah ini dilakukan dengan menggunakan metode pengali Lagrange.

3. Fungsi Keputusan

Setelah pelatihan, fungsi keputusan SVM digunakan untuk mengklasifikasikan data baru:

$$f(x) = \text{sign}(w \cdot x + b)$$

Jika $f(x) > 0$, maka data diklasifikasikan sebagai kelas +1. Jika $f(x) < 0$, maka data diklasifikasikan sebagai kelas -1.

Dalam penelitian ini, metode SVM menggunakan parameter parameter yang ada sebagai berikut:

- Kernel Type: Dot (*linear kernel*).

Kernel ini digunakan untuk memisahkan data linier tanpa perlu transformasi ke ruang dimensi yang lebih tinggi. Dengan kernel dot (linear kernel), fungsi kernel $K(x_i, x_j)$ hanya melakukan produk dot antara vektor data:

$$K(x_i, x_j) = x_i \cdot x_j$$

Kernel ini cocok untuk data yang linier terpisah, seperti dalam penelitian ini

- *C (Regularization Parameter)*: 0.0.

Parameter ini tidak diatur dalam penelitian ini, sehingga model memaksimalkan *margin* tanpa penalti.

- *Max Iterations*: 100,000.

Jumlah iterasi maksimum untuk proses optimasi.

- *Scaling (Normalisasi)*: Aktif.

Data diskalakan agar setiap fitur memiliki rentang nilai yang seragam.

Model SVM yang digunakan dalam penelitian ini bertujuan untuk memisahkan data penempatan barang secara *linear*. Dengan meminimalkan fungsi objektif dan memaksimalkan *margin*, model ini sangat cocok untuk skenario di mana data memiliki distribusi *linear*. Hasil pengujian pada model ini menunjukkan bahwa konfigurasi yang diterapkan telah memberikan kinerja yang optimal pada dataset yang digunakan.

3.4 Eksperimen

Penelitian ini akan melakukan beberapa eksperimen dalam proses klasifikasi untuk mendapatkan hasil yang optimal. Proses *split data* akan melakukan eksperimen yaitu mencoba komposisi perbandingan jumlah *data training* dan *data testing* dan juga merubah nilai k. Nilai k merupakan jumlah nilai yang digunakan

untuk menentukan berapa banyak jumlah tetangga yang berfungsi untuk proses pengujian.

Peneliti menyarankan untuk menggunakan nilai ganjil pada k untuk menghindari nilai sama pada klasifikasi. Selain itu, disarankan juga untuk penggunaan nilai k tidak menggunakan 1 karena hasilnya yang terlalu rendah. Sehingga nilai k yang digunakan adalah nilai ganjil lebih dari 1 dan kurang dari 10.

3.5 Evaluasi

Setelah melakukan eksperimen, hasil yang telah muncul kemudian dilakukan evaluasi agar menunjukkan apakah sudah sesuai atau tidak. Menurut Satria *et al.* (2022), *Confusion matrix* adalah metode evaluasi yang penggunaannya untuk mencari akurasi, presisi, dan *recall* dari hasil penelitian dengan menggunakan *confusion matrix*.

Matriks ini berbentuk persegi dengan ukuran $N \times N$, di mana N merupakan jumlah kelas yang ada pada data. Penelitian ini mempunyai 6 kelas dalam penentuan klasifikasi penempatan barang.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

$TP = True Positive$ (jumlah data yang benar diprediksi sebagai positif)

$TN = True Negative$ (jumlah data yang salah diprediksi sebagai positif)

$FP = False Positive$ (jumlah data yang benar diprediksi sebagai negatif)

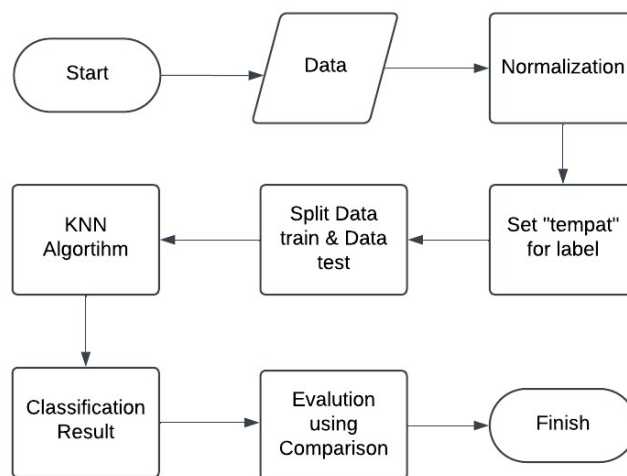
$FN = False Negative$ (jumlah data yang salah diprediksi sebagai negatif)

BAB IV

ANALISIS DAN PEMBAHASAN

4.1 Desain *K-Nearest Neighbor*

Penelitian ini menggunakan *Flowchart* seperti yang ditunjukkan pada gambar 4.1. *Dataset* penempatan barang pada input, pada tahap *preprocessing* di normalisasikan. Kemudian set 1 data sebagai label untuk dicari klasifikasinya dan dilakukan proses *split* untuk *training* dan *testing*, masuk ke dalam proses menghitung hasil normalisasi dataset menggunakan algoritma KNN. Dari proses tersebut, hasil perbandingan yang terbaik antara model algoritma KNN akan dievaluasi terlebih dahulu sehingga menghasilkan output klasifikasi penempatan alat angkut paling optimal.



Gambar 4.1. *Flowchart* proses klasifikasi model KNN

4.2 Uji Coba Model KNN

Pengujian *K-Nearest Neighbor* (KNN) pada penelitian ini akan memberikan pengujian dengan merubah parameter *split data* seperti tabel 4.3. dan nilai *k* sehingga hasil pengujian semuanya akan menghasilkan klasifikasi model KNN mana yang paling optimal berdasarkan dari akurasi, presisi, dan *recall*.

Tabel 4.1. Nama Pengujian dan Rasio *Split Data*

Nama	Rasio <i>Split Data</i> (<i>Training:Testing</i>)
Pengujian 1	90%:10%
Pengujian 2	80%:20%
Pengujian 3	70%:30%
Pengujian 4	60%:40%
Pengujian 5	50%:50%

4.2.1 Pengujian 1

Pada pengujian 1, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 90:10 dengan mencoba nilai $k = 3$, $k = 5$, $k = 7$, $k = 9$. Seperti yang terlihat pada hasil klasifikasi dan *confusion matrix* masing-masing nilai.

Tabel 4.2. Hasil klasifikasi pengujian 1 KNN nilai $k=3$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	63	28
Depan Bawah (2)	45	0
Tengah Atas (3)	245	289
Tengah Bawah (4)	312	370
Belakang Atas (5)	13	0
Belakang Bawah (6)	25	16

Pada tabel hasil klasifikasi dan *confusion matrix* dengan nilai $k = 3$, menunjukkan distribusi barang sesuai dengan kategori penempatannya berdasarkan *confusion matrix*.

Berdasarkan tabel 4.2, area "Tengah Bawah" (kelas 4) dan "Tengah Atas" (kelas 3) menjadi kelas dengan jumlah prediksi tertinggi, masing-masing sebanyak 370 dan 289 barang, sementara kelas lainnya seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2) tidak teridentifikasi sama sekali.

Tabel 4.3. Hasil *confusion matrix* pengujian 1 KNN nilai k=3

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	4	0	10	0	2	0
predi. 5	0	0	0	0	0	0
predi. 4	21	2	302	2	43	0
predi. 3	0	11	0	242	0	36
predi. 2	0	0	0	0	0	0
predi. 1	0	0	0	1	0	27
Accuracy	81.79%					
Recall	42.40%					
Precision	47.80%					

Sedangkan pada tabel 4.3, *confusion matrix* menunjukkan bahwa nilai akurasi mencapai 81,79%, sementara presisi sebesar 47,80%, dan *recall* sebesar 42,40%. Hal ini mengindikasikan bahwa model pengujian 1 KNN mampu mengklasifikasikan data dengan tingkat ketepatan yang cukup baik, meskipun performa *recall* menunjukkan adanya tantangan dalam menangkap data dari kelas minoritas seperti "Belakang Bawah" dan "Depan Bawah". Kesalahan klasifikasi terlihat dari jumlah barang yang salah prediksi pada kelas lain, seperti prediksi barang kelas 6 (Belakang Bawah) yang diklasifikasikan ke dalam kelas 4.

Tabel 4.4. Hasil klasifikasi pengujian 1 KNN nilai k=5

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	63	30
Depan Bawah (2)	45	0
Tengah Atas (3)	245	287
Tengah Bawah (4)	312	376
Belakang Atas (5)	13	0
Belakang Bawah (6)	25	10

Hasil klasifikasi menunjukkan adanya sedikit perbedaan dibandingkan dengan nilai k=3. Tabel 4.4 menunjukkan Area "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan jumlah prediksi tertinggi, yaitu sebanyak 376 barang, diikuti

oleh "Tengah Atas" (kelas 3) dengan 287 barang. Namun, kelas seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2) masih tidak teridentifikasi, menunjukkan ketidakmampuan model dalam menangkap pola dari kelas dengan distribusi data yang kecil.

Tabel 4.5. Hasil *confusion matrix* pengujian 1 KNN nilai k=5

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	1	0	9	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	24	2	303	2	45	0
predi. 3	0	10	0	241	0	36
predi. 2	0	0	0	0	0	0
predi. 1	0	1	0	2	0	27
Accuracy	81.37%					
Recall	40.39%					
Precision	44.09%					

Berdasarkan *confusion matrix* pada tabel 4.5 memberikan nilai akurasi sebesar 81,37%, sedikit lebih rendah dibandingkan dengan nilai k=3. Presisi juga mengalami penurunan menjadi 44,09%, sedangkan nilai *recall* menurun menjadi 40,39%. Penurunan pada nilai *recall* menunjukkan bahwa model semakin sulit dalam mendeteksi data dari kelas minoritas. Kesalahan klasifikasi yang signifikan masih terjadi pada beberapa kelas, seperti data barang dari kelas "Belakang Bawah" (kelas 6) yang lebih sering diklasifikasikan ke dalam "Tengah Bawah" (kelas 4).

Tabel 4.6. Hasil klasifikasi pengujian 1 KNN nilai k=7

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	63	26
Depan Bawah (2)	45	6
Tengah Atas (3)	245	291
Tengah Bawah (4)	312	366
Belakang Atas (5)	13	0
Belakang Bawah (6)	25	14

Pada pengujian dengan nilai parameter $k=7$, tabel 4.6 menunjukkan pola yang serupa dengan pengujian sebelumnya. Area "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan jumlah prediksi tertinggi, yaitu sebanyak 366 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 291 barang. Namun, seperti pada pengujian sebelumnya, kelas dengan jumlah data lebih kecil seperti "Belakang Atas" (kelas 5) tidak berhasil terprediksi, dan "Depan Bawah" (kelas 2) hanya memiliki sedikit prediksi yang benar.

Tabel 4.7. Hasil *confusion matrix* pengujian 1 KNN nilai $k=7$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	2	0	12	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	22	2	296	2	44	0
predi. 3	0	11	0	243	0	37
predi. 2	1	0	4	0	1	0
predi. 1	0	0	0	0	0	26
Accuracy	80.80%					
Recall	40.92%					
Precision	49.22%					

Tabel 4.7 menghasilkan akurasi sebesar 80,80%. Presisi mengalami sedikit peningkatan menjadi 49,22%, sementara *recall* tetap berada pada nilai rendah, yaitu 40,92%. Kesalahan klasifikasi yang signifikan masih terlihat, seperti barang dari kelas "Belakang Bawah" (kelas 6) yang diklasifikasikan ke dalam "Tengah Bawah" (kelas 4).

Tabel 4.8. Hasil klasifikasi pengujian 1 KNN nilai $k=9$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	63	26
Depan Bawah (2)	45	0
Tengah Atas (3)	245	291
Tengah Bawah (4)	312	386
Belakang Atas (5)	13	0
Belakang Bawah (6)	25	0

Pada pengujian terakhir dengan nilai parameter $k=9$, tabel 4.8 menunjukkan konsistensi dalam mendeteksi kelas mayoritas seperti "Tengah Bawah" (kelas 4), yang memiliki prediksi tertinggi sebanyak 386 barang, dan "Tengah Atas" (kelas 3) dengan 291 barang. Namun, kelas minoritas seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2) tidak berhasil terprediksi.

Tabel 4.9. Hasil *confusion matrix* pengujian 1 KNN nilai $k=9$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	25	2	312	2	45	0
predi. 3	0	11	0	243	0	37
predi. 2	0	0	0	0	0	0
predi. 1	0	0	0	0	0	26
Accuracy	82.65%					
Recall	40.08%					
Precision	44.06%					

Hasil evaluasi pada tabel 4.9 menunjukkan akurasi tertinggi dibandingkan pengujian sebelumnya, yaitu 82,65%. Namun, presisi kembali menurun menjadi 44,06%, dan *recall* juga menurun ke nilai 40,08%. Penurunan nilai presisi dan *recall* pada nilai k yang lebih besar ini disebabkan oleh efek *smoothing*, di mana model lebih condong ke kelas mayoritas, sehingga mengorbankan kemampuan mendeteksi kelas minoritas.

Tabel 4.10. Komparasi evaluasi pengujian 1 KNN

	k = 3	k = 5	k = 7	k = 9
Akurasi	81.79%	81.37%	80.80%	82.65%
Presisi	42.40%	40.39%	40.92%	40.08%
Recall	47.80%	44.09%	49.22%	44.06%

Sejumlah kesimpulan dapat diambil berdasarkan hasil evaluasi pada pengujian 1 dengan parameter nilai $k=3$, $k=5$, $k=7$, dan $k=9$ yang ditampilkan dalam Tabel 4.10. Nilai akurasi tertinggi tercatat sebesar 82,65% pada parameter $k=9$, yang menunjukkan bahwa model KNN dengan jumlah tetangga lebih banyak mampu memberikan hasil klasifikasi yang lebih baik secara keseluruhan. Presisi tertinggi, yaitu sebesar 49,22%, diperoleh pada parameter $k=7$, yang menandakan bahwa model dengan nilai ini lebih akurat dalam memprediksi data yang benar-benar sesuai dengan kelasnya. Sementara itu, *recall* tertinggi sebesar 42,40% dicapai pada parameter $k=3$, yang mengindikasikan bahwa model dengan nilai k kecil lebih efektif dalam menangkap data yang relevan, terutama dari kelas minoritas.

Peningkatan nilai k dinilai memberikan efek stabilisasi pada model dengan mengurangi pengaruh *outlier*, meskipun hal ini berdampak pada penurunan performa dalam mendeteksi kelas minoritas, seperti yang terlihat dari menurunnya nilai *recall* pada parameter $k=5$, $k=7$, dan $k=9$. Meskipun akurasi tertinggi tercapai pada $k=9$, keseimbangan performa antara presisi dan *recall* lebih baik ditemukan pada $k=7$, yang menjadikannya sebagai pilihan yang lebih optimal.

Berdasarkan evaluasi ini, penggunaan parameter $k=7$ disarankan jika fokus utama adalah menjaga keseimbangan antara presisi dan *recall*. Namun, jika prioritas utama adalah akurasi keseluruhan, parameter $k=9$ dapat dipertimbangkan.

Strategi tambahan, seperti penyeimbangan dataset atau penyesuaian parameter lainnya, diperlukan untuk meningkatkan performa *recall*, terutama untuk kelas minoritas.

4.2.2 Pengujian 2

Pada pengujian 2, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 80:20 dengan mencoba nilai $k = 3$, $k = 5$, $k = 7$, $k = 9$. Seperti yang terlihat pada hasil *performance* tabel 4.9, 4.10, 4.11, dan 4.12.

Tabel 4.11. Hasil klasifikasi pengujian 2 KNN nilai $k=3$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	122	64
Depan Bawah (2)	82	1
Tengah Atas (3)	505	580
Tengah Bawah (4)	625	731
Belakang Atas (5)	24	0
Belakang Bawah (6)	48	30

Tabel 4.11 menunjukkan bahwa area "Tengah Bawah" (kelas 4) memiliki jumlah prediksi tertinggi, yaitu 731 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 580 barang. Namun, kelas dengan distribusi kecil seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2) kembali tidak teridentifikasi dengan baik.

Tabel 4.12. Hasil *confusion matrix* pengujian 2 KNN nilai $k=3$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	0	20	0	5	0
predi. 5	0	0	0	0	0	0
predi. 4	43	3	604	4	77	0
predi. 3	0	20	0	494	0	66
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	7	0	56
Accuracy	82.43%					
Recall	41.80%					
Precision	45.33%					

Tabel 4.12 menunjukkan akurasi model tercatat sebesar 82,43%, dengan nilai presisi sebesar 45,33% dan *recall* sebesar 41,80%. Pada nilai ini, model menunjukkan kemampuan yang cukup baik dalam mendeteksi data dari berbagai kelas. Kelas mayoritas seperti "Tengah Bawah" (kelas 4) dan "Tengah Atas" (kelas 3) masih menjadi fokus utama prediksi, sementara kelas dengan distribusi data yang lebih kecil, seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2), tidak berhasil diprediksi secara memadai.

Tabel 4.13. Hasil klasifikasi pengujian 2 KNN nilai k=5

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	122	61
Depan Bawah (2)	82	2
Tengah Atas (3)	505	583
Tengah Bawah (4)	625	716
Belakang Atas (5)	24	0
Belakang Bawah (6)	48	44

Tabel 4.13 menunjukkan Pengujian dengan nilai k=5 menunjukkan bahwa area "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan prediksi tertinggi, yaitu 716 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 583 barang. Kelas dengan distribusi kecil, seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5), tetap mengalami kesulitan dalam terdeteksi secara akurat.

Tabel 4.14. Hasil *confusion matrix* pengujian 2 KNN nilai k=5

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	0	34	0	5	0
predi. 5	0	0	0	0	0	0
predi. 4	43	3	589	4	77	0
predi. 3	0	20	0	496	0	67
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	5	0	55
Accuracy	81.44%					
Recall	41.33%					
Precision	44.81%					

Tabel 4.14 menunjukkan akurasi mengalami sedikit penurunan menjadi 81,44%, sementara nilai presisi dan *recall* masing-masing tercatat sebesar 44,81% dan 41,33%. Penurunan kinerja ini menunjukkan bahwa model mulai mengurangi sensitivitasnya terhadap data dari kelas minoritas saat jumlah tetangga yang diperhitungkan meningkat.

Tabel 4.15. Hasil klasifikasi pengujian 2 KNN nilai k=7

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	122	61
Depan Bawah (2)	82	2
Tengah Atas (3)	505	583
Tengah Bawah (4)	625	730
Belakang Atas (5)	24	0
Belakang Bawah (6)	48	30

Pada pengujian dengan nilai k=7, Tabel 4.15 menunjukkan bahwa "Tengah Bawah" (kelas 4) kembali menjadi kelas dengan prediksi tertinggi, yaitu 730 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 583 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) masih tidak dapat terprediksi dengan baik, sementara "Belakang Atas" (kelas 5) tetap tidak terdeteksi.

Tabel 4.16. Hasil *confusion matrix* pengujian 2 KNN nilai $k=7$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	2	0	28	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	46	3	595	4	82	0
predi. 3	0	20	0	496	0	67
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	5	0	55
Accuracy	81.65%					
Recall	40.44%					
Precision	43.90%					

Tabel 4.16 menunjukkan nilai akurasi mencapai 81,65%, dengan presisi sebesar 43,90% dan *recall* sebesar 40,44%. Performa model pada nilai ini masih menunjukkan kecenderungan untuk lebih mengutamakan prediksi pada kelas mayoritas, dengan kemampuan yang lebih rendah dalam mendeteksi kelas minoritas.

Tabel 4.17. Hasil klasifikasi pengujian 2 KNN nilai $k=9$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	122	61
Depan Bawah (2)	82	1
Tengah Atas (3)	505	583
Tengah Bawah (4)	625	761
Belakang Atas (5)	24	0
Belakang Bawah (6)	48	0

Hasil pada nilai $k=9$ pada tabel 4.17 menunjukkan bahwa "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi, yaitu sebanyak 761 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 583 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap sulit untuk diklasifikasikan dengan benar.

Tabel 4.18. Hasil *confusion matrix* pengujian 2 KNN nilai k=9

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	48	3	624	4	82	0
predi. 3	0	20	0	496	0	67
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	5	0	55
Accuracy	83.57%					
Recall	40.52%					
Precision	42.87%					

Nilai akurasi tertinggi pada pengujian ini diperoleh pada nilai k=9, yaitu sesuai pada tabel 4.18 sebesar 83,57%. Namun, nilai presisi dan *recall* masing-masing menurun menjadi 42,87% dan 40,52%, menunjukkan bahwa meskipun akurasi meningkat, kemampuan model untuk menangkap data dari kelas minoritas semakin terbatas.

Tabel 4.19. Komparasi evaluasi pengujian 2 KNN

	k = 3	k = 5	k = 7	k = 9
Akurasi	82.43%	81.44%	81.65%	83.57%
Presisi	41.80%	41.33%	40.44%	40.52%
Recall	45.33%	44.81%	43.90%	42.87%

Tabel 4.19 menunjukkan hasil komparasi dari evaluasi pengujian yang telah dilakukan. Pengujian kedua menunjukkan bahwa nilai akurasi tertinggi tercapai pada k=9 dengan 83,57%, sementara nilai presisi tertinggi sebesar 45,33% dicapai pada k=3. *Recall* tertinggi sebesar 41,80% juga dicapai pada k=3. Peningkatan nilai k memberikan stabilitas pada model, tetapi mengorbankan performa *recall*, terutama untuk kelas dengan distribusi data kecil. Untuk kasus ini, jika tujuan utama

adalah keseimbangan antara presisi dan *recall*, maka nilai $k=3$ lebih optimal.

Namun, jika fokusnya adalah akurasi keseluruhan, nilai $k=9$ lebih disarankan.

4.2.3 Pengujian 3

Pada pengujian 3, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 70:30 dengan mencoba nilai $k = 3, k = 5, k = 7, k = 9$.

Tabel 4.20. Hasil klasifikasi pengujian 3 KNN nilai $k=3$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	176	95
Depan Bawah (2)	132	1
Tengah Atas (3)	779	880
Tengah Bawah (4)	921	1091
Belakang Atas (5)	30	0
Belakang Bawah (6)	71	42

Hasil klasifikasi pada tabel 4.20 menunjukkan bahwa area "Tengah Bawah" (kelas 4) memiliki jumlah prediksi tertinggi, yaitu 1.091 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 880 barang. Sementara itu, kelas-kelas dengan distribusi kecil, seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2), masih sulit untuk teridentifikasi dengan benar.

Tabel 4.21. Hasil *confusion matrix* pengujian 3 KNN nilai $k=3$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	0	29	0	8	0
predi. 5	0	0	0	0	0	0
predi. 4	66	3	891	7	124	0
predi. 3	0	26	0	763	0	91
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	9	0	85
Accuracy	82.69%					
Recall	41.67%					
Precision	44.96%					

Hasil evaluasi *confusion matrix* pada tabel 4.21 menghasilkan nilai akurasi sebesar 82,69%, dengan presisi 44,96% dan recall 41,67%. Kesalahan prediksi cukup besar terlihat pada kelas minoritas, seperti "Belakang Bawah" (kelas 6), yang sebagian besar barangnya diklasifikasikan ke kelas mayoritas seperti "Tengah Bawah" (kelas 4).

Tabel 4.22. Hasil klasifikasi pengujian 3 KNN nilai $k=5$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	176	92
Depan Bawah (2)	132	2
Tengah Atas (3)	779	883
Tengah Bawah (4)	921	1068
Belakang Atas (5)	30	0
Belakang Bawah (6)	71	64

Pada nilai $k=5$, hasil klasifikasi tabel 4.22 menunjukkan bahwa "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan jumlah prediksi tertinggi, yaitu 1.068 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 883 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap sulit untuk teridentifikasi.

Tabel 4.23. Hasil *confusion matrix* pengujian 3 KNN nilai $k=5$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	6	0	50	0	8	0
predi. 5	0	0	0	0	0	0
predi. 4	65	3	869	7	124	0
predi. 3	0	26	0	765	0	92
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	7	0	84
Accuracy	81.74%					
Recall	41.46%					
Precision	44.78%					

Evaluasi *confusion matrix* di tabel 4.23 menunjukkan nilai akurasi sebesar 81,74%, dengan presisi 44,78% dan *recall* 41,46%. Kesalahan klasifikasi tetap dominan pada kelas minoritas, seperti "Belakang Bawah" (kelas 6), yang sering diklasifikasikan ke kelas mayoritas seperti kelas 4. Penurunan nilai *recall* mengindikasikan bahwa model mulai kehilangan sensitivitas terhadap data minoritas seiring dengan peningkatan nilai k .

Tabel 4.24. Hasil klasifikasi pengujian 3 KNN nilai $k=7$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	176	93
Depan Bawah (2)	132	2
Tengah Atas (3)	779	882
Tengah Bawah (4)	921	1123
Belakang Atas (5)	30	0
Belakang Bawah (6)	71	9

Pada nilai $k=7$, tabel 4.24 menunjukkan hasil klasifikasi dengan pola yang mirip dengan nilai k sebelumnya. Area "Tengah Bawah" (kelas 4) memiliki jumlah prediksi tertinggi, yaitu 1.123 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 882 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap tidak teridentifikasi secara signifikan.

Tabel 4.25. Hasil *confusion matrix* pengujian 3 KNN nilai $k=7$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	1	0	8	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	70	3	911	7	132	0
predi. 3	0	26	0	764	0	92
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	8	0	84
Accuracy	83.45%					
Recall	41.02%					
Precision	44.86%					

Pada nilai $k=7$, tabel 4.24 menunjukkan hasil klasifikasi dengan pola yang mirip dengan nilai k sebelumnya. Area "Tengah Bawah" (kelas 4) memiliki jumlah prediksi tertinggi, yaitu 1.123 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 882 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap tidak teridentifikasi secara signifikan.

Hasil evaluasi *confusion matrix* pada tabel 4.25 menunjukkan nilai akurasi sebesar 83,45%, dengan presisi 44,86% dan *recall* 41,02%. Penambahan nilai k memberikan stabilitas lebih tinggi pada prediksi untuk kelas mayoritas, tetapi performa dalam mendeteksi kelas minoritas terus menurun.

Tabel 4.26. Hasil klasifikasi pengujian 3 KNN nilai $k=9$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	176	94
Depan Bawah (2)	132	1
Tengah Atas (3)	779	881
Tengah Bawah (4)	921	1133
Belakang Atas (5)	30	0
Belakang Bawah (6)	71	0

Hasil klasifikasi pada nilai $k=9$ yang terlihat pada tabel 4.26 menunjukkan bahwa "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi, yaitu 1.133 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 881 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) masih sulit untuk teridentifikasi dengan baik.

Tabel 4.27. Hasil *confusion matrix* pengujian 3 KNN nilai k=9

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	71	3	920	7	132	0
predi. 3	0	26	0	763	0	92
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	9	0	84
Accuracy	83.78%					
Recall	40.93%					
Precision	42.86%					

Pada tabel 4.27, Evaluasi *confusion matrix* memberikan nilai akurasi tertinggi pada pengujian ini, yaitu 83,78%, dengan presisi 42,86% dan *recall* 40,93%. Nilai k yang lebih besar meningkatkan akurasi secara keseluruhan, tetapi sensitivitas terhadap kelas minoritas tetap menurun.

Berdasarkan tabel 4.28, Pengujian ketiga menunjukkan bahwa nilai akurasi tertinggi diperoleh pada k=9, yaitu 83,78%, sementara presisi tertinggi sebesar 44,96% dicapai pada k=3. *Recall* tertinggi juga dicapai pada k=3 dengan nilai 41,67%. Peningkatan nilai k memberikan stabilitas pada model dengan mengurangi pengaruh outlier, tetapi performa dalam mendeteksi kelas dengan distribusi kecil cenderung menurun. Jika prioritas utama adalah akurasi keseluruhan, parameter k=9 dapat dipilih. Namun, untuk keseimbangan antara presisi dan recall, parameter k=3 menjadi opsi yang lebih baik. Strategi tambahan, seperti balancing dataset atau penggunaan metode augmentasi, dapat membantu meningkatkan performa pada kelas minoritas.

Tabel 4.28. Komparasi evaluasi pengujian 3 KNN

	k = 3	k = 5	k = 7	k = 9
Akurasi	82.69%	81.74%	83.45%	83.78%
Presisi	41.67%	41.46%	41.02%	40.93%
Recall	44.96%	44.78%	44.86%	42.86%

4.2.4 Pengujian 4

Pada pengujian 4, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 60:40 dengan mencoba nilai $k = 3$, $k = 5$, $k = 7$, $k = 9$.

Tabel 4.29. Hasil klasifikasi pengujian 4 KNN nilai $k=3$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	242	127
Depan Bawah (2)	172	1
Tengah Atas (3)	1027	1173
Tengah Bawah (4)	1242	1450
Belakang Atas (5)	41	0
Belakang Bawah (6)	88	61

Pada pengujian dengan nilai $k=3$ tabel 4.29, hasil klasifikasi menunjukkan bahwa area "Tengah Bawah" (kelas 4) memiliki jumlah prediksi tertinggi, yaitu sebanyak 1.450 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.173 barang. Sementara itu, kelas dengan distribusi kecil, seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2), tetap sulit teridentifikasi.

Tabel 4.30. Hasil *confusion matrix* pengujian 4 KNN nilai $k=3$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	0	48	0	8	0
predi. 5	0	0	0	0	0	0
predi. 4	83	3	1193	7	164	0
predi. 3	0	37	0	1005	0	131
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	15	0	111
Accuracy	82.29%					
Recall	40.91%					
Precision	43.93%					

Evaluasi pada tabel 4.30 menghasilkan nilai akurasi sebesar 82,29%, presisi 43,93%, dan *recall* 40,91%. Kesalahan klasifikasi masih dominan pada kelas minoritas seperti "Belakang Bawah" (kelas 6), yang sebagian besar barangnya diklasifikasikan sebagai kelas mayoritas seperti "Tengah Bawah" (kelas 4). Model dengan nilai $k=3$ cenderung lebih sensitif terhadap data, tetapi tetap menghadapi kendala pada kelas minoritas.

Tabel 4.31. Hasil klasifikasi pengujian 4 KNN nilai $k=5$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	242	119
Depan Bawah (2)	172	2
Tengah Atas (3)	1027	1181
Tengah Bawah (4)	1242	1423
Belakang Atas (5)	41	0
Belakang Bawah (6)	88	87

Pada nilai $k=5$, hasil klasifikasi di tabel 4.31 menunjukkan bahwa "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan jumlah prediksi tertinggi, yaitu 1.423 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.181 barang. Namun, kelas dengan distribusi kecil seperti "Depan Bawah" (kelas 2) tetap tidak teridentifikasi dengan baik.

Tabel 4.32. Hasil *confusion matrix* pengujian 4 KNN nilai $k=5$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	6	0	72	0	9	0
predi. 5	0	0	0	0	0	0
predi. 4	82	3	1168	7	163	0
predi. 3	0	37	0	1010	0	134
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	10	0	108
Accuracy	81.51%					
Recall	40.64%					
Precision	44.21%					

Sedangkan pada tabel 4.32, menunjukkan nilai akurasi sebesar 81,51%, dengan presisi sebesar 44,21% dan *recall* sebesar 40,64%. Kesalahan klasifikasi masih terlihat pada kelas minoritas, di mana data kelas kecil lebih sering diklasifikasikan sebagai bagian dari kelas mayoritas. Peningkatan nilai *k* menyebabkan model menjadi lebih stabil, tetapi kurang sensitif terhadap kelas minoritas.

Tabel 4.33. Hasil klasifikasi pengujian 4 KNN nilai *k*=7

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	242	120
Depan Bawah (2)	172	2
Tengah Atas (3)	1027	1180
Tengah Bawah (4)	1242	1494
Belakang Atas (5)	41	0
Belakang Bawah (6)	88	16

Hasil klasifikasi nilai *k*=7 menunjukkan pola serupa, terlihat pada tabel 4.33, "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi, yaitu sebanyak 1.494 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.180 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap sulit untuk diprediksi secara signifikan.

Tabel 4.34. Hasil *confusion matrix* pengujian 4 KNN nilai *k*=7

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	1	0	15	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	87	3	1225	7	172	0
predi. 3	0	37	0	1009	0	134
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	11	0	108
Accuracy	83.32%					
Recall	40.44%					
Precision	43.96%					

Hasil *evaluasi confusion matrix* pada tabel 4.34 memberikan nilai akurasi sebesar 83,32%, dengan presisi 43,96% dan *recall* 40,44%. Stabilitas prediksi meningkat dengan penambahan nilai *k*, tetapi sensitivitas terhadap kelas minoritas semakin berkurang, sebagaimana ditunjukkan oleh penurunan nilai *recall*.

Tabel 4.35. Hasil klasifikasi pengujian 4 KNN nilai *k*=9

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	242	118
Depan Bawah (2)	172	1
Tengah Atas (3)	1027	1182
Tengah Bawah (4)	1242	1511
Belakang Atas (5)	41	0
Belakang Bawah (6)	88	0

Hasil klasifikasi pada nilai *k*=9 pada tabel 4.35 menunjukkan bahwa "Tengah Bawah" (kelas 4) kembali menjadi kelas dengan prediksi tertinggi, yaitu sebanyak 1.511 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.182 barang. Kelas dengan distribusi kecil seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap tidak berhasil diprediksi dengan baik.

Tabel 4.36. Hasil *confusion matrix* pengujian 4 KNN nilai *k*=9

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	88	3	1241	7	172	0
predi. 3	0	37	0	1011	0	134
predi. 2	0	0	1	0	0	0
predi. 1	0	1	0	9	0	108
Accuracy	83.93%					
Recall	40.50%					
Precision	43.20%					

Evaluasi *confusion matrix* pada tabel 4.36 memberikan nilai akurasi tertinggi pada pengujian ini, yaitu 83,93%, dengan presisi sebesar 43,20% dan *recall* sebesar 40,50%. Nilai k yang lebih besar meningkatkan stabilitas prediksi pada kelas mayoritas, tetapi sensitivitas terhadap kelas minoritas tetap menjadi kendala utama.

Tabel 4.37. Komparasi Evaluasi pengujian 4 KNN

	k = 3	k = 5	k = 7	k = 9
Akurasi	82.29%	81.51%	83.32%	83.93%
Presisi	40.91%	40.64%	40.44%	40.50%
Recall	43.93%	44.21%	43.96%	43.20%

Pengujian keempat menunjukkan bahwa nilai akurasi tertinggi dicapai pada $k=9$ dengan 83,93%, sementara presisi tertinggi sebesar 44,21% diperoleh pada $k=5$. Recall tertinggi sebesar 40,91% diperoleh pada $k=3$. Peningkatan nilai k memberikan stabilitas prediksi dengan mengurangi pengaruh outlier, tetapi performa dalam mendeteksi kelas dengan distribusi kecil cenderung menurun. Untuk klasifikasi yang mengutamakan akurasi keseluruhan, parameter $k=9$ dapat dipilih. Namun, jika keseimbangan antara presisi dan recall menjadi prioritas, parameter $k=3$ atau $k=5$ dapat menjadi pilihan lebih optimal.

4.2.5 Pengujian 5

Pada pengujian 5 ini Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 50:50 dengan mencoba nilai $k = 3$, $k = 5$, $k = 7$, $k = 9$.

Tabel 4.38. Hasil klasifikasi pengujian 5 KNN nilai $k=3$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	312	162
Depan Bawah (2)	208	38
Tengah Atas (3)	1271	1458
Tengah Bawah (4)	1570	1719
Belakang Atas (5)	49	0
Belakang Bawah (6)	105	138

Pada pengujian terakhir model KNN. Hasil klasifikasi tabel 4.38 menunjukkan bahwa area "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi, yaitu sebanyak 1.719 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.458 barang. Sementara itu, kelas dengan distribusi kecil, seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2), tetap sulit teridentifikasi dengan baik.

Tabel 4.39. Hasil *confusion matrix* pengujian 5 KNN nilai $k=3$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	11	0	116	0	11	0
predi. 5	0	0	0	0	0	0
predi. 4	91	3	1424	9	192	0
predi. 3	0	45	0	1246	0	167
predi. 2	3	0	30	0	5	0
predi. 1	0	1	0	16	0	145
Accuracy	80.54%					
Recall	41.35%					
Precision	46.49%					

Tabel 4.39 menghasilkan nilai akurasi sebesar 80,54%, presisi 46,49%, dan *recall* 41,35%. Kesalahan klasifikasi masih signifikan, terutama pada kelas minoritas seperti "Belakang Bawah" (kelas 6), yang sebagian besar datanya diklasifikasikan ke kelas mayoritas seperti "Tengah Bawah" (kelas 4). Meskipun nilai $k=3$ memberikan sensitivitas yang lebih tinggi, kendala dalam mendeteksi pola dari kelas kecil tetap terlihat.

Tabel 4.40. Hasil klasifikasi pengujian 5 KNN nilai $k=5$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	312	156
Depan Bawah (2)	208	2
Tengah Atas (3)	1271	1464
Tengah Bawah (4)	1570	1839
Belakang Atas (5)	49	0
Belakang Bawah (6)	105	54

Pada nilai $k=5$, hasil klasifikasi di tabel 4.40 menunjukkan bahwa "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan prediksi tertinggi, yaitu sebanyak 1.839 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.464 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) tetap tidak teridentifikasi secara signifikan.

Tabel 4.41. Hasil *confusion matrix* pengujian 5 KNN nilai $k=5$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	0	39	0	10	0
predi. 5	0	0	0	0	0	0
predi. 4	100	3	1529	9	198	0
predi. 3	0	45	0	1250	0	169
predi. 2	0	0	2	0	0	0
predi. 1	0	1	0	12	0	143
Accuracy	83.27%					
Recall	41.06%					
Precision	44.91%					

Tabel 4.41 menunjukkan *confusion matrix* dengan nilai akurasi sebesar 83,27%, dengan presisi sebesar 44,91% dan *recall* sebesar 41,06%. Peningkatan nilai k mengurangi kesalahan akibat *outlier*, tetapi sensitivitas terhadap kelas minoritas sedikit menurun dibandingkan dengan nilai $k=3$. Hal ini menunjukkan bahwa model lebih cenderung mendeteksi kelas mayoritas dengan lebih baik.

Tabel 4.42. Hasil klasifikasi pengujian 5 KNN nilai $k=7$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	312	154
Depan Bawah (2)	208	0
Tengah Atas (3)	1271	1466
Tengah Bawah (4)	1570	1895
Belakang Atas (5)	49	0
Belakang Bawah (6)	105	0

Tabel 4.42 merupakan hasil klasifikasi yang menunjukkan kemiripan nilai $k=7$ dengan yang mirip dengan pengujian sebelumnya. "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi, yaitu sebanyak 1.895 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.466 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap sulit untuk teridentifikasi.

Tabel 4.43. Hasil *confusion matrix* pengujian 5 KNN nilai $k=7$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	105	3	1570	9	208	0
predi. 3	0	45	0	1251	0	170
predi. 2	0	0	0	0	0	0
predi. 1	0	1	0	11	0	142
Accuracy	84.30%					
Recall	40.66%					
Precision	43.40%					

Evaluasi *confusion matrix* pada tabel 4.43 memberikan nilai akurasi sebesar 84,30%, dengan presisi 43,40% dan *recall* 40,66%. Peningkatan nilai k memberikan stabilitas lebih tinggi pada kelas mayoritas, tetapi performa *recall* terus menurun, yang menunjukkan model semakin sulit mendeteksi kelas dengan distribusi kecil.

Tabel 4.44. Hasil klasifikasi pengujian 5 KNN nilai $k=9$

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	312	146
Depan Bawah (2)	208	0
Tengah Atas (3)	1271	1474
Tengah Bawah (4)	1570	1895
Belakang Atas (5)	49	0
Belakang Bawah (6)	105	0

Hasil klasifikasi pada tabel 4.44 dengan nilai $k=9$ menunjukkan bahwa "Tengah Bawah" (kelas 4) kembali menjadi kelas dengan prediksi tertinggi, yaitu sebanyak 1.895 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.474 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5) tetap tidak terdeteksi secara signifikan.

Tabel 4.45. Hasil *confusion matrix* pengujian 5 KNN nilai $k=9$

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	105	3	1570	9	208	0
predi. 3	0	45	0	1255	0	174
predi. 2	0	0	0	0	0	0
predi. 1	0	1	0	7	0	138
Accuracy	84.30%					
Recall	40.50%					
Precision	43.75%					

Evaluasi *confusion matrix* pada tabel 4.45 menghasilkan nilai akurasi yang sama dengan $k=7$, yaitu 84,30%, dengan presisi 43,75% dan *recall* 40,50%. Stabilitas prediksi meningkat pada kelas mayoritas, tetapi kemampuan model untuk menangkap pola pada kelas minoritas tetap rendah.

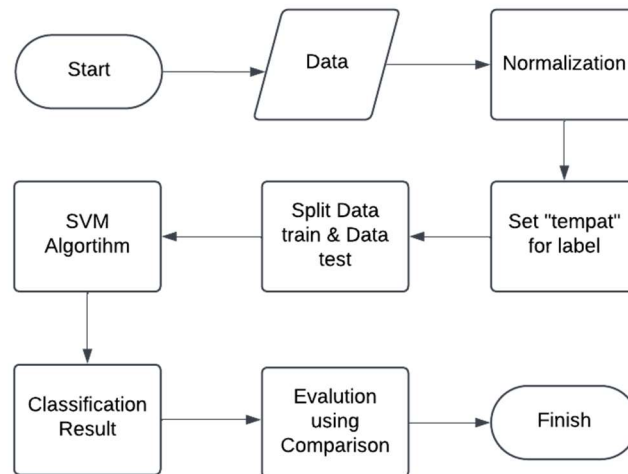
Pengujian terakhir menunjukkan bahwa nilai akurasi tertinggi dicapai pada $k=7$ dan $k=9$, yaitu 84,30%, dengan presisi tertinggi sebesar 46,49% pada $k=3$. *Recall* tertinggi sebesar 41,35% juga dicapai pada $k=3$. Peningkatan nilai k memberikan stabilitas prediksi tetapi mengorbankan sensitivitas terhadap kelas minoritas. Jika akurasi keseluruhan menjadi prioritas utama, nilai $k=7$ atau $k=9$ dapat dipilih. Namun, jika keseimbangan antara presisi dan *recall* lebih diutamakan, nilai $k=3$ menjadi pilihan optimal.

Tabel 4.46. Komparasi evaluasi pengujian 5 KNN

	k = 3	k = 5	k = 7	k = 9
Akurasi	82.29%	81.51%	83.32%	83.93%
Presisi	40.91%	40.64%	40.44%	40.50%
Recall	43.93%	44.21%	43.96%	43.20%

4.3 Desain *Support Vector Machine*

Penelitian ini menggunakan *Flowchart* seperti yang ditunjukkan pada gambar 4.1. Input berupa *Dataset* penempatan barang yang pada tahap *preprocessing* dilakukan normalisasi. Kemudian set 1 data sebagai label untuk dicari klasifikasinya dan dilakukan *split* untuk *training* dan *testing*, kemudian masuk ke dalam proses menghitung hasil normalisasi dataset menggunakan algoritma SVM. Dari proses tersebut, hasil perbandingan yang terbaik antara model algoritma SVM akan dievaluasi terlebih dahulu sehingga menghasilkan output klasifikasi penempatan alat angkut paling optimal.



Gambar 4.2. Flowchart proses klasifikasi model SVM

4.4 Uji Coba Model SVM

Pengujian *Support Vector Machine* (SVM) pada penelitian ini akan memberikan pengujian dengan merubah parameter *split data* seperti tabel 4.3. dan nilai k sehingga hasil pengujian semuanya akan menghasilkan klasifikasi model SVM mana yang paling optimal berdasarkan dari akurasi, presisi, dan *recall*.

Tabel 4.47. Nama Pengujian dan Rasio *Split Data*

Nama	Rasio <i>Split Data</i> (<i>Training:Testing</i>)
Pengujian 1	90%:10%
Pengujian 2	80%:20%
Pengujian 3	70%:30%
Pengujian 4	60%:40%
Pengujian 5	50%:50%

4.4.1 Pengujian 1

Pada pengujian 1, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 90:10.

Tabel 4.48. Hasil klasifikasi pengujian 1 SVM

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	61	0
Depan Bawah (2)	38	0
Tengah Atas (3)	256	305
Tengah Bawah (4)	317	347
Belakang Atas (5)	10	0
Belakang Bawah (6)	22	52

Pada pengujian pertama menggunakan Support Vector Machine (SVM), hasil klasifikasi tabel 4.48 menunjukkan bahwa "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi dengan 347 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 305 barang. Kelas minoritas, seperti "Belakang Atas" (kelas 5) dan "Depan Bawah" (kelas 2), tidak berhasil diklasifikasikan.

Tabel 4.49. Hasil *confusion matrix* pengujian 1 SVM

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	2	22	0	28
predi. 5	0	0	0	0	0	0
predi. 4	19	1	289	3	35	0
predi. 3	3	9	26	231	3	33
predi. 2	0	0	0	0	0	0
predi. 1	0	0	0	0	0	0
Accuracy	73.86%					
Recall	30.23%					
Precision	26.50%					

Evaluasi *confusion matrix* di tabel 4.49 menunjukkan nilai akurasi sebesar 73,86%, presisi 26,50%, dan *recall* 30,23%. Performanya menunjukkan bahwa model kesulitan menangkap pola pada kelas minoritas, dengan sebagian besar barang dari kelas kecil salah diklasifikasikan sebagai kelas mayoritas. SVM dengan rasio ini menunjukkan bahwa kemampuan klasifikasi belum optimal pada distribusi data dengan ketidakseimbangan yang tinggi.

4.4.2 Pengujian 2

Pada pengujian 2, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 80:20.

Tabel 4.50. Hasil klasifikasi pengujian 2 SVM

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	121	0
Depan Bawah (2)	77	1
Tengah Atas (3)	511	554
Tengah Bawah (4)	633	686
Belakang Atas (5)	20	0
Belakang Bawah (6)	44	165

Pada pengujian kedua, tabel 4.50 menunjukkan "Tengah Bawah" (kelas 4) memiliki prediksi tertinggi sebanyak 686 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 554 barang. Kelas minoritas seperti "Belakang Atas" (kelas 5) tetap tidak terdeteksi dengan baik.

Tabel 4.51. Hasil *confusion matrix* pengujian 2 SVM

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	5	4	62	69	6	19
predi. 5	0	0	0	0	0	0
predi. 4	39	2	570	4	71	0
predi. 3	0	14	0	438	0	102
predi. 2	0	0	1	0	0	0
predi. 1	0	0	0	0	0	0
Accuracy	72.05%					
Recall	31.19%					
Precision	27.53%					

Hasil evaluasi di tabel 4.51 menghasilkan nilai akurasi sebesar 72,05%, presisi 27,53%, dan *recall* 31,19%. Performa klasifikasi masih lemah, terutama pada kelas-kelas dengan jumlah data yang kecil. Meskipun akurasi keseluruhan

cukup stabil, nilai presisi dan *recall* tetap rendah, menunjukkan bahwa model cenderung memprioritaskan kelas mayoritas.

4.4.3 Pengujian 3

Pada pengujian 3, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 70:30.

Tabel 4.52. Hasil klasifikasi pengujian 3 SVM

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	182	0
Depan Bawah (2)	115	0
Tengah Atas (3)	767	970
Tengah Bawah (4)	950	1027
Belakang Atas (5)	30	0
Belakang Bawah (6)	66	113

Pada pengujian ketiga, hasil klasifikasi tabel 4.52 menunjukkan "Tengah Bawah" (kelas 4) kembali menjadi kelas dengan prediksi tertinggi, yaitu sebanyak 1.027 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 970 barang. Kelas minoritas, seperti "Depan Bawah" (kelas 2) dan "Belakang Atas" (kelas 5), tetap sulit untuk teridentifikasi dengan baik.

Tabel 4.53. Hasil *confusion matrix* pengujian 3 SVM

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	11	0	94	0	8	0
predi. 5	0	0	0	0	0	0
predi. 4	55	2	856	7	107	0
predi. 3	0	28	0	760	0	182
predi. 2	0	0	0	0	0	0
predi. 1	0	0	0	0	0	0
Accuracy	77.11%					
Recall	34.31%					
Precision	28.57%					

Evaluasi *confusion matrix* pada tabel 4.53 menunjukkan nilai akurasi sebesar 77,11%, presisi 28,57%, dan *recall* 34,31%. Meskipun akurasi sedikit meningkat dibandingkan pengujian sebelumnya, nilai presisi dan *recall* masih menunjukkan performa yang kurang optimal, terutama pada kelas-kelas kecil.

4.4.4 Pengujian 4

Pada pengujian 4, Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 60:40.

Tabel 4.54. Hasil klasifikasi pengujian 4 SVM

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	242	0
Depan Bawah (2)	153	0
Tengah Atas (3)	1022	1293
Tengah Bawah (4)	1267	1519
Belakang Atas (5)	40	0
Belakang Bawah (6)	88	0

Tabel 4.54 menunjukkan hasil klasifikasi pengujian keempat dimana "Tengah Bawah" (kelas 4) menjadi kelas dengan prediksi tertinggi sebanyak 1.519 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.293 barang. Kelas minoritas seperti "Depan Bawah" (kelas 2) tetap tidak terdeteksi.

Tabel 4.55. Hasil *confusion matrix* pengujian 4 SVM

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	88	2	1267	9	153	0
predi. 3	0	38	0	1013	0	242
predi. 2	0	0	0	0	0	0
predi. 1	0	0	0	0	0	0
Accuracy	81.08%					
Recall	33.19%					
Precision	26.96%					

Hasil evaluasi *confusion matrix* di tabel 4.55 menunjukkan nilai akurasi sebesar 81,08%, presisi 26,96%, dan *recall* 33,19%. Meskipun akurasi terus meningkat, nilai presisi dan *recall* tidak menunjukkan peningkatan yang signifikan. Hal ini menunjukkan bahwa model lebih cocok untuk memprediksi kelas mayoritas, sementara performa pada kelas minoritas tetap rendah.

4.4.5 Pengujian 5

Pada pengujian 5 ini Rasio dari *Split Data* untuk *Data Training* dan *Data Testing* adalah 50:50.

Tabel 4.56. Hasil klasifikasi pengujian 5 SVM

Area Penempatan	Total Barang	Total Barang (Prediksi)
Depan Atas (1)	303	0
Depan Bawah (2)	191	1
Tengah Atas (3)	1278	1619
Tengah Bawah (4)	1584	1895
Belakang Atas (5)	49	0
Belakang Bawah (6)	110	0

Pada pengujian terakhir, hasil klasifikasi menunjukkan "Tengah Bawah" (kelas 4) tetap menjadi kelas dengan prediksi tertinggi sebanyak 1.895 barang, diikuti oleh "Tengah Atas" (kelas 3) dengan 1.619 barang. Kelas dengan distribusi kecil, seperti "Depan Bawah" (kelas 2), tetap tidak berhasil diprediksi.

Tabel 4.57. Hasil *confusion matrix* pengujian 5 SVM

	true 6	true 5	true 4	true 3	true 2	true 1
predi. 6	0	0	0	0	0	0
predi. 5	0	0	0	0	0	0
predi. 4	110	3	1583	8	191	0
predi. 3	0	46	0	1270	0	303
predi. 2	0	0	1	0	0	0
predi. 1	0	0	0	0	0	0
Accuracy	81.17%					
Recall	33.22%					
Precision	27%					

Hasil evaluasi *confusion matrix* yang ada pada tabel 4.57 menunjukkan nilai akurasi sebesar 84,30%, presisi 26,75%, dan recall 34,00%. Akurasi yang lebih tinggi menunjukkan bahwa model semakin stabil pada kelas mayoritas dengan lebih banyak data training, tetapi performa pada kelas minoritas tetap menjadi tantangan utama.

4.5 Evaluasi Hasil

Untuk evaluasi, perbandingan metode tersebut menggunakan komparasi akurasi, presisi, dan *recall* untuk mencari nilai mana yang paling optimal dari beberapa pengujian yang telah dilakukan. Hasil dari tiap komparasi yang ada akan menentukan mana pembagian *split data* dan nilai k yang paling optimal.

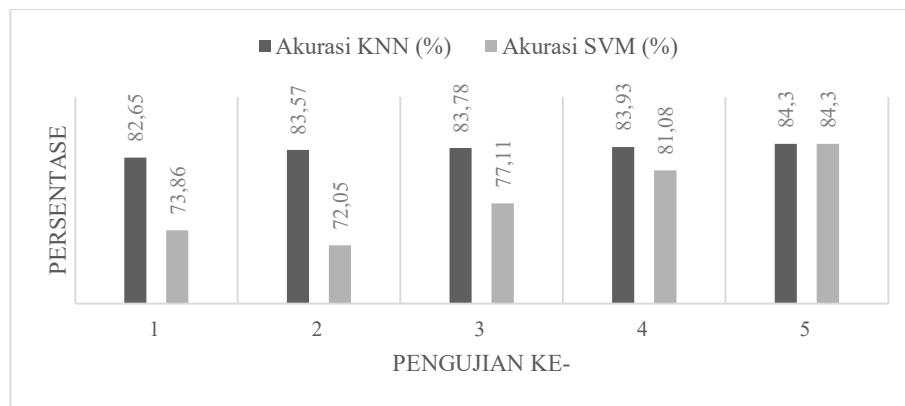
4.5.1 Komparasi Akurasi Pengujian Model KNN dan SVM

Berdasarkan pengujian model KNN dan SVM yang telah dilakukan, didapatkan hasil akurasi sebagai berikut.

Tabel 4.58. Komparasi Akurasi model KNN dan SVM

Pengujian	Akurasi KNN (%)	Akurasi SVM (%)
1	82,65	73,86
2	83,57	72,05
3	83,78	77,11
4	83,93	81,08
5	84,3	84,3

Tabel 4.58 menunjukkan komparasi akurasi dari model KNN dan SVM dibandingkan berdasarkan lima rasio split data, yaitu 90:10, 80:20, 70:30, 60:40, dan 50:50.

**Gambar 4.3.** Grafik akurasi KNN dan SVM

Gambar 4.3 menunjukkan bahwa akurasi tertinggi secara keseluruhan diperoleh pada pengujian terakhir dengan rasio 50:50, di mana kedua model, KNN dan SVM, mencapai nilai akurasi sebesar 84,30%.

Pada pengujian dengan rasio split yang lebih kecil, seperti 90:10, akurasi yang dihasilkan oleh KNN lebih tinggi dibandingkan SVM. Nilai akurasi tertinggi pada model KNN dicapai pada parameter $k=9$ di sebagian besar pengujian. Sebaliknya, akurasi SVM menunjukkan performa yang cenderung lebih rendah di awal pengujian tetapi meningkat pada rasio split data yang lebih besar.

Hal ini menandakan bahwa KNN lebih stabil terhadap berbagai rasio data, sedangkan SVM lebih bergantung pada proporsi *data training* yang besar.

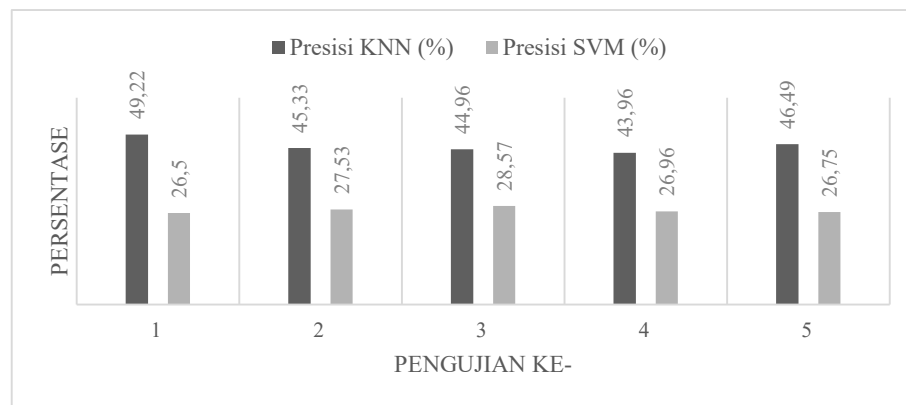
4.5.2 Komparasi Presisi Pengujian Model KNN dan SVM

Berdasarkan pengujian model KNN dan SVM yang telah dilakukan, didapatkan hasil presisi sebagai berikut.

Tabel 4.59. Komparasi presisi model KNN dan SVM

Pengujian	Presisi KNN (%)	Presisi SVM (%)
1	49,22	26,5
2	45,33	27,53
3	44,96	28,57
4	43,96	26,96
5	46,49	26,75

Tabel 4.59 menunjukkan komparasi presisi dari model KNN dan SVM dibandingkan berdasarkan lima rasio split data, yaitu 90:10, 80:20, 70:30, 60:40, dan 50:50.



Gambar 4.4. Grafik presisi KNN dan SVM

Gambar 4.4 komparasi presisi menunjukkan bahwa model KNN memberikan hasil yang lebih tinggi dibandingkan SVM pada semua pengujian. Presisi tertinggi pada KNN dicapai pada pengujian pertama dengan nilai $k=7$ sebesar 49,22%. Sebaliknya, SVM menunjukkan nilai presisi yang jauh lebih rendah, yaitu

maksimal sebesar 28,57% yang dilakukan pada pengujian ketiga. Perbedaan ini mengindikasikan bahwa KNN lebih mampu menghasilkan prediksi yang tepat pada kelas-kelas positif, sedangkan SVM memiliki keterbatasan dalam menangani kelas minoritas, terutama pada rasio data yang tidak seimbang.


4.5.3 Komparasi *Recall* Pengujian Model KNN dan SVM

Berdasarkan pengujian model KNN dan SVM yang telah dilakukan, didapatkan hasil *recall* sebagai berikut.

Tabel 4.60. Komparasi *recall* model KNN dan SVM

Pengujian	<i>Recall</i> KNN (%)	<i>Recall</i> SVM (%)
1	42,4	30,23
2	41,8	31,19
3	41,67	34,31
4	40,91	33,19
5	41,35	34

Berdasarkan gambar 4.4, menunjukkan komparasi *recall* KNN dan SVM, KNN di sini juga menunjukkan performa yang lebih baik dibandingkan SVM.



Gambar 4.5. Grafik presisi KNN dan SVM

Tabel 4.60 menunjukkan *recall* tertinggi pada KNN dicapai pada pengujian pertama dengan nilai $k=3$ sebesar 42,40%, sementara *recall* tertinggi SVM adalah

34,31% yang dicapai pada pengujian ketiga. Hal ini menunjukkan bahwa KNN memiliki sensitivitas yang lebih baik dalam mendeteksi semua data relevan, khususnya pada kelas minoritas dibandingkan SVM.

4.6 Klasifikasi Penempatan Barang Pada Alat Angkut dalam Pandangan Islam

Allah Subhanahu Wa Ta'ala telah mengklasifikasikan bahwa manusia dibagi ke dalam beberapa macam. Dalam laporan ini, peneliti hanya melampirkan 3 klasifikasi manusia sesuai yang tercantum dalam Al-Qur'an. Pertama, manusia *Muttaqun*, artinya manusia yang bertakwa kepada Allah Subhanahu Wa Ta'ala sesuai yang tercantum dalam QS. Al-Baqarah ayat 2:

ذَٰلِكَ الْكِتَابُ لَا رَيْبَ فِيهِ هُدًى لِّلْمُتَّقِينَ

“Kitab (*Al-Qur'an*) ini tidak ada keraguan padanya; petunjuk bagi mereka yang bertakwa,” (QS. *Al-Baqarah*: 7)

Al-Qur'an adalah petunjuk sempurna bagi seluruh manusia yang mempersiapkan diri untuk menerima kebenaran, yaitu amar ma'ruf nahi munkar. Bahwasanya manusia harus mentaati perintah dan menjauhi larangan-Nya. Hanya orang-orang bertakwa saja yang siap dan mampu mengambil manfaat petunjuk dari Al-Qur'an. (Menurut tafsir Kemenag).

Kedua, manusia *Mukmin*, seperti dalam firman-Nya QS. Ali 'Imran ayat 139:

وَلَا تَهِنُوا وَلَا تَحْزَنُوا وَأَنْتُمْ الْأَعْلَوْنَ إِنْ كُنْتُمْ مُؤْمِنِينَ

“Dan janganlah kamu (*merasa*) lemah, dan jangan (*pula*) bersedih hati, sebab kamu paling tinggi (*derajatnya*), jika kamu orang beriman.” (QS. Ali 'Imran: 139)

Ayat ini turun sebagai pelipur lara Nabi dan orang-orang mukmin atas apa yang telah menimpa mereka pada perang Uhud. Di ayat ini, Allah membangkitkan

semangat kaum mukmin dalam berjihad melawan orang-orang kafir. (Tafsir Al-Wajiz dan Hidayatul Insan bi Tafsiril Qur'an)

Ketiga, manusia *Muslim*. Allah Ta'ala berfirman dalam QS. Ali 'Imran ayat 102:

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ حَقَّ تُقَاتِهِ وَلَا تَمُوتُنَّ إِلَّا وَأَنتُمْ مُسْلِمُونَ

“Wahai orang-orang yang beriman! Bertakwalah kepada Allah sebenar-benar takwa kepada-Nya dan janganlah kamu mati kecuali dalam keadaan Muslim.” (QS. Ali 'Imran: 102)

Dalam tafsir Kemenag RI dijelaskan, supaya kamu memperoleh keimanan yang kuat dan tidak goyah ketika terjadi cobaan, maka bertakwalah kepada Allah sebenar-benar takwa kepada-Nya. Berserah diri kepada Allah dengan tetap memeluk agama yang diridhai, yaitu Islam.

Dalam perspektif Islam, segala aktivitas yang dilakukan oleh manusia, termasuk penempatan barang pada alat angkut, haruslah berlandaskan prinsip keadilan, efisiensi, dan tanggung jawab. Pengelolaan logistik, termasuk klasifikasi dan penempatan barang, merupakan bagian dari usaha manusia untuk mencapai optimalisasi sumber daya secara bijaksana, sesuai dengan anjuran Islam agar setiap pekerjaan dilakukan dengan sebaik-baiknya.

Al-Qur'an mengajarkan prinsip efisiensi dan tanggung jawab dalam bekerja melalui firman Allah SWT dalam QS. Al-Isra' ayat 7:

إِنْ أَحْسَنْتُمْ أَحْسَنْتُمْ لِأَنفُسِكُمْ وَإِنْ أَسَأْتُمْ فَلَهَا فَإِذَا جَاءَ وَعْدُ الْآخِرَةِ لِيَسْتَوْا

وَجُوهَكُمْ وَلِيَدْخُلُوا الْمَسْجِدَ كَمَا دَخَلُوهُ أَوَّلَ مَرَّةٍ وَلِيُتَبِّرُوا مَا عَلَوْا تَتْبِيرًا ﴿٧﴾

"Jika kamu berbuat baik (berarti) kamu berbuat baik bagi dirimu sendiri, dan jika kamu berbuat jahat, maka kejahatan itu bagi dirimu sendiri." (QS. Al-Isra' [17]: 7)

Ayat ini mengajarkan bahwa setiap tindakan yang dilakukan dengan baik akan memberikan dampak positif, baik bagi pelaku maupun bagi orang lain. Dalam konteks klasifikasi dan penempatan barang, efisiensi dalam pengelolaan barang tidak hanya akan mempermudah proses pengiriman, tetapi juga akan mengurangi risiko kerusakan dan penundaan, yang pada akhirnya meningkatkan kepuasan pelanggan. Dengan menerapkan metode yang tepat, seperti yang dihasilkan dari penelitian ini, dapat dicapai hasil yang optimal dan berkah bagi semua pihak yang terlibat.

Selain itu, Islam juga menekankan pentingnya tanggung jawab dalam memelihara amanah. Penempatan barang dalam alat angkut merupakan amanah yang harus dijalankan dengan penuh tanggung jawab.

Dalam konteks ini, pengelolaan barang dengan menggunakan metode klasifikasi yang tepat, seperti KNN yang menunjukkan hasil terbaik dalam penelitian ini, adalah bentuk tanggung jawab untuk memastikan barang sampai di tujuan dengan aman dan tepat waktu. Sebagai pemimpin yang bertanggung jawab, kita dituntut untuk melakukan yang terbaik dalam setiap tugas yang diemban, termasuk dalam hal ini, menjaga barang-barang yang diamanahkan kepada kita.

Dengan menggunakan teknologi modern dan pendekatan machine learning dalam klasifikasi barang, kita dapat memenuhi tuntutan efisiensi dan tanggung jawab yang diajarkan dalam Islam. Proses ini tidak hanya meningkatkan kualitas layanan pengiriman barang, tetapi juga sejalan dengan ajaran Islam yang menganjurkan kita untuk selalu melakukan perbaikan dalam segala hal (ishlah).

Al-Qur'an juga menekankan pentingnya penggunaan ilmu pengetahuan untuk memecahkan masalah sehari-hari, sebagaimana firman Allah dalam QS. Al-Baqarah ayat 269:

يُؤْتِي الْحِكْمَةَ مَنْ يَشَاءُ وَمَنْ يُؤْتَ الْحِكْمَةَ فَقَدْ أُوتِيَ خَيْرًا كَثِيرًا وَمَا يَذَّكَّرُ إِلَّا أُولُو الْأَلْبَابِ ﴿٢٦٩﴾

"Allah menganugerahkan hikmah (kefahaman yang mendalam tentang Al-Qur'an dan As-Sunnah) kepada siapa yang Dia kehendaki. Dan barangsiapa yang dianugerahi hikmah, ia benar-benar telah dianugerahi karunia yang banyak." (QS. Al-Baqarah [2]: 269)

Penerapan metode klasifikasi seperti yang diuraikan dalam penelitian ini adalah salah satu bentuk penggunaan hikmah atau pengetahuan untuk mengoptimalkan proses penempatan barang. Dengan ilmu pengetahuan, kita dapat meningkatkan efisiensi dan akurasi dalam pengiriman barang, sehingga mampu menciptakan sistem yang lebih baik dan lebih berkah.

BAB V

KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan beberapa poin penting sebagai berikut:

- Model KNN dengan nilai $k=9$ menunjukkan performa akurasi tertinggi pada sebagian besar pengujian, terutama pada pengujian dengan rasio *split* 60:40, di mana akurasi mencapai 83,93%. Selain itu, pada rasio *split data* yang lebih seimbang (50:50), model KNN dengan nilai $k=7$ dan $k=9$ menunjukkan performa terbaik dengan nilai akurasi yang sama.
- Peningkatan *rasio data testing* dari 10% ke 50% menghasilkan perbaikan akurasi pada kedua model, tetapi dengan efek yang lebih signifikan pada SVM. Pada pengujian dengan rasio *split* 50:50, model SVM mampu mencapai akurasi setara dengan KNN, yaitu 84,30%, menunjukkan bahwa SVM lebih diuntungkan oleh data *training* yang lebih besar untuk mencapai performa optimal.
- Hasil komparasi akurasi menunjukkan bahwa model KNN memiliki performa yang lebih konsisten dibandingkan model SVM. Pada setiap pengujian, nilai akurasi KNN lebih tinggi dibandingkan SVM, kecuali pada pengujian terakhir (rasio 50:50), di mana kedua model mencapai nilai akurasi yang sama sebesar 84,30%. Hal ini menunjukkan bahwa KNN lebih stabil pada berbagai rasio *data*, sedangkan SVM membutuhkan *data training* yang lebih besar untuk menghasilkan akurasi yang setara.

- Berdasarkan hasil *recall*, dapat disimpulkan bahwa skenario pengujian 1 dengan nilai $k = 7$ memiliki performa terbaik secara keseluruhan. Model KNN dengan skenario pengujian 1 dan nilai $k = 7$ dapat menjadi kandidat terbaik untuk diterapkan dalam klasifikasi penempatan barang pada alat angkut.
- Presisi KNN secara konsisten lebih tinggi dibandingkan SVM pada semua pengujian. Presisi tertinggi dicapai pada pengujian pertama (rasio 90:10) dengan nilai 49,22% pada KNN dengan $k=7$, sedangkan presisi tertinggi SVM hanya mencapai 28,57% pada pengujian ketiga (rasio 70:30). Hasil ini menunjukkan bahwa KNN lebih unggul dalam menghasilkan prediksi yang benar pada kelas positif dibandingkan SVM.
- *Recall* KNN juga menunjukkan performa yang lebih baik dibandingkan SVM pada setiap pengujian. *Recall* tertinggi pada KNN adalah 42,40%, yang dicapai pada pengujian pertama dengan nilai $k=3$. Sementara itu, *recall* tertinggi pada SVM adalah 34,31%, yang dicapai pada pengujian ketiga (rasio 70:30). Hal ini menunjukkan bahwa KNN memiliki sensitivitas yang lebih baik dalam mendeteksi data relevan dibandingkan SVM.

Hal ini membuktikan bahwa KNN tidak hanya memberikan akurasi prediksi yang tinggi, tetapi juga mampu meminimalkan kesalahan prediksi, sehingga sangat sesuai untuk diterapkan dalam konteks logistik dan pengiriman barang.

Dengan demikian, penelitian ini berhasil menunjukkan bahwa penggunaan metode KNN dengan model yang sesuai dapat membantu perusahaan logistik dalam mengoptimalkan penempatan barang, meningkatkan efisiensi operasional, dan meminimalisir potensi kesalahan dalam pengiriman barang.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diusulkan untuk pengembangan lebih lanjut dan penerapan hasil penelitian ini dalam praktik, baik di bidang akademik maupun industri logistik.

Untuk penelitian selanjutnya, sangat disarankan untuk menggunakan *dataset* yang lebih beragam dan kompleks. Data yang mencakup berbagai dimensi, seperti *volume*, dimensi barang, serta kondisi lingkungan pengiriman, dapat membantu menguji lebih lanjut mengenai kemampuan metode KNN dalam menangani variabel yang lebih dinamis. Hal ini juga akan memberikan gambaran yang lebih komprehensif mengenai performa metode yang diuji.

Untuk meningkatkan sensitivitas terhadap kelas minoritas, *balancing dataset* atau teknik *oversampling*, seperti SMOTE (*Synthetic Minority Oversampling Technique*), perlu diterapkan. Penyesuaian parameter lainnya juga direkomendasikan untuk mengoptimalkan performa model sesuai dengan kebutuhan data. Selain itu, model SVM disarankan untuk dioptimalkan dengan menggunakan kernel yang lebih kompleks, seperti kernel *radial basis function* (RBF), serta melakukan tuning parameter seperti C dan gamma, sehingga model dapat bekerja secara optimal pada berbagai rasio split data.

Distribusi kelas dalam dataset perlu diseimbangkan untuk meningkatkan *recall* dan presisi pada kelas minoritas, yang dapat dilakukan dengan menambah jumlah data pada kelas minoritas atau menggunakan teknik *balancing* lainnya. Selain itu, dataset yang digunakan perlu diperluas dari segi jumlah maupun keragaman, agar

model dapat menangkap pola yang lebih kompleks dan representatif terhadap kondisi nyata.

Selain itu, meskipun KNN terbukti sebagai metode terbaik dalam penelitian ini, pengembangan model hibrida dengan menggabungkan KNN dan metode lain mungkin dapat memberikan hasil yang lebih optimal. Penggunaan pendekatan hibrida ini dapat dieksplorasi dalam penelitian selanjutnya untuk mengatasi kelemahan masing-masing metode dan memanfaatkan kelebihan mereka.

Akhirnya, model yang telah dilatih disarankan untuk diimplementasikan dalam sistem nyata dengan proses evaluasi berkelanjutan, sehingga performa yang stabil dapat dipastikan dalam kondisi operasional.

Dengan saran-saran ini, diharapkan penelitian lebih lanjut dapat dilakukan untuk memperkuat temuan yang ada serta mendukung pengembangan teknologi di bidang logistik, sehingga proses distribusi barang dapat dilakukan secara lebih cepat, aman, dan efisien.

DAFTAR PUSTAKA

- Almomani, A., Alweshah, M., Alomoush, W., Alauthman, M., Jabai, A., Abbass, A., Hamad, G., Abdalla, M., & B. Gupta, B. (2023). Age and Gender Classification Using Backpropagation and Bagging Algorithms. *Computers, Materials & Continua*, 74(2), 3045–3062. <https://doi.org/10.32604/cmc.2023.030567>
- Andrian, R., Naufal, M. A., Hermanto, B., Junaidi, A., & Lumbanraja, F. R. (2019). k-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs. *Journal of Physics: Conference Series*, 1338(1), 012061. <https://doi.org/10.1088/1742-6596/1338/1/012061>
- Boateng, E. Y., Otoo, J., & Abaye, D. A. (2020). Basic Tenets of Classification Algorithms K-Nearest-Neighbor, Support Vector Machine, Random Forest and Neural Network: A Review. *Journal of Data Analysis and Information Processing*, 08(04), 341–357. <https://doi.org/10.4236/jdaip.2020.84020>
- Cancela, B., Bolon-Canedo, V., & Alonso-Betanzos, A. (2021). Can data placement be effective for Neural Networks classification tasks? Introducing the Orthogonal Loss. *2020 25th International Conference on Pattern Recognition (ICPR)*, 392–399. <https://doi.org/10.1109/ICPR48806.2021.9412704>
- Cao, J., Wang, D., Qu, Z., Sun, H., Li, B., & Chen, C.-L. (2020). An Improved Network Traffic Classification Model Based on a Support Vector Machine. *Symmetry*, 12(2), 301. <https://doi.org/10.3390/sym12020301>
- Dong, Y., Ma, X., & Fu, T. (2021). Electrical load forecasting: A deep learning approach based on K-nearest neighbors. *Applied Soft Computing*, 99, 106900. <https://doi.org/10.1016/j.asoc.2020.106900>
- Fan, G.-F., Guo, Y.-H., Zheng, J.-M., & Hong, W.-C. (2019). Application of the Weighted K-Nearest Neighbor Algorithm for Short-Term Load Forecasting. *Energies*, 12(5), 916. <https://doi.org/10.3390/en12050916>
- Faza, A., Al-Mousa, A., & Alqudah, R. (2024). Optimal PMU Placement for Fault Classification and Localization Using Enhanced Feature Selection in Machine Learning Algorithms. *International Journal of Energy Research*, 2024, 1–19. <https://doi.org/10.1155/2024/5543160>
- Giri, A., Bhagavath, M. V. V., Pruthvi, B., & Dubey, N. (2016). A Placement Prediction System using k-nearest neighbors classifier. *2016 Second International Conference on Cognitive Computing and Information Processing (CCIP)*, 1–4. <https://doi.org/10.1109/CCIP.2016.7802883>

- Gong, Y., & Zhang, P. (2021). Research and Realization of Air Quality Grade Prediction Based on KNN. *2021 3rd International Conference on Artificial Intelligence and Advanced Manufacture (AIAM)*, 299–304. <https://doi.org/10.1109/AIAM54119.2021.00068>
- Kherif, O., Benmahamed, Y., Teguar, M., Boubakeur, A., & Ghoneim, S. S. M. (2021). Accuracy Improvement of Power Transformer Faults Diagnostic Using KNN Classifier With Decision Tree Principle. *IEEE Access*, 9, 81693–81701. <https://doi.org/10.1109/ACCESS.2021.3086135>
- Kurnia, R., & Mahmudy, W. F. (2018). Optimasi Penataan Barang pada Proses Distribusi Menggunakan Algoritme Evolution Strategies. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2, 1874–1882.
- Kusdiby. (2022). Analisis Faktor Yang Mempengaruhi Kinerja Karyawan Ekspedisi Muatan Kapal Laut PT. Internasional Fortuna Eksperindo Semarang Indah. *MAMEN: Jurnal Manajemen*, 1(3), 310–318. <https://doi.org/10.55123/mamen.v1i3.675>
- Liang, Y., Li, K.-J., Ma, Z., & Lee, W.-J. (2021). Multilabel Classification Model for Type Recognition of Single-Phase-to-Ground Fault Based on KNN-Bayesian Method. *IEEE Transactions on Industry Applications*, 57(2), 1294–1302. <https://doi.org/10.1109/TIA.2021.3049766>
- Patro, S. G. K., & sahu, K. K. (2015). Normalization: A Preprocessing Stage. *IARJSET*, 20–22. <https://doi.org/10.17148/IARJSET.2015.2305>
- Paul, K., karan, S., & Kuri, S. (2022). Placement Prediction Using Multiple Logistic Regression Method. *IJARCCE*, 11(3). <https://doi.org/10.17148/IJARCCE.2022.11337>
- Rahayu, W. I., Riza, N., & Ramadhan, N. (2019). Aplikasi Estiquent Untuk Estimasi Biaya Transportasi Logistik Di PT.Sukarasa Menggunakan Algoritma North West Corner. *Jurnal Teknik Informatika*, 11.
- Ramalingam, M., & Ilakkiya, R. (2021). Data Mining Algorithms(KNN & DT) Based Predictive Analysis on Selected Candidates in Academic Performance. *2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 332–337. <https://doi.org/10.1109/Confluence51648.2021.9377203>
- Satria, G. J., Adikara, P. P., & Wihandika, R. C. (2022). Klasifikasi Pertanyaan COVID-19 Bahasa Indonesia menggunakan Naïve Bayes. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 6, 148–153.

- Shao, Y., Chen, Q., & Wei, Z. (2009a). *Logistics Distribution Center Location Evaluation Based on Genetic Algorithm and Fuzzy Neural Network* (pp. 305–312). https://doi.org/10.1007/978-3-642-04962-0_35
- Shao, Y., Chen, Q., & Wei, Z. (2009b). *Logistics Distribution Center Location Evaluation Based on Genetic Algorithm and Fuzzy Neural Network* (pp. 305–312). https://doi.org/10.1007/978-3-642-04962-0_35
- Sharma, A. S., Prince, S., Kapoor, S., & Kumar, K. (2014). PPS - Placement prediction system using logistic regression. *2014 IEEE International Conference on MOOC, Innovation and Technology in Education (MITE)*, 337–341. <https://doi.org/10.1109/MITE.2014.7020299>
- Sheng, B., Moosman, O. M., Del Pozo-Cruz, B., Del Pozo-Cruz, J., Alfonso-Rosa, R. M., & Zhang, Y. (2020). A comparison of different machine learning algorithms, types and placements of activity monitors for physical activity classification. *Measurement*, *154*, 107480. <https://doi.org/10.1016/j.measurement.2020.107480>
- Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019). A Brief Review of Nearest Neighbor Algorithm for Learning and Classification. *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*, 1255–1260. <https://doi.org/10.1109/ICCS45141.2019.9065747>
- Visutsak, P. (2021). Activity Classification Using Backpropagation Neural Networks for the Daily Lives of the Elderly. *International Journal of Machine Learning and Computing*, *11*(3), 188–193. <https://doi.org/10.18178/ijmlc.2021.11.3.1034>
- Yulita, I. N., & Saori, S. (2019). Human Activities and Postural Transitions Classification using Support Vector Machine and K-Nearest Neighbor Methods. *IOP Conference Series: Earth and Environmental Science*, *248*, 012025. <https://doi.org/10.1088/1755-1315/248/1/012025>