

Pengembangan *model quantum support vector machine (QSVM)* untuk prediksi stabilitas dan *flow marshall* pada campuran aspal

Ryandra Narlan^{1,*}, Setya Winarno¹

¹Jurusan Teknik Sipil, Fakultas Teknik Sipil dan Perencanaan, Universitas Islam Indonesia, Yogyakarta, Indonesia

Article Info

Available online

Keywords:

Quantum classification
Marshall parameters
Asphalt quality
Hybrid learning
Binary prediction

Corresponding Author:

Ryandra Narlan
23934003@students.uii.ac.id

Abstract

The Quantum Support Vector Machine (QSVM) is a hybrid machine learning approach that combines the computational power of quantum computing with classical classification algorithms. This study aims to evaluate the performance of QSVM in classifying asphalt mixture quality based on Marshall Stability (MS) and Marshall Flow (MF) values. The dataset used consists of technical parameters of the mixture, including asphalt content (Pb), specific gravity (Gmb, Gmm), air voids (Va), voids in mineral aggregate (VMA, VFA), as well as aggregate characteristics (Gsb, Gse). The MS and MF targets were divided into two classes (low and high) using the quantile binarization method. The QSVM model was constructed using a quantum kernel based on ZZFeatureMap and executed through statevector simulation on a classical backend. Evaluation results indicate that QSVM achieved an accuracy of 90.2% for MS prediction and 86.9% for MF, with macro F1-scores of 0.88 and 0.83, respectively. These results demonstrate the superiority of QSVM in binary classification compared to conventional regression models such as Artificial Neural Network (ANN), Random Forest (RF), Multi Expression Programming (MEP), and XGBoost. This classification approach is also considered more practical for field applications, particularly in the context of rapid decision-making regarding asphalt mixture quality assessment. The study recommends QSVM as an intelligent alternative for data-driven asphalt quality control systems.

Copyright © 2025 Universitas Islam Indonesia
All rights reserved

Pendahuluan

Latar belakang

Perkerasan jalan yang tahan lama dan andal sangat bergantung pada kualitas campuran aspal yang digunakan dalam konstruksi. Salah satu metode yang paling umum untuk menilai performa campuran aspal adalah pengujian Marshall, yang menghasilkan dua parameter utama: Stabilitas Marshall (*Marshall Stability/MS*) dan Aliran Marshall (*Marshall Flow/MF*). Parameter ini digunakan sebagai

indikator kekuatan dan kemampuan deformasi plastis dari campuran aspal. Namun demikian, metode konvensional untuk memperoleh MS dan MF melibatkan proses laboratorium yang rumit, memakan waktu, serta membutuhkan peralatan dan tenaga kerja yang signifikan (Asi dkk., 2024; Zahoor dkk., 2025). Kondisi ini menjadi tantangan tersendiri, terutama ketika diperlukan evaluasi cepat dalam skenario rekayasa praktis atau dalam proses optimasi campuran secara iteratif.

Seiring dengan kemajuan teknologi kecerdasan buatan, pendekatan berbasis machine learning (ML) telah diadopsi secara luas dalam berbagai bidang teknik sipil, termasuk dalam prediksi parameter-parameter *Marshall*. Beberapa penelitian terdahulu telah berhasil menerapkan model seperti *Artificial Neural Network* (ANN), *Adaptive Neuro-Fuzzy Inference System* (ANFIS), dan *Multi Expression Programming* (MEP), *Random Forest* (RF), *Gradient Boosting*, *Extreme Gradient Boosting* (XGB), and *Bagging Regressor* (BR) untuk membangun hubungan antara variabel input campuran aspal (seperti kadar aspal, gravitasi spesifik, dan porositas) terhadap nilai MS dan MF (Al-Ammari dkk., 2025; Gul dkk., 2022; Jamil dkk., 2025; Zahoor dkk., 2025). Model-model ini terbukti mampu memberikan akurasi tinggi dan efisiensi waktu yang lebih baik dibandingkan metode laboratorium konvensional. Namun, tantangan tetap ada terkait dengan keterbatasan kapasitas generalisasi model klasik terhadap dataset berdimensi tinggi dan nonlinier yang kompleks, serta kebutuhan interpretabilitas dan efisiensi komputasi (Chen dkk., 2023; Houlík dkk., 2024; Li dkk., 2023).

Dalam beberapa tahun terakhir, pendekatan baru yang menggabungkan pembelajaran mesin dengan prinsip-prinsip komputasi kuantum mulai berkembang, dikenal sebagai *Quantum Machine Learning* (QML). Salah satu bentuk implementasinya adalah *Quantum Support Vector Machine* (QSVM), yang memanfaatkan fenomena kuantum seperti superposisi dan interferensi dalam ruang fitur berdimensi tinggi melalui sirkuit kuantum yang dikonstruksi sebagai kernel dkk., 2021; Havlicek dkk., 2018). QSVM bekerja dengan prinsip *precomputed quantum kernel*, yang kemudian digunakan dalam klasifikasi data menggunakan *Support Vector Classifier* (SVC) (Schuld, 2021). Studi sebelumnya menunjukkan bahwa QSVM menggunakan *quantum kernels* dapat mengungguli SVM klasik pada dataset kecil dan kompleks, karena quantum kernel menyediakan ekspresifitas tinggi dan generalisasi yang kuat meskipun jumlah data terbatas (Canatar dkk.,

2023; Caro dkk., 2021.; Park dkk., 2020.). Lebih lanjut, pengaturan *bandwidth kernel* juga terbukti meningkatkan kemampuan generalisasi model QSVM (Canatar dkk., 2023).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi performa model klasifikasi QSVM dalam membedakan kategori MS dan MF pada campuran aspal. Kinerja QSVM akan dibandingkan dengan model prediktif klasik seperti ANN, *Random Forest* (RF), *Multi Expression Programming* (MEP) dan *XGBoost* dari segi akurasi klasifikasi, keseimbangan antar kelas (precision, recall, f1-score), serta efisiensi proses pelatihan. Dengan pendekatan ini, diharapkan tercipta sebuah sistem prediksi mutu campuran aspal yang lebih adaptif, cepat, dan mendukung pengambilan keputusan berbasis data di lapangan.

Tinjauan Pustaka

Prediksi parameter marshall menggunakan machine learning

Penggunaan metode pembelajaran mesin (machine learning/ML) untuk memprediksi Stabilitas Marshall (MS) dan Aliran Marshall (MF) telah banyak dikaji dalam beberapa tahun terakhir sebagai alternatif dari metode laboratorium konvensional yang mahal dan memakan waktu. (Asi dkk., 2024) mengembangkan model prediktif menggunakan algoritma *CatBoost* dan menemukan bahwa model tersebut mencapai nilai R^2 sebesar 0,835 untuk MS dan 0,845 untuk MF, dengan menggunakan teknik *explainable AI* (XAI) berupa SHAP untuk mengevaluasi pengaruh setiap fitur input terhadap hasil prediksi. Studi serupa dilakukan oleh (Zahoor dkk., 2025) yang membandingkan berbagai metode ML seperti *Random Forest*, SVM, *Gaussian Process*, *Ensemble Learning*, dan ANN dalam memprediksi MS dan MF, dengan kesimpulan bahwa pemilihan fitur yang relevan secara signifikan mempengaruhi performa model.

Beberapa pendekatan non-konvensional seperti ANFIS dan MEP juga telah terbukti

memberikan hasil yang kompetitif. (Gul dkk., 2022) menerapkan *Artificial Neural Network* (ANN), *Adaptive Neuro-Fuzzy Inference System* (ANFIS), dan *Multi Expression Programming* (MEP) untuk memprediksi MS dan MF pada campuran aspal, dan menemukan bahwa kedua pendekatan tersebut mampu memberikan akurasi tinggi dengan struktur model yang relatif sederhana dan mudah diinterpretasikan. Penelitian lain oleh (Al-Ammari dkk., 2025) menyoroti pentingnya optimalisasi parameter input dan validasi eksternal dalam model prediktif campuran aspal berbasis ML. Meskipun berbagai model klasik menunjukkan kinerja prediktif yang menjanjikan, tantangan seperti overfitting, kurangnya interpretabilitas, dan ketergantungan terhadap volume data besar masih menjadi hambatan penerapan di industri.

Quantum support vector machine dalam prediksi teknik sipil

Quantum Support Vector Machine (QSVM) merupakan pendekatan hybrid yang menggabungkan prinsip SVM klasik dengan kernel yang dihitung menggunakan sirkuit kuantum parameterisasi. (Havlicek dkk., 2018) memperkenalkan konsep QSVM melalui pemanfaatan *ZZFeatureMap* dalam ruang fitur kuantum, yang mampu mengekspresikan hubungan kompleks antar fitur dalam bentuk nonlinier dan sulit direpresentasikan secara klasik. QSVM terbukti efektif dalam klasifikasi biner berdimensi tinggi dengan dataset kecil, terutama karena sifat komputasi kuantum yang tidak terikat secara eksponensial oleh dimensi data (Cerezo dkk., 2021).

Meskipun implementasi QSVM dalam rekayasa sipil masih tergolong baru, potensinya mulai menarik perhatian. (Alnaqbi dkk., 2024) menunjukkan efektivitas model machine learning dalam prediksi kelelahan perkerasan fleksibel, dan menyarankan eksplorasi metode kuantum sebagai solusi terhadap tantangan generalisasi model. Sementara itu, (Li dkk., 2023) memperkenalkan pendekatan metaheuristik

berbasis data untuk prediksi deformasi, yang dapat digabungkan secara metodologis ke dalam pendekatan kernel kuantum.

Sejumlah studi menunjukkan bahwa QSVM memiliki potensi besar untuk diterapkan dalam klasifikasi mutu campuran aspal secara efisien dan adaptif. Pendekatan ini dinilai relevan untuk diintegrasikan dalam sistem pengambilan keputusan teknik sipil berbasis data, khususnya pada konteks pengendalian mutu. Beberapa literatur juga mengindikasikan bahwa QSVM dapat dikombinasikan dengan teknologi digital seperti sistem pemantauan berbasis sensor dan Internet of Things (IoT), yang memungkinkan pelaksanaan klasifikasi mutu secara real-time di lapangan (Cerezo dkk., 2021; Havlicek dkk., 2018). Dengan kemampuannya dalam melakukan klasifikasi cepat dan akurat, QSVM dinilai berpotensi digunakan sebagai komponen sistem pendukung keputusan untuk menentukan kelayakan campuran sebelum dilakukan pengujian laboratorium lanjutan. Hal ini membuka peluang efisiensi dalam proses kendali mutu dan pencegahan kegagalan struktural pada pekerjaan perkerasan jalan.

Metodologi Penelitian

Data, variabel input dan target output

Penelitian ini memanfaatkan data hasil pengujian Marshall pada campuran aspal jenis Asphalt Wearing Course (AWC), yang diperoleh dari 305 sampel laboratorium terkait proyek jalan nasional di wilayah Sumatera Selatan. Dataset tersebut mencakup delapan parameter utama yang merepresentasikan karakteristik fisik dan volumetrik campuran, meliputi: kadar aspal (Pb), berat jenis bulk (Gmb), berat jenis maksimum teoritis (Gmm), ruang antar agregat (VMA), porositas (Va), persentase void yang terisi aspal (VFA), berat jenis agregat (Gsb), serta berat jenis aspal efektif (Gse). Variabel-variabel ini dipilih berdasarkan relevansinya dalam memengaruhi parameter performa Marshall seperti *Marshall Stability* (MS) dan *Marshall Flow* (MF), sebagaimana dilaporkan dalam studi-studi sebelumnya (Al-Ammari dkk.,

2025; Zahoor dkk., 2025). Dataset diolah menggunakan perangkat lunak *Python* dengan pustaka pendukung seperti *Scikit-learn* dan *Qiskit*.

Target output terdiri dari dua variabel yaitu: MS: *Marshall Stability* (kg), MF: *Marshall Flow* (0,25 mm)

Pra-pemrosesan data

Seluruh data input dinormalisasi menggunakan teknik *MinMaxScaler* agar berada dalam rentang [0, 1]. Normalisasi ini bertujuan untuk mengoptimalkan proses encoding fitur ke dalam sirkuit kuantum, yang sensitif terhadap skala input. Data kemudian dibagi menjadi dua bagian: 80% untuk pelatihan dan 20% untuk pengujian. Proses pembagian dilakukan secara stratifikasi agar distribusi kelas pada data target tetap seimbang.

Untuk keperluan klasifikasi, nilai MS dan MF dibagi menjadi dua kelas menggunakan metode *quantile discretization* (qcut) dari pustaka *pandas*. Kelas 0 menunjukkan nilai rendah dan kelas 1 menunjukkan nilai tinggi. Proses ini dilakukan secara terpisah untuk masing-masing target (MS dan MF), menghasilkan dua set klasifikasi biner yang independen.

Pengembangan model quantum support vector machine (QSVM)

Model QSVM dibangun menggunakan pendekatan kernel kuantum yang dikombinasikan dengan *Support Vector Classifier* (SVC) klasik. Proses pengembangan model dilakukan dalam dua tahap utama: 1) Pemetaan Fitur Kuantum (*Quantum Feature Map*): Data input diekode ke dalam sirkuit kuantum menggunakan *ZZFeatureMap* dengan pengaturan *entanglement* linear dan $\text{reps} = 2$. Sirkuit ini membentuk vektor status kuantum (*quantum state*) dari setiap data sampel., 2) Evaluasi Kernel dan Pelatihan Model: Kemiripan antar sampel dihitung dalam ruang *Hilbert* kuantum menggunakan *QuantumKernel* dari *Qiskit Machine Learning*. Kernel ini dievaluasi melalui

backend statevector simulator untuk menghasilkan matriks kernel *precomputed*. Matriks ini digunakan sebagai input ke algoritma SVC (SVC(kernel='precomputed')) untuk proses pelatihan model dan klasifikasi data uji.

Model QSVM dibangun secara terpisah untuk masing-masing target (MS dan MF), dengan prosedur identik mulai dari preprocessing hingga evaluasi.

Model pembandingan (baseline klasik)

Untuk mengukur keunggulan QSVM, dilakukan perbandingan dengan empat model machine learning klasik, yaitu: *Artificial Neural Network* (ANN), *Random Forest* (RF), *Multi Expression Programming* (MEP) dan *Extreme Gradient Boosting* (XGBoost).

Seluruh model baseline menggunakan parameter default dengan tuning minimal untuk menjaga konsistensi perbandingan. Input dan pembagian data tetap sama seperti pada QSVM.

Evaluasi model

Kinerja model dievaluasi menggunakan beberapa metrik klasifikasi penting untuk mengukur akurasi dan kualitas prediksi. Pertama, *Accuracy* mengukur proporsi prediksi yang benar dibandingkan dengan seluruh data uji, mencerminkan sejauh mana model secara keseluruhan mampu mengklasifikasikan data dengan tepat. Selanjutnya, *Precision* menunjukkan tingkat ketepatan prediksi positif model, yaitu seberapa banyak dari data yang diprediksi sebagai kelas positif (1) benar-benar positif. *Recall* atau sensitivitas mengukur sejauh mana model mampu mendeteksi seluruh kasus positif yang sebenarnya. *F1-Score* merupakan harmonisasi antara *precision* dan *recall*, yang berguna untuk menilai kinerja model secara seimbang, khususnya saat terdapat ketidakseimbangan kelas. Semua metrik tersebut dihitung secara terpisah untuk masing-masing kelas (0 dan 1). Terakhir, *Confusion Matrix* digunakan untuk memvisualisasikan hasil klasifikasi model, sehingga memudahkan dalam

mengidentifikasi kesalahan tipe I (*false positive*) dan tipe II (*false negative*).

Evaluasi dilakukan menggunakan *classification_report* dan *confusion_matrix* dari *Scikit-learn*. Hasil akhir disajikan dalam bentuk tabel perbandingan dan grafik visual untuk memudahkan analisis performa antar model.

Alat dan lingkungan pemrograman

Eksperimen dan pemodelan dalam penelitian ini dijalankan menggunakan platform *Google Colaboratory*, yang menyediakan lingkungan pemrograman *Python* berbasis *cloud* dengan akses GPU/CPU secara fleksibel.

Pemrograman dilakukan menggunakan bahasa *Python 3*, dengan pustaka utama sebagai berikut: *Pandas* dan *NumPy* untuk pengelolaan dan manipulasi data.; *Scikit-learn (sklearn)* untuk pemisahan data, normalisasi, algoritma *Support Vector Classifier (SVC)*, dan metrik evaluasi seperti akurasi, precision, recall, F1-score, serta *confusion matrix*.; *Matplotlib* dan *Seaborn* untuk visualisasi hasil evaluasi model.; *Qiskit* (versi $\geq 0.43.1$) dan *Qiskit Machine Learning* (versi $\geq 0.5.0$) untuk implementasi komputasi kuantum, terutama pembuatan *Quantum Feature Map (ZZFeatureMap)*, evaluasi kernel melalui *QuantumKernel*, dan simulasi dengan *Aer statevector simulator*.

Kernel kuantum dihitung menggunakan simulator *statevector_simulator* dari *Qiskit Aer*, sedangkan proses klasifikasi dilakukan dengan model *SVC(kernel='precomputed')* dari *Scikit-learn*. Seluruh eksperimen dijalankan secara online melalui *Google Colab* dengan *runtime GPU*.


Hasil dan Pembahasan

Hasil evaluasi model QSVM

Model *Quantum Support Vector Machine (QSVM)* yang dikembangkan dalam penelitian ini menunjukkan performa klasifikasi yang sangat baik dalam membedakan kategori nilai *Marshall Stability (MS)* dan *Marshall Flow (MF)*. Berdasarkan hasil klasifikasi biner, model QSVM

memperoleh akurasi sebesar 90,2% dan *F1-score* 0,88 untuk prediksi MS, serta akurasi 86,9% dan *F1-score* 0,83 untuk MF. Evaluasi dilakukan terhadap dua kelas (rendah dan tinggi) yang dibentuk menggunakan teknik binarisasi *qcut*, dengan distribusi data yang seimbang pada setiap kelas.

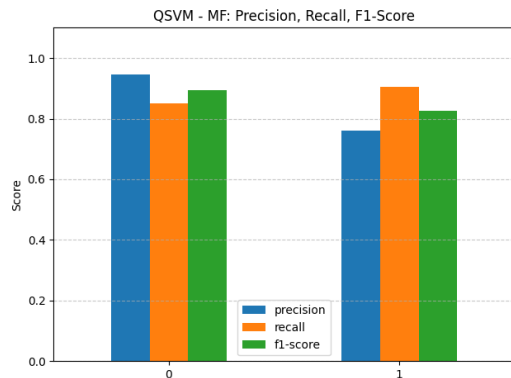
Dari hasil *classification_report* yang divisualisasikan pada Evaluasi Kinerja Model QSVM pada gambar 1. diketahui bahwa model QSVM menunjukkan keseimbangan *precision* dan *recall* yang tinggi untuk klasifikasi MS, mencerminkan stabilitas kinerja terhadap kedua kelas.



Gambar 1. Evaluasi Kinerja Model QSVM pada Prediksi *Marshall Stability (MS)* Berdasarkan Precision, Recall, dan F1-Score

Sementara itu, seperti dapat dilihat pada gambar 2, pada prediksi MF, meskipun recall untuk kelas tinggi mencapai 90%, precision-nya relatif lebih rendah (sekitar 76%), yang menunjukkan potensi false positive lebih tinggi untuk kelas tersebut. Namun, secara keseluruhan, performa QSVM dapat dikategorikan sangat baik dan konsisten.

Hasil ini mendukung temuan (Cerezo et al., 2021; Havlicek et al., 2018) bahwa penggunaan quantum kernel memungkinkan pemodelan relasi nonlinier dalam ruang berdimensi tinggi secara efisien, bahkan pada dataset kecil dan kompleks.



Gambar 2. Evaluasi Kinerja Model QSVM pada Prediksi Marshall Flow (MF) Berdasarkan Precision, Recall, dan F1-Score

Dengan memanfaatkan *ZZFeatureMap* dan simulasi kuantum menggunakan *statevector_simulator*, QSVM terbukti mampu menggeneralisasi pola klasifikasi secara lebih stabil dibanding pendekatan klasik.

Perbandingan dengan model regresi klasik

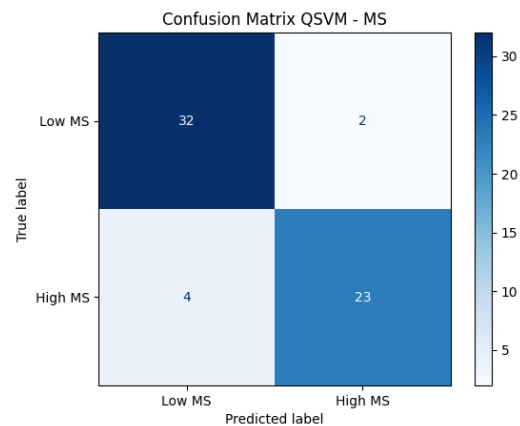
Untuk memahami performa QSVM secara lebih menyeluruh, dilakukan perbandingan dengan beberapa model regresi konvensional: *Artificial Neural Network* (ANN), *Random Forest* (RF), *Extreme Gradient Boosting* (XGBoost), dan *Multi Expression Programming* (MEP).

Hasil pada Tabel 1. menunjukkan bahwa model regresi seperti *Random Forest* dan *XGBoost* memberikan performa prediksi yang tinggi untuk target MF ($R^2 > 0.90$), namun performanya menurun untuk prediksi MS (R^2 hanya sekitar 0.72–0.75). Sementara itu, QSVM memberikan performa klasifikasi yang sangat baik untuk kedua target secara konsisten, dan secara praktis lebih mudah diinterpretasikan dalam pengambilan keputusan lapangan.

Analisis komparatif dan interpretasi

Visualisasi confusion matrix QSVM untuk parameter *Marshall Stability* (MS) pada Gambar 3. menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dalam membedakan mutu campuran aspal berdasarkan tingkat kestabilannya. QSVM mampu mengklasifikasikan 32 dari 34 sampel *Low MS* dengan benar (*true negative*) dan 23 dari 27 sampel *High MS* secara akurat (*true positive*), menghasilkan tingkat akurasi keseluruhan sebesar 90,2%.

Hasil ini mengindikasikan bahwa model cukup andal dalam mengenali campuran dengan stabilitas rendah, yang biasanya lebih rentan terhadap deformasi, sekaligus mampu mengidentifikasi campuran dengan stabilitas tinggi yang lebih tahan terhadap beban lalu lintas. Meskipun terdapat beberapa kesalahan klasifikasi (*false negative* = 4 dan *false positive* = 2). Mayoritas kesalahan berada pada *false negative* (yaitu ketika mutu tinggi diprediksi sebagai rendah), yang secara praktis lebih aman daripada false positive. Hal ini berarti model lebih konservatif, cenderung tidak salah memberi nilai tinggi jika datanya sebenarnya rendah, sebuah karakteristik penting dalam sistem kendali mutu konstruksi jalan.

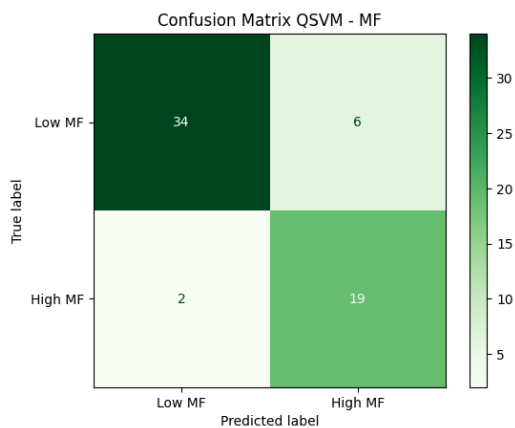


Gambar 3. Visualisasi confusion matrix QSVM untuk parameter Marshall Stability (MS)

Tabel 1. Perbandingan Evaluasi Model (Regresi vs Klasifikasi)

Model	Target	R ²	RMSE	MAE	Accuracy	F1-score	Keterangan
ANN	MS	0.426	32.58	23.20	-	-	Regresi
ANN	MF	0.870	0.093	0.071	-	-	Regresi
RF	MS	0.746	21.68	15.80	-	-	Regresi
RF	MF	0.926	0.070	0.045	-	-	Regresi
XGBoost	MS	0.720	22.74	15.71	-	-	Regresi
XGBoost	MF	0.911	0.077	0.051	-	-	Regresi
MEP	MS	0.664	24.90	18.42	-	-	Regresi
MEP	MF	0.879	0.089	0.072	-	-	Regresi
QSVM	MS	-	-	-	0.902	0.88	Klasifikasi
QSVM	MF	-	-	-	0.869	0.83	Klasifikasi

Visualisasi confusion matrix QSVM untuk parameter Marshall Flow (MF) pada gambar 4. menunjukkan bahwa model mampu melakukan klasifikasi mutu campuran aspal dengan tingkat akurasi yang tinggi, yakni sekitar 86,9%. Model berhasil mengidentifikasi 34 dari 40 sampel *Low MF* secara benar (*true negative*) dan 19 dari 21 sampel *High MF* secara akurat (*true positive*), menandakan bahwa QSVM cukup andal dalam membedakan karakteristik campuran aspal yang kaku (*Low MF*) dan yang lebih lentur (*High MF*).



Gambar 4. Visualisasi *confusion matrix* QSVM untuk parameter *Marshall Flow* (MF)

Kinerja *recall* untuk kelas *High MF* mencapai 90,5%, yang berarti model sangat baik dalam mengenali campuran dengan tingkat kelenturan tinggi. Meskipun terdapat 6 kesalahan klasifikasi pada kelas *Low MF* yang diprediksi sebagai *High MF* (*false positive*), hal ini masih dalam batas yang dapat diterima, terutama karena konsekuensi

praktis dari kesalahan ini relatif tidak berisiko dibanding jika model gagal mengenali MF tinggi (*false negative*).

Kinerja QSVM secara umum tetap konsisten dan menjanjikan untuk digunakan sebagai alat bantu evaluasi mutu campuran aspal di tahap awal desain atau inspeksi lapangan. Secara keseluruhan, hasil ini menegaskan bahwa QSVM tidak hanya efektif dalam mengenali pola kompleks pada dataset teknik sipil, tetapi juga menunjukkan keunggulan dalam menangani masalah klasifikasi pada domain dengan data terbatas, seperti yang sering dihadapi dalam pengujian mutu material di lapangan. Dengan kinerja tersebut, QSVM layak dipertimbangkan sebagai bagian dari sistem klasifikasi mutu aspal yang cepat, akurat, dan siap diterapkan dalam lingkungan digital berbasis data.

Kelebihan QSVM terletak pada pemanfaatan *quantum-enhanced feature space* untuk meningkatkan pemisahan antar kelas, sebagaimana juga ditunjukkan oleh (Abbas dkk., 2021; Park dkk., 2020.). Pendekatan ini mampu mengatasi keterbatasan kapasitas representasi dari model klasik yang cenderung mengalami overfitting atau kehilangan akurasi saat berhadapan dengan data yang kompleks atau tidak terdistribusi secara ideal (Canatar dkk., 2023; Cerezo dkk., 2021).

MEP dan ANFIS dalam studi (Gul dkk., 2022) juga terbukti efektif dalam regresi MS, namun masih memerlukan struktur model yang lebih eksplisit. Sebaliknya,

QSVM cukup fleksibel karena hanya membutuhkan pemetaan fitur dan kernel evaluasi, sehingga pelatihan tetap efisien meskipun dengan jumlah data terbatas.

Implikasi teknik dan praktis

Secara teknis, model QSVM memiliki karakteristik yang sangat cocok untuk diintegrasikan dalam sistem pemantauan mutu campuran aspal berbasis data. Pendekatan klasifikasi biner juga lebih sesuai dengan kebutuhan teknis dalam pengambilan keputusan cepat, seperti penentuan kelayakan *batch* campuran sebelum dilakukan uji destruktif laboratorium (Al-Ammari dkk., 2025; Zahoor dkk., 2025).

Kesimpulan

Penelitian ini menunjukkan bahwa *Quantum Support Vector Machine* (QSVM) merupakan pendekatan yang efektif dalam klasifikasi mutu campuran aspal berdasarkan parameter *Marshall Stability* (MS) dan *Marshall Flow* (MF). Model QSVM yang dikembangkan dengan menggunakan quantum kernel dari *ZZFeatureMap* berhasil mencapai akurasi klasifikasi yang tinggi, yaitu sebesar 90,2% untuk MS dan 87,0% untuk MF, dengan *F1-score* yang seimbang pada kedua kelas target. Hasil ini mengindikasikan bahwa QSVM mampu mengidentifikasi mutu campuran aspal secara akurat bahkan pada dataset yang terbatas, berkat kemampuannya mengeksplorasi hubungan nonlinier antar fitur dalam ruang fitur kuantum berdimensi tinggi. Jika dibandingkan dengan model regresi klasik seperti ANN, Random Forest, XGBoost, dan MEP, QSVM menawarkan keunggulan dari sisi efisiensi klasifikasi, interpretabilitas hasil, serta potensi penerapan langsung dalam pengambilan keputusan di lapangan. Dengan kemampuan tersebut, QSVM berpotensi menjadi bagian dari sistem inspeksi mutu digital berbasis Internet of Things (IoT), yang dapat mendeteksi dan mengklasifikasikan mutu campuran secara real-time sebelum dilakukan uji laboratorium. Temuan ini

memperkuat pandangan dalam literatur bahwa integrasi machine learning kuantum dalam rekayasa sipil membuka peluang baru bagi pengembangan sistem cerdas dalam pengendalian mutu dan proses konstruksi jalan yang lebih efisien dan berbasis data.

Saran

Berdasarkan hasil penelitian ini, disarankan agar studi lanjutan dilakukan dengan memperluas cakupan dataset melalui pengumpulan data dari berbagai jenis proyek jalan dan variasi campuran aspal agar model QSVM dapat divalidasi secara lebih luas dan diperkuat kemampuan generalisasinya. Selain itu, pengembangan sistem inspeksi mutu berbasis IoT yang mengintegrasikan QSVM dengan sensor digital di lapangan menjadi langkah potensial yang dapat mempercepat proses evaluasi mutu dan meningkatkan efisiensi manajemen mutu di proyek konstruksi. Penelitian ke depan juga perlu mengeksplorasi pendekatan *Quantum Machine Learning* lainnya seperti *Quantum Neural Network* (QNN) atau *Variational Quantum Classifier* (VQC), sehingga dapat dibandingkan performa dan efisiensinya terhadap QSVM dalam konteks klasifikasi maupun prediksi regresi. Di samping itu, penggabungan QSVM dengan pendekatan *Explainable AI* (XAI) seperti SHAP atau LIME dapat meningkatkan transparansi dan kepercayaan pengguna terhadap hasil klasifikasi model, khususnya dalam penerapannya di lingkungan teknik sipil yang membutuhkan interpretasi dan justifikasi teknis terhadap keputusan berbasis model kecerdasan buatan.

Daftar Pustaka

- Abbas, A., Sutter, D., Zoufal, C., Lucchi, A., Figalli, A., & Woerner, S. (2021). The power of quantum neural networks. *Nature Computational Science*, 1(6), 403–409. <https://doi.org/10.1038/S43588-021-00084-1>
- Al-Ammari, M., Dong, R., Nasser, M., & Al-Maswari, A. (2025). Innovative Machine Learning Approaches for Predicting the Asphalt Content During Marshall Design of Asphalt Mixtures. *Materials*, 18(7). <https://doi.org/10.3390/ma18071474>

- Alnaqbi, A. J., Zeiada, W., Al-Khateeb, G., Abttan, A., & Abuzwidah, M. (2024). Predictive models for flexible pavement fatigue cracking based on machine learning. *Transportation Engineering*, 16. <https://doi.org/10.1016/j.treng.2024.100243>
- Asi, I., Alhadidi, Y. I., & Alhadidi, T. I. (2024). Predicting Marshall stability and flow parameters in asphalt pavements using explainable machine-learning models. *Transportation Engineering*, 18. <https://doi.org/10.1016/j.treng.2024.100282>
- Canatar, A., Peters, E., Wild, S. M., & Shayduln, R. (2023). *Bandwidth Enables Generalization in Quantum Kernel Models*.
- Caro, M. C., Huang, H.-Y., Cerezo, M., Sharma, K., Sornborger, A., Cincio, L., & Coles, P. J. (n.d.). *Generalization in quantum machine learning from few training data*.
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., McClean, J. R., Mitarai, K., Yuan, X., Cincio, L., & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics* 2021 3:9, 3(9), 625–644. <https://doi.org/10.1038/s42254-021-00348-9>
- Chen, Y., Li, F., Zhou, S., Zhang, X., Zhang, S., Zhang, Q., & Su, Y. (2023). Bayesian optimization based random forest and extreme gradient boosting for the pavement density prediction in GPR detection. *Construction and Building Materials*, 387. <https://doi.org/10.1016/j.conbuildmat.2023.131564>
- Gul, M. A., Islam, M. K., Awan, H. H., Sohail, M., Al Fuhaid, A. F., Arifuzzaman, M., & Qureshi, H. J. (2022). Prediction of Marshall Stability and Marshall Flow of Asphalt Pavements Using Supervised Machine Learning Algorithms. In *Symmetry* (Vol. 14, Issue 11). MDPI. <https://doi.org/10.3390/sym14112324>
- Havlicek, V., Córcoles, A. D., Temme, K., Harrow, A. W., Kandala, A., Chow, J. M., & Gambetta, J. M. (2018). *Supervised learning with quantum enhanced feature spaces*.
- Houlík, J., Valentin, J., & Nežerka, V. (2024). *Predicting the fatigue life of asphalt concrete using neural networks*. <http://arxiv.org/abs/2406.01523>
- Jamil, M. H., Jagirdar, R., Kashem, A., Ali, M. N., & Deb, D. (2025). Modeling of Marshall Stability of plastic-reinforced asphalt concrete using machine learning algorithms and SHAP. *Hybrid Advances*, 10. <https://doi.org/10.1016/j.hybadv.2025.100483>
- Li, Z., Korovin, I., Shi, X., Gorbachev, S., Gorbacheva, N., Huang, W., & Cao, J. (2023). *A data-driven rutting depth short-time prediction model with metaheuristic optimization for asphalt pavements based on RIOHTrack*. <https://doi.org/10.1109/JAS.2023.123192>
- Park, J.-E., Quanz, B., Wood, S., Higgins, H., & Harishankar, R. (n.d.). *Practical application improvement to Quantum SVM: theory to practice*.
- Schuld, M. (2021). *Supervised quantum machine learning models are kernel methods*.
- Zahoor, M. F., Hussain, A., & Khattak, A. (2025). Machine Learning-Based Prediction Performance Comparison of Marshall Stability and Flow in Asphalt Mixtures. *Infrastructures*, 10(6), 142. <https://doi.org/10.3390/infrastructures10060142>