Populer: Jurnal Penelitian Mahasiswa
Volume. 5, Nomor. 3, September 2026
e-ISSN :2963-5306 ; p-ISSN :2962-116X, Hal 88-95
DOI: https://doi.org/10.58192/populer.v5i3.5452
Tersedia: https://journal.unimar-amni.ac.id/index.php/Populer

Sistem Deteksi Dini Penyakit Stroke Menggunakan Algoritma *Support Vector Machine* (SVM)

Ahmad Labib Zainuddin [1*], Ghufron [2]
[1,2] Program Studi Teknik Informatika, Fakultas Teknologi Industri, Universitas Islam Sultan Agung, Indonesia

**Penulis Korespondensi : labibzain680@gmail.com*

Abstract*. Stroke is one of the most dangerous non-communicable diseases and a leading cause of death and long-term disability worldwide, including in Indonesia. Early detection of stroke risk is essential to prevent more severe conditions and to accelerate medical treatment. This study aims to develop an early detection system for stroke using the Support Vector Machine (SVM) algorithm. The dataset was obtained from Kaggle (Stroke Prediction Dataset), consisting of 5,110 patient records with features such as age, gender, hypertension, heart disease, work status, body mass index (BMI), average glucose level, and smoking status. The data underwent preprocessing, including data cleaning, categorical encoding, normalization using a Standard Scaler, and an 80:20 train-test split. The SVM model was tested using four kernel types (linear, polynomial, RBF, and sigmoid) to obtain the most optimal configuration. The RBF kernel achieved the best performance, with 91% accuracy during kernel comparison and a final accuracy of 84.58%, average precision of 0.85, average recall of 0.85, average F1-score of 0.85, and an AUC of 0.92. The system was implemented as a Streamlit-based dashboard so that it can be used as an early screening tool for stroke risk by medical personnel and the general public.*

Keywords: *Classification; Early Detection; Machine Learning; RBF Kernel; Support Vector Machine.*

Abstrak. Stroke merupakan salah satu penyakit tidak menular yang paling berbahaya dan menjadi penyebab utama kematian serta kecacatan jangka panjang di berbagai negara, termasuk Indonesia. Deteksi dini terhadap risiko stroke sangat penting untuk mencegah kondisi yang lebih parah serta mempercepat penanganan medis. Penelitian ini bertujuan mengembangkan sistem deteksi dini penyakit stroke menggunakan algoritma *Support Vector Machine* (SVM). Dataset diperoleh dari Kaggle (*Stroke Prediction Dataset*) yang mencakup 5.110 data pasien dengan fitur seperti usia, jenis kelamin, hipertensi, penyakit jantung, status pekerjaan, indeks massa tubuh (BMI), kadar glukosa darah, dan status merokok. Data melalui tahap praproses meliputi pembersihan data, encoding kategorikal, normalisasi menggunakan Standard Scaler, serta pembagian data latih dan uji dengan rasio 80:20. Model SVM diuji menggunakan empat jenis kernel (linear, polynomial, RBF, dan sigmoid) untuk memperoleh konfigurasi paling optimal. Kernel RBF memberikan performa terbaik dengan akurasi 91% pada tahap perbandingan kernel, serta akurasi akhir 84,58%, precision rata-rata 0,85, recall rata-rata 0,85, F1-score rata-rata 0,85, dan nilai AUC sebesar 0,92. Sistem diimplementasikan dalam bentuk dashboard berbasis Streamlit sehingga dapat digunakan sebagai alat bantu skrining awal risiko stroke oleh tenaga medis maupun masyarakat umum.

Kata kunci: Deteksi Dini; Kernel RBF; Klasifikasi; Pembelajaran Mesin; *Support Vector Machine*.

1. LATAR BELAKANG

Stroke merupakan penyakit tidak menular yang sangat berbahaya karena disebabkan oleh gangguan fungsional otak akibat tersumbatnya aliran peredaran darah. Penyakit ini tergolong ke dalam *cerebrovascular disease* yang membutuhkan penanganan cepat, karena keterlambatan penanganan dapat menyebabkan kematian. Menurut *World Health Organization* (WHO), stroke merupakan penyebab kematian peringkat kedua setelah penyakit jantung iskemik, dengan lebih dari lima belas juta penderita di seluruh dunia setiap tahunnya, dan setiap 4-5 menit terdapat satu penderita stroke yang meninggal dunia. Berdasarkan data Kementerian Kesehatan Indonesia, jumlah kasus stroke meningkat sebesar 3,9% dari tahun 2013 ke tahun

Naskah Masuk: 12 Agustus 2026; Revisi: 26 Agustus 2026; Diterima: 12 September 2026; Terbit: 18 September 2026

2018, dengan kelompok usia 55-64 tahun sebagai kelompok yang paling sering terdampak (Patmawati, 2023).

Deteksi dini dan penanganan yang tepat sangat diperlukan untuk meminimalkan kerusakan otak lebih lanjut serta mencegah komplikasi pada bagian tubuh lain. Salah satu pendekatan yang dapat digunakan untuk melakukan deteksi dini adalah dengan membangun model klasifikasi berbasis *machine learning* yang mempertimbangkan faktor-faktor risiko seperti hipertensi, hiperglikemia, penyakit jantung, usia, dan status merokok. Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengembangkan sebuah sistem deteksi dini penyakit stroke menggunakan algoritma *Support Vector Machine* (SVM) dengan menerapkan tahap praproses data yang lebih menyeluruh, mengevaluasi performa empat jenis kernel (*linear, polynomial, RBF, dan sigmoid*) untuk memperoleh model paling optimal, serta mengimplementasikan model terbaik ke dalam sebuah dashboard interaktif berbasis Streamlit. Dengan adanya sistem ini, diharapkan tenaga medis maupun masyarakat umum dapat melakukan skrining awal risiko stroke secara cepat, mudah, dan akurat berdasarkan data klinis dasar yang dimiliki pasien.

2. KAJIAN TEORITIS

Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang bekerja dengan mencari *hyperplane* terbaik untuk memisahkan dua kelas data secara maksimal. Untuk menangani data yang tidak dapat dipisahkan secara linear, SVM memanfaatkan fungsi kernel yang memetakan data ke ruang berdimensi lebih tinggi. Terdapat empat jenis kernel yang umum digunakan, yaitu: (1) *Linear*, yang menggunakan pemisahan linier langsung pada ruang fitur; (2) *Polynomial*, yang menggunakan kombinasi polinomial antar fitur input; (3) *Radial Basis Function* (RBF), yang efektif menangani data kompleks dan tidak linear; dan (4) *Sigmoid*, yang menyerupai fungsi aktivasi pada jaringan saraf tiruan.

Beberapa penelitian terdahulu menunjukkan bahwa algoritma SVM memiliki performa yang baik dalam berbagai kasus klasifikasi medis. Penelitian pada kasus Intra *Uterine Growth Restriction* (IUGR) menggunakan SVM dengan *multiclass classification* pada empat jenis kernel berhasil mencapai akurasi hingga 96% (Karinasari, 2020). Penelitian lain pada prediksi serangan jantung dengan optimasi *hyperparameter GridSearchCV* pada SVM memperoleh akurasi 86%, precision 84%, recall 91%, dan F1-score 87% (Maisat dkk., 2023). Pada kasus klasifikasi penyakit stroke secara khusus, penelitian sebelumnya melaporkan akurasi SVM sebesar 76-80% pada data unbalanced dan 76-77% pada data balanced dengan kernel linear dan polynomial (Kenny Riva dkk., 2022). Kajian-kajian ini menjadi dasar pemilihan SVM

sebagai algoritma utama dalam penelitian ini, dengan harapan performa yang lebih baik dapat diperoleh melalui praproses data yang lebih menyeluruh dan perbandingan empat jenis kernel secara sistematis.

3. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan, yaitu pengumpulan data, praproses data (data cleaning, normalisasi, dan pembagian data), perancangan dan pelatihan model SVM dengan beberapa jenis kernel, pengujian dan evaluasi model, hingga implementasi model ke dalam antarmuka dashboard berbasis web.

Dataset

Dataset yang digunakan dalam penelitian ini adalah Stroke Prediction Dataset yang diperoleh dari platform Kaggle, terdiri atas 5.110 baris data dan 11 atribut, yaitu 10 atribut independen (fitur) dan 1 atribut target. Fitur-fitur yang digunakan meliputi gender (jenis kelamin), *age* (usia), *hypertension* (riwayat hipertensi), *heart_disease* (riwayat penyakit jantung), *ever_married* (status pernikahan), *work_type* (jenis pekerjaan), *Residence_type* (tempat tinggal), *avg_glucose_level* (rata-rata kadar glukosa darah), bmi (indeks massa tubuh), dan *smoking_status* (status merokok), dengan stroke sebagai label target (0 = tidak stroke, 1 = stroke).

Praproses Data

Tahap praproses data terdiri atas tiga langkah utama. Pertama, data cleaning dilakukan dengan menghapus kolom id yang tidak relevan terhadap proses klasifikasi, serta mengisi nilai kosong (*missing values*) pada kolom bmi menggunakan nilai median, karena median lebih tahan terhadap outlier dibandingkan nilai rata-rata. Kedua, kolom-kolom kategorikal seperti gender, *ever_married*, *work_type*, *Residence_type*, dan smoking_status diubah menjadi nilai numerik menggunakan metode *Label Encoding*, karena algoritma SVM hanya dapat memproses data numerik. Ketiga, dilakukan normalisasi data menggunakan metode *Standardization (Z-Score Normalization*) melalui fungsi *StandardScaler* dari pustaka *scikit-learn*, sebagaimana dirumuskan pada Persamaan (1), agar seluruh fitur memiliki skala yang seragam (mean = 0 dan standar deviasi = 1) sehingga tidak mendistorsi perhitungan jarak pada SVM.

$$x' = (x - \mu)/\sigma$$

Persamaan (1). Rumus standardisasi Z-Score

Dengan x adalah nilai asli sebelum dinormalisasi, x' adalah nilai setelah dinormalisasi, μ adalah nilai rata-rata *(mean*) fitur, dan σ adalah standar deviasi fitur. Setelah tahap

normalisasi, dataset dibagi menjadi data latih (*training*) dan data uji (*testing*) dengan rasio 80:20, sehingga menghasilkan 4.088 data latih dan 1.022 data uji sebagaimana disajikan pada Tabel 1.

Tabel 1. Pembagian Data Latih dan Data Uji.

Dataset	Jumlah Data	Data Latih	Data Uji
Stroke	5.110	4.088	1.022

Perancangan Model SVM

Pada penelitian ini dilakukan eksperimen terhadap empat jenis kernel SVM, yaitu *linear, polynomial, radial basis function (RBF), dan sigmoid*. Setiap model dilatih menggunakan parameter *class_weight='balanced'* untuk mengatasi ketidakseimbangan kelas, serta *probability=True* untuk mengaktifkan estimasi probabilitas prediksi. Model dilatih menggunakan data latih (*X_train, y_train*) dan diuji pada data uji (*X_test, y_test*) menggunakan pustaka *scikit-lear*n. Setelah diperoleh kernel dengan performa terbaik, model dilatih ulang menggunakan konfigurasi kernel tersebut dengan parameter random_state=42 untuk memastikan hasil yang konsisten dan dapat direproduksi. Model yang telah dilatih kemudian digunakan untuk memprediksi risiko stroke pada data uji, dengan ambang batas (threshold) probabilitas sebesar 0,5 sebagai penentu klasifikasi label 0 (tidak stroke) atau label 1 (stroke).

Evaluasi Model

Evaluasi performa model dilakukan dengan menggunakan confusion matrix serta metrik akurasi, precision, recall, F1-score, dan kurva Receiver Operating Characteristic (ROC) beserta nilai Area Under Curve (AUC). Confusion matrix digunakan untuk menghitung jumlah True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), yang selanjutnya digunakan untuk menghitung akurasi, precision, recall, dan F1-score pada masing-masing kelas. Kurva ROC dan nilai AUC digunakan untuk menilai kemampuan model dalam membedakan kelas positif (stroke) dan kelas negatif (tidak stroke) pada berbagai ambang batas klasifikasi.

4. HASIL DAN PEMBAHASAN

Perbandingan Performa Kernel SVM

Pengujian awal dilakukan terhadap empat jenis kernel SVM untuk menentukan kernel dengan performa terbaik pada data prediksi stroke. Hasil pengujian ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Empat Kernel SVM.

Kernel	Akurasi	Precision	Recall / F1-Score
Linear	0.89	0.85	0.82 / 0.83
Polynomial	0.88	0.83	0.81 / 0.82
RBF	0.91	0.88	0.85 / 0.86
Sigmoid	0.84	0.79	0.76 / 0.77

Berdasarkan Tabel 2, kernel RBF menunjukkan performa terbaik dengan akurasi 91%, precision 0,88, recall 0,85, dan F1-score 0,86, mengungguli kernel linear, polynomial, dan sigmoid. Hasil ini sejalan dengan karakteristik data stroke yang memiliki hubungan non-linear antar variabel, seperti interaksi antara usia, kadar glukosa, tekanan darah, dan status merokok, sehingga kernel RBF yang mampu memetakan data ke ruang berdimensi lebih tinggi menjadi pilihan yang paling sesuai untuk kasus ini. Oleh karena itu, kernel RBF dipilih sebagai kernel utama untuk tahap pelatihan dan pengujian model selanjutnya.

Confusion Matrix Model SVM Kernel RBF

Hasil pengujian model SVM dengan kernel RBF pada data uji menghasilkan confusion matrix sebagaimana disajikan pada Tabel 3.

Tabel 3. *Confusion Matrix* Model SVM Kernel RBF.

	Prediksi = 0	Prediksi = 1
Aktual = 0	TN = 756	FP = 217
Aktual = 1	FN = 83	TP = 889

Berdasarkan Tabel 3, model berhasil mengenali 756 pasien yang benar-benar tidak mengalami stroke (*True Negative*) dan 889 pasien yang benar-benar mengalami stroke (*True Positive*). Namun demikian, terdapat 217 pasien yang sebenarnya tidak mengalami stroke tetapi diprediksi sebagai stroke (*False Positive*), serta 83 pasien yang sebenarnya mengalami stroke namun diprediksi sebagai tidak stroke (*False Negative*). Kesalahan jenis *False Negative* perlu mendapat perhatian khusus karena berisiko menyebabkan pasien stroke tidak tertangani secara cepat. Berdasarkan nilai TP, TN, FP, dan FN tersebut, diperoleh nilai akurasi model sebesar 84,58%, yang menunjukkan bahwa model mampu mengklasifikasikan dengan benar sekitar 84,58% dari keseluruhan data uji sebanyak 1.945 data.

Hasil Evaluasi Metrik Klasifikasi

Hasil evaluasi lengkap model SVM kernel RBF berdasarkan precision, recall, dan F1-score untuk masing-masing kelas disajikan pada Tabel 4.

Tabel 4. Hasil Evaluasi Model SVM Kernel RBF per Kelas.

Label	Precision	Recall	F1-Score	Support
0 (Tidak Stroke)	0.90	0.78	0.83	973
1 (Stroke)	0.80	0.91	0.86	972
Accuracy	-	-	0.85	1945
Macro Avg	0.85	0.85	0.85	1945
Weighted Avg	0.85	0.85	0.85	1945

Pada kelas 0 (tidak stroke), model memperoleh precision 0,90 dan recall 0,78, yang berarti 90% prediksi tidak-stroke bernilai benar, sementara model hanya berhasil mengenali 78% dari keseluruhan pasien yang benar-benar tidak mengalami stroke. Pada kelas 1 (stroke), model memperoleh precision 0,80 dan recall 0,91, yang menunjukkan bahwa model sangat sensitif dalam mendeteksi pasien stroke meskipun sebagian prediksi positif ternyata keliru. Nilai recall yang tinggi pada kelas stroke (91%) menjadi keunggulan penting dalam konteks medis, karena meminimalkan risiko pasien stroke yang luput dari deteksi (*false negative*), meskipun berimplikasi pada precision kelas stroke yang relatif lebih rendah dibanding kelas tidak-stroke. Secara keseluruhan, model memperoleh akurasi 85% dengan nilai *macro average* dan *weighted average* yang konsisten sebesar 0,85, menunjukkan performa yang stabil pada kedua kelas.

Evaluasi Kurva ROC dan AUC

Evaluasi tambahan dilakukan menggunakan kurva *Receiver Operating Characteristic* (ROC) yang menggambarkan hubungan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR) pada berbagai ambang batas klasifikasi. Hasil pengujian menunjukkan nilai *Area Under Curve* (AUC) sebesar 0,92. Nilai AUC yang mendekati 1 ini mengindikasikan bahwa model SVM kernel RBF memiliki kemampuan diskriminatif yang sangat baik dalam membedakan pasien yang berisiko dan tidak berisiko mengalami stroke, jauh lebih baik dibandingkan model klasifikasi acak (baseline AUC = 0,5).

Implementasi Dashboard Streamlit

Model SVM dengan kernel RBF yang telah dievaluasi selanjutnya diimplementasikan ke dalam sebuah dashboard interaktif berbasis Streamlit dengan judul 'Sistem Deteksi Dini Penyakit Stroke (SVM)'. Dashboard ini menyediakan formulir input berupa dropdown, slider, dan kotak angka untuk memasukkan data pasien, seperti jenis kelamin, usia, riwayat hipertensi, riwayat penyakit jantung, status pernikahan, jenis pekerjaan, tempat tinggal, rata-rata kadar glukosa darah, BMI, dan status merokok. Setelah data diisi, pengguna dapat menekan tombol 'Prediksi Risiko Stroke' untuk menjalankan model dan menampilkan hasil klasifikasi beserta nilai probabilitasnya.

Pada pengujian dengan data pasien laki-laki berusia 78 tahun yang memiliki riwayat hipertensi dan penyakit jantung, sudah menikah, bekerja wiraswasta, tinggal di perkotaan, kadar glukosa 200 mg/dL, BMI 50,0, dan status merokok aktif, sistem menampilkan notifikasi 'Risiko Stroke TERDETEKSI!!' dengan probabilitas 57,47%. Sebaliknya, pada pengujian dengan data pasien laki-laki berusia 29 tahun tanpa riwayat hipertensi maupun penyakit jantung, belum menikah, tinggal di pedesaan, kadar glukosa 100 mg/dL, BMI 22,0, dan tidak pernah merokok, sistem menampilkan notifikasi 'Tidak terdeteksi risiko stroke' dengan probabilitas hanya 1,08%. Hasil ini menunjukkan bahwa sistem mampu memberikan hasil prediksi yang konsisten dengan faktor risiko klinis yang telah diketahui secara medis, seperti usia lanjut, riwayat hipertensi, penyakit jantung, kadar glukosa tinggi, dan kebiasaan merokok.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan, dapat disimpulkan bahwa algoritma *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF) mampu digunakan secara efektif dalam membangun sistem deteksi dini penyakit stroke. Dari empat kernel yang diuji, kernel RBF menunjukkan performa terbaik dengan akurasi 91% pada tahap perbandingan awal, dan pada pengujian akhir memperoleh akurasi 84,58%, precision rata-rata 0,85, recall rata-rata 0,85, F1-score rata-rata 0,85, serta nilai AUC sebesar 0,92. Proses praproses data, seperti pembersihan data, *encoding kategorikal*, dan normalisasi menggunakan *Standard Scaler*, turut berkontribusi signifikan dalam meningkatkan performa model.

Secara keseluruhan, sistem ini berpotensi dijadikan alat bantu dalam proses skrining awal risiko stroke pada pasien, sehingga tenaga medis dapat melakukan intervensi lebih cepat dan tepat. Untuk penelitian selanjutnya, disarankan menggunakan dataset klinis yang lebih lengkap dan representatif (rekam medis, hasil laboratorium, maupun citra medis seperti CT-Scan atau MRI), melakukan pengujian langsung pada lingkungan klinis bersama tenaga medis, membandingkan performa SVM dengan algoritma lain seperti *Random Forest, XGBoost*, atau *Artificial Neural Network* (ANN), menerapkan pendekatan *Explainable AI* (XAI) agar sistem dapat menjelaskan alasan di balik hasil prediksinya, serta menambahkan fitur klinis lain seperti riwayat keluarga, konsumsi alkohol, tingkat stres, pola makan, dan aktivitas fisik untuk memperkaya kualitas prediksi sistem.

DAFTAR REFERENSI

Akmal, K., Faqih, A., & Dikananda, F. (2023). Perbandingan Metode Algoritma Naïve Bayes Dan K-Nearest Neighbors Untuk Klasifikasi Penyakit Stroke. JATI (Jurnal Mahasiswa Teknik Informatika), 7(1), 470–477. https://doi.org/10.36040/jati.v7i1.6367

Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. Karya Ilmiah Mahasiswa Bertauhid (KARIMAH TAUHID), 2(1), 1–6.

Arnolus Juantri E. Oktavianus, Lamhot Naibaho, & Djoys Anneke Rantung. (2023). Pemanfaatan Artificial Intelligence pada Pembelajaran dan Asesmen di Era Digitalisasi. Jurnal Kridatama Sains Dan Teknologi, 05(2), 473–476.

Budiprasetyo, G., Hani'ah, M., & Aflah, D. Z. (2023). Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM). Jurnal Nasional Teknologi Dan Sistem Informasi, 8(3), 164–172. https://doi.org/10.25077/teknosi.v8i3.2022.164-172

Hovi, H. S. W., Id Hadiana, A., & Rakhmat Umbara, F. (2022). Prediksi Penyakit Diabetes Menggunakan Algoritma Support Vector Machine (SVM). Informatics and Digital Expert (INDEX), 4(1), 40–45. https://doi.org/10.36423/index.v4i1.895

Kanedi, I., & Jumadi, J. (2024). Implementasi Machine Learning Untuk Prediksi Penjualan Oli Shell Pada CV. Harapan Karya Mandiri Bengkulu. 20(2), 534–541.

Karinasari, I. K. (2020). Deteksi Dini Penyakit Iugr (Intra Uterine Growth Retriction) Dengan Metode Svm (Support Vector Machine). Klik - Kumpulan Jurnal Ilmu Komputer, 7(2), 176. https://doi.org/10.20527/klik.v7i2.321

Kenny Riva, S., Casi, S., & Randy Erfa, S. (2022). Analisis Algoritma Support Vector Machine Dalam Klasifikasi Penyakit Stroke. E-Proceeding of Engineering, 9(3), 922.

Maisat, Z., Darmawan, E., & Fauzan, A. (2023). Implementasi Optimasi Hyperparameter GridSearchCV Pada Sistem Prediksi Serangan Jantung Menggunakan SVM. Unipdu, 13(1), 8–15.

Otchere, D. A., Arbi Ganat, T. O., Gholami, R., & Ridha, S. (2021). Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. Journal of Petroleum Science and Engineering, 200, 108182. https://doi.org/10.1016/j.petrol.2020.108182

Patmawati. (2023). Prediksi Penyakit Stroke Menggunakan Support Vector Machine (Svm). Bulletin of Network Engineer and Informatics, 1(1), 12–17.

Purwono, P., Dewi, P., Wibisono, S. K., & Dewa, B. P. (2022). Model Prediksi Otomatis Jenis Penyakit Hipertensi dengan Pemanfaatan Algoritma Machine Learning Artificial Neural Network. Insect (Informatics and Security): Jurnal Teknik Informatika, 7(2), 82–90. https://doi.org/10.33506/insect.v7i2.1828

Saputri, N. D., Khalid, K., & Rolliawati, D. (2022). Komparasi Penerapan Metode Bagging dan Adaboost pada Algoritma C4.5 untuk Prediksi Penyakit Stroke. Jurnal Sistem Informasi, 11(3), 567–577.

Sari, Z. D. R., Jasmir, J., & Arvita, Y. (2024). Penerapan Data Mining Untuk Prediksi Penyakit Diabetes. Jurnal Informatika Dan Rekayasa Komputer (JAKAKOM), 4, 827–834.

Sharma, R. (2020). Study of Supervised Learning and Unsupervised Learning. International Journal for Research in Applied Science and Engineering Technology, 8(6), 588–593. https://doi.org/10.22214/ijraset.2020.6095

Wijoyo A, Saputra A, Ristanti S, Sya'ban S, Amalia M, & Febriansyah R. (2024). Pembelajaran Machine Learning. OKTAL (Jurnal Ilmu Komputer Dan Science), 3(2), 375–380.