

Memperkirakan Kepadatan Kering Maksimum Tanah melalui Regresi Vektor

Ragil Arman Maulana¹

¹Program Studi Teknik Sipil, Program Magister, Universitas Brawijaya, Malang

ABSTRAK: Kepadatan kering maksimum (MDD) memiliki arti penting dalam rekayasa geoteknik karena menandakan massa tanah yang ideal per satuan volume pada kondisi tertentu. Hal ini penting dalam menentukan stabilitas dan efektivitas berbagai pekerjaan tanah, seperti tanggul dan fondasi. MDD dapat bervariasi berdasarkan faktor-faktor yang meliputi jenis tanah, distribusi ukuran butiran, tingkat pemadatan, dan kadar air. Biasanya, peningkatan upaya pemadatan menghasilkan nilai MDD yang lebih tinggi, yang mengarah ke struktur yang lebih padat, sementara peningkatan kadar air cenderung menurunkannya. Estimasi MDD yang tepat sangat penting bagi para insinyur untuk membuat keputusan yang tepat, guna memastikan umur panjang dan keamanan struktur teknik sipil dari waktu ke waktu. Makalah ini memperkenalkan metode baru untuk memprediksi kepadatan kering maksimum (MDD) dengan menggunakan algoritma regresi vektor dukungan kuadrat terkecil (LSSVR). Pendekatan ini melibatkan penggunaan teknik LSSVR untuk mengembangkan model yang tepat yang menghubungkan MDD tanah yang distabilisasi dengan beberapa karakteristik tanah intrinsik seperti distribusi ukuran partikel, plastisitas, kembang susut linier, dan komposisi serta jumlah bahan stabilisasi yang digunakan. Dalam penelitian ini, dataset lengkap yang terdiri dari 187 sampel dari berbagai jenis tanah yang bersumber dari hasil uji stabilisasi yang telah dipublikasikan sebelumnya digunakan untuk memformulasikan dan mengevaluasi model prediktif.

Kata Kunci: kata kunci, tidak bolrh, lebih dari, 5 kata

1. PENDAHULUAN

Karena keragaman jenis tanah yang sangat luas yang ditemukan di alam, tidak semua tanah cocok untuk jenis struktur tanah tertentu. Inilah sebabnya mengapa tanah memiliki sejarah terpanjang dan merupakan bahan konstruksi yang paling banyak digunakan. Seperti material konstruksi lainnya, setiap jenis tanah memiliki metode ilmiah dan daya dukungnya masing-masing. Tanah merupakan hal yang sangat penting dalam teknik sipil, terutama ketika merancang struktur yang bersentuhan langsung dengan tanah, seperti konstruksi berbasis tanah, pondasi, dan tanggul [1], [2], [3]. Karena ketidakpastian yang signifikan dalam analisis dan konstruksi tanah, struktur-struktur ini membutuhkan faktor keamanan yang jauh lebih tinggi daripada bahan bangunan lainnya. Namun, terlepas dari apakah mereka digunakan dalam kondisi alami atau dengan perbaikan seperti pemadatan, konsolidasi, dan penguatan, tanah dan batu masih merupakan elemen bangunan yang diperlukan [4], [5].

Stabilisasi kimiawi adalah proses yang memasukkan bahan kimia tertentu, seperti aspal, kapur, semen, atau kombinasinya, ke dalam tanah. Bahan kimia ini berinteraksi dengan komponen alami tanah untuk meningkatkan kekuatannya, mengubah permeabilitas, porositas, volume, dan kepadatannya, membuat tahan air, dan mengurangi abrasi permukaan dengan menyatukan partikel-partikel tanah [6]. Stabilisasi kimiawi, yang melibatkan penambahan bahan kimia, sering kali menurunkan biaya proyek-proyek teknik sipil termasuk membangun jalan, fondasi, dan dinding tanah. Berbagai hasil, termasuk penyesuaian kekuatan, penyusutan, kepadatan, dan daya tahan, dapat diperoleh dari prosedur ini. Biasanya, salah satu faktor terpenting dalam menilai apakah suatu tanah dapat diterima untuk stabilisasi adalah kepadatan kering maksimum (MDD). MDD berfungsi sebagai kriteria kinerja stabilisasi dan merupakan indikator

yang dapat diandalkan untuk hasil stabilisasi di lapangan. Hal ini merepresentasikan kondisi tanah setelah pemadatan tetapi sebelum pemeraman [7], [8], [9].

Dengan mengembangkan model matematis untuk memperkirakan nilai MDD berdasarkan sifat-sifat tanah sebelum stabilisasi, seperti tekstur, plastisitas, serta jumlah dan jenis kembang susut lapisan, seseorang dapat menyederhanakan proses dan mengurangi kebutuhan akan eksperimen laboratorium MDD yang ekstensif dan melelahkan pada proyek-proyek konstruksi baru. Selain itu, hal ini dapat meningkatkan pemahaman mengenai hubungan yang menantang di antara sifat-sifat tanah dan parameter-parameter yang berpotensi mempengaruhi.

Sementara itu, beberapa penelitian telah mengeksplorasi perubahan sifat material sebelum dan sesudah stabilisasi, hanya sedikit yang berusaha memprediksi MDD menggunakan sifat-sifat ini. Penelitian sebelumnya berkonsentrasi pada simulasi peningkatan kekuatan dan densitas yang dihasilkan dari stabilisasi kimia dengan menggunakan teknik pencarian hibrida seperti *simulated annealing* (SA) dan pemrograman genetik (GP) serta variasinya, seperti pemrograman genetik linier (LGP). Sebagai contoh, Heshmati dkk. menggunakan GP [10], [11] SA untuk memperkirakan MDD campuran stabilisator tanah [12], [13], [14]. Terlepas dari sejarah panjang stabilisasi dengan menggunakan bahan semen, belum banyak penelitian yang dilakukan mengenai penggunaan jaringan syaraf tiruan (JST) untuk mencapai tujuan ini [15], [16].

Meskipun beberapa penelitian telah meneliti perubahan sifat material sebelum dan sesudah distabilisasi, namun masih sedikit penelitian yang berfokus pada prediksi MDD berdasarkan sifat-sifat ini. Penelitian sebelumnya sebagian besar berfokus pada penggunaan algoritma pencarian hibrida seperti *simulated annealing* (SA) yang dikombinasikan dengan pemrograman genetik

(GP) dan cabang- cabangnya, seperti pemrograman genetik linier (LGP), untuk meniru peningkatan densitas dan kekuatan yang dihasilkan dari stabilisasi kimiawi [17], [18], [19]. Sebagai contoh, Heshmati et al. menggunakan metodologi GP/SA untuk memperkirakan MDD campuran stabilisator tanah [12], [20]. Terlepas dari sejarah yang panjang dari stabilisasi dengan menggunakan bahan semen, eksplorasi mengenai penerapan jaringan syaraf tiruan (JST) untuk mencapai tujuan ini masih kurang [21], [22], [23].

Machine learning (ML) secara signifikan meningkatkan efisiensi pemrosesan data dalam skenario yang kompleks, di mana memahami informasi yang diekstraksi merupakan hal yang menantang. Tingginya permintaan untuk ML berasal dari berlimpahnya kumpulan data, yang mendorong relevan. Tujuan utama ML adalah untuk memperoleh pengetahuan dari data, mendorong penelitian ekstensif tentang pembelajaran mesin otonom tanpa pemrograman eksplisit. Para ahli matematika dan pemrogram menggunakan beragam metodologi untuk mengatasi tantangan yang ditimbulkan oleh kumpulan data yang besar. ML, sebuah subbidang dari kecerdasan buatan, mengembangkan algoritme yang memperoleh pengetahuan dari kumpulan data dan terus meningkatkan kinerja. ML unggul dalam mengelola set data yang kompleks, mengidentifikasi tren, dan membuat prediksi yang akurat. Metodologi ML yang didokumentasikan secara ekstensif mencakup pembelajaran yang diawasi dan tidak diawasi, pembelajaran penguatan, dan pembelajaran mendalam. ML digunakan secara luas di bidang kesehatan, keuangan, manufaktur, dan transportasi, yang menunjukkan potensi dalam analisis citra medis, deteksi anomali, identifikasi penipuan, dan manajemen risiko. Literatur ilmiah secara ekstensif mengeksplorasi ide-ide ini [24], [25].

Investigasi yang dilakukan oleh Grundi dkk. [26] menguji kemampuan model PNN dan MLPNN dalam mengestimasi parameter kualitas air yang penting, khususnya DO dan kebutuhan oksigen biokimia lima hari (BOD 5). Melalui evaluasi komprehensif dengan menggunakan berbagai metrik statistik, penelitian ini mengungkapkan kinerja model PNN yang lebih unggul daripada model MLPNN dalam hal akurasi estimasi untuk parameter DO dan BOD. Selain itu, penggabungan variabel input tambahan menunjukkan peningkatan kinerja model dalam kondisi tertentu. Hal yang paling penting adalah kemampuan model PNN dalam mengestimasi parameter kualitas air, yang dibuktikan dengan indikator evaluasi yang optimal untuk memprediksi BOD ($R^2=0.93$, $RMSE=0.231$, $MAE=0.197$) dan DO ($R^2=0.94$, $RMSE=0.222$, $MAE=0.175$).

Penelitian yang dilakukan oleh Allawi dkk. [24] memperkenalkan model GA-CANFIS baru yang dimodifikasi untuk memprediksi penguapan waduk, yang menunjukkan kinerja yang lebih unggul dibandingkan dengan model kecerdasan buatan yang terkemuka seperti GA-ANFIS, GA-SVR, dan GA-RBFNN dalam hal akurasi. Khususnya, model GA-CANFIS yang dimodifikasi mencapai hasil yang luar biasa dengan RMSE minimum (15,22 mm bulan-luntuk AHD, 8,78 mm bulan-luntuk TTD), MAE minimum (12,48 mm

bulan-luntuk AHD, 5,11 mm bulan-luntuk TTD), dan koefisien determinasi maksimum (0,98 untuk AHD, 0,95 untuk TTD) di kedua studi kasus (Bendungan Tinggi Aswan dan Bendungan Timah Tasoh). Temuan ini menggarisbawahi kemampuan model GA-CANFIS yang dimodifikasi sebagai alat yang kuat untuk prediksi penguapan waduk yang akurat, yang menawarkan kemajuan yang menjanjikan dalam pengelolaan waduk dan perencanaan sumber daya air. Dalam penyelidikan mereka, [27], [28] menetapkan untuk menilai kemanjuran berbagai model pembelajaran mesin dalam memprediksi konsentrasi ozon jangka pendek. Secara khusus, LR, SVR, GPR, dan ANN muncul sebagai yang paling menjanjikan, menghasilkan nilai R^2 tertinggi sebesar 83% dan 89% dengan hiperparameter spesifik di berbagai stasiun pemantauan. Untuk mengukur kinerja model secara komprehensif penelitian ini menggunakan metrik seperti RMSE, MAE, R^2 , dan waktu pelatihan. Nilai R^2 , yang berfungsi sebagai indikator penting dari akurasi prediksi, mendekati satu dalam kasus-kasus dengan tingkat presisi yang tinggi. Untuk melakukan analisis mereka, para peneliti memanfaatkan set data konsentrasi ozon yang bersumber dari sistem pemantauan kualitas udara yang terletak di tiga stasiun yang berbeda di Semenanjung Malaysia. Dengan menggunakan dataset ini, model-model tersebut menjalani validasi melalui optimalisasi hiperparameter mereka, sehingga memberikan wawasan yang berharga mengenai prakiraan konsentrasi ozon jangka pendek dan implikasinya terhadap manajemen kualitas udara. Sebuah studi oleh Khouja dkk. [29] melakukan penelitian yang bertujuan untuk menciptakan model baru menggunakan algoritma sistem inferensi neuro-fuzzy (CAN-FIS) yang dimodifikasi untuk meningkatkan ekstraksi fitur dalam kerangka kerja berbasis data. Temuan mereka menyoroti keunggulan model CANFIS yang dimodifikasi dibandingkan model tradisional seperti ANFIS, SVR, dan RBF-NN dalam memprediksi penguapan. Model CANFIS yang dimodifikasi menunjukkan nilai kesalahan relatif di bawah 23% untuk Bendungan Tinggi Aswan (AHD) dan 20% untuk Bendungan Timah Tasoh (TTD), disertai dengan nilai kesalahan absolut rata-rata (MAE) sebesar 12,72 mm bulan-luntuk AHD dan 7,63 mm bulan-luntuk TTD, serta nilai RMSE sebesar 15,42 mm bulan-luntuk AHD dan 8,53 mm bulan-luntuk TTD. Selain itu, penelitian ini juga menghasilkan koefisien determinasi yang tinggi, yaitu 0,96 untuk AHD dan 0,91 untuk TTD. Penelitian ini juga mengeksplorasi metode untuk mengatasi keterbatasan model yang ada untuk lebih meningkatkan akurasi. Khususnya, mereka menghitung persentase peningkatan akurasi, yang disebut IA, antara model CANFIS yang dimodifikasi dan model tradisional, yang menggambarkan kemajuan yang menjanjikan dalam kemampuan prediktif dan menggarisbawahi pentingnya menyempurnakan metodologi yang ada untuk hasil yang lebih tepat.

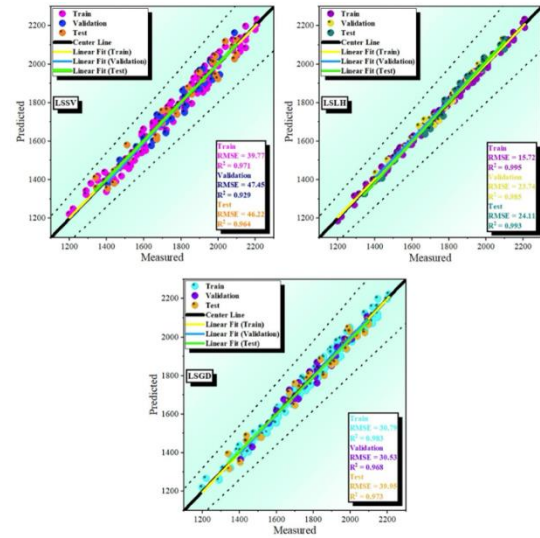
Penelitian ini berfokus pada pengembangan model regresi vektor pendukung kuadrat terkecil (least square support vector regression, LSSVR) untuk memprediksi MDD secara akurat. Model prediksi yang akurat untuk MDD sangat penting dalam teknik sipil karena model ini mengoptimalkan konstituen campuran dan memfasilitasi

hasil kinerja yang diinginkan. Para insinyur dapat mencapai daya tahan dan keberlanjutan dengan membuat keputusan yang tepat terkait penggunaan material, desain struktur, dan metode konstruksi. Namun, untuk meningkatkan kinerja prediktif LSSVR diperlukan parameter optimasi parameter. Untuk mengatasi hal ini, penelitian ini mengintegrasikan dua algoritma optimisasi, optimisasi Leader Harris Hawk (LHHO) dan optimisasi distribusi normal tergeneralisasi (GNDO). Pendekatan ini bertujuan untuk meningkatkan proses desain dan konstruksi yang terkait dengan MDD, yang bermanfaat bagi sektor infrastruktur dan lingkungan binaan. Kerangka kerja yang diusulkan dievaluasi dengan menggunakan kumpulan data MDD yang telah dipublikasikan, dan analisis komparatif dilakukan untuk menilai efektivitas dan kinerjanya. Selain itu, beberapa penilaian kriteria digunakan untuk menilai kinerja model-model ML yang digunakan dalam penelitian ini.

2. METODOLOGI PENELITIAN

Sebuah metode untuk memperkirakan MDD tanah melibatkan penggunaan enam variabel, termasuk persentase semen dan kapur, serta indeks plastisitas (PI), Batas Cair (LL), dan batas plastis (PL). Model LSSVR digunakan untuk memprediksi MDD berdasarkan variabel-variabel prediktor tersebut. Proses pengumpulan data dilakukan dengan mengumpulkan sampel tanah dari berbagai lokasi dan melakukan pengujian laboratorium, seperti yang ditunjukkan pada Tabel 1, yang meliputi sumber sampel, jumlah sampel, dan rentang variable [9], [30], [31], [32]. Uji Atterberg Limits digunakan untuk menentukan LL, PL, dan PI, sementara teknik normal digunakan untuk menghitung persentase tanah, semen, dan kapur. Kadar air pada saat tanah berubah dari kondisi plastis menjadi cair ditunjukkan oleh LL, dan kadar air pada saat tanah berubah dari kondisi plastis menjadi semipadat ditunjukkan oleh PL. Perbedaan antara LL dan PL adalah PI, yang merupakan singkatan dari plastisitas tanah. Terakhir, tergantung pada informasi yang dikumpulkan mengenai karakteristik tanah dan jumlah semen, kapur, LL, PL, dan PI, beberapa rumus dan korelasi digunakan untuk memperkirakan MDD tanah. Selanjutnya, sebaran dan histogram distribusi antara input dan MDD ditunjukkan pada Gbr. 1

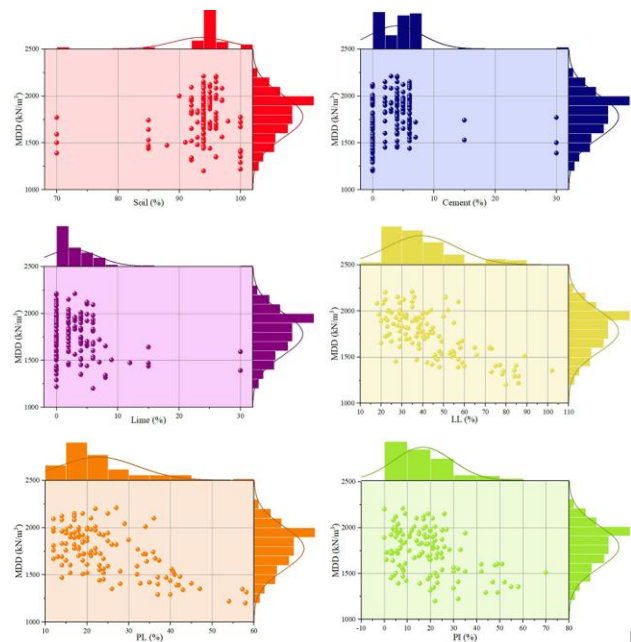
Indikator	Variabel						Target
	Masukan						
	Tanah (%)	Semen (%)	Kapur (%)	LL (%)	PL (%)	PI (%)	MDD (kN/m ³)
Maks	100	30	30	102	58.24	70	2210
Min	70	0	0	18	12	0	1200
Rata-rata	93.604	3.807	2.588	39.428	22.673	16.755	1780.61
St.Dev	4.6366	4.316	4.086	16.763	9.412	12.694	227.508



Gbr. 1 Plot pencar untuk perbandingan antara nilai prediksi dan nilai pengukuran

3. HASIL DAN PEMBAHASAN

Pada bagian ini, artikel ini menjelaskan kinerja berbagai model untuk memprediksi MDD. Kemampuan pelatihan, validasi, dan pengujian model-model ini ditunjukkan pada Tabel 2, dan artikel ini menerapkan model LSSVR, yang biasa digunakan dalam pemodelan laboratorium, untuk meramalkan MDD dengan hasil yang baik. Model LSSVR dioptimalkan dengan menggunakan algoritma inovatif seperti LHHO dan GNDO, yang telah terbukti efektif dalam penelitian sebelumnya. Model-model tersebut dievaluasi berdasarkan kinerjanya terhadap pengukuran eksperimental selama fase pelatihan (70%), validasi (15%), dan pengujian (15%). Penelitian ini menggunakan lima metrik statistik untuk mengevaluasi dan membandingkan algoritma yang digunakan dalam penelitian ini secara komprehensif.



Gbr. 1.1 Plot sebaran dan distribusi histogram untuk korelasi variabel input dan output

Kinerja dua model hibrida, LSLH dan LSGN, dan model LSSVR individu dalam memprediksi sifat MDD

dinilai. Model-model tersebut dievaluasi berdasarkan nilai R^2 mereka, yang mengindikasikan jumlah porsi variabilitas dalam variabel dependen yang dapat dikaitkan dengan pengaruh variabel independen. Setiap model terdiri dari tiga bagian: pelatihan, validasi, dan pengujian, dan keluarannya diwakili oleh berbagai parameter. Bagian pelatihan model LSLH memiliki nilai R^2 tertinggi, sedangkan bagian validasi model LSSVR memiliki nilai R^2 terendah. Parameter RMSE berkisar antara 15.7259 hingga 47.455, dengan bagian train LSLH memiliki error terendah dan bagian validasi LSSVR memiliki error tertinggi. Model LSLH memiliki nilai MSE terkecil, sedangkan model LSSVR memiliki nilai MSE tertinggi. Bagian kereta model LSLH memiliki nilai RSR yang paling sesuai sedangkan bagian validasi model LSSVR memiliki nilai RSR yang paling rendah. Model hybrid LSLH memiliki performa yang paling optimal dengan nilai 0.7844 pada bagian train untuk MAPE dan parameter lainnya, sedangkan model LSSVR memiliki performa yang paling buruk dengan nilai 2.3684 pada bagian validasi.

Nilai proyeksi dari dua model hibrida LSGN dan LSLH serta nilai aktual dari satu model LSSVR dikontraskan dalam plot sebaran yang ditunjukkan pada Gbr. 3. Tahap pelatihan, validasi, dan pengujian diwakili oleh tiga kecocokan linier pada plot, yang juga berisi garis tengah. Hasilnya menunjukkan bahwa ketiga model memiliki hubungan positif yang kuat korelasi antara nilai yang diharapkan dan nilai aktual, yang menunjukkan akurasi prediksi yang tinggi. Karena, LSLH memiliki tingkat pengelompokan titik data maksimum di sekitar garis kecocokan linier, yang menunjukkan peningkatan akurasinya, scatter plot menunjukkan bahwa LSLH memiliki kinerja yang lebih baik daripada dua model lainnya. Sebaliknya, LSGN dan LSSVR menunjukkan lebih banyak variasi pada titik-titik datanya. Garis kecocokan linier kedua model memiliki kemiringan dan intersep yang sama, yang menunjukkan kapasitas pra-diksi yang serupa.

Perbandingan sampel yang diprediksi dan diukur dari tiga model ditunjukkan pada Gbr. 4 dengan menggunakan plot simbol garis, yang menilai tingkat kesesuaian antara nilai yang diharapkan dan nilai yang diamati dan menekankan efektivitas model. Kedekatan atau kesesuaian antara nilai yang diprediksi dan nilai yang diukur di seluruh dataset menunjukkan bahwa LSLH memberikan akurasi yang baik dan sesuai dengan temuan. Meskipun terdapat korelasi yang signifikan antara hasil pengukuran dan prediksi untuk LSGN dan LSSVR, data empiris menunjukkan perbedaan yang cukup besar. Hal ini menunjukkan bahwa, meskipun LSGN dan LSSVR efisien, akurasinya tidak dapat menyamai LSLH. Hasil ini menyoroiti kemampuan model-model yang diusulkan, terutama LSLH, untuk memprediksi MDD.

Distribusi persentase kesalahan untuk model yang dibangun ditunjukkan pada Gambar 5, di mana sumbu vertikal menunjukkan frekuensi kejadian dan sumbu horizontal menunjukkan % kesalahan pengambilan. Temuan ini menunjukkan bahwa LSLH memiliki jumlah kesalahan yang paling sedikit, dengan sebagian besar persentase kesalahan berada di antara 0 dan 10%. Sebagai perbandingan, penyebaran persentase kesalahan lebih luas

untuk LSGN dan LSSVR, dan terdapat frekuensi yang lebih besar untuk hasil yang berada di atas ambang batas 10%. Selain itu, distribusi yang condong ke arah kanan terlihat pada LSGN dan LSSVR.

kesalahan untuk model-model yang digunakan dalam investigasi ini ditunjukkan pada Gambar . 6. Selama fase pelatihan, LSLH menunjukkan distribusi normal, sedikit penyebaran, dan tingkat kesalahan rata-rata 0%. Nilai-nilai dalam distribusi kesalahan berada di bawah batas 4%, yang menguntungkan. Di sisi lain, LSSVR menunjukkan dispersi pada kedua fase dan memiliki distribusi normal yang lebih seragam dan simetris. Tetapi model ini hanya memiliki persentase kesalahan sebesar 4%. Dengan satu datum outlier selama tahap evaluasi yang mencapai lebih dari 4% dari dataset, sebuah kejadian yang jarang terjadi dalam analisis statistik, LSGN menunjukkan perbedaan yang paling banyak dan paling bervariasi. Dibandingkan dengan dua model lainnya, distribusi Gaussian LSSVR menunjukkan lebih banyak penyebaran dan frekuensi kejadian yang lebih rendah di sekitar nol. Sementara, semua model berkinerja baik secara keseluruhan, LSLH menghasilkan hasil yang lebih baik

4. KESIMPULAN

Dalam penelitian ini, sebuah pendekatan baru disajikan untuk mengestimasi kepadatan kering maksimum (MDD) dengan menggunakan model regresi vektor dukungan kuadrat terkecil (LSSVR), yang telah diperbaiki dengan optimasi Leader Harris Hawks, LHHO) dan algoritma meta-heuristik optimasi distribusi normal tergeneralisasi (GNDO). Kinerja model hibrida yang diusulkan, LSLH dan LSGN, serta model LSSVR individual dilatih, divalidasi, dan diuji menggunakan sampel laboratorium yang dikutip dalam artikel yang diterbitkan. Menurut penelitian tersebut, model yang diusulkan dapat menghasilkan prediksi MDD yang akurat, yang sangat penting untuk memastikan keamanan dan daya tahan struktur dalam proyek konstruksi dan rekayasa. Kinerja model dinilai melalui evaluasi, termasuk R^2 , RMSE, MSE, RSR, dan MAPE. Sebagai hasil dari penelitian ini, model hibrida LSLH mengungguli model hibrida LSGN dan model LSSVR individual dengan mencapai nilai R^2 tertinggi pada fase pelatihan dan pengujian.

Selain itu, pengoptimal LHHO diamati telah menghasilkan kombinasi yang sesuai dengan LSSVR, menghasilkan akurasi yang tinggi. Studi ini menyoroiti potensi teknik ML dalam memprediksi sifat-sifat tanah, khususnya MDD. Model yang diusulkan secara umum dapat digunakan pada berbagai jenis tanah, upaya pemadatan, dan kadar air untuk prediksi yang akurat. Namun, penelitian lebih lanjut diperlukan untuk mengevaluasi kinerja model di bawah kondisi yang berbeda dan kepraktisannya dalam skenario dunia nyata.

5. DAFTAR PUSTAKA

- [1] V. Nasir, S. Ayanleye, S. Kazemirad, F. Sassani, and S. Adamopoulos, "Acoustic emission monitoring of wood materials and timber structures: A critical review," *Constr Build Mater*,

vol. 350, 2022, doi: 10.1016/j.conbuildmat.2022.128877.

[2] J. Luo, M. Huang, and Y. Lei, “Temperature Effect on Vibration Properties and Vibration-Based Damage Identification of Bridge Structures: A Literature Review,” *Buildings*, vol. 12, no. 8, 2022, doi: 10.3390/buildings12081209.

[3] U. M. N. Jayawickrema, H. M. C. M. Herath, N. K. Hettiarachchi, H. P. Sooriyaarachchi, and J. A. Epaarachchi, “Fibre-optic sensor and deep learning-based structural health monitoring systems for civil structures: A review,” *Measurement (Lond)*, vol. 199, 2022, doi: 10.1016/j.measurement.2022.111543.

[4] H. Zhang *et al.*, “A Stochastic Bi-Level Optimal Allocation Approach of Intelligent Buildings Considering Energy Storage Sharing Services,” *IEEE Transactions on Consumer Electronics*, vol. 70, no. 3, pp. 5142–5153, 2024, doi: 10.1109/TCE.2024.3412803.

[5] C. Zhou *et al.*, “Two-stage robust optimization for space heating loads of buildings in integrated community energy systems,” *Appl Energy*, vol. 331, 2023, doi: 10.1016/j.apenergy.2022.120451.

[6] J. G. Zornberg, S. Subramanian, G. H. Roodi, Y. Yalcin, and V. V. Kumar, “Sustainability Benefits of Adopting Geosynthetics in Roadway Design,” *International Journal of Geosynthetics and Ground Engineering*, vol. 10, no. 3, 2024, doi: 10.1007/s40891-024-00551-5.

[7] M. A. Benbouras and L. Lefilef, “Progressive Machine Learning Approaches for Predicting the Soil Compaction Parameters,” *Transportation Infrastructure Geotechnology*, vol. 10, no. 2, pp. 211–238, 2023, doi: 10.1007/s40515-021-00212-4.

[8] Y. Wang, R. I. Borja, and W. Wu, “Dynamic strain localization into a compaction band via a phase-field approach,” *J Mech Phys Solids*, vol. 173, 2023, doi: 10.1016/j.jmps.2023.105228.

[9] F. P. Eka Putra, . S., A. Ramadhani, and . M., “Integrasi Teknologi Kuantum dan fiber Optik untuk Meningkatkan Keamanan dan Efisiensi Jaringan Masa Depan,” *Jurnal Ilmiah ILKOMINFO - Ilmu Komputer & Informatika*, vol. 8, no. 2, pp. 151–163, 2025, doi: 10.47324/ilkominfo.v8i2.342.

[10] Z. Zhou, J. Zhang, C. Gong, and W. Wu, “Automatic tunnel lining crack detection via deep learning with generative adversarial network-based data augmentation,” *Underground Space (China)*, vol. 9, pp. 140–154, 2023, doi: 10.1016/j.undsp.2022.07.003.

[11] M. A. Yousif, H. H. Zghair, and F. Alsaedi, “Optimal design of mechanical performances of asphalt mixtures comprising nano-clay additives,” *Open Engineering*, vol. 14, no. 1, 2024, doi: 10.1515/eng-2022-0586.

[12] E. N. Jasim and H. H. Joni, “Assessment of potential resistance to moisture damage and fatigue cracks of asphalt mixture modified with ground granulated blast furnace slag,” *Open Engineering*, vol. 14, no. 1, 2024, doi: 10.1515/eng-2022-0551.

[13] L. Djakfar, R. Kusumaningrum, T. A. Kusuma, and A. H. Rahman, “The Effect of Sugar Palm Fiber Content on the Marshall Performance of Hot Mix Buton-Asphalt Mixture,” *Civil Engineering and Architecture*, vol. 11, no. 5, pp. 3242–3248, 2023, doi: 10.13189/cea.2023.110833.

[14] F. P. E. Putra, U. Ubaidi, R. N. Saputra, F. M. Haris, and S. N. R. Barokah, “Application of Internet of Things Technology in Monitoring Water Quality in Fishponds,” *Brilliance: Research of Artificial Intelligence*, vol. 4, no. 1, pp. 356–361, 2024, doi: 10.47709/brilliance.v4i1.4231.

[15] F. P. E. Putra, K. Mufidah, R. M. Ilhamsyah, S. A. Efendy, and S. N. R. Barokah, “Tinjauan Performa RouterOS Mikrotik dalam Jaringan Internet: Analisis Kinerja dan Kelayakan,” *Digital Transformation Technology*, vol. 3, no. 2, pp. 903–910, 2024, doi: 10.47709/digitech.v3i2.3446.

[16] F. Prasetyo, E. Putra, M. Riski, M. S. Yahya, and M. H. Ramadhan, “Mengenal Teknologi Jaringan Nirkabel Terbaru Teknologi 5G,” *Jurnal Sistim Informasi dan Teknologi*, vol. 5, no. 2, pp. 167–174, 2023, [Online]. Available: <https://jsisfotek.org/index.php>

[17] G. Fan, M. Nasiri, and E. Amiri, “Stabilized Slope Using Stone Columns Reinforced with Geotextile Encasement and Laminated Coatings: A Case Study,” *Nat Hazards Rev*, vol. 26, no. 2, 2025, doi: 10.1061/NHREFO.NHENG-2143.

[18] P. G. dos S. Pereira, R. Q. Coutinho, D. P. de Souza Neto, and I. F. Gomes, “Stability Analysis of an Urban Slope Under Human Activities and Critical Rainfall: Case Study of Recife, Brazil,” *Geotechnical and Geological Engineering*, vol. 43, no. 2, 2025, doi: 10.1007/s10706-024-03011-z.

[19] K. Chen, M. E. Torbaghan, N. Thom, and A. Faramarzi, “Physics-guided neural network for predicting international roughness index on flexible pavements considering accuracy, uncertainty and stability,” *Eng Appl Artif Intell*, vol. 142, 2025, doi: 10.1016/j.engappai.2024.109922.

[20] M. Z. Arifin, I. F. Senin, H. Bowoputro, D. M. H. Kore, I. S. Ingsih, and F. F. B. Putri, “the Effect of Polyethylene Terephthalate (Pet) Plastic Addition To Ac-Wc in a Wet Mixture on Increase of Asphalt Stability,” *EUREKA, Physics and Engineering*, vol. 2024, no. 2, pp. 21–33, 2024, doi: 10.21303/2461-4262.2024.003328.

[21] Z. Wang *et al.*, “Geohazard Sensitivity Evaluation in Xinning, Hunan, China, Using Random Forest, Artificial Neural Network, and Logistic Regression Algorithms,” *Nat Hazards Rev*, vol. 26, no. 2, 2025, doi: 10.1061/NHREFO.NHENG-2138.

[22] Z. Yuan *et al.*, “Predicting mechanical behaviors of rubber materials with artificial neural networks,” *Int J Mech Sci*, vol. 249, 2023, doi: 10.1016/j.ijmecsci.2023.108265.

- [23] A. Kaveh, *Applications of Artificial Neural Networks and Machine Learning in Civil Engineering*, vol. 1168. 2024. doi: 10.1007/978-3-031-66051-1.
- [24] F. G. Vieira *et al.*, “A machine-learning based objective measure for ALS disease severity,” *NPJ Digit Med*, vol. 5, no. 1, 2022, doi: 10.1038/s41746-022-00588-8.
- [25] J. Fang, J. Hu, H. Elzarka, H. Zhao, and C. Gao, “An Improved Inspection Process and Machine-Learning-Assisted Bridge Condition Prediction Model,” *Buildings*, vol. 13, no. 10, 2023, doi: 10.3390/buildings13102459.
- [26] G. Grundl, R. Müller, and W. Kunz, “Salt effects on liquid-liquid equilibria in the ternary water/n-butanol/HMF system and solvent effects on HMF separation from water,” *J Mol Liq*, vol. 325, 2021, doi: 10.1016/j.molliq.2020.114551.
- [27] S. Chen *et al.*, “Impact of Tetrabutylammonium on the Oxidation of Bromide by Ozone,” *ACS Earth Space Chem*, vol. 5, no. 11, pp. 3008–3021, 2021, doi: 10.1021/acsearthspacechem.1c00233.
- [28] M. Zhang, Y. Feng, K. Zhang, Y. Wang, and X. Pan, “Impact of salinity on colloidal ozone aphrons in removing phenanthrene from sediments,” *J Hazard Mater*, vol. 384, 2020, doi: 10.1016/j.jhazmat.2019.121436.
- [29] A. Khouja, N. Lehoux, and Y. Cimon, “A fuzzy-based competitiveness assessment tool for construction SMEs,” *Benchmarking*, vol. 30, no. 3, pp. 868–898, 2023, doi: 10.1108/BIJ-08-2021-0483.
- [30] T. A. Cameron and S. H. Kolstoe, “Using Auxiliary Population Samples for Sample-Selection Correction in Models Based on Crowd-Sourced Volunteered Geographic Information,” *Land Econ*, vol. 98, no. 1, pp. 1–21, 2022, doi: 10.3368/le.98.1.040720-0050R1.
- [31] W. Jiang, J. Huang, G. Xu, and C. Wu, “Sample-Oriented Electricity Storage Sharing Mechanism Design with Performance Guarantees,” *IEEE Trans Smart Grid*, vol. 15, no. 2, pp. 2030–2043, 2024, doi: 10.1109/TSG.2023.3308686.
- [32] T. Wu, S. Gorbachev, H. K. Lam, J. H. Park, L. Xiong, and J. Cao, “Adaptive Event-Triggered Space-Time Sampled-Data Synchronization for Fuzzy Coupled RDNNs Under Hybrid Random Cyberattacks,” *IEEE Transactions on Fuzzy Systems*, vol. 31, no. 6, pp. 1855–1869, 2023, doi: 10.1109/TFUZZ.2022.3215747.