

## ACCREDITATION PREDICTION OF EARLY CHILDHOOD EDUCATION INSTITUTIONS USING MACHINE LEARNING TECHNIQUES

Noripansyah<sup>\*1</sup>, Abdul Kadir<sup>2</sup>, Dewi Kusumaningsih<sup>3</sup>, Haderiansyah<sup>4</sup>

<sup>1,4</sup>Information Systems Study Program, Institut Teknologi Sapta Mandiri, Indonesia

<sup>2</sup>Student Computer Science, Universiti Malaysia Sabah, Malaysia

<sup>3</sup>Information Systems, Information Technology Faculty, Universitas Budi Luhur, Indonesia

Email: <sup>1</sup>[noripansyah@itsmandiri.ac.id](mailto:noripansyah@itsmandiri.ac.id), <sup>2</sup>[abdul\\_kadir\\_di20@iluv.ums.edu.my](mailto:abdul_kadir_di20@iluv.ums.edu.my),

<sup>3</sup>[dewi.kusumaningsih@budiluhur.ac.id](mailto:dewi.kusumaningsih@budiluhur.ac.id), <sup>4</sup>[dery@itsmandiri.ac.id](mailto:dery@itsmandiri.ac.id)

(Article received: May 03, 2023; Revision: May 29, 2023; published: June 26, 2023)

### Abstract

Accreditation is an acknowledgement of an educational institution regarding the feasibility of carrying out the educational process. Making predictions can save time for early childhood education institutions in compiling accreditation forms that will be submitted. Prediction in determining accreditation becomes an important lesson for an institution in self-assessing the quality of its services. Choosing which method to use in the accreditation prediction process becomes a serious problem, so the prediction results can be the closest or most accurate. Machine Learning is an application that is part of Artificial Intelligence which is widely used in prediction research. In this experiment, three algorithms in machine learning are tested, namely SVM, KNN and ANN. This study uses data from the accreditation results of early childhood education institutions in South Kalimantan; the sample data is 75%, and the remaining data is 25%. The results of the KNN algorithm with Euclidean distance and the number of neighbours 5 have the best performance in predicting the value of the accreditation predicate compared to other methods. The results of calculations using the KNN method produce Area Under Curve values of 1,000, CA 1,000, F1 1,000, precision 1,000 and Recall 1,000.

**Keywords:** Accreditation, ANN, Early Childhood Education, KNN, SVM.

## PREDIKSI AKREDITASI LEMBAGA PENDIDIKAN PAUD MENGGUNAKAN MACHINE LEARNING

### Abstrak

Akreditasi merupakan pengakuan suatu lembaga pendidikan mengenai kelayakan untuk menyelenggarakan proses pendidikan. Membuat prediksi dapat menghemat waktu lembaga pendidikan anak usia dini dalam menyusun borang akreditasi yang akan diajukan. Prediksi dalam menentukan akreditasi menjadi pelajaran penting bagi sebuah institusi dalam menilai sendiri kualitas layanannya. Memilih metode mana yang akan digunakan dalam proses prediksi akreditasi menjadi masalah serius, sehingga hasil prediksi bisa mendekati atau paling akurat. Machine Learning merupakan aplikasi bagian dari Artificial Intelligence yang banyak digunakan dalam penelitian prediksi. Pada percobaan ini diuji tiga algoritma pada machine learning yaitu SVM, KNN dan ANN. Penelitian ini menggunakan data hasil akreditasi lembaga pendidikan anak usia dini di Kalimantan Selatan; data sampel 75%, dan data sisanya 25%. Hasil algoritma KNN dengan jarak Euclidean dan jumlah tetangga 5 memiliki performa terbaik dalam memprediksi nilai predikat akreditasi dibandingkan dengan metode lainnya. Hasil perhitungan menggunakan metode KNN menghasilkan nilai Area Under Curve 1.000, CA 1.000, F1 1.000, precision 1.000 dan Recall 1.000.

**Kata kunci:** Akreditasi, ANN, KNN, Pendidikan usia dini, SVM.

### 1. PENDAHULUAN

Akreditasi adalah penetapan dari pihak ketiga terkait dengan bukti formal bahwa lembaga penilaian kesesuaian memiliki kompetensi untuk melakukan tugas penilaian kesesuaian tertentu [1]. Lembaga yang melakukan akreditasi disebut badan akreditasi.

Akreditasi merupakan bagian dari kewajiban pemerintah untuk menentukan apakah satuan pendidikan layak untuk diakses oleh masyarakat [2]. Hal ini penting agar masyarakat tidak salah memilih institusi yang berkualitas. Secara empiris selama lebih dari 30 tahun, NAEYC telah melakukan

akreditasi dan menetapkan standar satuan pendidikan anak usia dini. Akreditasi NAEYC membantu orang tua menemukan pengalaman anak usia dini terbaik untuk anak-anak mereka. *National Association for Early Childhood Education (NAEYC)* adalah asosiasi nirlaba terbesar di Amerika Serikat yang mewakili pendidikan anak usia dini [3]. *NAEYC* telah menetapkan 10 standar untuk program anak usia dini untuk membantu keluarga membuat pilihan yang tepat saat mencari pusat penitipan anak, prasekolah, atau taman kanak-kanak [4].

Di Indonesia, akreditasi PAUD dilakukan oleh BAN PAUD dan PNF. Kondisi empiris saat ini menunjukkan banyak lembaga pendidikan anak usia dini yang bergerak ke arah industrialisasi pendidikan dan lebih mengutamakan keuntungan. Peningkatan pendidikan bagi masyarakat Indonesia akan memacu pencapaian tujuan dan sasaran lainnya, terutama peningkatan indeks pembangunan manusia (IPM). Peran pendidikan diharapkan dapat meningkatkan daya saing Indonesia dalam mendukung SDGs 2030. PAUD sebagai fundamental pendidikan yang merupakan pondasi awal kualitas tumbuh kembang anak sangat penting untuk melandasi pendidikan selanjutnya, termasuk peningkatan IPM [6].

Prediksi dalam menentukan akreditasi menjadi pelajaran penting bagi sebuah institusi dalam menilai sendiri kualitas layanan yang dimilikinya [7] dan [8]. Membuat prediksi dapat menghemat waktu lembaga PAUD dalam menyusun borang akreditasi yang akan diajukan [9]. Dengan hasil prediksi, lembaga dapat meningkatkan akreditasi, yaitu: dengan memperbaiki instrumen akreditasi dan instrumen pengumpulan data dan informasi, menyiapkan semua dokumen akreditasi dan informasi pendukung akreditasi, menyiapkan dokumen, akreditasi sekolah, dan menunjuk guru yang lebih profesional dalam PBM untuk dinilai. Penilai akreditasi, melengkapi sarana dan prasarana sekolah, mendekorasi ruang penilaian akreditasi semenarik mungkin, dan mengundang komite sekolah pada hari penilaian akreditasi.

*SVM* adalah salah satu metode terbaik yang dapat digunakan dalam masalah prediksi. Konsep *SVM* berasal dari masalah prediksi dua kelas yang membutuhkan set pelatihan positif dan negatif [16]. *SVM* mencoba mencari *hyperplane* (pemisah) terbaik untuk dipisahkan menjadi dua kelas dan memaksimalkan margin antara kedua kelas tersebut [17] dan [18]. Dalam beberapa kasus, *SVM* terbukti memiliki akurasi prediksi yang tinggi. Misalnya, model prediksi keausan alat abrasif dengan hasil percobaan keausan menunjukkan akurasi prediksi model *IHDGWO-SVM* adalah 92% [19]. Prediksi koefisien kelengkungan dan keseragaman pada tanah laterit tak jenuh yang diolah dengan komposit semen hibrida dan butiran tambang berstruktur nano, hasilnya 97% mendekati akurat [20]. Model prediksi untuk penyakit arteri koroner dengan akurasi 88% [21]. Algoritma *SVM* dengan akurasi 95% untuk

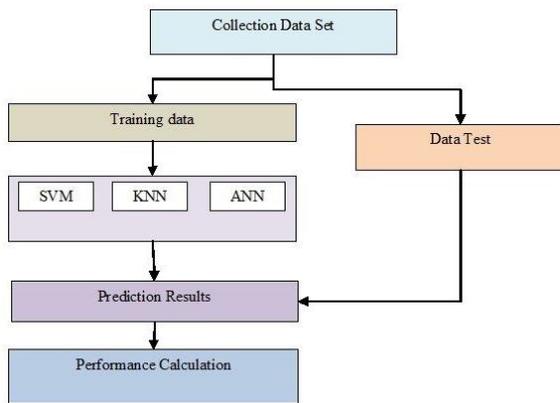
model prediksi peringatan dini gempa [22]. Akurasi di atas 95% untuk prediksi stroke jantung [23].

*ANN* atau jaringan syaraf tiruan adalah salah satu representasi buatan dari otak manusia yang selalu berusaha mensimulasikan proses pembelajaran pada otak manusia. Otak manusia mengandung jutaan sel saraf (*neuron*) yang memproses informasi. Setiap sel berinteraksi satu sama lain untuk mendukung kemampuan kerja otak. Setiap sel saraf akan memiliki satu inti sel yang bertanggung jawab untuk memproses informasi. Menurut informasi dari penelitian dan jurnal yang ada, Metode Prediksi *ANN* banyak diimplementasikan dalam metode analisis ilmiah. Contoh salah satu implementasi *ANN* yang sering digunakan dalam peramalan dan prediksi. Hasil penelitian [24] Prediksi harga emas di pasar komoditas India dengan hasil MPA terbaik yang diperoleh diberikan oleh metode *GDM\_LCH* dengan nilai akurasi 92,4%. Model jaringan (*ANN*) untuk memprediksi modulus elastisitas (*MOE*) *BWC* dengan nilai akurasi *MAPE* 98% sehingga dapat melacak kualitas *BWC* dalam proses produksi [25]. *ANN* menganalisis data, menentukan berapa banyak air yang telah dipraktikkan sistem irigasi di India, dan memprediksi hasilnya dapat mengatur penghematan air [26]. Model *A DEA-ANN* dapat memperkirakan efisiensi pengajaran di universitas Kanada. Hasil prediksi dengan *ANN* dapat memaksimalkan daya prediksi awal [27].

*K-Nearest Neighbor (KNN)* adalah salah satu algoritma untuk mengklasifikasikan data pada suatu objek berdasarkan beberapa *K training* data yang memiliki jarak terdekat atau tetangga terdekat dengan objek tersebut [9]. *KNN* digunakan untuk mengklasifikasikan objek baru berdasarkan atribut dan sampel data latih [28] dan [29], mengikuti rumus algoritma *KNN*: (a) *Proximity* biasanya bernilai 0-1, (b) 0 artinya kasusnya tidak terlalu bagus. Serupa, sedangkan untuk satu berarti kasus yang sangat mirip. Dalam penelitian, *KNN* dapat memprediksi secara akurat. Prediksi kesalahan perkalian dalam kesalahan perkalian, tugas klasifikasi dalam *Data-Driven System* dengan hasil akurasi 97% [30]. Tes memprediksi penyakit jantung dengan *KNN* memberikan hasil prediksi 69% [31] dan akurasi 67% [32]. Makalah ini mengusulkan prediksi akreditasi lembaga PAUD dengan tiga algoritma, yaitu *Support Vector Machines (SVM)*, *Artificial Neural Networks (ANN)* dan *K-Nearest Neighbor (KNN)*. Data yang digunakan berasal dari 225 lembaga di Kalimantan Selatan. Proposal dengan ketiga algoritma tersebut bertujuan untuk menguji algoritma mana yang paling tepat untuk memprediksi nilai akreditasi.

## 2. METODE PENELITIAN

Metodologi penelitian terdiri dari pengumpulan dataset, pembentukan model klasifikasi, pelatihan model klasifikasi, pengujian, dan penghitungan kinerja. Gambar 1 menunjukkan alur metodologi penelitian.



Gambar 1. Tahapan Penelitian

**2.1. Pengumpulan Set Data**

Dataset yang digunakan adalah data hasil akreditasi lembaga pendidikan anak usia dini di Kalimantan Selatan yang terdiri dari TK negeri, TK swasta dan kelompok bermain. Jumlah data yang digunakan sebanyak 225 lembaga, dengan rincian data pelatihan yang digunakan sebanyak 200 data lembaga dan data uji yang digunakan sebanyak 25 data lembaga. Data dikumpulkan menggunakan teknik online dengan mengakses <https://akreditasi.banpaupdnf.or.id/data/0/150000> [33].

**2.2. Pembentukan Model Prediksi**

Pada tahap ini, setiap algoritma dikonfigurasi menggunakan beberapa parameter. Tujuannya adalah untuk mengetahui pengaruh parameter terhadap kinerja algoritma pembelajaran mesin yang mengambil data berlabel sebagai masukan dan menghasilkan akurasi yang lebih baik dalam memprediksi hasil akreditasi lembaga pendidikan anak usia dini.

**2.3. Support Vector Machine (SVM)**

Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti hyperplane margining yang mirip dengan konsep lainnya [34]. SVM adalah algoritma pembelajaran mesin yang menggunakan teknik dengan mengambil data berlabel sebagai masukan dan menghasilkan akurasi yang lebih baik dalam masalah prediksi maupun regresi [35].

Konsep SVM secara sederhana dapat dijelaskan sebagai upaya mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua kelas pada input space [36] dan [37]. Pola yang merupakan anggota dari dua kelas: +1 dan -1. Pola yang termasuk kelas -1 dilambangkan dengan warna merah (persegi), sedangkan pola di kelas +1 dilambangkan dengan warna kuning (lingkaran). Masalah klasifikasi dapat diterjemahkan dengan mencoba mencari garis (hyperplane) yang memisahkan kedua kelompok

tersebut. Berbagai alternatif garis pemisah (batas diskriminasi). Data yang tersedia dinotasikan sementara  $x_i^{\rightarrow} \in \mathbb{R}^d$  masing-masing label dinotasikan  $y_i \in \{-1, +1\}$  untuk  $i=1,2,\dots,l$ , Yang mana  $l$  adalah jumlah data. Diasumsikan bahwa dua kelas -1 dan +1 dapat sepenuhnya dipisahkan oleh hyperplane dimensi yang didefinisikan:

$$w^{\rightarrow} \cdot x^{\rightarrow} + b = 0 \tag{1}$$

$w$  = Medan normal

$b$  = Posisi bidang relatif terhadap pusat koordinat

Pola  $x_i^{\rightarrow}$  yang termasuk kelas -1 (sampel negatif) dapat dirumuskan sebagai pola yang memenuhi pertidaksamaan:

$$w^{\rightarrow} \cdot x^{\rightarrow} + b \leq 1 \tag{2}$$

Saat ini  $x_i^{\rightarrow}$  yang tergolong kelas +1 (sampel positif)

$$w^{\rightarrow} \cdot x^{\rightarrow} + b \geq 1 \tag{3}$$

Margin terbesar dapat dicari dengan memaksimalkan nilai jarak antara hyperplane dengan titik terdekatnya, yaitu  $1 / \|w^{\rightarrow}\|$ . Hal ini dapat dirumuskan sebagai masalah Pemrograman Kuadratik [37], yaitu mencari titik minimum persamaan (4), dengan memperhatikan batasan persamaan (5).

$$w^{\rightarrow \min} \tau (w) = \frac{1}{2} \|w^{\rightarrow}\|^2 y_i (w^{\rightarrow} \cdot x^{\rightarrow} + b) \geq 0, \forall_i \tag{4}$$

Masalah ini dapat diselesaikan dengan berbagai teknik komputasi, termasuk pengali lagrange [38].

$$L ( w^{\rightarrow}, b, \infty ) = \frac{1}{2} \|w^{\rightarrow}\|^2 - \sum_{i=1}^l \infty_i (y_i ((w^{\rightarrow} \cdot x^{\rightarrow} + b) - 1)) \tag{5}$$

Dengan  $\infty_i$  adalah pengali Lagrange, yaitu nol atau positif ( $\infty_i \geq 0$ ). Nilai optimal persamaan (6) dapat dihitung dengan meminimalkan L ke  $w^{\rightarrow}$  dan, memaksimalkan L terhadap  $\infty_i$ . Dengan mempertimbangkan sifat bahwa pada titik optimal gradien L = 0, persamaan (5) dapat dimodifikasi sebagai masalah maksimisasi yang hanya berisi  $\infty_i$ , seperti persamaan (6) di bawah ini.

Maksimalkan: (6)

$$\sum_{i=1}^l \infty_i \frac{1}{2} \sum_{i,i=1}^l \infty_i \infty_j y_i y_j x_i^{\rightarrow} \cdot x_j^{\rightarrow} \tag{6}$$

Tunduk pada (7)

$$\infty_i \geq 0 \quad (i = 1, 2, \dots, l) \quad \sum_{i=1}^l \infty_i y_i = 0 \quad (7)$$

Dari hasil perhitungan ini diperoleh sebagian besar positif. Data yang berkorelasi dengan  $\infty_i$  yang positif ini disebut vektor dukungan.

#### 2.4. Algoritma *K-Nearest Neighbor* (KNN)

Algoritma *K-Nearest Neighbor* (KNN) adalah metode untuk mengklasifikasikan objek berdasarkan data pembelajaran yang paling dekat dengan objek [39] dan [40]. Data pembelajaran diproyeksikan ke dalam ruang multidimensi, di mana setiap dimensi mewakili fitur data. Ruang ini dibagi menjadi beberapa bagian berdasarkan klasifikasi data pembelajaran [41]. Sebuah titik dalam ruang ini ditandai sebagai kelas  $c$  jika kelas  $c$  adalah klasifikasi yang paling umum ditemukan di  $k$  tetangga terdekat dari titik tersebut. Dekat atau jauhnya tetangga biasanya dihitung berdasarkan jarak Euclidean dengan rumus seperti pada persamaan (8).

$$distance = \sqrt{\sum_{x=1}^n (x_{training}^i - x_{testing})^2} \quad (8)$$

Di mana :

$x_{training}^i$  = training data to  $i$ ,

$x_{testing}$  = data testing

$i$  = the  $i$ th (row) record of the table,

$n$  = amount of training data

Pada tahap pembelajaran, algoritma ini hanya melakukan penyimpanan vektor fitur dan klasifikasi data pembelajaran. Pada tahap klasifikasi, fitur yang sama dihitung untuk data uji (yang klasifikasinya tidak diketahui) [42]. Jarak dari vektor baru ini ke semua vektor data pembelajaran dihitung, dan nomor  $K$  terdekat diambil. Titik-titik yang baru terklasifikasi diperkirakan akan masuk dalam klasifikasi terbanyak dari titik-titik tersebut. Nilai  $K$  terbaik untuk algoritma ini bergantung pada data. Secara umum, nilai  $K$  yang tinggi akan mengurangi pengaruh noise pada klasifikasi, namun membuat batas antara setiap klasifikasi menjadi lebih kabur. Nilai  $K$  yang baik dapat dipilih dengan optimasi parameter, misalnya dengan menggunakan validasi silang. Kasus khusus di mana klasifikasi diprediksi berdasarkan data pembelajaran terdekat (dengan kata lain,  $K = 1$ ) disebut algoritma algoritma tetangga terdekat [43].

Keakuratan algoritma *KNN* sangat dipengaruhi oleh ada tidaknya fitur yang tidak relevan, atau jika bobot fitur tersebut tidak setara relevansinya dengan klasifikasi [44]. Algoritma *KNN* memiliki beberapa kelebihan yaitu ketangguhan terhadap data latih yang banyak noise dan efektif bila data latih besar. Sedangkan kelemahan *KNN* adalah *KNN* perlu menentukan nilai parameter  $K$  (jumlah tetangga terdekat), pelatihan berdasarkan jarak tidak jelas jarak

yang harus digunakan dan atribut apa yang harus digunakan untuk mendapatkan yang terbaik. hasil, dan biaya komputasi cukup tinggi karena diperlukan perhitungan. jarak dari setiap instance kueri ke seluruh sampel pelatihan. *K-Nearest Neighbor* (KNN) adalah metode yang menggunakan algoritma terawasi dimana hasil dari query instance baru diklasifikasikan berdasarkan mayoritas kategori yang ada di KNN. Tujuan dari algoritma ini adalah untuk mengklasifikasikan objek baru berdasarkan atribut dan sampel pelatihan. Pengklasifikasi tidak menggunakan model apa pun untuk dicocokkan dan hanya didasarkan pada memori. Diberikan sebuah query point, maka akan dicari sejumlah  $K$  objek atau (training point) yang paling dekat dengan query point. Klasifikasi menggunakan suara terbanyak di antara klasifikasi objek  $K$ . Algoritma *KNN* menggunakan klasifikasi tetangga sebagai nilai prediktif dari instance kueri baru.

#### 2.5. Algoritma *Artificial Neural Network* (ANN)

*Artificial Neural Network* (ANN) dapat secara mandiri menentukan parameternya. ANN atau Jaringan Syaraf Tiruan pertama kali ditemukan oleh McCulloch dan Pitts pada tahun 1943. McCulloch dan Pitts menyimpulkan bahwa penggabungan beberapa neuron sederhana menjadi sebuah sistem saraf akan meningkatkan kemampuan komputasinya [45]. Bobot dalam jaringan yang diusulkan oleh McCulloch dan Pitts disusun untuk melakukan fungsi logika sederhana. Fungsi aktivasi yang digunakan adalah fungsi threshold [46].

Secara umum, ANN dibentuk oleh sejumlah neuron sebagai unit pengolah informasi sebagai operasi dasar untuk menjalankan fungsi atau tugasnya. Secara matematis, persamaan berikut berlaku untuk neuron.

$$\begin{aligned} \mu_x &= \sum_{j=1}^p w_{kj} x_j \\ y_k &= \varphi(\mu_k - \theta_k) \end{aligned} \quad (4)$$

Dengan  $x_1, x_2, x_3 \dots, x_p$ , adalah sinyal input  $w_{k1}, w_{k2}, w_{k3} \dots, w_{kp}$  adalah bobot sinaptik untuk neuron,  $\mu_k$  adalah output kombinasi linier,  $\theta_k$  adalah nilai ambang batas,  $\varphi(\ )$  adalah fungsi aktivasi, dan adalah sinyal output neuron [47].

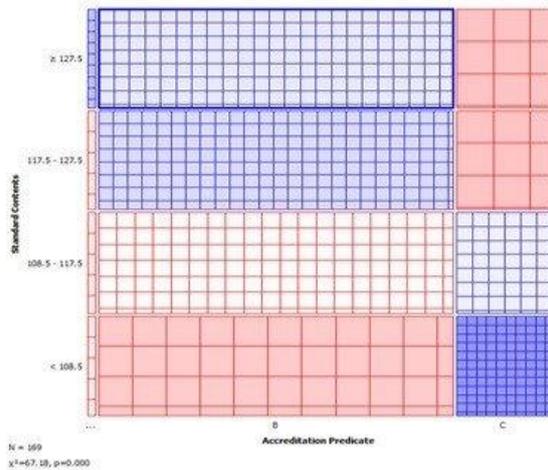
### 3. HASIL DAN PEMBAHASAN

#### 3.1. Metode *Artificial Neural Network* (ANN)

Tabel 1 menyajikan Data Akreditasi Lembaga Pendidikan Anak Usia Dini ini dapat diuraikan mengenai hasil dari penelitian beserta pengujian yang telah dilakukan. Selain itu, disampaikan juga mengenai pembahasan dari penelitian maupun pengujian yang telah dilakukan

Tabel 1. Kuantitas Data Akreditasi Lembaga Pendidikan Anak Usia Dini

Jumlah ditentukan	Predikat Akreditasi			Total
	A	B	C	
<b>A</b>	5.0	0.0	0.0	<b>5.0</b>
<b>B</b>	0.0	173.0	0.0	<b>173.0</b>
<b>C</b>	0.0	0.0	47.0	<b>47.0</b>
<b>Total</b>	<b>5.0</b>	<b>173.0</b>	<b>47.0</b>	<b>225.0</b>

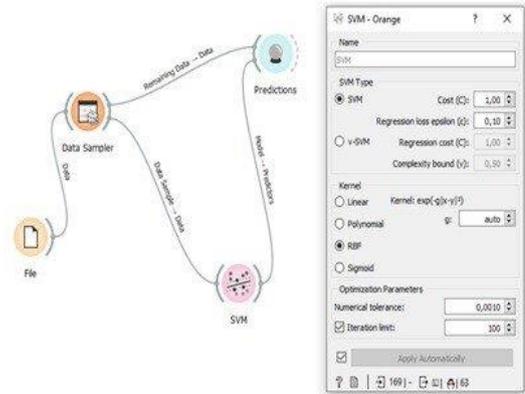


Gambar 2. Pemilihan Data Menggunakan Widget

Data hasil akreditasi yang telah melalui tahap preprocessing kemudian diuji untuk mendapatkan model prediksi terbaik untuk akreditasi lembaga pendidikan anak usia dini. Model prediksi yang telah diuji dan dievaluasi menggunakan set data uji pada aplikasi orange. Berdasarkan Gambar 2 proses pemilihan data menggunakan *widget*, pertama pilih kolom yang predikat akreditasinya adalah data target, standar isi, standar proses, standar kelulusan, standar tenaga pengajar, standar sarana prasarana, standar pengelolaan, standar pembiayaan dan standar penilaian dengan tipe numerik, fitur peran.

### 3.2. Perhitungan Metode SVM

Prinsip kerja *SVM* didasarkan pada prinsip *Structural Risk Minimization (SRM)*, yang bertujuan untuk menghasilkan hyperplane terbaik yang memisahkan ruang input menjadi dua kelas. Secara sederhana, prinsip dasar dari metode ini adalah linear classifier atau pengelompokan berarah, yang kemudian dikembangkan sehingga dapat bekerja dalam masalah linier. Prinsip ini sendiri merupakan kombinasi atau gabungan yang baik dari teori komputasi yang telah berkembang lama. sebelum adanya *SVM* [48]. Gambar 3 merupakan percobaan untuk menghitung nilai prediksi akreditasi menggunakan metode *SVM* menggunakan software orange dengan nilai dengan variabel biaya 1, kerugian regresi epsilon 0,10 menggunakan kernel RBF, optimalisasi parameter toleransi numerik sebesar 0,0010 dan iterasi pembatas sebesar 100 dan hasil yang diperoleh



Gambar 3. Model prediksi akreditasi dengan SVM

Tabel 2 . Hasil perhitungan prediksi dengan metode SVM yang menghasilkan Area Under Curve 1, CA 0.964, F1 0.963, Precision 0.966 dan Recall 0.964. Area Under Curve (AUC): adalah ukuran yang digunakan untuk mengevaluasi kinerja model klasifikasi. Nilai AUC yang sempurna adalah 1, sedangkan nilai AUC 0.5 menunjukkan kinerja model yang sama dengan tebakan acak. Dalam kasus ini, model SVM menghasilkan nilai AUC sebesar 1, yang menunjukkan bahwa model memiliki kinerja yang sangat baik. CA (Correct Accuracy): adalah persentase klasifikasi yang benar dari semua kasus yang diamati. Dalam kasus ini, model SVM menghasilkan nilai CA sebesar 0,964 atau 96,4%, yang menunjukkan bahwa model mampu mengklasifikasikan dengan benar 96,4% dari semua kasus yang diamati. F1-score: adalah ukuran harmonik rata-rata dari precision dan recall. F1-score memperhitungkan kedua metrik ini dan berguna dalam situasi ketika ada trade-off antara precision dan recall. Dalam kasus ini, model SVM menghasilkan F1-score sebesar 0,963, yang menunjukkan bahwa model ini memiliki keseimbangan yang baik antara precision dan recall. Precision: adalah ukuran dari seberapa sering model memberikan hasil positif yang benar. Dalam kasus ini, model SVM menghasilkan nilai precision sebesar 0,966, yang menunjukkan bahwa model memiliki kemampuan yang baik untuk memprediksi hasil positif dengan benar. Recall: adalah ukuran seberapa sering model dapat mengidentifikasi hasil positif secara keseluruhan. Dalam kasus ini, model SVM menghasilkan nilai recall sebesar 0,964, yang menunjukkan bahwa model memiliki kemampuan yang baik untuk mengidentifikasi hasil positif secara keseluruhan.

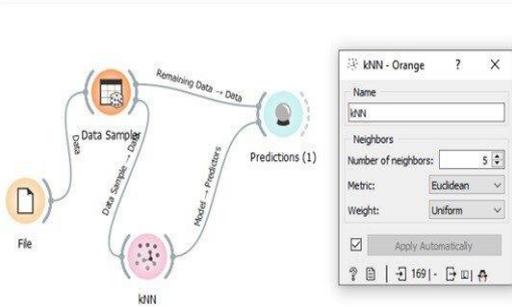
Tabel 2 . Hasil perhitungan prediksi dengan metode SVM

AUC	CA	F1	Presisi	mengingat
1.000	0,964	0,963	0,966	0,964

### 3.3. Metode Perhitungan KNN

*KNN* mengklasifikasikan dan memprediksi objek berdasarkan data pembelajaran (*data training*) yang paling dekat dengan objek tersebut. Tujuan dari algoritma *KNN* adalah untuk mengklasifikasikan

objek baru berdasarkan atribut dan sampel dari data pelatihan. Algoritma *KNN* akan menemukan *k* contoh pelatihan terdekat di ruang fitur dan menggunakan rata-rata fitur terdekat tersebut untuk membuat prediksi. Perhitungan prediksi akreditasi lembaga pendidikan anak usia dini menggunakan metode *KNN* menggunakan jumlah tetangga, lima *metrik Euclidean* dan bobot seragam menggunakan aplikasi orange



Gambar 4. Model Prediksi Akreditasi dengan KNN

Tabel 3 Hasil perhitungan menggunakan metode *KNN* menghasilkan nilai *Area Under Curve* 1.000, *CA* 1.000, *F1* 1.000, *precision* 1.000 dan *Recall* 1.000.

Tabel 3 . Hasil perhitungan prediksi menggunakan metode KNN

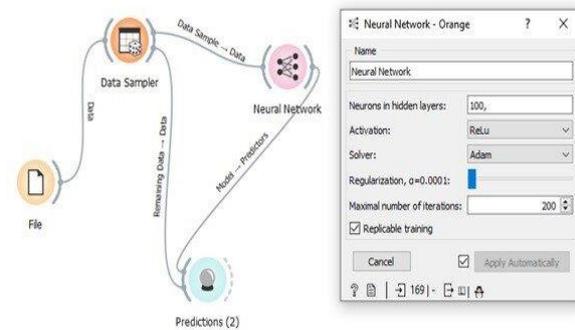
AUC	CA	F1	Presisi	Recall
1.000	1.000	1.000	1.000	1.000

Tabel 3 menunjukkan bahwa hasil perhitungan menggunakan metode *KNN* menghasilkan nilai *Area Under Curve* (AUC), *CA*, *F1*, *precision*, dan *recall* sebesar 1.000. Ini menunjukkan bahwa model *KNN* yang digunakan sangat akurat dalam memprediksi kelas target. Namun, untuk dapat memastikan keakuratan model tersebut, perlu dilakukan evaluasi yang lebih lengkap, seperti melakukan validasi silang (*cross-validation*) dan pengujian pada data uji yang belum pernah dilihat sebelumnya. Selain itu, penting juga untuk mempertimbangkan aspek lain seperti interpretasi hasil dan relevansi model terhadap masalah yang ingin diselesaikan. Dalam hal ini, jika hasil evaluasi lebih lanjut juga menunjukkan tingkat keakuratan yang tinggi, maka model *KNN* tersebut dapat dianggap sebagai model yang baik untuk memprediksi kelas target pada dataset yang diberikan.

**3.4. Perhitungan metode Artificial Neural Network (ANN) Algorithm**

Setiap model *ANN* memiliki input layer yang berperan sebagai media informasi berupa data yang berhubungan dengan output yang diinginkan [49] . Lapisan input ini terdiri dari beberapa neuron yang mewakili variabel atau parameter yang dibutuhkan untuk menyelesaikan suatu masalah. Lapisan input akan meneruskan data ini ke neuron berikutnya di

lapisan tersembunyi atau lapisan keluaran melalui serangkaian bobot [50] . Bobot ini adalah penghubung dari setiap neuron ke neuron lain di lapisan berikutnya, yang akan membantu menyesuaikan struktur *ANN* dengan pola data yang diberikan dengan memanfaatkan pembelajaran. Dalam proses pembelajaran, bobot akan diperbarui secara terus menerus hingga tercapai salah satu jumlah iterasi, error dan waktu proses [51] . Hal ini dilakukan untuk menyesuaikan struktur *ANN* dengan pola yang diinginkan berdasarkan permasalahan tertentu yang akan diselesaikan dengan menggunakan *ANN*. Proses eksperimen selanjutnya menggunakan metode *ANN* dengan 100 neuron pada lapisan tersembunyi, aktivasi relu, pemecah adam, regularisasi iterasi  $\alpha = 1000$  dan jumlah maksimum iterasi 200, menghasilkan perhitungan sebagai berikut.



Gambar 5. Model Prediksi Akreditasi dengan ANN

Tabel 4 Perhitungan dengan metode *ANN* menghasilkan nilai *Area Under Curve* sebesar 0,995, *CA* 0,964, *F1* 0,963, *presisi* 0,966 dan *Recall* 0,964.

Tabel 4 . Hasil perhitungan prediksi dengan metode ANN

AUC	CA	F1	Presisi
0,995	0,964	0,963	0,966

Dari hasil perhitungan di Tabel 4, nilai AUC sebesar 0,995 menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antara kelas positif dan negatif. Selain itu, nilai *CA*, *F1*, *precision*, dan *recall* yang tinggi juga menunjukkan bahwa model ini memiliki kinerja yang baik dalam melakukan prediksi. Namun, perlu diingat bahwa hasil evaluasi model dapat bervariasi tergantung pada dataset dan metrik evaluasi yang digunakan.

**3.5. Perbandingan Kinerja**

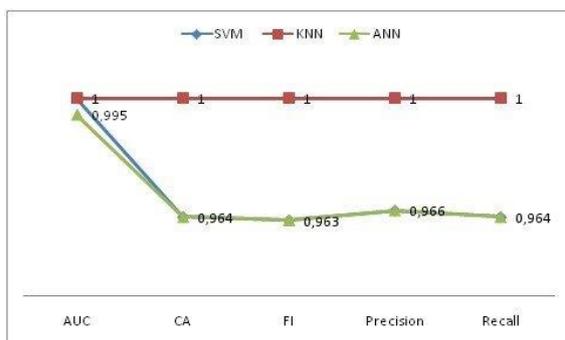
Kinerja klasifikasi dapat dihitung dengan menggunakan beberapa rumus. Hasilnya dapat berupa nilai akurasi, presisi, dan daya ingat, biasanya ditampilkan dalam persentase. Tabel 5 menunjukkan perbandingan kinerja antara algoritma *KNN*, *SVM*, dan *ANN*. Untuk algoritma *KNN*, penelitian ini memilih *KNN* dengan jarak Euclidean dan jumlah

tetangga lima, karena memiliki kinerja terbaik dibandingkan *KNN* dengan parameter lainnya. Sedangkan untuk algoritma *SVM*, penelitian ini memilih *SVM* dengan kernel RBF karena memiliki performa terbaik diantara *SVM* dengan parameter lainnya. Gambar 6 menunjukkan grafik perbandingan kinerja antara algoritma *KNN*, *SVM*, dan *ANN*.

Tabel 5. Perbandingan kinerja

metode	AUC	CA	F1	Presisi
<i>SVM</i>	1.000	0,964	0,963	0,966
<i>KNN</i>	1.000	1.000	1.000	1.000
<i>ANN</i>	0,995	0,964	0,963	0,966

Tabel 5 dan gambar 6 menunjukkan hasil perbandingan kinerja dengan hasil metode *KNN* yang sangat cocok untuk memprediksi data akreditasi lembaga pendidikan anak usia dini di Kalimantan Selatan yang menghasilkan perhitungan nilai AUC sebesar 1.000 CA 1.000 FI 1.000 Presisi 1.000 dan mengingat 1.000. Hasil prediksi perhitungan menggunakan metode *KNN* lebih akurat dibandingkan dengan metode *SVM* dan *ANN* pada percobaan prediksi trafik jangka pendek [52], *KNN* memberikan hasil yang lebih akurat dengan rata-rata proporsi kesalahan 14,348 dan nilai R-square 0,948 dibandingkan ke *SVM* dan *ANN*. Penelitian oleh [53] *KNN* dapat mengenali simbol dari sampel kecil secara akurat dengan skor 99,8% dalam studi komprehensif dari berbagai pendekatan dan teknik yang digunakan untuk mengembangkan pelajaran bahasa isyarat. Penelitian terkait lainnya juga membandingkan metode *SVM*, *KNN* dan *ANN* yaitu penelitian prediksi deteksi kanker payudara oleh [54] dimana *ANN* lebih unggul dengan nilai prediksi 97% dan *SVM* 91%. Klasifikasi tingkat pemasakan kelapa sawit dengan hasil menggunakan metode *ANN* unggul sebesar 93% [55]. Bahwa model prediksi akreditasi lembaga pendidikan anak usia dini perlu diuji dengan metode pada machine learning atau dengan teknik prediksi lainnya.



Gambar 6. Perbandingan kinerja

Algoritma *K-Nearest Neighbors (KNN)* merupakan algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan regresi. Secara sederhana, algoritma *KNN* membandingkan data yang baru dengan data yang sudah ada dalam basis data. Dalam penelitian akreditasi lembaga PAUD,

algoritma *KNN* dapat digunakan untuk memprediksi akreditasi suatu lembaga PAUD berdasarkan atribut-atribut yang dimiliki oleh lembaga tersebut. Di sisi lain, Artificial Neural Network (*ANN*) dan *Support Vector Machine (SVM)* juga merupakan algoritma pembelajaran mesin yang dapat digunakan untuk klasifikasi dan regresi. *ANN* dan *SVM* memiliki keunggulan tersendiri dalam memodelkan dan memprediksi data.

Hasil sesuai dengan dalam sebuah penelitian tahun 2020 yang diterbitkan di jurnal "Expert Systems with Applications", penulis membandingkan kinerja *KNN*, *SVM*, dan *ANN* dalam memprediksi harga saham. Hasilnya menunjukkan bahwa *SVM* memiliki kinerja yang lebih baik daripada *KNN* dan *ANN* [46] dan penelitian tahun 2020 yang membandingkan kinerja *KNN*, *ANN*, dan *SVM* dalam mengenali pola kanker payudara. Hasilnya menunjukkan bahwa *SVM* memiliki kinerja yang lebih baik daripada *KNN* dan *ANN* [47].

#### 4. KESIMPULAN

Prediksi akreditasi merupakan pelajaran yang bermanfaat bagi lembaga pendidikan anak usia dini. Dengan prediksi, lembaga dapat menilai kualitas layanannya. Dengan melihat hasil prediksi, Lembaga dapat meningkatkan akreditasi aktual di masa mendatang dengan memperbaiki instrumen akreditasi dan instrumen pengumpulan data dan informasi, menyiapkan semua dokumen akreditasi dan informasi pendukung lainnya. Jika institusi menginginkan hasil prediksi sesempurna mungkin, maka harus mempertimbangkan dengan cermat metodologi algoritmik yang digunakan selama proses akreditasi. Pembelajaran mesin adalah salah satu aplikasi AI yang paling banyak digunakan untuk mempelajari pola dan membuat prediksi. Hasil percobaan ini mengevaluasi tiga algoritma pembelajaran mesin, yaitu *SVM*, *KNN* dan *ANN*. Menggunakan data dari 75% dan 25% lembaga PAUD Kalsel yang terakreditasi. Performansi algoritma *KNN* dengan menggunakan jarak Euclidean dan jumlah tetangga lima lebih unggul dari *SVM* dan *ANN*. Hasil *KNN* diperoleh hasil 100% dengan nilai Area Under Curve (1.000), CA (1.000), F1 (1.000), presisi (1.000), dan recall (1.000).

Dengan melakukan prediksi, lembaga dapat meningkatkan akreditasi aktual di masa mendatang dengan memperbaiki instrumen akreditasi dan instrumen pengumpulan data dan informasi. Pembelajaran mesin adalah salah satu aplikasi AI yang dapat digunakan untuk mempelajari pola dan membuat prediksi, dan hasil percobaan menunjukkan bahwa algoritma *KNN* dengan menggunakan jarak Euclidean dan jumlah tetangga lima lebih unggul daripada *SVM* dan *ANN*. Hasil *KNN* menunjukkan performansi yang sangat baik dengan nilai 100% untuk Area Under Curve, CA, F1, presisi, dan recall. Oleh karena itu, menggunakan algoritma *KNN* dengan jarak Euclidean dan lima tetangga dapat

dijadikan rekomendasi untuk melakukan prediksi akreditasi lembaga pendidikan anak usia dini di masa depan.

#### DAFTAR PUSTAKA

- [1] C. D. Diem, P. Darusmiyati, and M. D. Sitingjak, "The Correlation between School Accreditation and Students' English Achievement of Public Senior High Schools," *Stud. Linguist. Lit.*, vol. 5, no. 2, p. p17, 2021, doi: 10.22158/sll.v5n2p17.
- [2] S. A. Makhoul, "Higher education accreditation, quality assurance and their impact to teaching and learning enhancement," *J. Econ. Adm. Sci.*, vol. 35, no. 4, pp. 235–250, 2019, doi: 10.1108/jeas-08-2018-0092.
- [3] C. Boyd-Swan and C. M. Herbst, "Influence of quality credentialing programs on teacher characteristics in center-based early care and education settings," *Early Child. Res. Q.*, vol. 51, pp. 352–365, 2020, doi: 10.1016/j.ecresq.2019.12.013.
- [4] L. K. Chandler *et al.*, "The Alignment of CEC/DEC and NAEYC Personnel Preparation Standards," *Topics Early Child. Spec. Educ.*, vol. 32, no. 1, pp. 52–63, 2012, doi: 10.1177/0271121412437047.
- [5] S. N. Asiah, "Analisis Manajemen PAUD Berbasis Standar Akreditasi PAUD dan PNF di Kutai Kartanegara," *SYAMIL J. Pendidik. Agama Islam (Journal Islam. Educ.*, vol. 6, no. 1, pp. 51–64, 2018, doi: 10.21093/sy.v6i1.1325.
- [6] H. R. Putera, Z. F. Ikatrinasari, and H. H. Purba, "Usulan Perbaikan Pelayanan Pendidikan Menggunakan Metode QFD dengan Pendekatan Variabel SERVQUAL," vol. 9, no. 2, 2022.
- [7] J. Sun, Z. Zhang, X. Liu, and H. Zheng, "Reduced Methane Combustion Mechanism and Verification, Validation, and Accreditation (VV&A) in CFD for NO Emission Prediction," *J. Therm. Sci.*, vol. 30, no. 2, pp. 610–623, 2021, doi: 10.1007/s11630-020-1321-3.
- [8] S. D. Mondal, D. N. Ghosh, and P. K. Dey, "Prediction of NAAC Grades for Affiliated Institute with the help of Statistical Multi Criteria Decision Analysis," vol. 1, no. 2, pp. 116–126, 2021.
- [9] L. Genisa and D. I. Mulyana, "Implementasi Penerapan Metode C4.5 dan Naïve Bayes Dalam Tingkat Kelulusan Akreditasi Lembaga PAUD Pada Badan Akreditasi Nasional," *J. Media Inform. Budidarma*, vol. 5, no. 4, p. 1595, 2021, doi: 10.30865/mib.v5i4.3267.
- [10] I. K. Nti, O. Nyarko-Boateng, F. A. Adekoya, and B. A. Weyori, "An empirical assessment of different kernel functions on the performance of support vector machines," *Bull. Electr. Eng. Informatics*, vol. 10, no. 6, pp. 3403–3411, 2021, doi: 10.11591/eei.v10i6.3046.
- [11] Z. Rustam, F. Zhafarina, J. E. Aurelia, and Y. Amalia, "Twin support vector machine using kernel function for colorectal cancer detection," *Bull. Electr. Eng. Informatics*, vol. 10, no. 6, pp. 3121–3126, 2021, doi: 10.11591/eei.v10i6.3179.
- [12] A. S. R. M. Sinaga, R. E. Putra, and A. S. Girsang, "Prediction measuring local coffee production and marketing relationships coffee with big data analysis support," *Bull. Electr. Eng. Informatics*, vol. 11, no. 5, pp. 2764–2772, 2022, doi: 10.11591/eei.v11i5.4082.
- [13] Y. Liang, S. Hu, W. Guo, and H. Tang, "Abrasive tool wear prediction based on an improved hybrid difference grey wolf algorithm for optimizing SVM," *Meas. J. Int. Meas. Confed.*, vol. 187, no. November 2021, p. 110247, 2022, doi: 10.1016/j.measurement.2021.110247.
- [14] K. C. Onyelowe, C. B. Mahesh, B. Srikanth, C. Nwa-David, J. Obimba-Wogu, and J. Shakeri, "Support vector machine (SVM) prediction of coefficients of curvature and uniformity of hybrid cement modified unsaturated soil with NQF inclusion," *Clean. Eng. Technol.*, vol. 5, p. 100290, 2021, doi: 10.1016/j.clet.2021.100290.
- [15] K. S. Nugroho, A. Y. Sukmadewa, A. Vidianto, and W. F. Mahmudy, "Effective predictive modelling for coronary artery diseases using support vector machine," *IAES Int. J. Artif. Intell.*, vol. 11, no. 1, pp. 345–355, 2022, doi: 10.11591/ijai.v11i1.pp345-355.
- [16] J. Song, J. Zhu, and S. Li, "Continuous prediction method of earthquake early warning magnitude for high-speed railway based on support vector machine," *Railw. Sci.*, 2022, doi: 10.1108/rs-04-2022-0002.
- [17] H. Puri, J. Chaudhary, K. R. Raghavendra, R. Mantri, and K. Bingi, "Prediction of Heart Stroke Using Support Vector Machine Algorithm," *2021 8th Int. Conf. Smart Comput. Commun. Artif. Intell. AI Driven Appl. a Smart World, ICSCC 2021*, pp. 21–26, 2021, doi: 10.1109/ICSCC51209.2021.9528241.
- [18] S. Verma, G. T. Thampi, and M. Rao, "ANN based method for improving gold price forecasting accuracy through modified

- gradient descent methods,” *IAES Int. J. Artif. Intell.*, vol. 9, no. 1, pp. 46–57, 2020, doi: 10.11591/ijai.v9.i1.pp46-57.
- [19] G. You, B. Wang, J. Li, A. Chen, and J. Sun, “The prediction of MOE of bamboo-wood composites by ANN models based on the non-destructive vibration testing,” *J. Build. Eng.*, vol. 59, no. July, p. 105078, 2022, doi: 10.1016/j.jobte.2022.105078.
- [20] M. N. Amogha Hegde, M. S. Naik, S. N. Chaitra, M. Madhavi, and A. Ravichandra, “Prediction and Analysis of Water Requirement in Automated Irrigation System using Artificial Neural Network(ANN) and Lora Technology,” *2021 IEEE Int. Conf. Distrib. Comput. VLSI, Electr. Circuits Robot. Discov. 2021 - Proc.*, pp. 88–92, 2021, doi: 10.1109/DISCOVER52564.2021.9663706.
- [21] S. K. Jauhar, “A DEA-ANN-based analytical framework to assess and predict the efficiency of Canadian universities in a service supply chain context,” 2022, doi: 10.1108/BIJ-08-2021-0458.
- [22] B. Wang and Z. Mao, “A dynamic ensemble outlier detection model based on an adaptive k-nearest neighbor rule,” *Inf. Fusion*, vol. 63, no. October 2019, pp. 30–40, 2020, doi: 10.1016/j.inffus.2020.05.001.
- [23] H. Ohmaid, S. Eddarouich, A. Bourouhou, and M. Timouyas, “Comparison between svm and knn classifiers for iris recognition using a new unsupervised neural approach in segmentation,” *IAES Int. J. Artif. Intell.*, vol. 9, no. 3, pp. 429–438, 2020, doi: 10.11591/ijai.v9.i3.pp429-438.
- [24] X. Ding, K. Charlotte, L. Li, and S. X. Ding, “Isolation in Dynamic Systems Using Data-Driven in -Gap Metric based based kNN Algorithm based kNN Algorithm based kNN based kNN,” *IFAC Pap.*, vol. 55, no. 6, pp. 169–174, 2022, doi: 10.1016/j.ifacol.2022.07.124.
- [25] C. Chethana, “Prediction of heart disease using different KNN classifier,” *Proc. - 5th Int. Conf. Intell. Comput. Control Syst. ICICCS 2021*, no. Iccics, pp. 1186–1194, 2021, doi: 10.1109/ICICCS51141.2021.9432178.
- [26] K. S. K. Reddy and K. V. Kanimozhi, “Novel Intelligent Model for Heart Disease Prediction using Dynamic KNN (DKNN) with improved accuracy over SVM,” *2022 Int. Conf. Bus. Anal. Technol. Secur. ICBATS 2022*, 2022, doi: 10.1109/ICBATS54253.2022.9758996.
- [27] “Akreditasi BAN PAUD dan PNF.” [Online]. Available: <https://akreditasi.banpaudpnf.or.id/data/0/150000>. [Accessed: 13-Sep-2022].
- [28] I. S. Al-Mejibli, J. K. Alwan, and D. H. Abd, “The effect of gamma value on support vector machine performance with different kernels,” *Int. J. Electr. Comput. Eng.*, vol. 10, no. 5, pp. 5497–5506, 2020, doi: 10.11591/IJECE.V10I5.PP5497-5506.
- [29] G. V. Gopal and G. R. M. Babu, “An ensemble feature selection approach using hybrid kernel based SVM for network intrusion detection system,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 23, no. 1, pp. 558–565, 2021, doi: 10.11591/ijeecs.v23.i1.pp558-565.
- [30] N. S. A. Yasmin, N. A. Wahab, and A. N. Anuar, “Improved support vector machine using optimization techniques for an aerobic granular sludge,” *Bull. Electr. Eng. Informatics*, vol. 9, no. 5, pp. 1835–1843, 2020, doi: 10.11591/eei.v9i5.2264.
- [31] M. T. Tally and H. Amintoosi, “A hybrid method of genetic algorithm and support vector machine for intrusion detection,” *Int. J. Electr. Comput. Eng.*, vol. 11, no. 1, pp. 900–908, 2021, doi: 10.11591/ijece.v11i1.pp900-908.
- [32] J. Xu, W. Zeng, Y. Lan, J. Guo, and X. Cheng, “Modeling the parameter interactions in ranking SVM with low-rank approximation,” *IEEE Trans. Knowl. Data Eng.*, vol. 31, no. 6, pp. 1181–1193, 2019, doi: 10.1109/TKDE.2018.2851257.
- [33] T. Altalmas, S. Ahmad, N. N. W. N. Hashim, S. S. Hassan, and W. Sediono, “Characteristics with opposite of quranic letters mispronunciation detection: a classifier-based approach,” *Bull. Electr. Eng. Informatics*, vol. 11, no. 5, pp. 2817–2827, 2022, doi: 10.11591/eei.v11i5.3715.
- [34] A. R. Lubis, M. Lubis, and Al-Khowarizmi, “Optimization of distance formula in k-nearest neighbor method,” *Bull. Electr. Eng. Informatics*, vol. 9, no. 1, pp. 326–338, 2020, doi: 10.11591/eei.v9i1.1464.
- [35] M. J. Al Dujaili, A. Ebrahimi-Moghadam, and A. Fatlawi, “Speech emotion recognition based on SVM and KNN classifications fusion,” *Int. J. Electr. Comput. Eng.*, vol. 11, no. 2, pp. 1259–1264, 2021, doi: 10.11591/ijece.v11i2.pp1259-1264.
- [36] N. Qu *et al.*, “Machine learning guided phase formation prediction of high entropy alloys,” *Mater. Today Commun.*, vol. 32, no. April, p. 104146, 2022, doi: 10.1016/j.mtcomm.2022.104146.
- [37] N. Benayad, Z. Soumaya, B. D. Taoufiq, and A. Abdelkrim, “Features selection by genetic

- algorithm optimization with k-nearest neighbour and learning ensemble to predict Parkinson disease,” *Int. J. Electr. Comput. Eng.*, vol. 12, no. 2, pp. 1982–1989, 2022, doi: 10.11591/ijece.v12i2.pp1982-1989.
- [38] L. Xiong and Y. Yao, “Study on an adaptive thermal comfort model with K-nearest-neighbors (KNN) algorithm,” *Build. Environ.*, vol. 202, no. June, p. 108026, 2021, doi: 10.1016/j.buildenv.2021.108026.
- [39] R. Ma, J. Ban, Q. Wang, and T. Li, “Statistical spatial-temporal modeling of ambient ozone exposure for environmental epidemiology studies: A review,” *Sci. Total Environ.*, vol. 701, p. 134463, 2020, doi: 10.1016/j.scitotenv.2019.134463.
- [40] A. G. Farizawani, M. Puteh, Y. Marina, and A. Rivaie, “A review of artificial neural network learning rule based on multiple variant of conjugate gradient approaches,” *J. Phys. Conf. Ser.*, vol. 1529, no. 2, 2020, doi: 10.1088/1742-6596/1529/2/022040.
- [41] A. Afandi, N. Lusi, I. Catrawedarma, and B. Rudiyanto, “Prediction of Temperature in 2 Meters Temperature Probe Survey in Blawan Geothermal Field Using Artificial Neural Network (ANN) Method,” *SSRN Electron. J.*, vol. 38, no. October 2021, p. 102309, 2021, doi: 10.2139/ssrn.3954816.
- [42] A. Muneer, R. F. Ali, A. Alghamdi, S. M. Taib, A. Almaghthawi, and E. A. Abdullah Ghaleb, “Predicting customers churning in banking industry: A machine learning approach,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 26, no. 1, pp. 539–549, 2022, doi: 10.11591/ijeecs.v26.i1.pp539-549.
- [43] M. S. Khrisat and Z. A. Alqadi, “Solving multiple linear regression problem using artificial neural network,” vol. 12, no. 1, pp. 770–775, 2022, doi: 10.11591/ijece.v12i1.pp770-775.
- [44] R. Meenal, A. I. Selvakumar, P. A. Michael, and E. Rajasekaran, “Sensitivity analysis based artificial neural network approach for global solar radiation prediction in India,” vol. 20, no. 1, pp. 31–38, 2020, doi: 10.11591/ijeecs.v20.i1.pp31-38.
- [45] M. Yanto, S. Sanjaya, Yulasmi, D. Guswandi, and S. Arlis, “Implementation multiple linear regression in neural network predict gold price,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 22, no. 3, pp. 1635–1642, 2021, doi: 10.11591/ijeecs.v22.i3.pp1635-1642.
- [46] W. Rizka, U. Fadilah, D. Agfiannisa, and Y. Azhar, “Analisis Prediksi Harga Saham PT. Telekomunikasi Indonesia Menggunakan Metode Support Vector Machine,” *Fountain Informatics J.*, vol. 5, no. 2, pp. 2548–5113, 2020, doi: 10.21111/fij.v5i2.4449.
- [47] F. Febrian, “Perbandingan Teknik Klasifikasi Neural Network, Support Vector Machine, dan Naive Bayes dalam Mendeteksi Kanker Payudara,” *BINA Insa. ICT J.*, vol. 7, no. 1, pp. 53–62, 2020.