

Tinjauan Pustaka: Pemodelan Spasial Suhu Udara Berbasis *Machine Learning* dengan Integrasi *LST*, *Albedo*, dan Data Observasi Stasiun Cuaca

David Sampelan^{a,b,*}

^aStasiun Klimatologi Nusa Tenggara Barat, BMKG, Lombok Barat, Nusa Tenggara Barat, Indonesia, 83362

^bDepartemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 60111

*Korespondensi Penulis: david.sampelan@bmgk.go.id



Dikirim: 27 Agustus 2025;
Diterima: 2 September 2025;
Diterbitkan: 2 September 2025.

Abstrak. Suhu udara (T_a) merupakan indikator iklim penting yang berperan dalam kajian lingkungan, kesehatan, dan perencanaan wilayah. Keterbatasan stasiun cuaca menjadikan variasi spasial T_a sulit dipetakan secara detail, terutama di wilayah dengan topografi kompleks. Kajian ini menyajikan *systematic literature review* mengenai pemodelan spasial T_a berbasis *machine learning* (ML) dengan integrasi data suhu permukaan darat (*Land Surface Temperature/LST*), *Albedo*, dan observasi stasiun cuaca. Pencarian pustaka dilakukan menggunakan perangkat *Publish or Perish* yang terhubung ke Google Scholar untuk periode 2016–2025. Dari 1.000 publikasi yang diperoleh, hanya 8 artikel yang memenuhi kriteria inklusi dan relevan dianalisis lebih lanjut. Hasil telaah menunjukkan bahwa *LST* merupakan variabel utama yang digunakan dalam seluruh studi, dengan dukungan variabel tambahan seperti *Albedo*, *NDVI*, *DEM*, radiasi matahari, dan faktor meteorologi. Metode ML

yang paling dominan adalah *Random Forest* (RF), disusul *Gradient Boosting*, *Support Vector Regression* (SVR), *Cubist Regression*, serta *Multiple Linear Regression* (MLR) sebagai pembanding. RF dan *Gradient Boosting* banyak diterapkan karena akurasinya tinggi dalam menangani data heterogen, sementara SVR efektif untuk regresi nonlinier, dan *Cubist Regression* terbukti stabil di wilayah bertopografi ekstrem. Secara umum, integrasi data satelit dengan pengamatan darat menghasilkan model dengan performa tinggi ($R^2 > 0,9$ dan RMSE sekitar 1–2 °C). Kajian ini menegaskan bahwa pendekatan ML berbasis penginderaan jauh memiliki potensi besar untuk meningkatkan pemahaman dan pemodelan T_a , sekaligus membuka peluang penelitian lanjutan di wilayah dengan dinamika lingkungan yang beragam.

Kata kunci: *Albedo*, *LST*, *Machine Learning*, Penginderaan Jauh, Suhu Udara.

Machine Learning-Based Air Temperature Spatial Modeling with Integration of *LST*, *Albedo*, and Weather Station Observation Data: Literature Review

Abstract. Air temperature (T_a) is a crucial climate indicator that informs environmental, health, and regional planning studies. However, the limitations of weather stations hinder the detailed mapping of spatial variations, particularly in regions with complex topography. This systematic literature review examines machine learning (ML)-based spatial modeling that integrates Land Surface Temperature (LST), Albedo, and weather station observations. A comprehensive search of Google Scholar using Publish or Perish yielded 1,000 publications from 2016 to 2025, of which eight articles met the inclusion criteria. The review reveals that Land Surface Temperature (LST) is a primary variable, supplemented by Albedo, Normalized Difference Vegetation Index (NDVI), Digital Elevation Model (DEM), solar radiation, and meteorological factors. Random Forest (RF) is the most dominant ML method, followed by Gradient Boosting, Support Vector Regression (SVR), Cubist Regression, and Multiple Linear Regression (MLR). RF and Gradient Boosting excel in handling heterogeneous data, while SVR effectively

addresses nonlinear regression and Cubist Regression performs stably in extreme topographic regions. The integration of satellite data with ground-based observations yields high-performance models ($R^2 > 0.9$ and RMSE $\approx 1\text{--}2\text{ }^\circ\text{C}$). This review confirms the potential of remote sensing-based ML approaches to enhance the understanding and modeling of T_a , highlighting opportunities for further research in regions with diverse environmental dynamics.

Keywords: Air Temperature, Albedo, LST, Machine Learning, Remote Sensing.

I. PENDAHULUAN

Suhu udara (T_a) merupakan salah satu parameter penting dalam kajian klimatologi, lingkungan, dan perencanaan pembangunan wilayah [1], [2]. Nilai suhu udara bervariasi secara spasial maupun temporal, serta berubah sepanjang hari akibat pengaruh radiasi, kelembaban, angin, dan kondisi penutup lahan. Oleh karena itu, suhu udara tidak selalu identik dengan suhu permukaan darat (*Land Surface Temperature/LST*) yang diperoleh dari citra satelit, meskipun keduanya memiliki hubungan yang erat. Informasi mengenai suhu udara tidak hanya bermanfaat untuk memahami kondisi iklim lokal, tetapi juga berhubungan erat dengan isu-isu lingkungan seperti perubahan iklim [3], fenomena pulau panas perkotaan (*urban heat island*) [4], [5], serta kesehatan ekosistem [6]. Di wilayah tropis seperti Pulau Lombok, dinamika Suhu udara dipengaruhi oleh faktor iklim regional, kondisi topografi yang beragam, serta perubahan tutupan lahan akibat aktivitas manusia. Oleh karena itu, pemodelan suhu udara menjadi kebutuhan yang semakin mendesak dalam rangka mendukung perencanaan pembangunan berkelanjutan dan mitigasi dampak lingkungan, di wilayah tersebut [7].

Seiring dengan berkembangnya teknologi penginderaan jauh, pemanfaatan Suhu Permukaan Darat (*LST*) [8], [9] dan *Albedo* [10] sebagai variabel penjelas telah banyak digunakan dalam penelitian untuk menduga variasi Suhu udara [11]. Data *LST* dapat menggambarkan distribusi panas pada permukaan bumi [8], [9], sementara *Albedo* berperan dalam menjelaskan seberapa besar energi matahari yang dipantulkan oleh permukaan tertentu [10]. Kedua parameter ini, bila digabungkan dengan data observasi suhu udara dari stasiun cuaca seperti yang dimiliki BMKG, memberikan peluang besar untuk menghasilkan model prediksi yang lebih akurat [12].

Dalam satu dekade terakhir, metode pemodelan berbasis *machine learning* menunjukkan hasil yang lebih menjanjikan dibandingkan pendekatan statistik konvensional [12]. Algoritma seperti *Random Forest* [13], [14], *Support Vector Machine* [15], dan *Artificial Neural Network* [16] mampu menangkap hubungan non-linear antarvariabel serta mengurangi bias dalam estimasi [12], [17]. Meskipun demikian, sebagian besar penelitian serupa masih didominasi oleh studi di kawasan subtropis dan perkotaan besar, sementara wilayah kepulauan tropis seperti Pulau Lombok relatif jarang menjadi fokus [18], [19].

Dengan kondisi geografis yang unik yang terdiri atas pesisir, dataran rendah, hingga pegunungan seperti Rinjani, Pulau Lombok menghadirkan tantangan sekaligus peluang untuk mengembangkan model spasial Suhu udara [18]. Kajian pustaka ini bertujuan untuk merangkum hasil-hasil penelitian sebelumnya terkait pemodelan Suhu udara berbasis *Machine Learning* dengan integrasi *LST*, *Albedo*, serta data observasi stasiun cuaca. Selain itu, tinjauan ini berupaya mengidentifikasi kesenjangan penelitian (research gap) yang masih ada, sehingga dapat menjadi landasan kuat bagi penelitian lebih lanjut di Pulau Lombok.

II. METODOLOGI

Proses penyusunan tinjauan pustaka ini mengikuti pendekatan *systematic literature review* (SLR) agar hasil yang diperoleh lebih terarah, transparan, dan dapat dipertanggungjawabkan. Beberapa tahapan utama yang dilakukan meliputi perumusan strategi pencarian, penentuan kriteria seleksi, proses penyaringan, serta analisis pustaka yang relevan.

2.1 Pertanyaan Penelitian

Pemodelan Suhu udara masih menghadapi tantangan karena adanya perbedaan spasial dan temporal antara *Land Surface Temperature (LST)* dan suhu udara (T_a), serta variasi kinerja metode *machine learning* yang digunakan. Meskipun *Random Forest*, *Gradient Boosting*, *Cubist Regression*, maupun *Deep Learning* telah banyak diaplikasikan, belum ada kesepakatan mengenai algoritma yang paling sesuai untuk wilayah tropis dengan heterogenitas lahan yang tinggi. Di Pulau Lombok, kontras lanskap seperti savana di Sembalun, hutan di Senaru, serta perkembangan urban di Kota Mataram semakin menegaskan perlunya pemodelan suhu berbasis ML yang memanfaatkan *LST* sebagai variabel utama, dengan dukungan variabel lain seperti *Albedo*, vegetasi, topografi, dan data meteorologi. Oleh karena itu, pertanyaan mendasar penelitian ini adalah “Bagaimana *machine learning* dapat dimanfaatkan untuk memodelkan suhu udara secara akurat pada konteks tropis – maritim dengan kondisi lingkungan yang kompleks seperti Pulau Lombok”.

2.2 Strategi Pencarian Pustaka

Pencarian pustaka dilakukan dengan bantuan perangkat lunak *Publish or Perish* (PoP) yang terhubung ke basis data Google Scholar. Perangkat ini dipilih karena mampu mengumpulkan publikasi secara lebih sistematis sekaligus menampilkan data sitasi untuk menilai relevansi artikel.

Beberapa kombinasi kata kunci yang digunakan dalam pencarian antara lain : *Machine Learning*, *Land Surface Temperature*, *Albedo*, dan *Air Temperature*.

Pencarian dibatasi pada periode 2016–2025 (sepuluh tahun terakhir) agar pustaka yang dikaji benar-benar mutakhir serta merepresentasikan perkembangan terkini dalam pemodelan suhu udara.

2.3 Kriteria Inklusi dan Eksklusi

Agar hasil pencarian lebih fokus, ditetapkan sejumlah kriteria :

1. Kriteria Inklusi :

- Artikel dipublikasikan pada periode 2016–2025.
- Ditulis dalam bahasa Inggris atau bahasa Indonesia.
- Fokus pada pemodelan Suhu udara (T_a) dengan integrasi Suhu Permukaan Darat (*LST*), *Albedo*, dan/atau data stasiun cuaca.
- Menggunakan pendekatan *Machine Learning* (*ML*)
- Artikel dipublikasikan pada jurnal ilmiah yang telah melalui proses *peer-review*.
- Menyediakan informasi metodologi yang jelas (jenis data, algoritma, prosedur validasi, dan metrik akurasi).

2. Kriteria Eksklusi

- Artikel berupa prosiding, laporan teknis, tesis/disertasi, atau preprint yang belum *peer-reviewed*.
- Publikasi tidak tersedia secara lengkap (hanya abstrak).
- Penelitian yang hanya membahas satu variabel tanpa integrasi (misalnya hanya *LST*).
- Artikel dengan metode tidak transparan (tidak melaporkan validasi atau metrik akurasi).

Proses penyusunan tinjauan pustaka dalam penelitian ini merujuk pada kerangka kerja *PRISMA* (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). Pendekatan ini dipilih untuk memastikan proses seleksi artikel dilakukan secara sistematis, transparan, serta dapat dipertanggungjawabkan. Alur seleksi ditunjukkan dalam Gambar 1, yang menunjukkan perjalanan dari identifikasi awal artikel hingga artikel yang akhirnya disertakan dalam analisis.

Tahap pertama adalah identifikasi, di mana lebih dari 1.000 artikel berhasil dikumpulkan dari basis data Google Scholar menggunakan bantuan perangkat lunak *Publish or Perish* (*Pop*) dengan rentang tahun publikasi 2016–2025. Pada tahap ini dilakukan penyaringan awal untuk menghapus duplikasi serta publikasi yang tidak relevan dengan topik, sehingga jumlah artikel yang dipertimbangkan lebih lanjut berkurang menjadi 195.


Tahap berikutnya adalah penyaringan (*screening*), yang dilakukan dengan menelaah judul dan abstrak. Artikel yang tidak sesuai dengan fokus penelitian, misalnya di luar konteks pemodelan suhu udara atau tidak melibatkan *machine learning*—dikeluarkan dari daftar. Selanjutnya, pada tahap kelayakan (*eligibility*), dilakukan penilaian terhadap teks lengkap (*full-text*) untuk memastikan kesesuaian dengan kriteria inklusi. Artikel yang tidak memenuhi persyaratan, seperti bukan jurnal *peer-reviewed*, hanya tersedia dalam bentuk abstrak, atau tidak menjelaskan metodologi secara transparan, dieliminasi pada tahap ini. Tahap terakhir adalah inklusi (*included*). Setelah melalui serangkaian proses seleksi, hanya tersisa 8 artikel yang dinilai paling relevan dan sesuai dengan tujuan penelitian. Artikel – artikel ini secara konsisten membahas pemodelan Suhu udara dengan mengintegrasikan *Land Surface Temperature* (*LST*), *Albedo*, maupun data stasiun cuaca melalui pendekatan *machine learning*.

2.4 Proses Penyaringan Pustaka

Tahapan penyaringan dilakukan secara berlapis. Pertama, artikel yang muncul dari hasil pencarian dibaca judul dan abstraknya untuk menilai relevansi. Kedua, artikel yang lolos tahap awal ditelaah lebih lanjut dengan membaca metode dan hasil penelitian sehingga menghasilkan 8 artikel yang benar – benar relevan dengan topik penelitian. Pada tahap ini dilakukan pengecekan apakah penelitian benar-benar memenuhi kriteria inklusi seperti yang dijelaskan pada Gambar 1

2.5 Analisis dan Sintesis

Artikel yang telah terpilih kemudian diekstraksi informasinya ke dalam matrik pustaka yang mencakup : nama penulis, tahun publikasi, lokasi studi, data yang digunakan, metode pemodelan, hasil utama, serta relevansinya dengan konteks Pulau Lombok. Dari tabel ini, dilakukan analisis tematik untuk mengelompokkan penelitian berdasarkan variabel, metode, dan hasil.



Gambar 1 Diagram PRISMA Metodologi Pencarian dan Penyaringan Artikel

Sintesis dilakukan dengan merangkum dan juga menghubungkan antar-penelitian guna menemukan pola umum, perbedaan hasil, serta keterbatasan yang masih ada. Dari proses inilah nantinya dapat diidentifikasi *research gap* yang menjadi dasar penting bagi penelitian lanjutan di Pulau Lombok.

III. HASIL DAN PEMBAHASAN

3.1 Hasil Pencarian Pustaka

Pencarian pustaka dilakukan melalui Google Scholar dengan bantuan *Publish or Perish* menggunakan kata

kunci “*Machine Learning*”, “*Land Surface Temperature*”, “*Albedo*”, dan “*Air Temperature*”. Rentang waktu dibatasi 2016–2025 untuk memastikan relevansi dengan perkembangan terbaru. Dari hasil pencarian awal yang menghasilkan 1.000 publikasi, dilakukan penyaringan berdasarkan judul, abstrak, dan isi penuh sesuai kriteria inklusi – eksklusi. Setelah proses ini, sebanyak 8 artikel dinyatakan relevan dan dimasukkan ke dalam analisis.

Tabel 1. Matriks Pustaka Artikel Terpilih (2016–2025)

Penulis & Tahun	Tujuan Penelitian	Metode ML	Variabel Input Utama	Temuan Utama
Dos Santos (2020) [20]	Memproduksi model parsimoni untuk mendapatkan Tmax dengan resolusi spasial dan temporal tinggi.	<i>Gradient Boosting</i>	<i>LST</i> , <i>Julian day</i> , <i>NDVI</i> , <i>DEM</i> , <i>solar zenith angle</i> , <i>data 29 stasiun cuaca</i>	Model <i>Gradient Boosting</i> dengan lima prediktor dengan performa terbaik. Pendekatan ini dapat direplikasi di kota lain untuk penilaian mortalitas terkait panas.
Zeng Dkk (2021) [21]	Mengestimasi suhu udara harian dan 8-harian maksimum dan minimum pada skala global.	<i>Random Forest</i>	<i>LST</i> , data pembantu lainnya dari <i>MODIS</i>	Akurasi model dipengaruhi oleh ukuran data dan distribusi stasiun. Performa lebih rendah di daerah dengan stasiun yang jarang seperti Afrika dan Amerika Selatan.
Wang Dkk (2022) [12]	Mengestimasi Suhu udara harian dan instan di wilayah Jingjinji, Tiongkok.	<i>Random Forest</i>	<i>LST</i> , Radiasi, <i>DEM</i> , <i>NDVI</i> , data stasiun cuaca. <i>LST</i> adalah variabel terpenting (40-60%).	<i>RF</i> adalah algoritma optimal yang mengungguli metode lain. <i>LST</i> adalah faktor paling signifikan untuk estimasi suhu udara.
Xu Dkk (2018) [22]	Memetakan suhu udara bulanan di Dataran Tinggi Tibet.	<i>Cubist</i> (terbaik dari 10 algoritma yang dibandingkan)	<i>LST</i> , ketinggian, radiasi matahari.	Algoritma <i>Cubist</i> berkinerja lebih baik daripada yang lain dan memiliki sensitivitas rendah terhadap kontaminasi awan. <i>Nighttime LST</i> adalah prediktor terpenting.
Liu Dkk (2021) [23]	Mengestimasi Suhu udara dan dekat permukaan di Tiongkok Barat Laut yang kering.	<i>Multiple Linear Regression</i> (MLR) dan <i>Random Forest</i> (RF)	<i>LST</i> , <i>NDVI</i> , <i>Albedo</i> permukaan, <i>DEM</i> , kecepatan angin, <i>Julian day</i> .	Kedua model (MLR dan RF) cocok untuk estimasi Ta di area dengan stasiun yang terbatas. <i>LST</i> adalah parameter paling penting untuk estimasi Ta.
Shen Dkk (2020) [24]	Pemetaan suhu udara maksimum harian di Tiongkok.	<i>Deep Belief Network</i> (DBN)	Data multi-sumber yang digabungkan: penginderaan jauh, stasiun cuaca, data asimilasi, data sosio-ekonomi.	DBN berhasil menggabungkan data multi-sumber untuk pemetaan Ta, menjadikannya model <i>deep learning</i> pertama untuk pemetaan Ta berdasarkan penginderaan jauh dan stasiun darat.
Li Dkk (2021) [25]	Menghasilkan data suhu udara 1 km yang mulus secara spasial dan kontinu secara temporal.	<i>Deep Learning</i> (termasuk DBN dan LSTM)	<i>LST</i> (dari TRIMS), <i>Albedo</i> , kecepatan angin, kelembaban tanah (dari ERA-5).	Model <i>deep learning</i> dapat menghasilkan data suhu udara yang mulus dan kontinu secara spasial dan temporal dengan akurasi tinggi. DBN memiliki peforma <i>downscaling</i> terkuat.
Chen Dkk (2022) [26]	Pemetaan suhu udara jam-an pada resolusi 1-km selama musim hangat di Guangdong, Tiongkok.	<i>Random Forest</i>	Faktor meteorologi (terutama kelembaban relatif) dan faktor lanskap.	Model ini menunjukkan akurasi tinggi pada malam hari, yang penting untuk meneliti efek pulau panas perkotaan (<i>urban heat island</i>).

3.2 Karakteristik Pustaka Terpilih

Karakteristik 8 artikel terpilih menunjukkan beberapa pola penting, diantaranya: (1) Penerbitan artikel meningkat sejak tahun 2020, menunjukkan tren naiknya minat penelitian pada topik pemodelan suhu udara berbasis *machine learning*. (2) Studi dilakukan pada skala urban (misalnya Berlin, London), regional (Jingjinji, Taiwan), hingga *global*, serta wilayah bertopografi ekstrem (Tibet Plateau, Andes, Antartika). (3) Seluruh studi menggunakan LST sebagai variabel utama, sebagian besar mengintegrasikan Albedo dan lebih dari setengah memanfaatkan data stasiun cuaca untuk validasi dan pelatihan. (4) Metode ensemble learning (Random Forest, Gradient Boosting, Cubist) mendominasi. Sementara itu, pendekatan Deep Learning (DBN, CNN, LSTM) mulai banyak dipakai sejak 2020 untuk menghasilkan peta suhu resolusi tinggi. Tabel 1 menyajikan matriks pustaka artikel terpilih yang telah diekstraksi.

3.3 Analisis Tematik

3.3.1 Tujuan Penelitian

Sebagian besar studi dalam Tabel 1 berfokus pada peningkatan akurasi estimasi Suhu udara (T_a) dengan memanfaatkan kombinasi data satelit, pengukuran stasiun, serta variabel tambahan seperti topografi dan vegetasi.

- Dos Santos pada 2020 [20] menargetkan pengembangan model parsimonious untuk prediksi suhu maksimum harian (T_{max}) di kota dengan resolusi tinggi, yang dapat digunakan untuk analisis risiko kesehatan.
- Zeng Dkk pada 2021 [21] serta Wang Dkk pada 2022 [12] berupaya mengestimasi suhu udara harian maupun instan dengan cakupan spasial luas, mulai dari level regional (Jingjinji, Tiongkok) hingga global.
- Xu Dkk pada 2018 [22] menekankan pada wilayah dengan kondisi ekstrem, yaitu Dataran Tinggi Tibet, di mana distribusi stasiun sangat terbatas.
- Liu Dkk pada 2021 [23] meneliti daerah kering di Tiongkok Barat Laut, dengan tujuan menilai kontribusi variabel tambahan selain LST.
- Studi lain seperti Shen Dkk pada 2020 [24], Li Dkk pada 2021 [25], dan Chen Dkk pada 2022 [26] mengarahkan penelitian pada pemetaan suhu resolusi tinggi berbasis data multi-sumber, yang relevan untuk memahami fenomena perkotaan seperti urban heat island.

3.3.2 Metode

Tabel 1 menunjukkan adanya variasi metode dengan perbedaan kompleksitas :

- *Random Forest (RF)* mendominasi, digunakan pada studi Wang dkk pada 2022 [12], Liu Dkk pada 2021

[23], dan Chen Dkk pada 2026 [26]. Algoritma ini populer karena fleksibel, tahan terhadap noise, serta mampu menangani data heterogen.

- *Gradient Boosting (GBM)* digunakan Santos pada 2020 [20], terbukti efisien dalam prediksi suhu dengan jumlah variabel terbatas namun informatif.
- Cubist Regression Xu dkk pada 2018 [22] menonjol karena stabil di area dengan gangguan awan, serta lebih sensitif terhadap variabel topografi.
- *Deep Learning (DL)* digunakan oleh Shen dkk pada 2020 [24] dan Li dkk pada 2021 [25], dengan arsitektur seperti Deep Belief Network (DBN) dan LSTM. Metode ini lebih kompleks namun unggul dalam menangkap pola non-linear antarvariabel dan menghasilkan dataset kontinu spasial-temporal.

Tabel 2 merangkum perbandingan metode *machine learning* yang digunakan dalam pemodelan Suhu udara. *Random Forest (RF)* banyak dipilih karena akurasinya tinggi, tahan terhadap *overfitting* (kecenderungan model terlalu menyesuaikan diri dengan data latih sehingga kinerjanya menurun pada data baru), serta mampu mengidentifikasi variabel penting, meskipun interpretasinya relatif kompleks. *Support Vector Machines (SVM)* atau *SVR* efektif untuk regresi nonlinier dan *gap-filling*, namun sensitif terhadap pemilihan kernel dan kurang efisien untuk data besar. Metode *deep learning (DL)* seperti DBN atau LSTM unggul dalam menangani hubungan nonlinier yang kompleks dan sangat efektif pada data berukuran besar, tetapi membutuhkan komputasi tinggi dan sulit diinterpretasi. Sebaliknya, regresi linier berganda (*MLR*) meskipun sederhana dan mudah diimplementasikan, memiliki keterbatasan signifikan karena asumsi linearitas yang kaku serta performa yang rendah di wilayah dengan heterogenitas spasial tinggi.

3.3.3 Variabel Input Utama

Hampir semua penelitian menempatkan LST (*Land Surface Temperature* / Suhu Permukaan Darat) sebagai variabel inti. LST terbukti menjadi prediktor paling konsisten, bahkan kontribusinya pada model RF [12] mencapai 40% – 60%.

- Variabel tambahan yang banyak dipakai antara lain : *NDVI* (vegetasi), *DEM* (topografi), radiasi matahari, kecepatan angin, serta *Albedo*.
- Faktor sosial-ekonomi juga muncul [24], menandakan adanya integrasi data non-lingkungan dalam model suhu perkotaan.
- Kelembaban relatif [26] memberikan kontribusi signifikan, khususnya dalam menjelaskan variasi suhu malam hari yang berhubungan dengan fenomena *urban heat island*.

Tabel 2 Perbandingan Metode *Machine Learning*

Metode ML	Aplikasi Khas	Variabel Masukan Utama	Kelebihan	Kekurangan
<i>Random Forest (RF)</i>	Prediksi Ta, Downscaling LST, Klasifikasi Lahan	<i>LST</i> , radiasi, <i>Albedo</i> , <i>DEM</i> , <i>NDVI</i> , data meteorologi	Akurasi tinggi, tahan overfitting, mengidentifikasi variabel penting, tidak sensitif terhadap penambahan variabel	Membutuhkan banyak pohon untuk stabil, interpretasi kompleks
<i>Support Vector Machines (SVM)/SVR</i>	Gap-filling LST, Klasifikasi Lahan	<i>LST</i> , <i>NDVI</i> , <i>Albedo</i>	Efektif untuk regresi nonlinier, performa tinggi dalam gap-filling	Sensitif terhadap pemilihan kernel dan parameter, kompleksitas komputasi tinggi untuk data besar
<i>Deep Learning (DL)</i>	Rekonstruksi <i>LST</i> all-weather, prediksi Ta beresolusi tinggi, fusi data	<i>LST</i> , multispektral, data meteorologi, <i>DEM</i> , <i>Albedo</i>	Sangat efektif untuk hubungan nonlinier kompleks, performa luar biasa dengan data besar	Membutuhkan sumber daya komputasi besar, data pelatihan berlimpah, interpretasi sulit
Regresi Linier Berganda (<i>MLR</i>)	Prediksi (sebagai tolak ukur)	Suhu, titik embun, kecepatan angin, curah hujan, tekanan udara	Mudah diimplementasikan, cepat, mudah diinterpretasi	Asumsi linearitas kaku, performa buruk di lanskap heterogen (misalnya, pegunungan)

3.3.4 Temuan Utama

Beberapa temuan penting dari pustaka terpilih antara lain :

- *ML* sederhana (*RF*, *GBM*, *Cubist*) efektif digunakan di wilayah dengan keterbatasan data, dan tetap menghasilkan akurasi tinggi ($R^2 > 0,9$).
- *DL* (*DBN*, *LSTM*) menawarkan akurasi lebih tinggi pada wilayah kompleks, menghasilkan dataset suhu resolusi 1 km yang kontinu spasial-temporal [25].
- *LST* terbukti sebagai prediktor paling dominan, sedangkan variabel tambahan seperti *NDVI*, *DEM*, dan *Albedo* meningkatkan stabilitas model.
- Aplikasi spesifik, seperti prediksi suhu malam hari di Berlin [26] atau pemetaan suhu di dataran tinggi Tibet [22], memperlihatkan potensi *ML/DL* untuk berbagai konteks geografis dan iklim.


Dari delapan artikel yang ditelaah, seperti yang terlihat pada Gambar 2, *Random Forest (RF)* menjadi metode paling dominan (37,5%), dipilih karena kemampuannya menangani data non-linear dan menghasilkan akurasi tinggi, terutama saat *LST* menjadi variabel utama misalnya [12]. Metode *Deep Learning (DL)*, khususnya Deep Belief Network (*DBN*) dan *LSTM*, digunakan pada 25% studi. Metode lain seperti *Gradient Boosting*, *Cubist Regression*, dan *MLR* masing-masing digunakan pada 12,5%.

Pada Gambar 3 terlihat bahwa hasil telaah menunjukkan bahwa seluruh studi (100%) menggunakan *LST* sebagai variabel utama. Selain itu, *Albedo* digunakan pada sekitar 25% artikel, *NDVI* pada 25%, *DEM*/topografi pada 25%, serta radiasi matahari pada 25%. Variabel


tambahan lain seperti data meteorologi (kelembaban, angin, *Julian day*) muncul pada sebagian kecil studi dengan porsi di bawah 20%.

3.3.5 Relevansi terhadap Kajian di Pulau Lombok

Hasil kajian pustaka tidak hanya memberikan gambaran global, tetapi juga memiliki implikasi langsung bagi konteks lokal di Pulau Lombok. Sebagai pusat aktivitas urban, Kota Mataram berpotensi mengalami fenomena *urban heat island* akibat dominasi permukaan kedap air (aspal, beton, bangunan) serta pertumbuhan infrastruktur yang pesat. Fenomena UHI telah banyak diteliti di berbagai kota di Indonesia, menunjukkan peningkatan suhu akibat urbanisasi dan perubahan tutupan lahan [27], [28], [29], [30]. Integrasi variabel *LST* dan *Albedo* melalui algoritma *ML* dapat membantu memetakan hotspot UHI, sehingga pemerintah daerah memiliki dasar ilmiah dalam merancang ruang terbuka hijau atau sistem ventilasi kota [28], [31], [32].



Gambar 2 Distribusi metode yang digunakan pada artikel terpilih 2016 - 2025



Gambar 3 Distribusi variabel yang digunakan pada artikel terpilih 2016 – 2025

Selain itu, heterogenitas penutup lahan di Pulau Lombok yang khas juga relevan [33]. Di kawasan timur laut, misalnya, Sembalun didominasi oleh savana terbuka, sedangkan sisi utara, seperti Senaru, masih ditutupi hutan lebat di kaki Gunung Rinjani [34]. Kontras ini menciptakan perbedaan *Albedo*, kelembapan, dan *LST* yang signifikan, yang berimplikasi pada variasi Suhu udara. Penerapan pendekatan *ML* dengan memasukkan faktor topografi [35], [36] dan vegetasi [37] dapat mengungkap bagaimana perbedaan lanskap tersebut berkontribusi terhadap distribusi spasial suhu.

Dengan demikian, Pulau Lombok dapat dijadikan laboratorium alami untuk menguji performa model *ML/DL* dalam kondisi tropis-maritim dengan topografi yang kompleks [33]. Hal ini sejalan dengan temuan pustaka global bahwa model berbasis *LST* dan *Albedo* sangat menjanjikan, tetapi masih memerlukan validasi lebih lanjut di wilayah dengan dinamika lingkungan yang heterogen seperti di Pulau Lombok [38], [39].

IV. KESIMPULAN

Secara ringkas, *Machine Learning* telah menjadi alat fundamental dan transformatif dalam pemodelan parameter geofisik kunci seperti *LST*, *Ta*, dan *Albedo*. Metode *ensemble* seperti *Random Forest* dan model berbasis kernel seperti *Support Vector Regression* telah membuktikan keandalannya dalam berbagai aplikasi, mulai dari prediksi suhu hingga pengisian celah data. Di sisi lain, *Deep Learning* menunjukkan potensi yang luar biasa untuk mengatasi tantangan yang lebih besar, seperti rekonstruksi data *all-weather* dan pemetaan beresolusi sangat tinggi, meskipun membutuhkan sumber daya komputasi yang lebih besar.

Melihat ke depan, penelitian di bidang ini harus fokus pada beberapa arah kunci. Pertama, pengembangan model *explainable machine learning* (*XML*) akan menjadi krusial. Model – model ini tidak hanya memberikan prediksi yang akurat, tetapi juga memberikan wawasan tentang hubungan fisik yang mendasarinya, sehingga meningkatkan pemahaman kita tentang dinamika lingkungan. Kedua, integrasi data multi – sensor yang lebih canggih, menggabungkan data satelit dengan data in-situ dan produk reanalisis, akan terus menjadi area penelitian

penting. Terakhir, pemodelan yang lebih kontekstual, yang mempertimbangkan karakteristik geografis unik (misalnya, iklim, topografi, dan tutupan lahan), akan membantu meningkatkan akurasi dan relevansi model untuk studi kasus spesifik.

V. DAFTAR PUSTAKA

- [1] L. Alonso dan F. Renard, "A New Approach for Understanding Urban Microclimate by Integrating Complementary Predictors at Different Scales in Regression and Machine Learning Models," *Remote Sens (Basel)*, vol. 12, no. 15, hlm. 2434, Jul 2020, doi: 10.3390/rs12152434.
- [2] G. F. Garuma, "Tropical surface urban heat islands in east Africa," *Sci Rep*, vol. 13, no. 1, Des 2023, doi: 10.1038/s41598-023-31678-6.
- [3] A. K. Kagawa-Viviani dan T. W. Giambelluca, "Spatial Patterns and Trends in Surface Air Temperatures and Implied Changes in Atmospheric Moisture Across the Hawaiian Islands, 1905–2017," *Journal of Geophysical Research: Atmospheres*, vol. 125, no. 2, Jan 2020, doi: 10.1029/2019JD031571.
- [4] M. Santamouris, "Cooling the cities – A review of reflective and green roof mitigation technologies to fight heat island and improve comfort in urban environments," *Solar Energy*, vol. 103, hlm. 682–703, Mei 2014, doi: 10.1016/j.solener.2012.07.003.
- [5] A. Dwivedi, "Macro- and micro-level studies using Urban Heat Islands to simulate effects of greening, building materials and other mitigating factors in Mumbai city," *Archit Sci Rev*, vol. 62, no. 2, hlm. 126–144, Mar 2019, doi: 10.1080/00038628.2019.1578193.
- [6] A. M. M. Irfeey, H.-W. Chau, M. M. F. Sumaiya, C. Y. Wai, N. Muttill, dan E. Jamei, "Sustainable Mitigation Strategies for Urban Heat Island Effects in Urban Areas," *Sustainability*, vol. 15, no. 14, hlm. 10767, Jul 2023, doi: 10.3390/su151410767.
- [7] M. Ranagalage dkk., "Spatiotemporal Variation of Urban Heat Islands for Implementing Nature-Based Solutions: A Case Study of Kurunegala, Sri Lanka," *ISPRS Int J Geoinf*, vol. 9, no. 7, hlm. 461, Jul 2020, doi: 10.3390/ijgi9070461.
- [8] J. Chung, Y. Lee, W. Jang, S. Lee, dan S. Kim, "Correlation Analysis between Air Temperature and MODIS Land Surface Temperature and Prediction of Air Temperature Using TensorFlow Long Short-Term Memory for the Period of Occurrence of Cold and Heat Waves," *Remote Sens (Basel)*, vol. 12, no. 19, hlm. 3231, Okt 2020, doi: 10.3390/rs12193231.
- [9] M. Otgonbayar, C. Atzberger, M. Mattiuzzi, dan A. Erdenedalai, "Estimation of Climatologies of Average Monthly Air Temperature over Mongolia Using MODIS Land Surface Temperature (*LST*) Time Series and Machine Learning Techniques," *Remote Sens (Basel)*, vol. 11, no. 21, hlm. 2588, Nov 2019, doi: 10.3390/rs11212588.

- [10] J. Hofierka, M. Gallay, K. Onačillová, dan J. Hofierka, "Physically-based land surface temperature modeling in urban areas using a 3-D city model and multispectral satellite data," *Urban Clim*, vol. 31, hlm. 100566, Mar 2020, doi: 10.1016/j.uclim.2019.100566.
- [11] R. Gupta, M. Sharma, G. Singh, dan R. K. Joshi, "Characterizing urban growth and land surface temperature in the western himalayan cities of India using remote sensing and spatial metrics," *Front Environ Sci*, vol. 11, Jan 2023, doi: 10.3389/fenvs.2023.1122935.
- [12] C. Wang, X. Bi, Q. Luan, dan Z. Li, "Estimation of Daily and Instantaneous Near-Surface Air Temperature from MODIS Data Using Machine Learning Methods in the Jingjinji Area of China," *Remote Sens (Basel)*, vol. 14, no. 8, hlm. 1916, Apr 2022, doi: 10.3390/rs14081916.
- [13] M. Karlson, M. Ostwald, H. Reese, J. Sanou, B. Tankoano, dan E. Mattsson, "Mapping Tree Canopy Cover and Aboveground Biomass in Sudano-Sahelian Woodlands Using Landsat 8 and Random Forest," *Remote Sens (Basel)*, vol. 7, no. 8, hlm. 10017–10041, Agu 2015, doi: 10.3390/rs70810017.
- [14] T. McCandless dkk., "Machine Learning for Improving Surface-Layer-Flux Estimates," *Boundary Layer Meteorol*, vol. 185, no. 2, hlm. 199–228, Nov 2022, doi: 10.1007/s10546-022-00727-4.
- [15] S. Ullah, X. Qiao, dan M. Abbas, "Addressing the impact of land use land cover changes on land surface temperature using machine learning algorithms," *Sci Rep*, vol. 14, no. 1, hlm. 18746, Agu 2024, doi: 10.1038/s41598-024-68492-7.
- [16] D. S. Roy, "Forecasting The Air Temperature at a Weather Station Using Deep Neural Networks," *Procedia Comput Sci*, vol. 178, hlm. 38–46, 2020, doi: 10.1016/j.procs.2020.11.005.
- [17] T. McCandless dkk., "Machine Learning for Improving Surface-Layer-Flux Estimates," *Boundary Layer Meteorol*, vol. 185, no. 2, hlm. 199–228, Nov 2022, doi: 10.1007/s10546-022-00727-4.
- [18] A. K. Kagawa-Viviani dan T. W. Giambelluca, "Spatial Patterns and Trends in Surface Air Temperatures and Implied Changes in Atmospheric Moisture Across the Hawaiian Islands, 1905–2017," *Journal of Geophysical Research: Atmospheres*, vol. 125, no. 2, Jan 2020, doi: 10.1029/2019JD031571.
- [19] D. Leutwyler dan C. Hohenegger, "Weak cooling of the troposphere by tropical islands in simulations of the radiative-convective equilibrium," *Quarterly Journal of the Royal Meteorological Society*, vol. 147, no. 736, hlm. 1788–1800, Apr 2021, doi: 10.1002/qj.3995.
- [20] R. S. dos Santos, "Estimating spatio-temporal air temperature in London (UK) using machine learning and earth observation satellite data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 88, hlm. 102066, Jun 2020, doi: 10.1016/j.jag.2020.102066.
- [21] L. Zeng dkk., "8-Day and Daily Maximum and Minimum Air Temperature Estimation via Machine Learning Method on a Climate Zone to Global Scale," *Remote Sens (Basel)*, vol. 13, no. 12, hlm. 2355, Jun 2021, doi: 10.3390/rs13122355.
- [22] Y. Xu, A. Knudby, Y. Shen, dan Y. Liu, "Mapping monthly air temperature in the Tibetan Plateau from MODIS data based on machine learning methods," ... *selected topics in applied earth ...*, 2018, [Daring]. Tersedia pada: <https://ieeexplore.ieee.org/abstract/document/8259240/>
- [23] Y. Liu, S. Ortega-Farias, F. Tian, S. Wang, dan S. Li, "Estimation of Surface and Near-Surface Air Temperatures in Arid Northwest China Using Landsat Satellite Images," *Front Environ Sci*, vol. 9, Des 2021, doi: 10.3389/fenvs.2021.791336.
- [24] H. Shen, Y. Jiang, T. Li, Q. Cheng, C. Zeng, dan L. Zhang, "Deep learning-based air temperature mapping by fusing remote sensing, station, simulation and socioeconomic data," *Remote Sens Environ*, vol. 240, hlm. 111692, Apr 2020, doi: 10.1016/j.rse.2020.111692.
- [25] R. Li, T. Huang, Y. Song, S. Huang, dan X. Zhang, "Generating 1 km Spatially Seamless and Temporally Continuous Air Temperature Based on Deep Learning over Yangtze River Basin, China," *Remote Sens (Basel)*, vol. 13, no. 19, hlm. 3904, Sep 2021, doi: 10.3390/rs13193904.
- [26] G. Chen dkk., "Integrating weather observations and local-climate-zone-based landscape patterns for regional hourly air temperature mapping using machine learning," *Science of The Total ...*, 2022, [Daring]. Tersedia pada: <https://www.sciencedirect.com/science/article/pii/S0048969722038347>
- [27] B. E. B. Dewantoro, M. A. Khafid, A. D. A. Putra, A. P. Wicaksono, dan F. W. Andita, "Identification of the impact of vegetation cover changes and the development of urban areas on Urban Heat Island using GIS and remote sensing: A case studies of Sleman regency, Province of Yogyakarta," *IOP Conf Ser Mater Sci Eng*, vol. 1098, no. 5, hlm. 052023, Mar 2021, doi: 10.1088/1757-899X/1098/5/052023.
- [28] M. N. Fatturusi, R. Irsan, dan D. R. Jati, "Ketetersediaan Ruang Terbuka Hijau Terhadap Urban Heat Island di Kota Pontianak," *Jurnal Teknologi Lingkungan Lahan Basah*, vol. 11, no. 1, hlm. 287–296, Jan 2023, doi: 10.26418/jtlb.v11i1.64565.
- [29] A. S. Liong, N. Nasrullah, dan B. Sulistyantara, "Assessing the impact of land cover changes on land surface temperature and the relation to urban heat island in Makassar City, South Sulawesi," *IOP Conf Ser Earth Environ Sci*, vol. 879, no. 1, hlm. 012010, Okt 2021, doi: 10.1088/1755-1315/879/1/012010.
- [30] R. N. Listyawati dan P. Prasetyo, "Analysis of Urban Heat Island Phenomenon as A Global Warming Control Based on Remote Sensing in Jember Urban, Indonesia," *IOP Conf Ser Earth Environ Sci*, vol. 887, no. 1, hlm. 012002, Okt 2021, doi: 10.1088/1755-1315/887/1/012002.
- [31] S. Mukherjee, P. K. Joshi, dan R. D. Garg, "Analysis of urban built-up areas and surface urban heat island using downscaled MODIS derived land surface temperature

- data,” *Geocarto Int*, vol. 32, no. 8, hlm. 900–918, Agu 2017, doi: 10.1080/10106049.2016.1222634.
- [32] R. Yunita, A. Wibowo, Supriatna, dan A. F. Rais, “Urban Heat Island Mitigation Strategy based on Local Climate Zone Classification using Landsat 8 satellite imagery,” *IOP Conf Ser Earth Environ Sci*, vol. 1039, no. 1, hlm. 012013, Sep 2022, doi: 10.1088/1755-1315/1039/1/012013.
- [33] Mahrup, M. Ma’shum, M. Idris, dan Fahrudin, “The future of Wallace region in Lombok: the pristine natural resource under climatic and anthropogenic threat,” *IOP Conf Ser Earth Environ Sci*, vol. 913, no. 1, hlm. 012049, Nov 2021, doi: 10.1088/1755-1315/913/1/012049.
- [34] S. SUTOMO, E. Van Etten, dan R. Iryadi, “Short communication: Savanna-forest boundary on Mount Rinjani, Lombok Island, West Nusa Tenggara, Indonesia,” *Biodiversitas*, vol. 22, no. 2, Jan 2021, doi: 10.13057/biodiv/d220225.
- [35] M. Ciazela dan J. Ciazela, “Topoclimate Mapping Using Landsat ETM+ Thermal Data: Wolin Island, Poland,” *Remote Sens (Basel)*, vol. 13, no. 14, hlm. 2712, Jul 2021, doi: 10.3390/rs13142712.
- [36] H. Zhang, W. W. Immerzeel, F. Zhang, R. J. de Kok, S. J. Gorrie, dan M. Ye, “Creating 1-km long-term (1980–2014) daily average air temperatures over the Tibetan Plateau by integrating eight types of reanalysis and land data assimilation products downscaled with MODIS-estimated temperature lapse rates based on machine learning,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 97, hlm. 102295, Mei 2021, doi: 10.1016/j.jag.2021.102295.
- [37] A. Aslam dan I. A. Rana, “The use of local climate zones in the urban environment: A systematic review of data sources, methods, and themes,” *Urban Clim*, vol. 42, hlm. 101120, Mar 2022, doi: 10.1016/j.uclim.2022.101120.
- [38] L. Li dan Y. Zha, “Estimating monthly average temperature by remote sensing in China,” *Advances in Space Research*, vol. 63, no. 8, hlm. 2345–2357, Apr 2019, doi: 10.1016/j.asr.2018.12.039.
- [39] D. Long dkk., “Generation of MODIS-like land surface temperatures under all-weather conditions based on a data fusion approach,” *Remote Sens Environ*, vol. 246, hlm. 111863, Sep 2020, doi: 10.1016/j.rse.2020.111863.