

TINJAUAN LITERATUR SISTEMATIS KLASIFIKASI CUACA BERBASIS CITRA MENGGUNAKAN METODE DEEP LEARNING

Gilang Andhika Buwana¹; Mohamad Nurkamal Fauzan^{2*}

Teknik Informatika^{1,2*}

Universitas Logistik dan Bisnis Internasional, Kota Bandung, Indonesia ^{1,2*}

<https://ulbi.ac.id/>^{1,2*}

andhika.bwn@gmail.com¹, m.nurkamal.f@ulbi.ac.id^{2*}

(*) Corresponding Author



Ciptaan disebarluaskan di bawah Lisensi Creative Commons Atribusi-NonKomersial 4.0 Internasional.

Abstract— *Image-based weather recognition has become an important research area due to its applications in intelligent transportation systems, autonomous vehicles, road condition monitoring, and computer vision. Recent advances in deep learning have significantly improved the automatic recognition of diverse weather conditions. However, the variety of image sources, datasets, deep learning architectures, and weather scenarios makes it challenging to obtain a comprehensive understanding of current research trend. Therefore, this study aims to identify the image sources and datasets used in weather recognition research, analyze dominant deep learning approaches, and investigate the weather conditions most frequently addressed in image-based weather recognition and road weather detection. A Systematic Literature Review (SLR) following the PRISMA 2020 guidelines was conducted using the Scopus database. From an initial set of 603 retrieved articles, 73 studies met the predefined inclusion criteria and were selected for further analysis. The results indicate that public datasets such as DAWN, RTTS, Foggy Cityscapes, nuScenes, WeatherDataset-4, and WeatherNet are among the most frequently used data sources. Convolutional Neural Networks (CNNs) remain the dominant approach, although the adoption of Transformer-based models, Vision Transformers, YOLO, Multimodal Fusion, and Multi-Task Learning has increased considerably in recent years. Furthermore, rain, fog, and snow are the most extensively investigated weather conditions due to their significant impact on visibility and perception system performance. The findings provide a comprehensive overview of recent developments in deep learning-based weather recognition and offer valuable insights and directions for future research.*

Keywords: *Deep Learning, Road Weather Detection, Systematic Literature Review, Weather Classification, Weather Recognition.*

Abstrak— *Pengenalan cuaca berbasis citra telah menjadi salah satu bidang penelitian yang penting karena penerapannya dalam sistem transportasi cerdas, kendaraan otonom, pemantauan kondisi jalan, dan computer vision. Kemajuan terbaru dalam deep learning telah meningkatkan kemampuan sistem cerdas dalam mengenali berbagai kondisi cuaca secara otomatis. Namun, keberagaman sumber citra, dataset, arsitektur deep learning, dan skenario cuaca menyulitkan diperolehnya pemahaman yang komprehensif mengenai tren penelitian terkini. Oleh karena itu, penelitian ini bertujuan untuk mengidentifikasi sumber citra dan dataset yang digunakan dalam penelitian pengenalan cuaca, menganalisis pendekatan deep learning yang dominan, serta mengkaji kondisi cuaca yang paling sering diteliti dalam image-based weather recognition dan road weather detection. Penelitian ini menggunakan metode Systematic Literature Review (SLR) dengan mengikuti pedoman PRISMA 2020 dan melakukan penelusuran literatur pada basis data Scopus. Dari 603 artikel yang berhasil diidentifikasi, sebanyak 73 artikel memenuhi kriteria inklusi dan dianalisis lebih lanjut. Hasil penelitian menunjukkan bahwa dataset publik seperti DAWN, RTTS, Foggy Cityscapes, nuScenes, WeatherDataset-4, dan WeatherNet merupakan sumber data yang paling banyak digunakan. Convolutional Neural Networks (CNNs) masih menjadi pendekatan yang paling dominan, meskipun penggunaan model berbasis Transformer, Vision Transformer, YOLO, Multimodal Fusion, dan Multi-Task Learning mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Selain itu, hujan, kabut, dan salju merupakan kondisi cuaca yang paling banyak diteliti karena dampaknya yang*

signifikan terhadap visibilitas dan kinerja sistem persepsi. Temuan penelitian ini memberikan gambaran yang komprehensif mengenai perkembangan terkini dalam pengenalan cuaca berbasis deep learning serta menawarkan wawasan dan arah penelitian yang bermanfaat bagi pengembangan studi di masa mendatang.

Kata kunci: *Deep Learning, Deteksi Cuaca Jalan, Tinjauan Literatur Sistematis, Klasifikasi Cuaca, Pengenalan Cuaca.*

PENDAHULUAN

Pengenalan kondisi cuaca berbasis citra (*image-based weather recognition*) merupakan salah satu bidang penelitian yang semakin penting dalam *computer vision* dan *artificial intelligence*. Informasi cuaca yang akurat berperan penting dalam berbagai aplikasi, seperti sistem transportasi cerdas, kendaraan otonom, pemantauan kondisi jalan, keselamatan lalu lintas, pertanian, dan manajemen bencana (Aloufi et al., 2024; Johansen et al., 2023; Samo et al., 2023). Kondisi cuaca seperti hujan, kabut, salju, awan, maupun cuaca cerah dapat memengaruhi visibilitas serta performa sistem persepsi yang digunakan oleh berbagai aplikasi cerdas (X. Li et al., 2026; Moroto et al., 2024; A. Sharma et al., 2022). Oleh karena itu, pengembangan metode yang mampu mengenali kondisi cuaca secara otomatis dan akurat menjadi kebutuhan yang semakin mendesak.

Penelitian awal dalam bidang *weather recognition* umumnya memanfaatkan pendekatan berbasis fitur manual dan algoritma *machine learning* tradisional. Metode seperti *Gray Degree-Based Factor Analysis*, *Support Vector Machine* (SVM), serta teknik ekstraksi fitur visual digunakan untuk mengidentifikasi pola cuaca pada citra (Song & Lu, 2025; T. Sharma et al., 2022). Namun, keterbatasan metode tersebut dalam menangkap pola kompleks dan variasi lingkungan mendorong berkembangnya pendekatan *deep learning*. Berbagai penelitian kemudian mengadopsi *Convolutional Neural Networks* (CNN), *Recurrent Neural Networks* (RNN), dan arsitektur hibrida CNN-RNN yang menunjukkan peningkatan performa klasifikasi cuaca secara signifikan (Xie et al., 2022; Xiao et al., 2021; S. Chen et al., 2023). Dalam beberapa tahun terakhir, perkembangan penelitian semakin mengarah pada penggunaan model *Transformer*, *Vision Transformer* (ViT), DETR, dan YOLO yang mampu menangkap representasi visual yang lebih kaya serta meningkatkan ketahanan terhadap kondisi cuaca yang beragam (Abdelraouf et al., 2022; S. Chen et al., 2023; J. Li & Luo, 2023; Lv et al., 2026).

Selain perkembangan arsitektur *deep learning*, penelitian *weather recognition* juga menunjukkan variasi yang besar pada sumber data dan *dataset* yang digunakan. Berbagai penelitian

memanfaatkan citra yang diperoleh dari kamera lalu lintas (*traffic surveillance cameras*), *dashboard cameras*, kamera stasiun cuaca, hingga dataset publik yang dikembangkan secara khusus untuk klasifikasi cuaca (Gupta et al., 2024; Acuña-Escobar et al., 2026; Senior-williams et al., 2024). Penggunaan sumber data yang beragam memberikan peluang untuk meningkatkan kemampuan generalisasi model, tetapi juga menyebabkan perbedaan karakteristik data, kualitas citra, serta representasi kondisi cuaca yang digunakan dalam proses pelatihan dan evaluasi model (Acuña-Escobar et al., 2026; Q. Wang et al., 2026). Perbedaan tersebut menjadikan pemilihan dataset sebagai faktor penting dalam pengembangan sistem pengenalan cuaca yang *robust* dan *reliable*.

Seiring berkembangnya penelitian, berbagai kondisi cuaca telah menjadi fokus kajian, termasuk hujan, kabut, salju, awan, cuaca cerah, badai, serta kombinasi beberapa kondisi cuaca ekstrem (Kalkan et al., 2022; C.-H. G. Li et al., 2021; Moroto et al., 2024; Park et al., 2025). Penelitian terbaru tidak hanya berfokus pada klasifikasi cuaca secara umum, tetapi juga pada pengenalan kondisi jalan yang dipengaruhi oleh cuaca, terutama dalam konteks kendaraan otonom dan sistem transportasi cerdas (Abdelraouf et al., 2022; Gragnaniello et al., 2025; Samo et al., 2023). Berbagai arsitektur *deep learning* telah diusulkan untuk meningkatkan kemampuan sistem dalam mengenali kondisi cuaca dan lingkungan jalan secara *real-time* dengan tingkat akurasi yang semakin tinggi (Jiao et al., 2026; J. Li et al., 2025; Q. Wang et al., 2026).

Meskipun jumlah penelitian terus meningkat, masih terdapat beberapa keterbatasan dalam literatur yang ada. Sebagian besar penelitian berfokus pada pengembangan model tertentu tanpa memberikan gambaran menyeluruh mengenai sumber data citra, sistem pengawasan lalu lintas, dan dataset yang digunakan dalam penelitian *weather recognition* (Acuña-Escobar et al., 2026; Gupta et al., 2024; Samo et al., 2023). Selain itu, perkembangan arsitektur *deep learning* yang sangat cepat menyebabkan sulitnya memperoleh pemetaan yang sistematis mengenai pendekatan yang paling banyak digunakan dan tren perkembangan model dari waktu ke waktu. Keterbatasan lainnya adalah belum tersedianya

sintesis komprehensif mengenai kondisi cuaca yang paling banyak diteliti serta distribusi fokus penelitian pada berbagai skenario cuaca.

Berdasarkan kesenjangan penelitian tersebut, penelitian ini dirancang untuk menjawab pertanyaan penelitian berikut:

RQ1: Apa saja sumber citra, sistem pengawasan lalu lintas, dan dataset yang digunakan dalam penelitian klasifikasi cuaca dan pengenalan cuaca jalan berbasis *deep learning*?

RQ2: Pendekatan dan arsitektur *deep learning* apa yang paling umum digunakan dalam deteksi cuaca berbasis citra dan klasifikasi cuaca jalan?

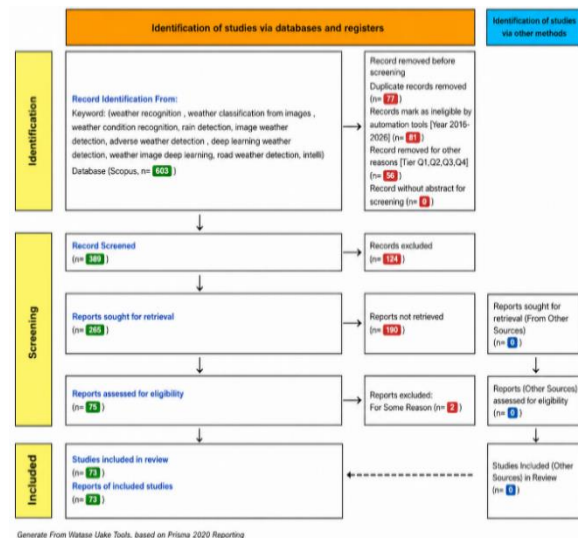
RQ3: Jenis kondisi cuaca apa yang paling banyak diteliti dalam penelitian pengenalan cuaca berbasis citra dan deteksi cuaca jalan?

Ketiga pertanyaan penelitian tersebut digunakan sebagai dasar dalam proses identifikasi, ekstraksi, dan sintesis data pada *Systematic Literature Review* (SLR) ini. Oleh karena itu, penelitian ini bertujuan untuk memetakan sumber data dan dataset yang digunakan, mengidentifikasi arsitektur *deep learning* yang dominan, serta menganalisis kondisi cuaca yang paling banyak diteliti dalam literatur terkini. Hasil penelitian diharapkan dapat memberikan gambaran komprehensif mengenai perkembangan penelitian *weather recognition* berbasis *deep learning* sekaligus menjadi landasan bagi penelitian selanjutnya dalam pengembangan sistem pengenalan cuaca yang lebih akurat, *robust*, dan adaptif.

BAHAN DAN METODE

Penelitian ini menggunakan metode *Systematic Literature Review* (SLR) untuk mengidentifikasi, mengevaluasi, dan mensintesis penelitian terkait *image-based weather recognition* dan *road weather recognition* yang memanfaatkan pendekatan *deep learning*. Metode SLR dipilih karena memungkinkan proses kajian literatur dilakukan secara sistematis, transparan, dan dapat direplikasi sehingga menghasilkan sintesis pengetahuan yang lebih komprehensif dibandingkan tinjauan literatur tradisional (Page et al., 2021).

Pelaksanaan SLR mengacu pada pedoman *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA). Kerangka kerja PRISMA digunakan untuk memastikan bahwa proses identifikasi, penyaringan, evaluasi kelayakan, dan pemilihan artikel dilakukan secara sistematis. Seluruh tahapan penelitian mengikuti empat fase utama PRISMA, yaitu *identification*, *screening*, *eligibility*, dan *inclusion*.



Sumber: (Hasil Penelitian, 2026)

Gambar 1. Diagram PRISMA

Sumber data yang digunakan dalam penelitian ini adalah basis data Scopus. Scopus dipilih karena memiliki cakupan publikasi multidisiplin yang luas, menyediakan metadata bibliografis yang terstruktur, serta mendukung penyaringan berdasarkan tahun publikasi, jenis dokumen, dan kualitas sumber publikasi. Penggunaan satu basis data juga dilakukan untuk menjaga konsistensi dalam proses pencarian, penggabungan hasil, penghapusan duplikasi, dan seleksi artikel. Dengan demikian, cakupan kajian ini dibatasi pada publikasi yang terindeks dalam basis data Scopus.

Pencarian literatur dilakukan pada basis data Scopus dengan bantuan perangkat Watase UAKE. Perangkat tersebut digunakan untuk mengidentifikasi kata kunci, membentuk *query* pencarian, mengelola hasil pencarian, dan menerapkan pembatasan rekaman. Dalam proses pembentukan *query*, kata-kata yang berada dalam satu istilah pencarian dihubungkan menggunakan operator *Boolean AND*, sedangkan variasi atau istilah alternatif dihubungkan menggunakan operator *OR*. Sebagai contoh, kata kunci yang terdiri atas beberapa kata dibentuk menjadi pola (*term 1 AND term 2 AND term 3*), sedangkan dua variasi kata kunci dibentuk menjadi (*keyword 1*) *OR* (*keyword 2*). Pengaturan ABS: No digunakan sehingga pencarian dilakukan pada bagian judul artikel di Scopus. Agar pencarian dapat direplikasi tanpa menggunakan Watase UAKE, setiap *query* kemudian dapat diterapkan secara manual melalui fitur *Advanced Search Scopus* menggunakan format *TITLE(term 1 AND term 2)*. Hasil pencarian dibatasi pada publikasi tahun 2016 sampai dengan 2026 dan sumber publikasi pada kuartil Q1, Q2, Q3, atau Q4.

Rincian kata kunci yang digunakan dan jumlah artikel yang diperoleh pada penelitian ini disajikan pada Tabel 1.

Tabel 1. Tabel Strategi Pencarian pada Scopus Menggunakan Watase UAE

No.	Kata kunci pencarian	Jumlah dokumen
1	weather recognition	96
2	weather classification from images	17
3	weather condition recognition	22
4	rain detection	130
5	image weather detection	36
6	adverse weather detection	116
7	deep learning weather detection	31
8	weather image deep learning	25
9	road weather detection	20
10	traffic surveillance camera	32
11	road surface condition detection	17
12	multi weather classification	12
13	weather image data	23
14	road weather image	9
15	traffic weather deep learning	17
Total dokumen		603

(Sumber: Hasil Penelitian, 2026)

Seluruh kata kunci dapat digabungkan menjadi satu string query eksplisit menggunakan operator Boolean OR sebagai berikut:

(
TITLE(weather AND recognition)
OR TITLE(weather AND classification AND from AND images)
OR TITLE(weather AND condition AND recognition)
OR TITLE(rain AND detection)
OR TITLE(image AND weather AND detection)
OR TITLE(adverse AND weather AND detection)
OR TITLE(deep AND learning AND weather AND detection)
OR TITLE(weather AND image AND deep AND learning)
OR TITLE(road AND weather AND detection)
OR TITLE(traffic AND surveillance AND camera)
OR TITLE(road AND surface AND condition AND detection)
OR TITLE(multi AND weather AND classification)
OR TITLE(weather AND image AND data)
OR TITLE(road AND weather AND image)
OR TITLE(traffic AND weather AND deep AND learning)
)
AND PUBYEAR > 2015
AND PUBYEAR < 2027

String query gabungan tersebut mencari dokumen yang judulnya memenuhi sekurang-kurangnya satu dari 15 kombinasi kata kunci yang telah ditetapkan. Setelah hasil pencarian diperoleh, penyaringan lanjutan dilakukan terhadap sumber publikasi yang termasuk dalam kuartil Q1, Q2, Q3, atau Q4.

Berdasarkan proses pencarian awal, diperoleh sebanyak 603 artikel. Selanjutnya, sebanyak 77 artikel duplikat dihapus, 81 artikel dikeluarkan karena berada di luar rentang tahun publikasi 2016 sampai dengan 2026, dan 56 artikel

dikeluarkan karena tidak memenuhi kriteria kualitas publikasi Q1–Q4. Setelah proses tersebut, sebanyak 389 artikel memasuki tahap *screening* berdasarkan judul dan abstrak. Pada tahap ini, sebanyak 124 artikel dikeluarkan karena tidak sesuai dengan ruang lingkup *image-based weather recognition* dan *road weather recognition*, tidak menggunakan pendekatan *deep learning*, tidak menggunakan data berbasis citra, atau tidak sesuai dengan pertanyaan penelitian. Sebanyak 265 artikel kemudian memasuki tahap *retrieval*. Dari jumlah tersebut, 190 artikel tidak berhasil diperoleh dalam bentuk *full-text*, sehingga hanya 75 artikel yang memasuki tahap *eligibility*. Pada tahap ini, dua artikel dikeluarkan. Satu artikel dikeluarkan karena dokumen *full-text* ditulis sepenuhnya dalam bahasa Mandarin sehingga tidak memenuhi kriteria bahasa Inggris. Satu artikel lainnya tidak dapat dievaluasi karena file PDF gagal dimuat pada Watase UAE. Dengan demikian, sebanyak 73 artikel memenuhi seluruh kriteria inklusi dan digunakan dalam proses sintesis literatur. Alur lengkap proses seleksi artikel ditunjukkan pada Gambar 1.

Artikel yang diperoleh kemudian diseleksi menggunakan kriteria inklusi dan eksklusi untuk memastikan kesesuaian topik, kualitas publikasi, dan ketersediaan dokumen. Kriteria inklusi dan eksklusi yang digunakan dalam penelitian ini ditunjukkan pada Tabel 2.

Tabel 2. Kriteria Inklusi dan Eksklusi

Kriteria	Inklusi	Eksklusi
Jenis Publikasi	Artikel jurnal dan conference paper	Editorial, book chapter, short paper
Bahasa	Bahasa Inggris	Selain bahasa Inggris
Tahun Publikasi	2016-2026	Sebelum 2016
Topik	Weather recognition, weather classification, road weather recognition berbasis deep learning	Tidak berkaitan dengan pengenalan cuaca atau tidak menggunakan deep learning
Kualitas Publikasi	Terindeks Scopus	Tidak terindeks Scopus
Ketersediaan Dokumen	Full-text tersedia	Full-text tidak tersedia

Sumber: (Hasil Penelitian, 2026)

Untuk menjawab pertanyaan penelitian, data dari setiap artikel diekstraksi dan dianalisis menggunakan pendekatan analisis tematik, komparatif, dan kuantitatif deskriptif. Informasi yang dikumpulkan meliputi sumber citra, dataset penelitian, jumlah kelas, tugas penelitian, arsitektur atau pendekatan deep learning, kondisi cuaca,

metrik evaluasi berupa accuracy, precision, recall, F1-score, dan mean Average Precision (mAP), nilai performa utama, serta kelebihan dan keterbatasan metode yang dilaporkan. Analisis komparatif dilakukan dengan mengelompokkan artikel berdasarkan kesamaan tugas, yaitu klasifikasi cuaca, deteksi objek pada kondisi cuaca buruk, klasifikasi multi-label atau multi-task, dan pendekatan multimodal. Meta-analysis tidak dilakukan karena terdapat heterogenitas yang tinggi pada dataset, jumlah kelas, skenario cuaca, pembagian data, tugas, dan metrik evaluasi. Oleh karena itu, nilai performa disintesis secara deskriptif dan dibandingkan secara kontekstual, bukan digabungkan menjadi satu effect size. Hasil ekstraksi kemudian dikelompokkan sesuai dengan Research Question (RQ). Seluruh referensi bertahun 2026 diperiksa melalui DOI dan halaman resmi penerbit. Artikel hanya dipertahankan apabila telah tersedia sebagai version of record atau early access sebelum finalisasi manuskrip; tahun, volume, nomor artikel, dan DOI disesuaikan dengan metadata penerbit.

HASIL DAN PEMBAHASAN

Berdasarkan proses *Systematic Literature Review* (SLR) yang mengikuti pedoman PRISMA

2020, diperoleh sebanyak 603 artikel dari database Scopus menggunakan kata kunci yang berkaitan dengan *weather recognition*, *weather classification*, *image weather detection*, *road weather detection*, dan *deep learning*. Setelah dilakukan proses penghapusan duplikasi, penyaringan berdasarkan tahun publikasi (2016-2026), serta penyaringan berdasarkan kualitas publikasi, diperoleh 389 artikel yang memenuhi syarat untuk memasuki tahap *screening*. Sebanyak 124 artikel kemudian dieliminasi berdasarkan evaluasi judul dan abstrak karena tidak relevan dengan topik penelitian.

Selanjutnya, sebanyak 265 artikel memasuki tahap *retrieval*. Namun, 190 artikel tidak berhasil diperoleh dalam bentuk *full-text*, sehingga hanya 75 artikel yang dapat dievaluasi pada tahap *eligibility*. Tidak diperolehnya sebagian besar dokumen yang telah lolos pemeriksaan judul dan abstrak menyebabkan proses sintesis hanya didasarkan pada artikel yang dokumen lengkapnya dapat diakses. Kondisi tersebut berpotensi mengurangi keterwakilan literatur dan menyebabkan pendekatan, dataset, kondisi cuaca, atau hasil penelitian tertentu tidak tercakup dalam analisis. Setelah dilakukan penilaian kelayakan, dua artikel dikeluarkan karena tidak memenuhi kriteria inklusi. Dengan demikian, diperoleh 73 artikel yang digunakan sebagai sumber utama dalam proses analisis dan sintesis literatur.

Tabel 3. Artikel Hasil Inklusi dan Ekslusi


No	Author	Year	Title	Publisher
1	(X. Li et al., 2026)	2026	Object Detection Method Based on Polarimetric Features and PFOD-Net Under Adverse Weather Conditions.	Applied Sciences
2	(Dasu et al., 2026)	2026	A self-attention driven multi-scale object detection framework for adverse weather in smart cities.	Scientific Reports
3	(Biswas et al., 2026)	2026	Multi-dimensional attention transformer for vehicle and pedestrian detection in adverse weather.	Scientific Reports
4	(Acuña-Escobar et al., 2026)	2026	MVP--A Multistep Visual Pretraining Pipeline for Efficient Weather Recognition.	IEEE Access
5	(Lv et al., 2026)	2026	FAD-DETR A Frequency-Adaptive and Haze-Aware Detection Transformer for Autonomous Driving in Adverse Weather.	Applied Sciences
6	(Jiao et al., 2026)	2026	Semantic-Enhanced Bidirectional Multimodal Fusion for 3D Object Detection Under Adverse Weather.	Applied Sciences
7	(Q. Wang et al., 2026)	2026	PF-ConvNeXt An Adverse Weather Recognition Network for Autonomous Driving Scenes.	Electronics
8	(Yuan et al., 2025)	2025	CME-YOLO A Cross-Modal Enhanced YOLO Algorithm for Adverse Weather Object Detection in Autonomous Driving.	Big Data and Cognitive Computing
9	(Liu et al., 2025)	2025	WRRT-DETR Weather-Robust RT-DETR for Drone-View Object Detection in Adverse Weather.	Drones
10	(Gao et al., 2025)	2025	YOLO-DER A Dynamic Enhancement Routing Framework for Adverse Weather Vehicle Detection.	Electronics
11	(Cote et al., 2025)	2025	Ground-Based Cloud Type Classification for Aviation Weather Hazard Detection Using Deep Learning.	IEEE Access
12	(Yang et al., 2025)	2025	A cross-environmental algorithm for multi-scale road crack detection under extreme weather conditions.	Computer-Aided Civil and Infrastructure Engineering
13	(L. Chen et al., 2025)	2025	Research on Weather Recognition Based on a Field Programmable Gate Array and Lightweight Convolutional Neural Network.	Electronics
14	(Ju et al., 2025)	2025	Multi-Modal Cross-Attention-Based Multi-Label Weather and Severity Level Classification.	IEEE Access

No	Author	Year	Title	Publisher
15	(Park et al., 2025)	2025	Real-Time Snowfall Recognition and Object Tracking System for Autonomous Driving in Adverse Snowy Weather.	IEEE Access
16	(Z. Wang et al., 2025)	2025	Enhancing Parking Spot Detection in Extreme Weather Conditions A Deep Learning Approach With Simulated Weather Augmentation.	IEEE Access
17	(J. Huang et al., 2025)	2025	A Fusion Estimation Method for Tire-Road Friction Coefficient Based on Weather and Road Images.	Lubricants
18	(P. Li et al., 2025)	2025	End-to-End Cascaded Image Restoration and Object Detection for Rain and Fog Conditions.	IET Computer Vision
19	(Song & Lu, 2025)	2025	A Review of Unmanned Visual Target Detection in Adverse Weather.	Electronics
20	(W. Chen et al., 2025)	2025	WCGNet A Weather Codebook and Gating Fusion for Robust 3D Detection Under Adverse Conditions.	Electronics
21	(J. Li et al., 2025)	2025	DSF-YOLO for robust multiscale traffic sign detection under adverse weather conditions.	Scientific Reports
22	(Gragnaniello et al., 2025)	2025	Real-time joint recognition of weather and ground surface conditions by a multi-task deep network.	Engineering Applications of Artificial Intelligence
23	(Salis et al., 2025)	2025	Time Distributed Deep Learning Models for Purely Exogenous Forecasting Application to Water Table Depth Predictions Using Weather Image Time Series.	Environmental Modelling & Software
24	(Alzanin, 2025)	2025	Explainable artificial intelligence with temporal convolutional networks for adverse weather condition detection in driverless vehicles.	Scientific Reports
25	(Senior-williams et al., 2024)	2024	The Classification of Tropical Storm Systems in Infrared Geostationary Weather Satellite Images Using Transfer Learning.	IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing
26	(Zhu et al., 2024)	2024	PODB A learning-based polarimetric object detection benchmark for road scenes in adverse weather conditions.	Information Fusion
27	(Gupta et al., 2024)	2024	Video WeAther RecoGnition (VARG) An Intensity-Labeled Video Weather Recognition Dataset.	Journal of Imaging
28	(Tabassum & El-Sharkawy, 2024)	2024	Vehicle Detection in Adverse Weather A Multi-Head Attention Approach with Multimodal Fusion.	Journal of Low Power Electronics and Applications
29	(Moroto et al., 2024)	2024	Snow- or ice-covered road detection in winter road surface conditions using deep neural networks.	Computer-Aided Civil and Infrastructure Engineering
30	(Aloufi et al., 2024)	2024	Enhancing Autonomous Vehicle Perception in Adverse Weather A Multi Objectives Model for Integrated Weather Classification and Object Detection.	Electronics
31	(Esmail Abbasi et al., 2024)	2024	Object and Pedestrian Detection on Road in Foggy Weather Conditions by Hyperparameterized YOLOv8 Model.	Electronics
32	(Sakhai et al., 2024)	2024	Spiking Neural Networks for Real-Time Pedestrian Street-Crossing Detection Using Dynamic Vision Sensors in Simulated Adverse Weather Conditions.	Electronics
33	(S. Wang et al., 2024)	2024	An Adaptive Multimodal Fusion 3D Object Detection Algorithm for Unmanned Systems in Adverse Weather.	Electronics
34	(Jing et al., 2024)	2024	YOLOv8-STE Enhancing Object Detection Performance Under Adverse Weather Conditions with Deep Learning.	Electronics
35	(Jakubec et al., 2024)	2024	Pothole detection in adverse weather leveraging synthetic images and attention-based object detection methods.	Multimedia Tools and Applications
36	(Tarmissi et al., 2024)	2024	Explainable artificial intelligence with fusion-based transfer learning on adverse weather conditions detection using complex data for autonomous vehicles.	AIMS Mathematics
37	(Zhang et al., 2024)	2024	Ship Detection in Maritime Scenes under Adverse Weather Conditions.	Remote Sensing
38	(Yoon et al., 2024)	2024	Auxcoformer Auxiliary and Contrastive Transformer for Robust Crack Detection in Adverse Weather Conditions.	Mathematics
39	(F. Huang et al., 2024)	2024	Polarization of road target detection under complex weather conditions.	Scientific Reports
40	(J. Wang et al., 2024)	2024	Joint image restoration for object detection in snowy weather.	IET Computer Vision
41	(Xiaoming & Yafeng, 2023)	2023	Weather recognition method based on convolutional neural network and feature fusion.	Journal of Applied Optics
42	(J. Li & Luo, 2023)	2023	A Study of Weather-Image Classification Combining VIT and a Dual Enhanced-Attention Module.	Electronics
43	(Samo et al., 2023)	2023	Deep Learning with Attention Mechanisms for Road Weather Detection.	Sensors

<i>No</i>	<i>Author</i>	<i>Year</i>	<i>Title</i>	<i>Publisher</i>
44	(L. Zheng et al., 2023)	2023	Weather image-based short-term dense wind speed forecast with a ConvLSTM-LSTM deep learning model.	Building and Environment
45	(Johansen et al., 2023)	2023	Who Cares about the Weather Inferring Weather Conditions for Weather-Aware Object Detection in Thermal Images.	Applied Sciences
46	(S. Chen et al., 2023)	2023	MASK-CNN-Transformer for real-time multi-label weather recognition.	Knowledge-Based Systems
47	(Kalkan et al., 2022)	2022	Cloudy clear weather classification using deep learning techniques with cloud images.	Computers and Electrical Engineering
48	(Xie et al., 2022)	2022	A CNN-based multi-task framework for weather recognition with multi-scale weather cues.	Expert Systems with Applications
49	(T. Sharma et al., 2022)	2022	Deep Learning-Based Object Detection and Scene Perception under Bad Weather Conditions.	Electronics
50	(Tran-Trung et al., 2022)	2022	Weather Forecast Based on Color Cloud Image Recognition under the Combination of Local Image Descriptor and Histogram Selection.	Electronics
51	(A. Sharma et al., 2022)	2022	Photonic Sensor for Multiple Targets Detection under Adverse Weather Conditions in Autonomous Vehicles.	Journal of Sensor and Actuator Networks
52	(Abdelraouf et al., 2022)	2022	Using Vision Transformers for Spatial-Context-Aware Rain and Road Surface Condition Detection on Freeways.	IEEE Transactions on Intelligent Transportation Systems
53	(Broughton et al., 2022)	2022	Embedding Weather Simulation in Auto-Labeling Pipelines Improves Vehicle Detection in Adverse Conditions.	Sensors
54	(Yao et al., 2022)	2022	Adverse Weather Target Detection Algorithm Based on Adaptive Color Levels and Improved YOLOv5.	Sensors
55	(Yildirim et al., 2022)	2022	Classification of the weather images with the proposed hybrid model using deep learning, SVM classifier, and mRMR feature selection methods.	Geocarto International
56	(Xie et al., 2021)	2021	Graph convolutional networks with attention for multi-label weather recognition.	Neural Computing and Applications
57	(Dong & Li, 2021)	2021	Smartphone Sensing of Road Surface Condition and Defect Detection.	Sensors
58	(Tumas et al., 2021)	2021	Augmentation of Severe Weather Impact to Far-Infrared Sensor Images to Improve Pedestrian Detection System.	Electronics
59	(Noh et al., 2021)	2021	Machine Learning-Based Hourly Frost-Prediction System Optimized for Orchards Using Automatic Weather Station and Digital Camera Image Data.	Atmosphere
60	(C.-H. G. Li et al., 2021)	2021	Real-Time Rain Detection and Wiper Control Employing Embedded Deep Learning.	IEEE Transactions on Vehicular Technology
61	(Yu et al., 2021)	2021	Global-Similarity Local-Saliency Network for Traffic Weather Recognition.	IEEE Access
62	(Xiao et al., 2021)	2021	Classification of Weather Phenomenon From Images by Using Deep Convolutional Neural Network.	Earth and Space Science
63	(Xia et al., 2020)	2020	ResNet15 Weather Recognition on Traffic Road with Deep Convolutional Neural Network.	Advances in Meteorology
64	(Singh Gill & Singh Khehra, 2020)	2020	Efficient image classification technique for weather degraded fruit images.	IET Image Processing
65	(Tan et al., 2020)	2020	Weather Recognition Based on 3C-CNN.	KSII Transactions on Internet and Information Systems
66	(Tog et al., 2020)	2020	Detection of weather images by using spiking neural networks of deep learning models.	Neural Computing and Applications
67	(Ibrahim et al., 2019)	2019	WeatherNet Recognising Weather and Visual Conditions from Street-Level Images Using Deep Residual Learning.	ISPRS International Journal of Geo-Information
68	(Zhao et al., 2019)	2019	Weather recognition via classification labels and weather-cue maps.	Pattern Recognition
69	(Zhao et al., 2018)	2018	A CNN-RNN architecture for multi-label weather recognition.	Neurocomputing
70	(Fan et al., 2018)	2018	Applications of the Gray Degree-Based Factor Analysis on Cloud Image to Improve the Accuracy of Weather Recognition.	Iranian Journal of Science and Technology, Transactions A: Science
71	(Lin & Wang, 2017)	2017	Metric learning for weather image classification.	Multimedia Tools and Applications
72	(C. Zheng et al., 2016)	2016	Active Discriminative Dictionary Learning for Weather Recognition.	Mathematical Problems in Engineering
73	(Zhang et al., 2016)	2016	Scene-free multi-class weather classification on single images.	Neurocomputing


Sumber: (Hasil Penelitian, 2026)

Analisis distribusi publikasi menunjukkan bahwa penelitian mengenai *image-based weather recognition* dan *road weather recognition* mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Publikasi mulai meningkat setelah tahun 2020 dan mencapai jumlah tertinggi pada periode 2024–2026. Peningkatan ini menunjukkan semakin besarnya perhatian peneliti terhadap pemanfaatan *deep learning* dalam sistem transportasi cerdas, kendaraan otonom, dan sistem pemantauan kondisi lingkungan berbasis citra.



Sumber: (Hasil Penelitian, 2026)
Gambar 2. Distribusi Publikasi Berdasarkan Tahun

Selain distribusi publikasi berdasarkan tahun, analisis negara asal penelitian menunjukkan bahwa China merupakan negara dengan kontribusi publikasi terbesar. Negara lain yang juga aktif melakukan penelitian pada bidang ini meliputi India, Korea Selatan, Amerika Serikat, Italia, Turki, dan Arab Saudi.




Sumber: (Hasil Penelitian, 2026)
Gambar 3. Distribusi Publikasi Berdasarkan Negara

Analisis Co-occurrence Istilah

Analisis bibliometrik tambahan dilakukan terhadap istilah yang muncul pada judul 73 artikel terpilih. Istilah yang memiliki makna serupa disatukan ke dalam kelompok konsep, kemudian hubungan dibentuk apabila dua konsep muncul pada judul yang sama. Hasil analisis menunjukkan

bahwa adverse weather (28 artikel), object detection (26 artikel), road/traffic (24 artikel), dan weather recognition (22 artikel) menjadi simpul paling dominan. Attention, multimodal fusion, Transformer/DETR, dan YOLO membentuk kluster sekunder yang menunjukkan pergeseran penelitian dari klasifikasi cuaca konvensional menuju deteksi objek, pemodelan konteks global, dan integrasi multisensor.



Sumber: Hasil Penelitian. 2026
Gambar 4. Co-occurrence Istilah pada Judul Artikel Terpilih

Untuk menjawab RQ1, dilakukan analisis terhadap sumber data visual, sistem pengawasan lalu lintas, dan dataset yang digunakan dalam penelitian. Hasil klasifikasi menunjukkan bahwa sebagian besar penelitian memanfaatkan dataset publik seperti DAWN, RTTS, Foggy Cityscapes, BDD100K, nuScenes, AWID, AWOD, WeatherDataset-4, dan WEAPD. Selain itu, beberapa penelitian menggunakan kamera pengawas lalu lintas, kamera kendaraan, kamera cuaca, dan citra satelit sebagai sumber data utama.

Tabel 4 Distribusi Artikel Berdasarkan Dataset dan Sumber Data

Dataset / Image Source	Jumlah Artikel
nuScenes Dataset	3
Ground-Based Cloud Image Dataset	4
Vehicle-Mounted Camera Images	5
Multimodal Sensor Data	6
Roadside Camera Images	4
RTTS Dataset	2
DAWN Dataset	1
Foggy Cityscapes	1
AWID Dataset	1

Dataset / Image Source	Jumlah Artikel
AWOD Dataset	1
PODB Dataset	1
VARG Dataset	1
SRSD Dataset	1
WEAPD Dataset	1
WeatherDataset-4	1
WeatherDataset-6	1
WeatherNet Dataset	1
Tropical Storm Satellite Imagery Dataset	2

Sumber: (Hasil Penelitian, 2026)

Untuk menjawab RQ2, dilakukan analisis terhadap metode deep learning yang digunakan dalam penelitian. Hasil menunjukkan bahwa CNN, Vision Transformer, YOLO, Attention Mechanism, Multi-Task Learning, dan Multimodal Fusion merupakan pendekatan yang paling sering digunakan untuk melakukan klasifikasi cuaca maupun deteksi objek pada kondisi cuaca buruk.

Tabel 5. Distribusi Artikel Berdasarkan Pendekatan Deep Learning

Pendekatan Deep Learning	Jumlah Artikel
YOLO-Based Detection	8
CNN-Based Deep Learning	6
Attention-Based Learning	6
Multi-Task Learning	5
Vision Transformer (ViT)	4
Transfer Learning	4
Multimodal Fusion	4
Transformer-Based Classification	3
Detection Transformer (DETR)	2
CNN-RNN Hybrid	2
Spiking Neural Network (SNN)	2
Graph Convolutional Network (GCN)	1
ConvLSTM-LSTM	1

Sumber: (Hasil Penelitian, 2026)

Kategori pendekatan *deep learning* pada Tabel 5 bersifat tidak saling eksklusif. Satu artikel dapat dihitung pada lebih dari satu kategori apabila menerapkan pendekatan hibrida, misalnya menggabungkan CNN dengan *attention mechanism*, Transformer, *multi-task learning*, atau *multimodal fusion*. Oleh karena itu, jumlah pada setiap kategori menunjukkan frekuensi kemunculan pendekatan dan tidak merepresentasikan jumlah artikel unik.

Untuk menjawab RQ3, dilakukan analisis terhadap kondisi cuaca yang menjadi fokus penelitian. Hasil menunjukkan bahwa hujan (*rain*), kabut (*fog*), dan salju (*snow*) merupakan kondisi cuaca yang paling banyak diteliti. Selain itu, beberapa penelitian juga membahas kondisi cuaca lainnya seperti *cloudy*, *frost*, *glare*, *sandstorm*, dan *low-light conditions*.

Tabel 6 Distribusi Artikel Berdasarkan Kondisi Cuaca

Kondisi Cuaca	Jumlah Artikel
Rain	12
Fog	11
Snow	7
Road Surface Condition	5
Multi-Weather Conditions	5
Cloudy	4
Low-Light Condition	3
Sandstorm	2
Glare	2
Tropical Storm	2
Frost	1

Sumber: (Hasil Penelitian, 2026)

Kategori kondisi cuaca pada Tabel 6 juga bersifat tidak saling eksklusif. Satu artikel dapat dihitung pada lebih dari satu kategori apabila membahas atau mengevaluasi beberapa kondisi cuaca sekaligus, seperti hujan, kabut, dan salju. Oleh karena itu, jumlah pada setiap kategori menunjukkan frekuensi kondisi cuaca yang diteliti dan tidak merepresentasikan jumlah artikel unik.

RQ1. Sumber Citra, Sistem Pengawasan Lalu Lintas, dan Dataset

Untuk menjawab RQ1, dilakukan analisis terhadap sumber citra, sistem pengawasan lalu lintas, dan dataset yang digunakan dalam penelitian *weather recognition* dan *road weather recognition*. Berdasarkan Tabel 4, sumber data yang paling banyak digunakan dalam penelitian *weather recognition* dan *road weather recognition* berasal dari dataset publik, kamera kendaraan (*vehicle-mounted camera*), kamera pengawas lalu lintas, dan data multimodal yang menggabungkan kamera dengan sensor lain seperti LiDAR dan radar. Penggunaan dataset publik seperti DAWN, RTTS, Foggy Cityscapes, nuScenes, WeatherDataset-4, dan WeatherNet menunjukkan pentingnya ketersediaan data terstandarisasi dalam pengembangan dan evaluasi model *deep learning* (Acuña-Escobar et al., 2026; Gupta et al., 2024; Zhu et al., 2024).

Selain dataset publik, beberapa penelitian memanfaatkan kamera pengawas lalu lintas, dashboard camera kendaraan, kamera stasiun cuaca, kamera *drone*, serta citra satelit sebagai sumber data visual (Abdelraouf et al., 2022; Senior-williams et al., 2024; Q. Wang et al., 2026). Kamera lalu lintas banyak digunakan pada penelitian *road weather recognition* karena mampu merepresentasikan kondisi jalan secara langsung dan *real-time*. Sebaliknya, penelitian *weather classification* cenderung menggunakan dataset citra cuaca yang telah diberi label berdasarkan kategori cuaca tertentu (Kalkan et al., 2022; Xiao et al., 2021).

Hasil analisis juga menunjukkan peningkatan penggunaan data multimodal yang mengombinasikan kamera RGB, radar, LiDAR, dan sensor lingkungan lainnya. Pendekatan ini bertujuan mengatasi keterbatasan kamera konvensional yang rentan terhadap gangguan cuaca buruk seperti hujan lebat, kabut, dan salju (Jiao et al., 2026; Tabassum & El-Sharkawy, 2024; S. Wang et al., 2024). Integrasi berbagai sensor memungkinkan sistem memperoleh informasi yang lebih komprehensif sehingga meningkatkan akurasi pengenalan kondisi cuaca dan lingkungan jalan. Meskipun demikian, sebagian besar penelitian masih bergantung pada dataset publik yang memiliki keterbatasan dalam variasi geografis, intensitas cuaca, dan kondisi lingkungan. Oleh karena itu, pengembangan dataset yang lebih representatif terhadap kondisi dunia nyata masih menjadi tantangan penting dalam penelitian *weather recognition*.

Selain keterbatasan cakupan, dataset *weather recognition* menghadapi persoalan class imbalance, kualitas anotasi, dan bias geografis. Kondisi kabut, salju, atau cuaca ekstrem umumnya memiliki jumlah citra lebih sedikit dibandingkan kondisi cerah, sehingga model dapat lebih condong pada kelas mayoritas. Batas visual antarlabel juga tidak selalu tegas, misalnya *cloudy* dan *foggy* atau *rainy* dan *low-light*, sehingga anotasi manual berpotensi bersifat subjektif dan menimbulkan noise label. Dominasi data dari jalan perkotaan dan negara tertentu membatasi representasi lingkungan tropis, pedesaan, serta variasi siang dan malam. Penggunaan cuaca sintesis dapat memperbesar jumlah data, tetapi belum selalu merepresentasikan karakteristik degradasi dunia nyata. Perbedaan kamera, lokasi, resolusi, dan distribusi kelas juga menimbulkan domain shift ketika model diterapkan pada dataset lain (Aloufi et al., 2024; Broughton et al., 2022; Gupta et al., 2024; Zhu et al., 2024).

RQ2 Pendekatan dan Arsitektur Deep Learning

Untuk menjawab RQ2, dilakukan analisis terhadap pendekatan dan arsitektur *deep learning* yang digunakan dalam penelitian yang ditinjau. Berdasarkan Tabel 5, pendekatan *deep learning* yang paling banyak digunakan adalah *YOLO-Based Detection*, *CNN-Based Deep Learning*, dan *Attention-Based Learning*. Temuan ini menunjukkan bahwa penelitian terkini tidak hanya berfokus pada klasifikasi cuaca, tetapi juga pada deteksi objek dan persepsi lingkungan di bawah kondisi cuaca buruk (Gao et al., 2025; Jing et al., 2024; Yao et al., 2022).

Pada periode awal penelitian, *Convolutional Neural Network* (CNN) menjadi

arsitektur yang paling dominan karena kemampuannya dalam mengekstraksi fitur visual secara otomatis tanpa memerlukan ekstraksi fitur manual. Berbagai varian CNN seperti ResNet, DenseNet, MobileNet, EfficientNet, dan ConvNeXt banyak digunakan untuk meningkatkan performa klasifikasi cuaca (L. Chen et al., 2025; Q. Wang et al., 2026; Xiao et al., 2021).

Seiring perkembangan teknologi *deep learning*, penggunaan *Transformer* dan *Vision Transformer* (ViT) semakin meningkat. Berbeda dengan CNN yang berfokus pada fitur lokal, *Transformer* mampu menangkap hubungan global antar area citra sehingga lebih efektif dalam mengenali pola cuaca yang kompleks (Abdelraouf et al., 2022; S. Chen et al., 2023; C.-H. G. Li et al., 2021). Selain itu, integrasi *Attention Mechanism* dan *Cross-Attention* juga mulai banyak diterapkan untuk meningkatkan fokus model terhadap area citra yang relevan (Gragnaniello et al., 2025; Samo et al., 2023).


Penelitian terbaru menunjukkan tren menuju pendekatan *Multimodal Fusion* dan *Multi-Task Learning* yang memungkinkan model memanfaatkan berbagai sumber informasi secara simultan (Gragnaniello et al., 2025; Jiao et al., 2026; Xie et al., 2022). Temuan ini mengindikasikan adanya pergeseran fokus penelitian dari peningkatan akurasi semata menuju pengembangan sistem yang lebih *robust*, efisien, dan siap diterapkan pada lingkungan nyata. Dari sisi performa, CNN tetap banyak digunakan karena efisien dalam mengekstraksi fitur visual lokal, sedangkan *attention* dan *Transformer* lebih mampu menangkap konteks global serta pola cuaca kompleks, tetapi membutuhkan data dan sumber daya komputasi yang lebih besar.

Pada tugas deteksi objek, YOLO unggul dalam kecepatan inferensi untuk aplikasi waktu nyata, sementara DETR, Transformer, dan pendekatan multimodal menawarkan ketahanan yang lebih baik pada kondisi cuaca buruk dengan konsekuensi kompleksitas dan biaya implementasi yang lebih tinggi. Namun, performa antarpenelitian tidak dapat dibandingkan secara langsung hanya berdasarkan akurasi, F1-score, atau mAP karena terdapat perbedaan dataset, jumlah kelas, kondisi cuaca, pembagian data, dan protokol evaluasi. Oleh karena itu, tidak terdapat satu arsitektur yang secara konsisten unggul pada seluruh tugas; CNN dan YOLO lebih sesuai untuk efisiensi dan pemrosesan waktu nyata, sedangkan Transformer, *attention-based learning*, dan *multimodal fusion* lebih potensial untuk kondisi cuaca yang kompleks.

Sintesis kuantitatif deskriptif menunjukkan variasi performa yang besar antarstudi.

WeatherNet melaporkan accuracy 91,6–95,6% dan F1-score 0,845–0,947 pada empat model residual untuk kondisi visual dan cuaca, sedangkan ResNet15 mencapai accuracy 96,03% pada WeatherDataset-4 (Ibrahim et al., 2019; Xia et al., 2020). Pada penelitian tahun 2026, PFOD-Net mencapai mAP@0.5 sebesar 81,7% pada Polar LITIS; model self-attention multi-scale berbasis YOLO melaporkan accuracy 97,25%, precision 95,33%, recall 96,37%, F1-score 96,55%, dan mAP 89,8%; PF-ConvNeXt melaporkan accuracy 90,16%, mAP 95,24%, dan F1-score 92,18%; sedangkan SeBFusion menghasilkan mAP 66,2% pada kabut dan 66,6% pada salju di nuScenes-C (X. Li et al., 2026; Dasu et al., 2026; Q. Wang et al., 2026; Jiao et al., 2026). Nilai tersebut tidak menunjukkan peringkat metode secara langsung karena berasal dari tugas, dataset, kelas, dan protokol evaluasi yang berbeda.

Dari perspektif waktu, periode 2016–2020 didominasi CNN dan CNN–RNN dengan fokus utama pada peningkatan accuracy klasifikasi. Periode 2021–2023 menunjukkan pergeseran menuju attention, GCN, multi-task learning, dan Vision Transformer untuk menangani konteks global serta multi-label. Pada periode 2024–2026, penelitian berkembang menuju YOLO, DETR, ConvNeXt, polarimetric imaging, dan multimodal fusion dengan perhatian lebih besar pada mAP, F1-score, FPS, robustness, serta implementasi waktu nyata. Tren numerik harus ditafsirkan secara kontekstual karena peningkatan metrik dari tahun ke tahun juga dipengaruhi oleh perubahan dataset, kompleksitas tugas, dan protokol pengujian.



(Sumber: Hasil Penelitian. 2026)

Gambar 5 Taxonomy Framework dan Roadmap Perkembangan Weather Recognition

RQ3. Kondisi Cuaca yang Diteliti

Untuk menjawab RQ3, dilakukan analisis terhadap berbagai kondisi cuaca yang menjadi fokus penelitian dalam studi *weather recognition* dan *road weather recognition* berbasis *deep learning*. Berdasarkan Tabel 6, hujan (*rain*), kabut (*fog*), dan salju (*snow*) merupakan kondisi cuaca yang paling banyak diteliti dibandingkan kondisi cuaca lainnya. Dominasi ketiga kondisi tersebut menunjukkan bahwa penelitian *weather recognition* masih berfokus pada kondisi cuaca yang memiliki dampak signifikan terhadap visibilitas dan performa sistem persepsi pada kendaraan otonom maupun sistem transportasi cerdas (Esmaeil Abbasi et al., 2024; C.-H. G. Li et al., 2021; Park et al., 2025).

Kabut menjadi salah satu kondisi yang paling menantang karena menyebabkan penurunan kontras dan detail objek pada citra. Oleh karena itu, banyak penelitian mengembangkan metode deteksi objek dan klasifikasi cuaca yang mampu beroperasi secara efektif pada kondisi berkabut (P. Li et al., 2025; Lv et al., 2026). Hujan juga menjadi fokus utama karena tetesan air dan refleksi permukaan jalan dapat mengganggu proses ekstraksi fitur visual (Abdelraouf et al., 2022; C.-H. G. Li et al., 2021). Sementara itu, salju menghadirkan tantangan tambahan berupa perubahan tekstur lingkungan dan penurunan kualitas visibilitas (Moroto et al., 2024; J. Wang et al., 2024).

Selain ketiga kondisi tersebut, penelitian juga membahas kondisi cuaca lain seperti *cloudy*, *frost*, *glare*, *sandstorm*, *low-light condition*, *tropical storm*, dan *road surface condition* (Kalkan et al., 2022; Noh et al., 2021; Senior-williams et al., 2024). Namun jumlah penelitian pada kondisi-kondisi tersebut masih relatif terbatas. Temuan ini menunjukkan bahwa masih terdapat peluang penelitian terkait pengenalan kondisi cuaca ekstrem maupun kombinasi beberapa kondisi cuaca yang terjadi secara bersamaan. Pengembangan dataset dan model yang mampu menangani *multi-weather conditions* menjadi salah satu arah penelitian yang menjanjikan di masa mendatang.

Research Gaps and Future Research Directions

Berdasarkan hasil sintesis literatur, terdapat beberapa kesenjangan penelitian yang masih perlu diperhatikan. Pertama, sebagian besar penelitian masih menggunakan dataset publik dengan cakupan geografis yang terbatas sehingga kemampuan generalisasi model pada lingkungan nyata belum sepenuhnya teruji (Gupta et al., 2024; Acuña-Escobar et al., 2026).

Kedua, sebagian besar penelitian masih berfokus pada kondisi cuaca tunggal seperti hujan, kabut, atau salju. Padahal dalam kondisi nyata sering terjadi kombinasi beberapa kondisi cuaca

secara bersamaan yang dapat memengaruhi performa sistem secara signifikan (Gragnaniello et al., 2025; Ju et al., 2025).

Ketiga, meskipun Transformer dan Multimodal Fusion menunjukkan performa yang menjanjikan, implementasinya masih membutuhkan sumber daya komputasi yang relatif besar (Jiao et al., 2026; J. Li & Luo, 2023). Oleh karena itu, pengembangan model *lightweight* yang mampu mempertahankan akurasi tinggi dengan kebutuhan komputasi rendah menjadi area penelitian yang penting.

Keempat, aspek *explainable artificial intelligence* (XAI) masih relatif jarang dibahas dalam penelitian *weather recognition*. Padahal kemampuan menjelaskan keputusan model menjadi faktor penting untuk meningkatkan kepercayaan pengguna terhadap sistem pengenalan cuaca (Alzanin, 2025; Tarmissi et al., 2024).

Kelima, kajian ini memiliki keterbatasan karena pencarian literatur hanya dilakukan pada basis data Scopus. Meskipun Scopus memiliki cakupan publikasi yang luas, terdapat kemungkinan bahwa studi relevan yang hanya terindeks pada Web of Science, IEEE Xplore, ACM Digital Library, SpringerLink, atau ScienceDirect belum teridentifikasi. Oleh karena itu, hasil kajian ini merepresentasikan literatur yang ditemukan melalui basis data Scopus pada periode 2016 sampai dengan 2026.

Keenam, sebanyak 190 dari 265 artikel yang memasuki tahap *retrieval* tidak berhasil diperoleh dalam bentuk *full-text*. Tidak tersedianya dokumen tersebut berpotensi menimbulkan bias akses dan bias seleksi karena karakteristik, metode, dataset, maupun hasil penelitian pada artikel yang tidak diperoleh dapat berbeda dari artikel yang berhasil dianalisis. Kondisi ini juga dapat menyebabkan pendekatan *deep learning*, kondisi cuaca, atau tren penelitian tertentu belum tercakup dalam hasil sintesis. Oleh karena itu, hasil kajian ini perlu dipahami sebagai pemetaan berdasarkan artikel yang dokumen lengkapnya berhasil diperoleh dan memenuhi kriteria inklusi, bukan sebagai representasi seluruh literatur pada bidang *image-based weather recognition*.

Ketujuh, penelitian ini belum menerapkan penilaian kualitas metodologis dan risiko bias secara terstruktur terhadap setiap artikel yang diinklusi. Kondisi tersebut menyebabkan kekuatan bukti dari masing-masing studi belum dapat dibandingkan secara sistematis. Oleh karena itu, hasil sintesis perlu diinterpretasikan dengan mempertimbangkan kemungkinan adanya variasi kualitas metodologis, bias data, bias evaluasi, dan bias pelaporan pada studi primer.

Kedelapan, meta-analysis tidak dapat dilakukan karena studi yang diinklusi memiliki heterogenitas tinggi pada tugas, dataset, label cuaca, metrik, dan protokol evaluasi. Konsekuensinya, kesimpulan mengenai metode yang paling efektif tidak dapat dibuktikan melalui effect size gabungan atau uji signifikansi lintas studi. Sintesis performa pada kajian ini bersifat kuantitatif deskriptif dan kontekstual, sehingga tidak dimaksudkan sebagai pemeringkatan statistik antarmetode.

Berdasarkan temuan tersebut, penelitian di masa mendatang dapat diarahkan pada pengembangan dataset multimodal berskala besar, pengenalan multi-weather conditions, pengembangan arsitektur *lightweight* Transformer, serta integrasi *explainable AI*. Kajian literatur selanjutnya juga disarankan menggunakan beberapa basis data, melakukan deduplikasi lintas sumber, menerapkan *quality assessment* dan *risk of bias* secara terstruktur, serta memperluas penelusuran *full-text*. Penelitian eksperimental perlu menggunakan benchmark lintas-dataset, pembagian data berbasis sumber, pelaporan metrik per kelas, dan protokol evaluasi yang seragam agar meta-analysis dan perbandingan statistik antarmodel dapat dilakukan secara lebih valid.

KESIMPULAN

Penelitian ini melakukan Systematic Literature Review terhadap 73 artikel mengenai *image-based weather recognition* dan *road weather recognition* berbasis *deep learning*. Dataset publik, kamera kendaraan dan lalu lintas, citra satelit, serta data multimodal menjadi sumber data utama. CNN dan YOLO tetap dominan untuk klasifikasi dan deteksi yang efisien, sedangkan Transformer, *attention-based learning*, DETR, *multi-task learning*, dan multimodal fusion semakin digunakan untuk menangani konteks global dan kondisi cuaca kompleks. Hujan, kabut, dan salju merupakan kondisi yang paling banyak dikaji. Analisis *co-occurrence* istilah memperlihatkan keterhubungan kuat antara *adverse weather*, *object detection*, *road/traffic*, dan *weather recognition*, sedangkan *taxonomy roadmap* menunjukkan pergeseran dari CNN menuju Transformer dan integrasi multisensor.

Sintesis performa menunjukkan bahwa tidak terdapat satu metode yang dapat dinyatakan paling efektif pada seluruh tugas. CNN dan YOLO lebih sesuai ketika efisiensi dan pemrosesan waktu nyata menjadi prioritas, sedangkan Transformer, DETR, *polarimetric imaging*, dan multimodal fusion menawarkan *robustness* yang lebih tinggi dengan kebutuhan komputasi atau sensor yang lebih besar.

Karena dataset, jumlah kelas, skenario cuaca, dan metrik evaluasi berbeda, nilai accuracy, precision, recall, F1-score, dan mAP hanya dibandingkan secara kontekstual dan tidak digabungkan melalui meta-analysis. Hasil kajian juga menegaskan perlunya dataset yang lebih seimbang, anotasi yang konsisten, representasi geografis yang lebih luas, evaluasi lintas-dataset, dan protokol pengujian yang seragam.

REFERENSI

- Abdelraouf, A., Abdel-Aty, M., & Wu, Y. (2022). Using Vision Transformers for Spatial-Context-Aware Rain and Road Surface Condition Detection on Freeways. *IEEE Transactions on Intelligent Transportation Systems*, 23(10), 18546–18556. <https://doi.org/10.1109/TITS.2022.3150715>
- Acuña-Escobar, D., Intriago-Pazmiño, M., & Ibarra-Fiallo, J. (2026). MVP—A Multistep Visual Pretraining Pipeline for Efficient Weather Recognition. *IEEE Access*, 14, 738–750. <https://doi.org/10.1109/ACCESS.2025.3648029>
- Aloufi, N., Alnori, A., & Basuhail, A. (2024). Enhancing Autonomous Vehicle Perception in Adverse Weather: A Multi Objectives Model for Integrated Weather Classification and Object Detection. *Electronics*, 13(15). <https://doi.org/10.3390/electronics13153063>
- Alzanin, S. (2025). Explainable artificial intelligence with temporal convolutional networks for adverse weather condition detection in driverless vehicles. *Scientific Reports*, 15. <https://doi.org/10.1038/s41598-025-05136-4>
- Biswas, S., Kumar, J., Mitra, A., Ganesh, A., & Singh, P. (2026). Multi-dimensional attention transformer for vehicle and pedestrian detection in adverse weather. *Scientific Reports*, 16(1), 1–19. <https://doi.org/10.1038/s41598-026-40319-7>
- Broughton, G., Janota, J., Blaha, J., Rouček, T., Simon, M., Vintř, T., Yang, T., Yan, Z., & Krajník, T. (2022). Embedding Weather Simulation in Auto-Labeling Pipelines Improves Vehicle Detection in Adverse Conditions. *Sensors*, 22(22), 1–22. <https://doi.org/10.3390/s22228855>
- Chen, L., Luo, F., Wang, F., & Lv, L. (2025). Research on Weather Recognition Based on a Field Programmable Gate Array and Lightweight Convolutional Neural Network. *Electronics*, 14(9). <https://doi.org/10.3390/electronics1409174>
- Chen, S., Shu, T., Zhao, H., & Tang, Y. Y. (2023). MASK-CNN-Transformer for real-time multi-label weather recognition. *Knowledge-Based Systems*, 278, 110881. <https://doi.org/10.1016/j.knosys.2023.110881>
- Chen, W., Yan, F., Wang, N., He, J., & Wu, Y. (2025). WCGNet: A Weather Codebook and Gating Fusion for Robust 3D Detection Under Adverse Conditions. *Electronics (Switzerland)*, 14(22), 1–14. <https://doi.org/10.3390/electronics14224379>
- Cote, M. P., Splitt, M. E., Lazarus, S. M., White, R. T., & Baker, C. G. (2025). Ground-Based Cloud Type Classification for Aviation Weather Hazard Detection Using Deep Learning. *IEEE Access*, 13, 203027–203040. <https://doi.org/10.1109/ACCESS.2025.3634057>
- Dasu, B. T., Reddy, M. V., Kumar, K. V., Chithaluru, P., Ahmed, N., & Abd Elminaam, D. S. (2026). A self-attention driven multi-scale object detection framework for adverse weather in smart cities. *Scientific Reports*, 16(1), 1–22. <https://doi.org/10.1038/s41598-025-31660-4>
- Dong, D., & Li, Z. (2021). Smartphone Sensing of Road Surface Condition and Defect Detection. *Sensors*, 21(16), 5433. <https://doi.org/10.3390/s21165433>
- Esmail Abbasi, A., Mangini, A. M., & Fanti, M. P. (2024). Object and Pedestrian Detection on Road in Foggy Weather Conditions by Hyperparameterized YOLOv8 Model. *Electronics (Switzerland)*, 13(18). <https://doi.org/10.3390/electronics13183661>
- Fan, G.-F., Peng, L.-L., Hong, W.-C., & Liao, Y.-S. (2018). Applications of the Gray Degree-Based Factor Analysis on Cloud Image to Improve the Accuracy of Weather Recognition. *Iranian Journal of Science and Technology, Transactions A: Science*, 42(4), 2117–2129. <https://doi.org/10.1007/s40995-017-0449-9>
- Gao, R., Omar, M. H., & Mahmuddin, M. (2025). YOLO-DER: A Dynamic Enhancement Routing Framework for Adverse Weather Vehicle Detection. *Electronics (Switzerland)*, 14(24). <https://doi.org/10.3390/electronics14244851>
- Gragnaniello, D., Greco, A., Sansone, C., & Vento, B. (2025). Real-time joint recognition of weather and ground surface conditions by a multi-task deep network. *Engineering Applications of*

- Artificial Intelligence*, 139(PA), 109543. <https://doi.org/10.1016/j.engappai.2024.109543>
- Gupta, H., Kotlyar, O., Andreasson, H., & Lilienthal, A. J. (2024). Video WeAther RecoGnition (VARG): An Intensity-Labeled Video Weather Recognition Dataset. *Journal of Imaging*, 10(11), 1–16. <https://doi.org/10.3390/jimaging10110281>
- Huang, F., Zheng, J., Liu, X., Shen, Y., & Chen, J. (2024). Polarization of road target detection under complex weather conditions. *Scientific Reports*, 14(1), 30348. <https://doi.org/10.1038/s41598-024-80830-3>
- Huang, J., Chen, X., Jin, Q., & Li, P. (2025). A Fusion Estimation Method for Tire-Road Friction Coefficient Based on Weather and Road Images. *Lubricants*, 13(10), 1–22. <https://doi.org/10.3390/lubricants13100459>
- Ibrahim, M. R., Haworth, J., & Cheng, T. (2019). WeatherNet: Recognising Weather and Visual Conditions from Street-Level Images Using Deep Residual Learning. *ISPRS International Journal of Geo-Information*, 8(12). <https://doi.org/10.3390/ijgi8120549>
- Jakubec, M., Lieskovska, E., Bucko, B., & Zabovska, K. (2024). Pothole detection in adverse weather: leveraging synthetic images and attention-based object detection methods. *Multimedia Tools and Applications*, 83(39), 86955–86982. <https://doi.org/10.1007/s11042-024-19723-6>
- Jiao, T., Chen, Y., Feng, X., Guo, C., & Song, J. (2026). Semantic-Enhanced Bidirectional Multimodal Fusion for 3D Object Detection Under Adverse Weather. *Applied Sciences (Switzerland)*, 16(6). <https://doi.org/10.3390/app16062943>
- Jing, Z., Li, S., & Zhang, Q. (2024). YOLOv8-STE: Enhancing Object Detection Performance Under Adverse Weather Conditions with Deep Learning. *Electronics (Switzerland)*, 13(24). <https://doi.org/10.3390/electronics13245049>
- Johansen, A. S., Nasrollahi, K., Escalera, S., & Moeslund, T. B. (2023). Who Cares about the Weather? Inferring Weather Conditions for Weather-Aware Object Detection in Thermal Images. *Applied Sciences (Switzerland)*, 13(18). <https://doi.org/10.3390/app131810295>
- Ju, H., Nalcakan, Y., Park, I., Jin, Y., Yeo, S., & Kim, S. (2025). Multi-Modal Cross-Attention-Based Multi-Label Weather and Severity Level Classification. *IEEE Access*, 13(October), 215882–215896. <https://doi.org/10.1109/ACCESS.2025.3645363>
- Kalkan, M., Bostancı, G. E., Güzel, M. S., Kalkan, B., Özşarı, Ş., Soysal, Ö., & Köse, G. (2022). Cloudy/clear weather classification using deep learning techniques with cloud images. *Computers and Electrical Engineering*, 102(June), 108271. <https://doi.org/10.1016/j.compeleceng.2022.108271>
- Zhang, Q., Wang, L., Meng, H., Zhang, Z., & Yang, C. (2024). Ship Detection in Maritime Scenes under Adverse Weather Conditions. *Remote Sensing*, 16(9), 1567. <https://doi.org/10.3390/rs16091567>
- Li, C.-H. G., Chen, K.-W., Lai, C.-C., & Hwang, Y.-T. (2021). Real-Time Rain Detection and Wiper Control Employing Embedded Deep Learning. *IEEE Transactions on Vehicular Technology*, 70(4), 3256–3266. <https://doi.org/10.1109/TVT.2021.3066677>
- Li, J., Deng, Q. W., Gao, W. X., Yang, B., Jia, L., Zhou, J., & Pu, H. B. (2025). DSF-YOLO for robust multiscale traffic sign detection under adverse weather conditions. *Scientific Reports*, 15(1), 1–17. <https://doi.org/10.1038/s41598-025-02877-0>
- Li, J., & Luo, X. (2023). A Study of Weather-Image Classification Combining VIT and a Dual Enhanced-Attention Module. *Electronics*, 12(5), 1213. <https://doi.org/10.3390/electronics12051213>
- Li, P., Ni, J., & Tao, D. (2025). End-to-End Cascaded Image Restoration and Object Detection for Rain and Fog Conditions. *IET Computer Vision*, 19(1). <https://doi.org/10.1049/cvi.2.70021>
- Li, X., Li, W., Yan, X., Wang, W., & Bu, F. (2026). Object Detection Method Based on Polarimetric Features and PFOD-Net Under Adverse Weather Conditions. *Applied Sciences*, 16(4), 1698. <https://doi.org/10.3390/app16041698>
- Lin, F., & Wang, T. (2017). *Metric learning for weather image classification*. <https://doi.org/10.1007/s11042-017-4948-7>
- Liu, B., Jin, J., Zhang, Y., & Sun, C. (2025). WRRT-DETR: Weather-Robust RT-DETR for Drone-View Object Detection in Adverse Weather. *Drones*, 9(5). <https://doi.org/10.3390/drones9050369>
- Lv, K., Yao, C., Huang, K., Ye, S., & Zhuang, J. (2026). FAD-DETR: A Frequency-Adaptive and Haze-

- Aware Detection Transformer for Autonomous Driving in Adverse Weather. *Applied Sciences (Switzerland)*, 16(6), 1–20. <https://doi.org/10.3390/app16062913>
- Moroto, Y., Maeda, K., Ogawa, T., & Haseyama, M. (2024). Snow- or ice-covered road detection in winter road surface conditions using deep neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 39(19), 2935–2950. <https://doi.org/10.1111/mice.13233>
- Noh, I., Doh, H.-W., Kim, S.-O., Kim, S.-H., Shin, S., & Lee, S.-J. (2021). Machine Learning-Based Hourly Frost-Prediction System Optimized for Orchards Using Automatic Weather Station and Digital Camera Image Data. *Atmosphere*, 12(7). <https://doi.org/10.3390/atmos12070846>
- Page, M., McKenzie, J., Bossuyt, P., Boutron, I., Hoffmann, T., Mulrow, C., Shamseer, L., Tetzlaff, J., Akl, E., Brennan, S., Chou, R., Glanville, J., Grimshaw, J., Hróbjartsson, A., Lalu, M., Li, T., Loder, E., Mayo-Wilson, E., McDonald, S., & Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Park, J.-I., Jo, S., Seo, H.-T., & Park, J. (2025). Real-Time Snowfall Recognition and Object Tracking System for Autonomous Driving in Adverse Snowy Weather. *IEEE Access*, 13, 166987–167000. <https://doi.org/10.1109/ACCESS.2025.3613456>
- Sakhai, M., Mazurek, S., Caputa, J., Argasiński, J. K., & Wielgosz, M. (2024). Spiking Neural Networks for Real-Time Pedestrian Street-Crossing Detection Using Dynamic Vision Sensors in Simulated Adverse Weather Conditions. *Electronics (Switzerland)*, 13(21). <https://doi.org/10.3390/electronics13214280>
- Salis, M., Atto, A. M., Ferraris, S., & Meo, R. (2025). Time Distributed Deep Learning Models for Purely Exogenous Forecasting: Application to Water Table Depth Predictions Using Weather Image Time Series. *Environmental Modelling and Software*, 193(November 2024), 106568. <https://doi.org/10.1016/j.envsoft.2025.106568>
- Samo, M., Mafeni Mase, J. M., & Figueredo, G. (2023). Deep Learning with Attention Mechanisms for Road Weather Detection. *Sensors*, 23(2), 798. <https://doi.org/10.3390/s23020798>
- Senior-Williams, J., Hogervorst, F., Platen, E., Kuijt, A., Onderwater, J., & Tervo, R. (2024). The classification of tropical storm systems in infrared geostationary weather satellite images using transfer learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 5234–5244. <https://doi.org/10.1109/JSTARS.2024.3365852>
- Sharma, A., Chaudhary, S., Malhotra, J., Khichar, S., & Wuttisittikulkij, L. (2022). Photonic Sensor for Multiple Targets Detection under Adverse Weather Conditions in Autonomous Vehicles. *Journal of Sensor and Actuator Networks*, 11(4). <https://doi.org/10.3390/jsan11040060>
- Sharma, T., Debaque, B., Duclos, N., Chehri, A., Kinder, B., & Fortier, P. (2022). Deep Learning-Based Object Detection and Scene Perception under Bad Weather Conditions. *Electronics (Switzerland)*, 11(4), 1–11. <https://doi.org/10.3390/electronics11040563>
- Singh Gill, H., & Singh Khehra, B. (2020). Efficient image classification technique for weather degraded fruit images. *IET Image Processing*, 14(14), 3463–3470. <https://doi.org/10.1049/iet-ipr.2018.5310>
- Song, Y., & Lu, Y. (2025). A Review of Unmanned Visual Target Detection in Adverse Weather. *Electronics (Switzerland)*, 14(13), 1–38. <https://doi.org/10.3390/electronics14132582>
- Tabassum, N., & El-Sharkawy, M. (2024). Vehicle Detection in Adverse Weather: A Multi-Head Attention Approach with Multimodal Fusion. *Journal of Low Power Electronics and Applications*, 14(2). <https://doi.org/10.3390/jlpea14020023>
- Tan, L., Xuan, D., Xia, J., & Wang, C. (2020). Weather Recognition Based on 3C-CNN. *KSII Transactions on Internet and Information Systems*, 14(8), 3567–3582. <https://doi.org/10.3837/tiis.2020.08.024>
- Tarmissi, K., Mengash, H., Negm, N., Said, Y., & Al-Sharafi, A. (2024). Explainable artificial intelligence with fusion-based transfer learning on adverse weather conditions detection using complex data for autonomous vehicles. *AIMS Mathematics*, 9, 35678–35701. <https://doi.org/10.3934/math.20241693>
- Tog, M., Ergen, B., & Co, Z. (2020). Detection of weather images by using spiking neural networks of deep learning models. <https://doi.org/10.1007/s00521-020-05388-3>
- Tran-Trung, K., Duong Thi Hong, H., & Truong Hoang, V. (2022). Weather Forecast Based on Color Cloud Image Recognition under the Combination of Local Image Descriptor and Histogram Selection. *Electronics*

- (Switzerland), 11(21), 0–14.
<https://doi.org/10.3390/electronics11213460>
- Tumas, P., Serackis, A., & Nowosielski, A. (2021). Augmentation of severe weather impact to far-infrared sensor images to improve pedestrian detection system. *Electronics (Switzerland)*, 10(8), 1–16.
<https://doi.org/10.3390/electronics10080934>
- Wang, J., Xu, M., Xue, H., Huo, Z., & Luo, F. (2024). Joint image restoration for object detection in snowy weather. *IET Computer Vision*, 18(6), 759–771.
<https://doi.org/10.1049/cvi2.12274>
- Wang, Q., Zhou, Z., & Zhang, Z. (2026). PF-ConvNeXt: An Adverse Weather Recognition Network for Autonomous Driving Scenes. *Electronics (Switzerland)*, 15(5).
<https://doi.org/10.3390/electronics15050920>
- Wang, S., Xie, X., Li, M., Wang, M., Yang, J., Li, Z., Zhou, X., & Zhou, Z. (2024). An Adaptive Multimodal Fusion 3D Object Detection Algorithm for Unmanned Systems in Adverse Weather. *Electronics (Switzerland)*, 13(23), 1–22.
<https://doi.org/10.3390/electronics13234706>
- Wang, Z., Zhou, P., Zhang, S., Du, W., & Chen, X. (2025). Enhancing Parking Spot Detection in Extreme Weather Conditions: A Deep Learning Approach with Simulated Weather Augmentation. *IEEE Access*, 13(July), 147163–147172.
<https://doi.org/10.1109/ACCESS.2025.3600276>
- Xia, J., Xuan, D., Tan, L., & Xing, L. (2020). ResNet15: Weather Recognition on Traffic Road with Deep Convolutional Neural Network. *Advances in Meteorology*, 2020(1), 6972826.
<https://doi.org/10.1155/2020/6972826>
- Xiao, H., Zhang, F., Shen, Z., Wu, K., & Zhang, J. (2021). Classification of Weather Phenomenon From Images by Using Deep Convolutional Neural Network. *Earth and Space Science*, 8(5), 1–9.
<https://doi.org/10.1029/2020EA001604>
- Xiaoming, H., & Yafeng, Q. (2023). Weather recognition method based on convolutional neural network and feature fusion. *Journal of Applied Optics*, 44(2), 323–329.
<https://doi.org/10.5768/JAO202344.0202004>
- Xie, K., Huang, L., Zhang, W., Qin, Q., & Lyu, L. (2022). A CNN-based multi-task framework for weather recognition with multi-scale weather cues. *Expert Systems with Applications*, 198(March), 116689.
<https://doi.org/10.1016/j.eswa.2022.116689>
- Xie, K., Wei, Z., Huang, L., Qin, Q., & Zhang, W. (2021). Graph convolutional networks with attention for multi-label weather recognition. *Neural Computing and Applications*, 33(17), 11107–11123.
<https://doi.org/10.1007/s00521-020-05650-8>
- Yang, H., Liu, L., Zhang, J., & Guo, K. (2025). A cross-environmental algorithm for multi-scale road crack detection under extreme weather conditions. *Computer-Aided Civil and Infrastructure Engineering*, 40(21), 3359–3384.
<https://doi.org/10.1111/mice.70014>
- Yao, J., Fan, X., Li, B., & Qin, W. (2022). Adverse Weather Target Detection Algorithm Based on Adaptive Color Levels and Improved YOLOv5. *Sensors*, 22(21), 1–21.
<https://doi.org/10.3390/s22218577>
- Yildirim, M., Çinar, A., & Cengil, E. (2022). Classification of the weather images with the proposed hybrid model using deep learning, SVM classifier, and mRMR feature selection methods. *Geocarto International*, 37(9), 2735–2745.
<https://doi.org/10.1080/10106049.2022.2034989>
- Yoon, J. H., Jung, J. W., & Yoo, S. B. (2024). Auxcoformer: Auxiliary and Contrastive Transformer for Robust Crack Detection in Adverse Weather Conditions. *Mathematics*, 12(5).
<https://doi.org/10.3390/math12050690>
- Yu, T., Kuang, Q., Hu, J., Zheng, J., & Li, X. (2021). Global-Similarity Local-Saliency Network for Traffic Weather Recognition. *IEEE Access*, 9, 4607–4615.
<https://doi.org/10.1109/ACCESS.2020.3048116>
- Yuan, Y., Wei, Y., Guo, Y., Chen, J., & Jiang, T. (2025). CME-YOLO: A Cross-Modal Enhanced YOLO Algorithm for Adverse Weather Object Detection in Autonomous Driving. *Big Data and Cognitive Computing*, 9(4).
<https://doi.org/10.3390/bdcc9040092>
- Zhang, Z., Ma, H., Fu, H., & Zhang, C. (2016). Scene-free multi-class weather classification on single images. *Neurocomputing*, 207, 365–373.
<https://doi.org/10.1016/j.neucom.2016.05.015>
- Zhao, B., Hua, L., Li, X., Lu, X., & Wang, Z. (2019). Weather recognition via classification labels and weather-cue maps. *Pattern Recognition*, 95, 272–284.
<https://doi.org/10.1016/j.patcog.2019.06.01>

7

Zhao, B., Li, X., Lu, X., & Wang, Z. (2018). A CNN-RNN architecture for multi-label weather recognition. *Neurocomputing*, 322, 47–57. <https://doi.org/10.1016/j.neucom.2018.09.048>

Zheng, C., Zhang, F., Hou, H., Bi, C., Zhang, M., & Zhang, B. (2016). Active Discriminative Dictionary Learning for Weather Recognition. *Mathematical Problems in Engineering*, 2016(1), 8272859. <https://doi.org/10.1155/2016/8272859>

Zheng, L., Lu, W., & Zhou, Q. (2023). Weather image-

based short-term dense wind speed forecast with a ConvLSTM-LSTM deep learning model. *Building and Environment*, 239(May), 110446. <https://doi.org/10.1016/j.buildenv.2023.110446>

Zhu, Z., Li, X., Zhai, J., & Hu, H. (2024). PODB: A learning-based polarimetric object detection benchmark for road scenes in adverse weather conditions. *Information Fusion*, 108(March), 300072. <https://doi.org/10.1016/j.inffus.2024.102385>