

PREDIKSI DAERAH RAWAN BANJIR DI KABUPATEN MALAKA MENGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE

Yovita Tae, Firman Nurdiyansyah, Fitria Marisa

Teknik Informatika, Universitas Widyagama Malang

Jln. Borobudur 35 Malang

ovhita3@gmail.com

ABSTRAK

Banjir menjadi salah satu bencana alam yang sering terjadi, dengan nilai persentasenya sebanyak 40% dibandingkan dengan bencana alam lainnya. Bencana banjir diakibatkan oleh beberapa faktor diantaranya curah hujan yang tinggi, kemiringan lereng, ketinggian lahan, jenis tanah, pengguna lahan, kerapian sungai serta perbuatan manusia yang tidak peduli akan lingkungan seperti, membuang sampah secara sembarangan. Untuk mengurangi tingkat kerugian pasca banjir dibutuhkan sebuah prediksi agar daerah rawan banjir dapat siap sedia saat terjadi atau akan terjadi banjir. Metode *Support Vector Machine* merupakan metode penyelesaian masalah pengklasifikasian data linear dan non-linear dengan mencari pemisah *hyperplane* yang optimal antar kelas, sehingga mempunyai tingkat akurasi yang tinggi untuk melakukan prediksi. Variabel yang digunakan dalam penelitian ini adalah curah hujan, jenis tanah, dan kemiringan lereng. Data didapatkan dari BPS dan BMKG untuk daerah Kabupaten Malaka. Berdasarkan hasil pengujian dan pembahasan, penggunaan model SVM untuk prediksi banjir memiliki akurasi yang tinggi dengan nilai akurasi tertinggi sebesar 95% pada model SVM dengan kernel linear pada penggunaan data training dan data testing 60:40. Curah hujan mempunyai pengaruh yang lebih tinggi terhadap kemungkinan banjir suatu daerah, jenis tanah aluvial dan tingkat kemiringan lereng sebesar 0-8% juga mempengaruhi terjadinya banjir jika terjadi hujan yang lebat atau tingkat curah hujan yang tinggi.

Kata kunci : *Prediksi, Banjir, Support Vector Machine*

1. PENDAHULUAN

Banjir adalah situasi di mana terjadi kenaikan level air yang drastis di area yang biasanya kering atau kurang berair. Fenomena ini dapat disebabkan oleh beberapa faktor, seperti curah hujan yang tinggi, kemiringan lereng, jenis tanah, dan perilaku manusia yang tidak memperhatikan lingkungan, seperti membuang sampah sembarangan. Banjir bisa mengakibatkan kerusakan pada properti, infrastruktur, lingkungan, serta dapat menyebabkan kematian.[1]

Menurut "Badan Meteorologi, Klimatologi, dan Geofisika"(BMKG), banjir memiliki pengertian yakni meningkatnya volume air dengan menggenangi daratan. Banjir merupakan bencana alam yang sering terjadi, sebanyak 40% dibandingkan dengan bencana alam lainnya. Bencana banjir disebabkan oleh berbagai faktor, termasuk curah hujan yang tinggi, kemiringan lereng, ketinggian lahan, jenis tanah, penggunaan lahan, kondisi sungai, serta perilaku manusia yang tidak peduli terhadap lingkungan, seperti membuang sampah sembarangan.[2]

Prediksi risiko banjir menjadi cara untuk mencegah dan mengurangi kerugian serta kerusakan akibat bencana banjir di masa depan di Kabupaten Malaka, Kota Betun. Penilaian bahaya banjir berdasarkan faktor-faktor penyebab banjir menjadi upaya dasar yang harus dilakukan. Kemudian, hasil penilaian ini dimodelkan secara spasial untuk menggambarkan distribusi tingkat bahaya banjir melalui visualisasi peta bahaya banjir.[3]

Dengan memanfaatkan teknologi geospasial, khususnya Sistem Informasi Geografis (SIG), kita dapat memodelkan dan memetakan bahaya banjir di suatu daerah berdasarkan faktor-faktor penyebabnya,

seperti curah hujan yang tinggi, topografi, dan penggunaan lahan. Teknologi ini memungkinkan pembuatan peta dari bahaya banjir serta prediksi kawasan permukiman yang akan terdampak oleh banjir.[1]

Banjir di Kabupaten malaka, dapat dilihat pada beberapa ruas desa, antara lain; di Desa Forekmodok, desa lamudur, desa wederok, desa angkaes, dan desa haitimuk yang adalah pusat kabupaten malaka. Dampak dari banjir di kabupaten malaka membuat sebagian aktivitas warga yang berada di kabupaten malaka terganggu karena terjadinya banjir.[3]

Beberapa sungai memiliki debit air di atas rata-rata, sehingga dapat digunakan sebagai sumber irigasi dan air bersih. Namun, debit air yang besar juga dapat menimbulkan ancaman bahaya banjir di musim hujan, terutama akibat terdegradasinya lahan di Kabupaten Malaka. Dengan demikian, selain mempertimbangkan variabel curah hujan dalam memprediksi kejadian banjir, besarnya debit air juga harus diperhitungkan. Banjir bandang dapat terjadi jika luapan air sungai tidak mampu menampung aliran air yang deras dari dataran yang lebih tinggi. Debit air juga dapat diprediksi menggunakan metode BP-NN (*Backpropagation Neural Network*).[1]

Metode *Support Vector Machine* (SVM) adalah teknik untuk menyelesaikan masalah klasifikasi data baik linear maupun non-linear dengan mencari *hyperplane* pemisah yang optimal antar kelas. *Hyperplane* ini ditentukan berdasarkan kasus pelatihan yang menempatkannya pada batas deskriptor kelas, yang dikenal sebagai *support vector*. SVM pada dasarnya adalah sebuah linear classifier, namun dikembangkan untuk menangani masalah non-linear

dengan menerapkan konsep kernel trick dalam ruang berdimensi tinggi. Dalam penelitian ini, untuk menangani klasifikasi non-linear yang melibatkan lebih dari dua kelas, diperlukan pendekatan *Support Vector Machine* yang dapat mengelola lebih dari dua kategori.[4]

Selain itu, terdapat dua pendekatan untuk menerapkan metode SVM dalam masalah klasifikasi multi-kelas dengan menggabungkan beberapa SVM biner, yaitu *One Against All* (OAA) dan *One Against One* (OAO). Pendekatan OAA menyelesaikan masalah klasifikasi dengan N kelas menggunakan N decision boundary. Setiap decision boundary dihasilkan dari pencarian hyperplane yang memisahkan setiap kelas ke-i dari kelas-kelas lainnya. Sementara itu, pendekatan OAO menyelesaikan masalah multi-kelas dengan $N(N-1)/2$ decision boundary, di mana setiap decision boundary dihasilkan dari pencarian hyperplane antara setiap pasangan kelas. Penelitian ini menggunakan pendekatan OAA sebagai model untuk menentukan kelas yang tepat, karena OAA umumnya menunjukkan performa yang lebih baik dibandingkan dengan OAO.[5]

Dalam penelitian ini, penulis menggunakan metode *Support Vector Machine* (SVM), yang merupakan teknik terbaru dan populer untuk prediksi, baik dalam kasus klasifikasi maupun regresi. SVM sejenis dengan *Artificial Neural Networks* (ANN) dalam hal fungsi dan permasalahan yang dapat diselesaikan, keduanya termasuk dalam kategori supervised learning. Teknik ini banyak digunakan oleh ilmuwan dan praktisi di bidang *Machine Learning*, *Data Mining*, atau *Big Data* untuk menyelesaikan berbagai masalah nyata dalam kehidupan sehari-hari dan untuk memprediksi kejadian di masa depan. Algoritma machine learning, termasuk SVM, belajar dari data, sehingga sangat penting untuk menyiapkan data dengan tepat agar dapat menyelesaikan masalah secara efektif.[5]

Penggunaan SVM untuk prediksi banjir mempunyai hasil akurasi yang tinggi. Penelitian yang dilakukan oleh [5] tentang prediksi banjir di daerah Bandung. Penelitian ini bertujuan memberikan informasi kepada masyarakat di Kabupaten Bandung mengenai apakah daerah tempat mereka tinggal termasuk dalam Zona Daerah Rawan Banjir atau tidak. Hasil penelitian yang dilakukan maka sistem Web menggunakan bahasa python dan metode SVM mampu memprediksi dengan baik, hasil yang diperoleh nilai akurasi terbaik adalah 97.62%.

Berdasarkan penelitian tersebut maka pada penelitian ini menggunakan metode SVM agar prediksi daerah rawan banjir dapat lebih akurat karena tingkat akurasi yang tinggi sehingga Masyarakat atau pemerintah setempat dapat melakukan pencegahan atau persiapan yang cukup jika terjadi banjir di daerah tersebut.

2. TINJAUAN PUSTAKA

Dalam melakukan suatu penelitian, kita perlu mengetahui penelitian terlebih dahulu dan mendalami pengetahuan mengenai metode bahkan hasil dalam penelitian tersebut harus kita ketahui. Berikut beberapa jurnal hasil penelitian terdahulu yang dapat dijadikan sebagai acuan.

Yang pertama, Optimasi Prediksi Bencana Banjir Menggunakan Algoritma SVM untuk Penentuan Daerah Rawan Bencana Banjir [5] mengidentifikasi masalah umum dalam klasifikasi dan machine learning, yaitu risiko “*overfitting*” yang muncul akibat banyaknya dimensi fitur dibandingkan jumlah data pelatihan. *Overfitting* terjadi ketika model terlalu sesuai dengan data pelatihan, yang disebabkan oleh jumlah data yang tidak memadai dibandingkan dengan jumlah atribut. Untuk mengatasi risiko ini, teknik *feature selection* digunakan. Penelitian ini bertujuan memberikan informasi kepada masyarakat di Kabupaten Bandung mengenai apakah daerah tempat mereka tinggal termasuk dalam Zona Daerah Rawan Banjir atau tidak. Informasi ini dapat diakses melalui halaman resmi BNPB, BPS Kabupaten Bandung, dan BMKG. Metode yang digunakan untuk prediksi bencana banjir adalah *Support Vector Machine* (SVM). Hasil penelitian yang dilakukan maka sistem Web menggunakan bahasa python dan metode SVM mampu memprediksi dengan baik, hasil yang diperoleh nilai akurasi terbaik adalah 97.62%.

Yang kedua, Agen Cerdas Berbasis Fuzzy Tsukamoto Pada Sistem Prediksi Banjir [6]. Masalah penelitian saat ini serta mengetahui pengetahuan *Fuzzy logic*. Untuk membantu memprediksi bencana banjir. Agen cerdas pada penelitian sistem prediksi banjir menggunakan metode *fuzzy Tsukamoto*. Hasil penelitian ini diterapkan untuk memprediksi banjir pada daerah di Semarang mempunyai akurasi sebesar 87,5%. Hal ini menunjukkan akurasi yang cukup bagus sehingga logika *Fuzzy* yang terbentuk dapat digunakan untuk melakukan prediksi di tahun-tahun berikutnya.

Yang ketiga, Algoritma J48 Untuk Pemodelan Sistem Prediksi Tingkat Kerawanan Banjir Dengan Visualisasi Web GIS[7]. Untuk menentukan daerah yang termasuk dalam zona rawan banjir di Kota Administrasi Jakarta Timur, diperlukan analisis berdasarkan kepadatan penduduk, ketinggian wilayah, jarak pusat daerah dengan sungai, dan rata-rata curah hujan. Metode yang digunakan untuk pemodelan sistem prediksi tingkat kerawanan banjir adalah metode J48. Hasil analisis terhadap parameter-parameter tersebut menghasilkan nilai akurasi sebesar 86,178%. Nilai akurasi ini menunjukkan bahwa model prediksi yang digunakan memiliki performa yang tinggi.

Yang keempat, Klasifikasi Resiko Tsunami Di Daerah Pantai Selatan Jawa Tengah Dengan Menerapkan Algoritma SVM (studi kasus Kab.Kebumen [4]. Data mengenai wilayah yang berisiko tsunami sangat penting, terutama untuk

Kabupaten Kebumen yang terletak di dataran rendah dan dekat pantai. Dengan melakukan pengestrakan data dari USGS Citra Landsat-8 serta menggunakan beberapa indeks vegetasi, penelitian ini bertujuan untuk memperoleh hasil prediksi mengenai daerah di Kabupaten Kebumen yang berpotensi terkena tsunami. Dengan demikian, diharapkan pemerintah dapat mengantisipasi risiko tersebut. Metode yang digunakan untuk mengklasifikasi risiko tsunami di daerah pantai selatan Jawa Tengah adalah *Support Vector Machine* (SVM). Hasil penelitian menunjukkan akurasi prediksi yang mencapai lebih dari 90%.

Yang kelima, Pemodelan Daerah Rawan Banjir Di Kecamatan Sirimau Menggunakan Metode *Multi-Criteria Analysis* (MCA) [8]. Banjir yang terjadi merendam 783 rumah dan 1 unit fasilitas pendidikan. Dengan genangan air setinggi 50-80 cm, akses jalan menjadi berbahaya bagi kendaraan, dan kondisi ini mengganggu aktivitas masyarakat. Sebanyak 3.126 warga terdampak dan satu orang ditemukan tewas. Pencegahan dan pengurangan kerugian akan kerusakan akibat banjir di masa depan, dilakukan dengan membuat pemetaan risiko banjir di Kecamatan Sirimau, Kota Ambon. Penilaian bahaya banjir berdasarkan faktor-faktor penyebab banjir menjadi upaya dasar yang harus dilakukan. Kemudian, hasil penilaian ini dimodelkan secara spasial untuk menggambarkan distribusi tingkat bahaya banjir melalui visualisasi peta bahaya banjir. Metode yang digunakan untuk pemodelan daerah rawan banjir adalah *Multi-Criteria Analysis* (MCA). Hasil penelitian menunjukkan bahwa daerah dengan zona bahaya banjir kelas tinggi mencakup seluas 540,09 ha atau 14,59%, kelas sedang seluas 1.607,14 ha atau 43,41%, dan kelas rendah seluas 1.555,34 ha atau 42,01%.

Yang keenam, Prediksi Debit Limpasan Air Permukaan Pada Daerah Rawan Banjir Di Kabupaten Jombang Berdasarkan Pemodelan Penggunaan Lahan [9]. Berkurangnya aliran dasar (*base flow*) dan pengisian air tanah (*infiltrasi*) berpotensi menyebabkan peningkatan volume limpasan air permukaan (*surface runoff*), yang pada gilirannya dapat menyebabkan ketidakseimbangan tata air. Proses percobaan dapat membantu mengidentifikasi dampak yang terjadi di masa depan, khususnya terkait dengan kenaikan debit limpasan yang berpotensi menimbulkan banjir. Data dikumpulkan melalui pengamatan secara langsung dan tidak langsung. Survei primer digunakan untuk memperoleh data dokumentasi kondisi eksisting serta hasil kuesioner Delphi dan AHP. Hasil prediksi untuk skenario tren pertumbuhan lahan menunjukkan bahwa terdapat 4.129,75 ha lahan yang berpotensi berubah menjadi kawasan terbangun, yang dapat menyebabkan kenaikan debit limpasan sangat tinggi, yakni 0,61 – 0,63 m³/s. Sementara itu, skenario analisis kebutuhan lahan menunjukkan 2.999,81 ha lahan yang berpotensi berubah menjadi kawasan terbangun, yang dapat

menyebabkan kenaikan debit limpasan sangat tinggi, yakni 0,38 – 0,4 m³/s.


Yang ketujuh, Analisis Prediksi Wilayah Rawan Banjir Dengan Algoritma *K-Means* [8]. Untuk menemukan pengetahuan tersembunyi yang dapat digunakan secara langsung, tujuan utamanya adalah untuk memperkirakan kelas dari objek yang kelasnya tidak diketahui dan mengelompokkan wilayah rawan banjir menjadi objek-objek clustering. Metode *K-Means Clustering* dipilih karena kemudahannya implementasinya, adaptabilitas, dan penggunaannya yang umum dalam studi-studi serupa. Dalam analisis prediksi wilayah rawan banjir, digunakan algoritma *K-Means*. Hasil pengujian dataset banjir menunjukkan nilai Davies-Bouldin Index sebesar -0,452. Nilai ini menunjukkan bahwa semakin kecil nilainya, semakin baik kualitas *cluster* yang diperoleh.

Yang kedelapan, Pemetaan Daerah Rawan Banjir Di Desa Batumerah Kecamatan Sirimau Kota Ambon Menggunakan Sistem Informasi Geografis [10]. Fenomena ini terjadi saat hujan deras membuat lapisan tanah tidak mampu menyerap air dengan jumlah yang besar tersebut dengan cepat, sehingga air mengalir ke sungai, danau, atau sistem drainase terdekat. Untuk menggambarkan daerah rawan banjir di Desa Batumerah, Kecamatan Sirimau, Kota Ambon, digunakan Sistem Informasi Geografis (SIG). Metode pemetaan ini melibatkan penggunaan SIG untuk menentukan tingkat kerawanan banjir. Hasil penelitian menunjukkan bahwa di Desa Batumerah, zona bahaya banjir terbagi sebagai berikut: kelas tinggi mencakup area seluas 176,05 ha (19,28%), kelas sedang seluas 387,71 ha (42,45%), dan kelas rendah seluas 349,62 ha (38,28%).

3. METODE PENELITIAN

3.1. Tahapan Umum Penelitian

Dalam penelitian ini terdapat beberapa tahap secara umum, diantaranya tahapan persiapan, pengumpulan data, sistem informasi geografis, prediksi daerah rawan banjir, Penyajian peta daerah rawan banjir, penyusunan laporan, selesai. Tahapan tahapan itu akan dilakukan secara berurutan agar bisa mendapatkan hasil yang maksimal dalam penulisan laporan akhir.



Gambar 1. Tahapan Umum Penelitian

3.2. Persiapan

Tahap ini merupakan tahap awal yang harus dilakukan untuk mempersiapkan bahan-bahan serta alat yang akan digunakan dalam penelitian ini.

3.3. Pengumpulan Data

Pengumpulan data merupakan tahapan mengumpulkan data yang akan digunakan dalam penelitian ini. Data yang digunakan dalam penelitian ini antara lain adalah data curah hujan yang didapatkan dengan mengakses situs BMKG, data jenis tanah, data kemiringan lereng, dan data daerah rawan banjir didapatkan dengan mengakses situs BPS.

3.4. Prediksi Daerah Rawan Banjir

Berdasarkan hasil yang diperoleh dari hasil overlay maka akan didapatkan prediksi daerah rawan banjir dan kemudian dibandingkan dengan hasil verifikasi lapangan.

3.5. Preprocessing Data

Preprocessing data yang dilakukan pada penelitian ini ada dua yaitu pengecekan data kosong dan normalisasi data. Adapun pengecekan data kosong menggunakan google colab dan tidak ada data kosong. Selanjutnya adalah melakukan normalisasi data. Normalisasi data pada penelitian ini adalah merubah data string pada dataset ke dalam angka.

3.6. Pengujian

Setelah *preprocessing* data akan dilanjutkan ke tahap pengujian. Pada tahap ini, dilakukan pengujian terhadap model yang telah dilatih menggunakan data prediksi daerah rawan banjir yang telah disiapkan sebelumnya. Hasil pengujian akan dievaluasi untuk melihat apakah model dapat berhasil prediksi banjir dengan akurat dan konsisten. Jika model berhasil prediksi banjir dengan baik, dapat dikatakan bahwa tahap pengujian telah berhasil. Hasil ini menunjukkan bahwa model yang telah dikembangkan mampu melakukan prediksi banjir dengan hasil yang memenuhi harapan.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Pengujian

Pengujian dilakukan di google colab, kernel yang digunakan ada empat yaitu sigmoid, polynomial, linear, dan RBF. Sedangkan untuk data perbandingan data training dan data uji ada 10 yaitu 95:5, 90:10, 85:15, 80:20, 75:25, 70:30, 65:35, 60:40, 55:45 dan 50:50. Setiap perbandingan data training dan data uji akan diuji sebanyak lima kali, karena data training dan data uji dipilih secara random.

Adapun persamaan yang digunakan:

- $Precision = \frac{TP}{TP + FP}$
- $Recall = \frac{TP}{TP + FN}$
- $F-1 \text{ Score} = 2 \times \frac{Recall \times Precision}{Recall + Precision}$
- $Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$

4.2. Kernel Sigmoid

Tabel 1. Hasil Pengujian SVM Kernel Sigmoid

No	Data Training: Data Uji (%)	Precision	Recall	F-1 Score	Akurasi
1	90 : 5	86%	86%	86%	75%
2	90 : 10	100%	93%	96%	93%
3	85 : 15	85%	94%	89%	82%
4	80 : 20	85%	96%	90%	83%
5	75 : 25	88%	97%	92%	86%
6	70 : 30	88%	97%	92%	86%
7	65 : 35	91%	98%	95%	90%
8	60 : 40	91%	100%	95%	91%
9	55 : 45	92%	98%	95%	91%
10	50 : 50	91%	98%	94%	90%

Berdasarkan hasil pengujian akurasi terendah pada penggunaan data dengan perbandingan 95:5 untuk data training dan data tes sebesar 75% dan akurasi tertinggi pada perbandingan 90:10 untuk data training dan data tes sebesar 93%. Sehingga model SVM untuk prediksi banjir dengan menggunakan kernel sigmoid lebih baik menggunakan perbandingan data 90:10 untuk data training dan data testing.

4.3. Kernel Polynomial

Tabel 2. Hasil Pengujian SVM Kernel Polynomial

No	Data Training: Data Uji (%)	Precision	Recall	F-1 Score	Akurasi
1	90 : 5	88%	100%	93%	88%
2	90 : 10	93%	100%	96%	93%
3	85 : 15	86%	100%	92%	86%
4	80 : 20	85%	100%	92%	86%
5	75 : 35	88%	100%	94%	89%
6	70 : 30	90%	100%	95%	91%
7	65 : 35	92%	100%	96%	92%
8	60 : 40	91%	100%	95%	91%
9	55 : 45	92%	100%	96%	92%
10	50 : 50	91%	100%	95%	92%

Berdasarkan hasil pengujian akurasi terendah pada penggunaan data dengan perbandingan 85:15 dan 80:20 untuk data training dan data tes sebesar 86% dan akurasi tertinggi pada perbandingan 90:10 untuk data training dan data tes sebesar 93%. Sehingga model SVM untuk prediksi banjir dengan menggunakan kernel polynomial lebih baik menggunakan perbandingan data 90:10 untuk data training dan data testing.

4.4. Kernel Linear

Tabel 3. Hasil Pengujian SVM Kernel Linear

No	Data Trainin: Data Uji (%)	Precision	Recall	F-1 Score	Akurasi
1	90 : 5	88%	100%	93%	88%
2	90 : 10	93%	100%	96%	93%
3	90 : 15	85%	94%	89%	82%
4	90 : 20	85%	100%	92%	86%
5	75 : 25	91%	100%	95%	92%
6	70 : 30	93%	100%	96%	93%
7	65 : 35	94%	100%	97%	94%
8	60 : 40	94%	100%	97%	95%
9	55 : 45	95%	98%	96%	94%
10	50 : 50	94%	98%	96%	93%

Berdasarkan hasil pengujian akurasi terendah pada penggunaan data dengan perbandingan 85:15 untuk data training dan data tes sebesar 82% dan akurasi tertinggi pada perbandingan 60:40 untuk data training dan data tes sebesar 95%. Sehingga model SVM untuk prediksi banjir dengan menggunakan kernel linear lebih baik menggunakan perbandingan data 60:40 untuk data training dan data testing.

4.5. Kernel RBF


Tabel 4. Hasil Pengujian SVM Kernel RBF

No	Data Training: Data Uji (%)	Pre- cision	Recall	F-1 Score	Akurasi
1	90 : 5	88%	100%	93%	88%
2	90 : 10	93%	100%	96%	93%
3	85 : 15	86%	100%	92%	86%
4	80 : 20	85%	100%	92%	86%
5	75 : 25	88%	100%	94%	89%
6	70 : 30	90%	100%	95%	91%
7	65 : 35	92%	100%	96%	92%
8	60 : 40	88%	93%	93%	88%
9	55 : 45	89%	94%	94%	89%
10	50 : 50	87%	83%	83%	88%

Berdasarkan hasil pengujian akurasi terendah pada penggunaan data dengan perbandingan 85:15 dan 80:20 untuk data training dan data tes sebesar 86% dan akurasi tertinggi pada perbandingan 90:10 untuk data training dan data tes sebesar 93%. Sehingga model SVM untuk prediksi banjir dengan menggunakan kernel RBF lebih baik menggunakan perbandingan data 90:10 untuk data training dan data testing.


4.6. Hasil Perbandingan Akurasi, Presisi, Recall dan F-1 Score

Hasil score akurasi pengujian dengan metode *Support Vector Machine* (SVM). Pada metode SVM dalam pengujian ini menggunakan 4 kernel *Sigmoid*, *Polynomial*, *Linear* dan *RBF*.




Gambar 2. Hasil Grafik Perbandingan Akurasi Antar Kernel

Berdasarkan hasil perbandingan, diketahui bahwa penggunaan kernel linear pada penggunaan data 60:40 (data training:data testing) menghasilkan nilai akurasi tertinggi sebesar 95%. Dan akurasi terendah pada kernel sigmoid pada penggunaan data 95:5 (data training : data testing) sebesar 75%.




Gambar 3. Hasil Grafik *Precession* Akurasi Antar Kernel

Berdasarkan hasil perbandingan, diketahui bahwa penggunaan kernel Sigmoid pada penggunaan data 90:10 (data training:data testing) menghasilkan nilai akurasi tertinggi sebesar 100%. Dan akurasi terendah pada kernel Sigmoid pada penggunaan data 85:15 dan 80:20, Polynomial pada penggunaan data 80:20, Linear pada penggunaan data 85:15 dan 80:20 dan RBF pada penggunaan data 80:20 (data training : data testing) sebesar 85%.



Gambar 4. Hasil Grafik Perbandingan *Recall* Antar Kernel

Berdasarkan hasil perbandingan, diketahui bahwa penggunaan kernel Sigmoid pada penggunaan data 60:40, Polynomial pada penggunaan data 95:5, 90:10 sampai dengan 50:50, Linear pada penggunaan data 95:5, 90:10, 80:20, 75:25, 70:30, 65:35, 60:40 dan RBF pada penggunaan data 95:5, 90:10 sampai dengan 50:50 (data training:data testing) menghasilkan nilai akurasi tertinggi sebesar 100%. Dan akurasi terendah pada kernel Sigmoid pada penggunaan data 90:10 (data training : data testing) sebesar 93%.



Gambar 5. Hasil Grafik Perbandingan F-1 Score Antar Kernel

Berdasarkan hasil perbandingan, diketahui bahwa penggunaan kernel Linear pada penggunaan data 65:35 dan 60:40 (data training:data testing) menghasilkan nilai akurasi tertinggi sebesar 97%. Dan akurasi terendah pada kernel RBF pada penggunaan data 50:50 (data training : data testing) sebesar 83%.

4.7. Hasil Perbandingan Akurasi Antar Kernel

Berdasarkan hasil pengujian model SVM untuk prediksi banjir dengan kernel Sigmoid, Polynomial, Linear, dan RBF, didapatkan hasil sebagai berikut.


Tabel 5. Hasil Perbandingan Akurasi Antar Kernel

No	Data Training: Data Uji (%)	Sigmoid	Poly- nomial	Linear	RBF
1	90 : 5	75%	88%	88%	88%
2	90 : 10	87%	93%	93%	93%
3	85 : 15	82%	86%	82%	86%
4	80 : 20	83%	86%	86%	86%
5	75 : 25	86%	89%	92%	89%
6	70 : 30	86%	91%	93%	91%
7	65 : 35	90%	92%	94%	92%
8	60 : 40	91%	91%	95%	88%
9	55 : 45	91%	92%	94%	89%
10	50 : 50	90%	92%	93%	88%

Berdasarkan hasil pengujian yang telah dilakukan, pada penggunaan data 95:5 (data training : data tes) kernel sigmoid menghasilkan akurasi sebesar 75%, kernel polynomial, kernel linear, dan kernel RBF menghasilkan akurasi sebesar 88%. Pada penggunaan data 90:10, kernel sigmoid menghasilkan akurasi sebesar 87%, kernel polynomial, kernel linear, dan kernel RBF menghasilkan akurasi sebesar 93%. Pada penggunaan data 85:15, kernel sigmoid dan kernel linear menghasilkan akurasi sebesar 82%, sedangkan kernel polynomial dan RBF menghasilkan akurasi sebesar 86%. Pada penggunaan data 80:20, kernel sigmoid menghasilkan akurasi sebesar 83%, kernel polynomial, kernel linear, dan kernel RBF menghasilkan akurasi sebesar 86%. Pada penggunaan data 75:25, kernel sigmoid menghasilkan tingkat akurasi terendah sebesar 86%, kernel polynomial dan kernel RBF menghasilkan akurasi sebesar 89%, sedangkan tingkat akurasi tertinggi pada kernel linear sebesar 92%.

Pengujian dengan menggunakan data 70:30 kernel sigmoid menghasilkan tingkat akurasi terendah sebesar 86%, kernel polynomial dan kernel RBF menghasilkan akurasi sebesar 91%, sedangkan tingkat akurasi tertinggi pada kernel linear sebesar 93%. Pada pengujian data 65:35 kernel sigmoid menghasilkan tingkat akurasi terendah sebesar 90%, kernel polynomial dan kernel RBF menghasilkan akurasi sebesar 92%, sedangkan tingkat akurasi tertinggi pada kernel linear sebesar 94%. Pada pengujian data 60:40 kernel RBF menghasilkan tingkat akurasi terendah sebesar 88%, kernel sigmoid dan kernel polynomial menghasilkan akurasi sebesar 91%, sedangkan tingkat akurasi tertinggi pada kernel linear sebesar 95%. Pada pengujian dengan data 55:45, kernel RBF menghasilkan tingkat akurasi terendah sebesar 89%, kernel sigmoid sebesar 91%, kernel polynomial sebesar 92%, dan tingkat akurasi tertinggi pada kernel linear sebesar 94%. Penggunaan data 50:50, kernel RBF menghasilkan tingkat akurasi terendah sebesar 88%, kernel sigmoid sebesar 90%, kernel polynomial sebesar 92%, dan tingkat akurasi tertinggi pada kernel

linear sebesar 93%. Berikut ini merupakan matrik perbandingan antar kernel.



Gambar 6. Matriks Perbandingan Antar Kernel

Berdasarkan hasil perbandingan, diketahui bahwa penggunaan kernel linear pada penggunaan data 60:40 (data training: data testing) menghasilkan nilai akurasi tertinggi sebesar 95%. Dan akurasi terendah pada kernel sigmoid pada penggunaan data 95:5 (data training : data testing) sebesar 75%. Hasil pengujian ini sesuai dengan hasil penelitian yang telah dilakukan oleh Dwiasnati & Devianto[5], yang menghasilkan tingkat akurasi sebesar 97% dan penelitian yang telah dilakukan oleh Wahani & Prasetyo[4], yang menghasilkan tingkat akurasi di atas 90%, sehingga model SVM dapat digunakan untuk melakukan prediksi wilayah rawan banjir di Kabupaten Malaka.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian dan pembahasan di atas, maka peneliti berkesimpulan bahwa penggunaan model SVM untuk prediksi banjir memiliki akurasi yang tinggi dengan nilai akurasi tertinggi sebesar 95% pada model SVM dengan kernel linear pada penggunaan data training dan data testing 60:40. Adapun saran untuk penelitian yang dilakukan selanjutnya adalah menggunakan variabel atau menambah variabel lainnya seperti jumlah hari hujan, ketinggian tanah dari permukaan laut atau luas wilayah dan membandingkan dengan algoritma atau metode peramalan yang lainnya.

DAFTAR PUSTAKA

- [1] I. Fitriyaningsih and Y. Basani, "Flood Prediction with Ensemble Machine Learning using BP-NN and SVM," *J. Teknol. Dan Sist. Komput.*, vol. 7, no. 3, pp. 93–97, 2019.
- [2] Y. Tasya and A. R. Putri, "Klasifikasi Tingkat Kerawanan Banjir Wilayah Medan Menggunakan Metode Naive Bayes Dan Algoritma J48," *J. Inf. Technol. Comput. Sci.*, vol. 6, no. 2, 2023.

-
- [3] H. Ryka, M. Kencanawati, and A. Syahid, "Sistem Informasi Geografis (SIG) Dengan ArcGIS Dalam Pemanfaatan Analisis Banjir Di Kelurahan Sepinggan," *J. Res.*, vol. 3, no. 1, pp. 45–51, 2020.
- [4] P. J. K. M. Wahani and S. Y. J. Prasetyo, "Klasifikasi Resiko Tsunami Di Daerah Pantai Selatan Jawa Tengah Dengan Menerapkan Algoritma SVM (Studi Kasus Kab. Kebumen)," *J. Transform.*, vol. 20, no. 1, 2022.
- [5] S. Dwiasnati and Y. Devianto, "Optimasi Prediksi Bencana Banjir menggunakan Algoritma SVM untuk penentuan Daerah Rawan Bencana Banjir," *J. Sist. Inf. dan Teknol.*, vol. 5, no. 1, 2021.
- [6] A. Sa'dan and dkk, "Agen Cerdas Berbasis Fuzzy Tsukamoto pada Sistem Prediksi Banjir," *J. Eksplora Inform.*, vol. 8, no. 2, pp. 104–111, 2019.
- [7] N. K. Asih and E. Eliyani, "Algoritma J48 untuk Pemodelan Sistem Prediksi Tingkat Kerawanan Banjir dengan Visualisasi Web GIS," *J. Sist. dan Teknol. Inf.*, vol. 10, no. 1, 2022.
- [8] P. C. Latue and dkk, "Pemodelan Daerah Rawan Banjir di Kecamatan Sirimau Menggunakan Metode Multi-Criteria Analysis (MCA)," *J. Res.*, vol. 18, no. 1, pp. 10–17, 2023.
- [9] I. K. B. Rahmadan and C. Susetyo, "Prediksi Debit Limpasan Air Permukaan pada Daerah Rawan Banjir di Kabupaten Jombang Berdasarkan Pemodelan Penggunaan Lahan," *J. Tek. ITS*, vol. 9, no. 2, 2020.
- [10] H. Rakuasa and dkk, "Pemetaan Daerah Rawan Banjir di Desa Batumerah Kecamatan Sirimau Kota Ambon Menggunakan Sistem Informasi Geografis," *J. Ilm. Multidisiplin*, vol. 2, no. 4, 2023.