

## SISTEM KLASIFIKASI POLA PERILAKU BENDUNGAN MENGGUNAKAN K-NEAREST NEIGHBOR BERBASIS DATA TEMPORAL DI BENDUNGAN DJUANDA

Fajar Tresnawiguna<sup>1</sup>, Yulison Herry Chrisnanto<sup>2</sup>, Puspita Nurul Sabrina<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknik Informatika, Universitas Jenderal Achmad Yani

E-mail : fajar.trсна@gmail.com<sup>1</sup>, y.chrisnanto@gmail.com<sup>2</sup>, puspitasabrina14@gmail.com<sup>3</sup>

### Abstrak

Bendungan memiliki peran yang sangat penting dalam sosial dan ekonomi masyarakat, diantaranya penyedia air irigasi, industri, pembangkit listrik, tempat rekreasi serta pengendali banjir. Selain memiliki beragam manfaat, Bendungan juga menyimpan potensi bencana sehingga diperlukan tindakan preventif dalam pengelolaan bencana. Klasifikasi pola perilaku bendungan dengan bantuan komputasi sangat diperlukan untuk mengetahui hasil penentuan pola perilaku yang akurat, cepat dan efisien. Pada penelitian dilakukan pembuatan sistem menggunakan K-NN Classifier berdasarkan data temporal yang terbentuk dengan tujuan untuk mengklasifikasi pola perilaku bendungan di Bendungan Djuanda. Hasil pengujian sistem menghasilkan akurasi terbaik sebesar 88% untuk label aman, 82% untuk label siaga dan 92% untuk label waspada dengan nilai k terbaik sebanyak 8.

**Kata Kunci:** Bendungan, Djuanda, K-NN Classifier, Klasifikasi, Temporal Data

### Abstract

*Dam had a vital role in the social and economic communities, including water providers for irrigation, industry, power plant, recreation, and flood control. Besides having various benefits, Dam also holds the potential of disaster. Preventive action in disaster management was necessary. Dam behavior pattern classification with computational assistance was needed to determine the results of determining accurate, fast, and efficient behavior patterns. In this research, the system made by using a K-NN Classifier based on temporal data that formed to predict the behavior patterns of dams in the Djuanda Dam. The system test results produce the best accuracy of 88% for safe labels, 82% for standby labels and 92% for alert labels with the best k value is 8.*

**Keywords:** Dam, Djuanda, K-NN Classifier, Classification, Temporal Data

### 1. PENDAHULUAN

Bendungan memiliki peran yang sangat penting dalam sosial dan ekonomi masyarakat. Peran dan manfaat bendungan diantaranya adalah sebagai penyedia air bagi masyarakat, irigasi, dan industri, pembangkit listrik, tempat rekreasi, serta pengendali banjir yang efektif. Selain berbagai manfaat yang diberikan, bendungan juga menyimpan potensi bahaya seperti keruntuhan yang akan mengakibatkan banjir besar dan bencana di

daerah hilir. Untuk mencegah bencana yang terjadi maka bendungan harus dikelola dengan baik agar manfaatnya dapat dirasakan secara maksimal. Salah satu tindakan pengelolaan bendungan adalah pengelolaan potensi bencana sebagai tindakan preventif [1]. Salah satu tindakan preventif yang dapat dilakukan adalah dengan melakukan Klasifikasi pola perilaku bendungan sehingga petugas dapat mengambil tindakan dengan tepat dan cepat saat bencana datang.

Klasifikasi merupakan suatu proses yang bertujuan untuk menentukan suatu obyek kedalam suatu kelas atau kategori yang sudah ditentukan sebelumnya. Klasifikasi adalah proses dari pembangunan terhadap suatu model yang mengklasifikasi suatu objek sesuai dengan beberapa atributnya. Klasifikasi data ataupun dokumen juga dapat dimulai dari membangun aturan klasifikasi tertentu yang menggunakan data training yang sering disebut sebagai tahapan pembelajaran dan pengujian digunakan sebagai data testing [2].

Bendungan Djuanda, adalah objek yang akan diklasifikasi pola perilakunya pada penelitian ini. Data yang dihasilkan dari penelitian adalah *Observation Well, Tridimension, Piezzo Cassagrande, Vnotch, Reservoir Water Level, Volume Percentfull dan Rainfall*. Data tersebut diambil dan diolah dari laporan triwulan dan laporan tahunan. Kegiatan pengambilan data akan dihasilkan suatu data temporal. Data temporal merupakan suatu data yang diambil berdasarkan periode tertentu secara berkelanjutan.

Proses analisis pola perilaku bendungan terhadap data-data tersebut dapat dilakukan tanpa bantuan komputasi, namun cara tersebut memiliki kelemahan yaitu memerlukan waktu yang cukup lama. Bantuan komputasi sangat diperlukan untuk mengetahui hasil penentuan pola perilaku yang akurat sehingga penentuan pola perilaku bendungan menjadi lebih cepat dan efisien. Hasil Klasifikasi pola perilaku bendungan ini kemudian digunakan oleh petugas untuk menentukan tindakan yang tepat saat bencana datang. Data hasil monitoring bendungan menghasilkan suatu data temporal.

Data temporal merupakan suatu data yang diambil dalam satuan waktu tertentu. Data temporal bertujuan untuk mentukan pola tertentu, tren tak terduga atau hubungan tersembunyi yang belum diketahui sebelumnya [3].

Dalam proses Klasifikasi ini dibutuhkan suatu teknik untuk melakukan *classifier*. Proses Klasifikasi dapat dilakukan dengan menggunakan salah satu teknik yaitu K-NN. Algoritma K-Nearest Neighbor (K-NN) adalah sebuah metode untuk melakukan klasifikasi terhadap obyek baru berdasarkan (K) tetangga terdekatnya. K-NN termasuk algoritma *supervised learning*. Hasil dari *query instance* yang baru, diklasifikasikan berdasarkan mayoritas dari kategori pada K-NN. Kelas yang paling banyak muncul yang akan menjadi kelas hasil klasifikasi [4].

Hasil dari penelitian terdahulu dengan judul “Teknik Data Mining Untuk Mengklasifikasi Masa Studi Mahasiswa Menggunakan Algoritma K-Nearest Neighborhood”, menyimpulkan bahwa dari *data training* yang berjumlah 30 untuk menguji 30 data testing menghasilkan nilai k terbaik sebesar 10 dengan tingkat keberhasilan sebesar 81.66% untuk dua semester, 76.66% untuk empat semester dan 81.66% untuk enam semester. Sedangkan dengan data training yang berjumlah 60 untuk menguji 61 data tesing menghasilkan nilai k terbaik sebesar 10 dengan tingkat keberhasilan sebesar 80% untuk dua semester, nilai k terbaik sebesar 30 dengan tingkat keberhasilan 78.33% untuk empat semester dan nilai k terbaik sebesar 20 dan 30 dengan tingkat keberhasilan 85% untuk enam semester[5].

Dari permasalahan tersebut maka dibutuhkan “Sistem Klasifikasi Pola Perilaku Bendungan Menggunakan K-NN Classifier Berbasis Data Temporal di Bendungan Djuanda” yang memiliki tujuan untuk membantu proses penentuan perilaku bendungan agar pihak direksi dan kepala balai bendungan dapat terbantu dalam menganalisis keputusan berdasarkan pola perilaku bendungan yang terbentuk.

## 2. KAJIAN PUSTAKA

### 2.1 Data Mining

*Data Mining* merupakan proses ekstraksi data menjadi informasi yang

sebelumnya belum tersampaikan, dengan teknik yang tepat proses data mining akan memberikan hasil yang optimal. *Data mining* lebih tepat disebut sebagai penambangan pengetahuan dari data. Data mining membantu perusahaan atau organisasi untuk mendapatkan pola dari data-data yang tersimpan di dalam basis data perusahaan. Pengetahuan yang diperoleh tersebut akan menjadi pedoman dalam mengambil tindakan-tindakan bisnis sebagai upaya pemeliharaan dan peningkatan tingkat kompetitif bisnis perusahaan [7].

Berikut merupakan tahapan-tahapan dalam data mining:


1. Pembersihan data (*data cleaning*), yaitu proses menghapus data pengganggu (*noise*) yang dikatakan tidak konsisten atau tidak diperlukan.
2. Integrasi data (*data integration*), yaitu menggabungkan berbagai sumber data.
3. Pemilihan data (*data selection*), yaitu memilih data yang dipilih sesuai kebutuhan analisis.
4. Transformasi data (*data transformation*), yaitu proses transformasi data ke dalam format untuk diproses dan siap ditambang.
5. Penggalian data (*data mining*), yaitu menerapkan metode kecerdasan untuk ekstraksi pola.
6. Evaluasi pola (*pattern evaluation*), yaitu mengidentifikasi pola-pola yang menarik yang merepresentasikan pengetahuan.
7. Penyajian pola (*knowledge presentation*), yaitu teknik untuk memvisualisasikan pola pengetahuan ke pengguna.

## 2.2 Klasifikasi

Klasifikasi merupakan proses pembelajaran suatu fungsi tujuan (target)  $f$  yang memetakan tiap himpunan atribut  $x$  ke

satu dari label kelas  $y$  yang didefinisikan sebelumnya [9].

Klasifikasi dapat juga diartikan suatu proses untuk menemukan suatu model atau fungsi yang menggambarkan dan membedakan kelas data atau konsep dengan tujuan dapat menggunakan model untuk memklasifikasi kelas objek yang label *class*-nya tidak diketahui. Model dari klasifikasi ditunjukkan pada Gambar 1 sebagai berikut.



Gambar 1. Sistem Pembangkitan Kalimat Ilmiah

Data input untuk klasifikasi adalah isi dari *record*. Setiap *record* dikenal sebagai *instance* atau contoh, yang ditentukan oleh sebuah *tuple*  $(x, y)$ , dimana  $x$  adalah himpunan atribut dan  $y$  adalah atribut tertentu, yang dinyatakan sebagai *label class* (juga dikenal sebagai kategori atau atribut target). Pendekatan umum yang digunakan dalam masalah klasifikasi adalah pertama, data testing berisi *record* yang mempunyai *label class* yang telah diketahui. Data *training* digunakan untuk membangun model klasifikasi yang kemudian diaplikasikan ke data testing yang berisi beberapa *record* dengan *label class* yang tidak diketahui [10].

## 2.3 K-Nearest Neighbor

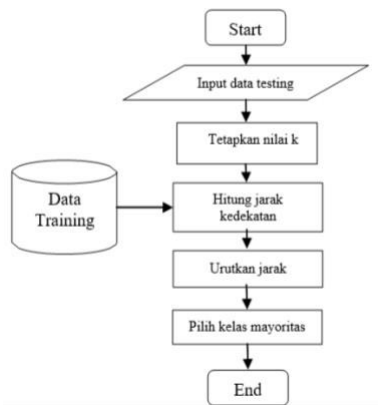
Algoritma K-Nearest Neighbor (K-NN) merupakan salah satu metode yang menerapkan algoritma *supervised*. Algoritma *supervised* terbagi dua yaitu *supervised learning* dengan *unsupervised learning*. Algoritma *supervised learning* bertujuan untuk mendapatkan pola baru sedangkan *unsupervised learning* untuk mendapatkan pola dalam sebuah data [11].

Tujuan algoritma KNN adalah mengklasifikasikan obyek baru berdasarkan atribut dan *training sample*. Classifier tidak menggunakan model apapun untuk dicocokkan dan hanya berdasarkan pada memori. Diberikan titik *query*, akan

ditemukan sejumlah  $k$  objek atau (titik *training*) yang paling dekat dengan titik *query*. Klasifikasi menggunakan voting terbanyak diantara klasifikasi dari  $k$  objek. Algoritma KNN menggunakan klasifikasi ketetanggaan sebagai nilai Klasifikasi dari *query instance* yang baru. Algoritma metode KNN sangatlah sederhana, bekerja berdasarkan jarak terpendek dari *query instance* ke *training sample* untuk menentukan KNN-nya.

Nilai  $k$  yang terbaik untuk algoritma ini tergantung pada data. Secara umum, nilai  $k$  yang tinggi akan mengurangi efek *noise* pada klasifikasi, tetapi membuat batasan antara setiap klasifikasi menjadi semakin kabur. Nilai  $k$  yang bagus dapat dipilih dengan optimasi parameter, misalnya dengan menggunakan *cross-validation*. Kasus khusus dimana klasifikasi diprediksikan berdasarkan *training* data yang paling dekat (dengan kata lain,  $k = 1$ ) disebut algoritma Nearest Neighbor [12].

Tahapan algoritma K-NN dijelaskan pada Gambar 2.



Gambar 2 Tahapan Algoritma K-NN

1. Tentukan parameter  $K$
2. Hitung jarak antara data yang akan dievaluasi dengan semua pelatihan
3. Urutkan jarak yang terbentuk (urut naik)
4. Tentukan jarak terdekat sampai urutan  $K$
5. Pasangkan kelas yang bersesuaian
6. Cari jumlah kelas dari tetangga yang terdekat dan tetapkan kelas tersebut sebagai kelas data yang akan dievaluasi dengan Persamaan 1.

$$d(x, y) = \sqrt{\sum_{i=1}^d (x_i - y_i)^2} \quad (1)$$

Keterangan:

$x$  = Sampel Data

$y$  = Data Uji / *Testing*

$i$  = Variabel Data


$d$  = Jarak

$d$  = Dimensi Data

Dalam penggunaan algoritma K-NN data dibagi menjadi dua bagian yaitu data latih dan data uji. Data latih digunakan algoritma untuk melakukan dasar Klasifikasi, Sedangkan data uji terdiri dari nilai yang diklasifikasi oleh algoritma. Data latih diubah menjadi vektor dan sebuah jarak dihitung menggunakan beberapa metode seperti *euclidean distance* atau *cosine similarity* [13].

### 2.4 K-Fold Cross Validation

Tujuan *K-Fold* adalah salah satu metode *Cross Validation* yang populer dengan melipat data sebanyak  $K$  dan melakukan iterasi terhadap percobaan sebanyak  $K$ . Dalam *K - Fold Cross-Validation*, set data pertama kali dibagi menjadi  $k$  partisi yang tidak tumpang tindih. Model diestimasi berdasarkan pada partisi  $k$  1, dan kemudian model dengan parameter yang tidak diketahui diperbaiki pada nilai estimasi sebelumnya yang kemudian akan diterapkan ke partisi yang tersisa [14]



Gambar 3 Pembentukan Model K-NN

### 2.5 Temporal Data Mining

Algoritma Perkembangan data mining secara alami membawa pada eksplorasi domain aplikasi dimana penggalan data tersebut dapat digunakan. Karena banyak dari domain ini bersifat *temporal* atau spasial context maka komponen waktu dan/atau

ruang harus diperhitungkan dalam proses penambangan, sehingga data yang dikumpulkan dapat ditafsirkan dengan benar [15].

Analisis dari peristiwa yang terjadi pada satu atau lebih dimensi waktu menjadi perhatian dalam penambangan data *temporal*. (Kemungkinan beberapa dimensi waktu dapat terjadi apabila suatu sistem dapat mengakomodasi berbagai garis waktu untuk suatu peristiwa, contohnya: Kevalidan waktu, waktu saat terjadi transaksi atau waktu saat terjadi keputusan). Secara garis besar, Penambangan data temporal terbagi menjadi dua arah. Penambangan data *temporal* pertama berfokus pada hubungan kasual yang terbentuk di antara peristiwa-peristiwa yang berorientasi sementara. Pembangan yang kedua berfokus pada persamaan pola yang terbentuk pada urutan waktu yang sama atau di antara urutan waktu berbeda. Pada saat ini, penambangan data dapat disebut juga analisis deret waktu (atau analisis trend). Analisis ini berfokus pada identifikasi kesamaan pola yang telah ditentukan sebelumnya, kesamaan waktu puncak diantara deret waktu [16].

Analisis deret waktu telah menjadi bahan penelitian sejak lama. Aspek penelitian meliputi pendugaan kurva dengan metode matematika; penurunan tingkat kebisingan; perbandingan deret waktu menggunakan teknik pencocokan pola dan Klasifikasi menggunakan metode matematika atau heuristik (seperti jaringan saraf) [17].

Ruang lingkup penambangan data berfokus pada penemuan hubungan kasual antara peristiwa yang mungkin terjadi dan saling terkait dalam suatu waktu. Dalam penambangan *data non-temporal*, hal tersebut merupakan respon terhadap penemuan "aturan", baik itu aturan asosiasi, aturan klasifikasi, karakterisasi atau beberapa struktur aturan lain dan semantik. Hal ini menyebabkan istilah "penemuan aturan *temporal*".

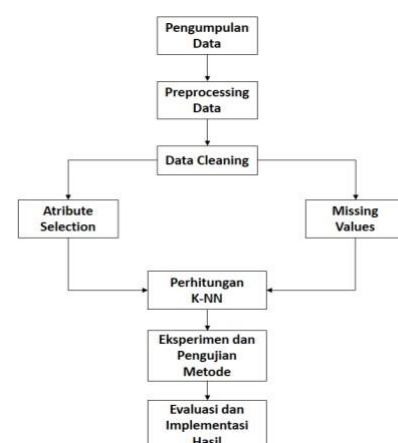
Susunan peristiwa membentuk urutan dan penyebab mengapa suatu peristiwa selalu terjadi sebelum hasilnya muncul. Oleh

karena itu, terdapat beberapa aturan temporal yang ada terjadi karena hasil urutan peristiwa pada poros waktu. karenanya, jika kita fokus pada aturan yang hanya berisi kondisi (mis. tidak ada disjungsi dan tidak ada negasi) kita dapat melakukan data mining pada urutan. Hal ini memberikan istilah seperti "urutan penambangan" [18].

*Temporal data mining* dapat didefinisikan sebagai "proses penemuan pengetahuan dalam *database temporal* yang menyebutkan struktur (pola atau model temporal) di atas *data temporal*, dan algoritma apa pun yang menyebutkan pola *temporal*. Tujuan dari *temporal data mining* adalah untuk menemukan pola *temporal*, tren yang tidak terduga, atau hubungan tersembunyi lainnya dalam data sekuensial yang lebih besar [19].

### 3 METODE PENELITIAN

Dalam penelitian ini data yang digunakan adalah data hasil *monitoring* Bendungan Djuanda yang diambil dari Perum Jasa Tirta 2 Purwakarta. Data hasil *monitoring* Bendungan Djuanda tersebut akan diolah menggunakan metode KNN sehingga hasilnya dapat digunakan sebagai *rules* dalam mengklasifikasi pola perilaku bendungan. Dalam penelitian ini akan dilakukan beberapa langkah-langkah atau tahapan seperti pada yang digambarkan pada Gambar 3.



Gambar 3 Tahapan Penelitian

Dalam Untuk mendukung penelitian, maka perlu mengkaji berbagai referensi

tentang tugas dari *data mining*, di mana salah satu tugas dari *data mining* adalah klasifikasi kasi. Teknik klasifikasi yang umum digunakan adalah K-NN. Metode K-NN dapat digunakan untuk melakukan pemilihan input untuk model nonlinear dan juga menyediakan perkiraan akurat untuk deret waktu dalam masalah prediksi. Jika K-NN digunakan untuk klasifikasi, objek diklasifikasikan dalam kelas paling banyak diminati di antara k tetangganya. Jika digunakan untuk regresi, nilai diberikan ke properti objek sebagai rata-rata dari nilai yang diketahui dari K tetangga terdekatnya. Pengambilan metode K-NN ini dilakukan karena data yang bersifat *numerik*.

### 3.1 Pengumpulan Data

Perolehan Metode pengumpulan data adalah teknik atau cara yang dilakukan oleh peneliti untuk mengumpulkan data. Pengumpulan data dilakukan untuk memperoleh informasi yang dibutuhkan dalam rangka mencapai tujuan penelitian. Sementara itu instrumen pengumpulan data merupakan alat yang digunakan untuk mengumpulkan data. Pada tahap pengumpulan data akan dilakukan dengan 2 cara, yaitu observasi dan wawancara. Data penelitian diambil data hasil *monitoring* Bendungan Djuanda.

### 3.2 Temporal Data

*Data mining* dapat didefinisikan sebagai “proses penemuan pengetahuan dalam *database temporal* yang menyebutkan struktur (pola atau *model temporal*) di atas data *temporal*, dan algoritma apa pun yang menyebutkan pola *temporal*. Tujuan dari *temporal data mining* adalah untuk menemukan pola *temporal*, tren yang tidak terduga, atau hubungan tersembunyi lainnya dalam data sekuensial yang lebih besar. Pada Sistem Klasifikasi Pola Perilaku Bendungan terdapat *data temporal* pada atribut waktu yang mana waktu tersebut diambil secara harian sehingga memunculkan pola *temporal*. Atribut waktu yang menghasilkan pola *temporal* pada Sistem Klasifikasi Pola

Perilaku Bendungan dapat dilihat pada Tabel 1.

Tabel 1 Data Temporal Pada Atribut Waktu

Atribut	Keterangan
Waktu	Atribut Waktu memiliki tipe data <i>Timestamp</i> yang mana data didalamnya terdapat tanggal, bulan, tahun dan juga jam yang diambil harian pada jam yang sama.

### 3.3 Preprocessing Data

Text Preprocessing *Data* menerangkan tipe-tipe proses yang melaksanakan data mentah untuk mempersiapkan proses prosedur yang lainnya. *Preprocessing* yang dilakukan yaitu proses pembersihan data mengalami tahap pembersihan yaitu *Data Cleaning*. Data yang telah didapatkan, akan dilakukan proses *Preprocessing Data* guna mengatasi atribut yang tidak memiliki data serta beberapa pembersihan data lainnya yang dibutuhkan untuk proses data mining yaitu sebagai berikut:

#### 3.3.1 Preprocessing Data

Data yang telah didapatkan dari Perum Jasa Tirta 2 Purwakarta akan dilakukan proses *cleaning* dengan maksud untuk membersihkan data dari atribut yang tidak diperlukan serta mengisi atribut data yang tidak memiliki nilai.

#### a. Attribute Selection

Data yang telah dilakukan proses *cleaning*, akan dilakukan proses *attributes selection* untuk memilih atribut yang memiliki tipe *numeric* dengan tujuan agar data dapat dihitung berdasarkan formula K – NN. Atribut yang dapat digunakan untuk proses klasifikasi dapat dilihat pada Tabel 2.

Tabel 2 Atribut Data yang Digunakan

NO	Nama Atribut	Keterangan
1	Observation Well	Menjelaskan tentang elevasi muka air yang ada pada Bendungan Djuanda.
2	Tri Dimension	Menjelaskan tentang pergerakan lempeng tanah pada Bendungan Djuanda.

3	Piezzo Cassagrande	Menjelaskan tentang tekanan air pori pada Bendungan Djuanda.
4	Vnotch	Menjelaskan tentang debit rembesan air pada Bendungan Djuanda.
5	Reservoir Water Level	Menjelaskan tentang tinggi muka air pada Bendungan Djuanda.
6	Volume Percentfull	Menjelaskan tentang persentase volume air pada Bendungan Djuanda.
7	Rainfall	Menjelaskan tentang Curah Hujan pada daerah sekitar Bendungan Djuanda

**b. Missing Values**

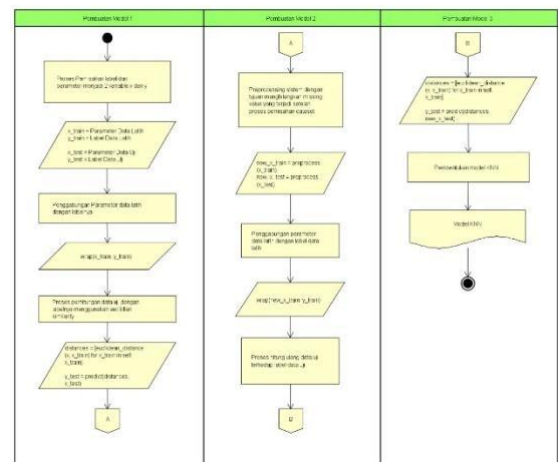
Data yang telah dilakukan proses *attributes selection*, akan dilakukan proses *missing value selection*, akan dilakukan proses *missing value* dengan tujuan untuk mengisi data dengan cara mencari nilai modus dari seluruh data dan menginputkan nilai modus tersebut pada atribut data yang kosong.

**3.4 Perhitungan K-NN**

Data yang telah dilakukan *preprocessing* akan menjadi data latih untuk data yang akan diuji dengan mengukur kedekatannya dengan data yang ada, perhitungan *distance* yang akan digunakan adalah *euclidian distance* dengan menggunakan Persamaan 1.


**3.5 Pembuatan Model K-NN**

*Recurrent Data* yang telah dilakukan *preprocessing* akan diubah menjadi sebuah model K-NN dengan cara membagi total *record dataset* menjadi 8:2, dimana 80% jumlah dataset akan menjadi data latih, dan 20% jumlah dataset akan menjadi data uji. Simulasi prosesnya dapat dilihat pada Gambar 4.



Gambar 3 Pemodelan Model K-NN

*K-Fold Cross validation* adalah metode statistik yang dapat digunakan untuk mengevaluasi kinerja model atau algoritma dimana data dipisahkan menjadi dua subset yaitu data proses pembelajaran dan data validasi atau evaluasi. Model atau algoritma dilatih oleh subset pembelajaran dan divalidasi oleh subset validasi. Selanjutnya pemilihan jenis *Cross Validation* dapat didasarkan pada ukuran *dataset*. Biasanya *K-Fold Cross Validation* digunakan karena dapat mengurangi waktu komputasi dengan tetap menjaga keakuratan estimasi. Simulasi *K-Fold Cross* dapat dilihat pada Gambar 4.



Gambar 4 K-Fold Cross Validation

**4 Hasil Dan Pembahasan**

Penelitian Kebutuhan perangkat lunak pada penelitian pengujian dilakukan menggunakan komputer pribadi. Lingkungan operasi aplikasi yang digunakan adalah lingkungan yang digunakan untuk menerapkan hasil rancangan pada bab analisis dan perancangan. Dalam penelitian ini perangkat lunak berbasis web dengan menggunakan bahasa pemrograman Python, dengan *text editor* menggunakan Microsoft

Visual Studio Code, Basis Data MySql, Web Server Apache yang ada pada aplikasi Laragon, web browser menggunakan Google Chrome dan Firefox serta *Framework* menggunakan Flask untuk Python. Dalam implementasi program penulis membuat *dataset* yang akan digunakan untuk proses perhitungan pada data baru. Nantinya data tersebut akan dihitung menggunakan proses K-NN dan dari hasil perhitungan tersebut akan diketahui berapa jumlah K – ideal yang ditampilkan ke dalam bentuk *line charts*.



Gambar 5 Implentasi Program

#	Waktu	Observation Well	T1 Dimension	Piezzo Casagrande	Vnutch	Reservoir Water Level	Volume Percentfull	Rainfall	Status
1	2020-08-10 10:45:00	2.0	2.0	2.0	2.0	2.0	2.0	2.0	AMAN
2	2020-08-25 10:00:00	43.0	25.0	54.0	25.0	80.0	25.0	10.0	AMAN

Gambar 6 Implementasi Visual Data Baru

### 5 Kesimpulan

Kesimpulan Dalam penelitian dan proses implementasi data mining pada penentuan pola perilaku bendungan pada di Bendungan Djuanda menggunakan *K-Nearest Neighbors* dapat disimpulkan bahwa *K-Nearest Neighbors* yang diimplementasikan pada proses pengujian pola perilaku bendungan di Bendungan Djuanda, menghasilkan akurasi sebesar 88% untuk label aman, 82% untuk label siaga dan 92% untuk label bahaya dari total data sebanyak 1.018 data.

### 6. REFERENSI

[1] R. T. Vulandari, D. Remawati, and Y. R. W, “Perbandingan Klasifikasi

Tinggi Muka Air Bendungan Wonogiri dengan Single Exponential Smoothing dan Brown ’ s Exponential Smoothing,” vol. 6, no. 2, pp. 167–176, 2018.

[2] Hasmawati, “Aplikasi Klasifikasi penjualan barang menggunakan metode,” vol. 3, no. 2, pp. 151–160, 2017.

[3] Y. Yang, “Temporal Data Mining,” *Temporal Data Min. Via Unsupervised Ensemble Learn.*, pp. 9–18, 2017.

[4] A. Y. Saputra and Y. Primadasa, “Penerapan Teknik Klasifikasi Untuk Klasifikasi Kelulusan Mahasiswa Menggunakan Algoritma K-Nearest Neighbor,” *Techno.Com*, vol. 17, no. 4, pp. 395–403, 2018.

[5] D. Z. Abidin, S. Nurmaini, and R. F. Malik, “Penerapan Metode K-Nearest Neighbor dalam MemKlasifikasi Masa Studi Mahasiswa ( Studi Kasus: Mahasiswa STIKOM Dinamika Bangsa ),” *Pros. Annu. Res. Semin.*, vol. 3, no. 1, pp. 133–138, 2017.

[6] S. Widaningsih, “Perbandingan Metode Data Mining Untuk Klasifikasi Nilai Dan Waktu Kelulusan Mahasiswa Prodi Teknik Informatika Dengan Algoritma C4,5, Naïve Bayes, Knn Dan Svm,” *J. Tekno Insentif*, vol. 13, no. 1, pp. 16–25, 2019.

[7] G. Abdillah *et al.*, “Penerapan Data Mining Pemakaian Air Pelanggan Untuk Menentukan Klasifikasi Potensi Pemakaian Air Pelanggan Baru Di Pdam Tirta Raharja Menggunakan Algoritma K-Means,” *Sentika 2016*, vol. 2016, no. Sentika, pp. 18–19, 2016.

[8] A. Sulistiyo, “ Penentuan Jurusan Sekolah Menengah Atas Menggunakan Metode K-Nearest Neighbor Classifier Pada SMAN 16 Semarang,” *Fasilkom Udinus*, vol. 1, no. 1, pp. 1–5, 2014.

[9] A. A. Syafitri Hidayatul AA, Yuita Arum S, “Seleksi Fitur Information Gain untuk Klasifikasi Penyakit Jantung Menggunakan Kombinasi Metode K-Nearest Neighbor dan Naïve Bayes,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 9, pp. 2546–2554, 2018.

[10] A. R. Yosafat and Y. Kurnia, “Aplikasi Klasifikasi Rating Film dengan

- Perbandingan Metode Naïve Bayes dan KNN Berbasis Website Menggunakan Framework Codeigniter,” *J. ALGOR*, vol. 1, no. 1, pp. 16–26, 2019.
- [11] W. T. Panjaitan, “Penerapan Algoritma Knn Pada Klasifikasi Produksi,” *J. Univ. AMIKOM Yogyakarta*, pp. 61–66, 2018.
- [12] I. A. A. Angreni, S. A. Adisasmita, and M. I. Ramli, “Terhadap Tingkat Akurasi Identifikasi Kerusakan Jalan,” vol. 7, no. 2, pp. 63–70, 2018.
- [13] D. Prajarini, “Perbandingan Algoritma Klasifikasi Data Mining Untuk Klasifikasi Penyakit Kulit,” *Informatics J.*, vol. 1, no. 3, p. 137, 2016.
- [14] F. Tempola, M. Muhammad, and A. Khairan, “Perbandingan Klasifikasi Antara Knn Dan Naive Bayes Pada Penentuan Status Gunung Berapi Dengan K-Fold Cross Validation Comparison of Classification Between Knn and Naive Bayes At the Determination of the Volcanic Status With K-Fold Cross,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 5, pp. 577–584, 2018.
- [15] R. Rawassizadeh, E. Momeni, C. Dobbins, J. Gharibshah, and M. Pazzani, “Scalable Daily Human Behavioral Pattern Mining from Multivariate Temporal Data,” *IEEE Trans. Knowl. Data Eng.*, vol. 28, no. 11, pp. 3098–3112, 2016.
- [16] G. Kaur, P. Tomar, and P. Singh, “Internet of Things and Big Data Analytics Toward Next-Generation Intelligence,” *Springer Int. Publ. AG 2018*, vol. 30, no. January, pp. 315–333, 2018.
- [17] S. Aljawarneh, V. Radhakrishna, P. V. Kumar, and V. Janaki, “A similarity measure for temporal pattern discovery in time series data generated by IoT,” *Proc. - 2016 Int. Conf. Eng. MIS, ICEMIS 2016*, pp. 31–34, 2016.
- [18] V. Radhakrishna, P. V. Kumar, V. Janaki, and S. Aljawarneh, “A similarity measure for outlier detection in timestamped temporal databases,” *Proc. - 2016 Int. Conf. Eng. MIS, ICEMIS 2016*, pp. 0–4, 2016.
- [19] H. Ltifi, E. Benmohamed, C. Kolski, and M. Ben Ayed, “Enhanced visual data mining process for dynamic decision-making,” *Knowledge-Based Syst.*, vol. 112, pp. 166–181, 2016.

