

Visuelle und KI-gestützte Risikoanalyse von Ausfällen der Straßenverkehrsinfrastruktur zur Vermeidung klimabedingter Schadensereignisse durch eine erhöhte Waldbrandgefahr

Nicolas Matheis, Sascha Henninger

(Nicolas Matheis, NicolasMaximilian.Matheis@lbm-kaiserslautern.rlp.de)

(Prof. Dr. rer. nat. Sascha Henninger, Rheinland-Pfälzische Technische Universität Kaiserslautern-Landau, Fachbereich Raum- und Umweltplanung, sascha.henninger@ru.rptu.de)

1 ABSTRACT

Der Klimawandel führt bereits heute zu einer deutlichen Zunahme klimabedingter Belastungen der Straßenverkehrsinfrastruktur in urbanen wie ländlichen Räumen. Extreme Wetterereignisse wie Starkregen, Überflutungen, Hitzeperioden oder Schnee- und Eisereignisse beeinträchtigen die Funktionsfähigkeit von Straßennetzen und gefährden die Verkehrssicherheit. Gleichzeitig sind viele bestehende Straßen- und Entwässerungssysteme historisch gewachsen und nur begrenzt an gegenwärtige und vor allem zu erwartende zukünftige Klimaextreme angepasst. Vor diesem Hintergrund adressiert dieser Beitrag den sogenannten Ausfall der Straßenverkehrsinfrastruktur, verstanden als kritische Überlastung des Straßennetzes infolge kumulativer klimatischer Stressoren. Ziel des Projektes ist die Entwicklung und prototypische Anwendung einer KI-gestützten Methodik zur Identifikation und Klassifikation klimatologisch gefährdeter Straßenzüge. Dabei soll ein systematischer, datenbasierter Ansatz entwickelt werden, der Klimaprojektionen, meteorologische Messreihen, topografische Informationen, Geodaten sowie verkehrsinfrastrukturelle Merkmale integriert und so eine räumlich möglichst hoch aufgelöste Risikobewertung erlaubt. Diese Arbeit schließt damit eine Lücke zwischen raumbezogener Klimaforschung, technischer Infrastrukturplanung und digitaler Risikobewertung. Methodisch folgt das Forschungsvorhaben einem mehrstufigen Design, einer theoretischen Fundierung in den Bereichen Klimapolitik, Stadt- und Geländeklimatologie, Infrastrukturvulnerabilität und KI-gestützter Risikoanalyse. Anschließend folgt der Aufbau eines referenzbasierten Datenmodells anhand ausgewählter urbaner und ruraler Modellregionen in denen Klimadaten, topografische Parameter und straßenbezogene Infrastrukturdaten zusammengeführt werden. Daraus resultierend folgt die Entwicklung eines KI-gestützten Analysemodells, das mittels linearer Regressionsmodellierung Risikomuster im Straßennetz identifiziert und in Form eines digitalen Risiko-Zwillings für das Jahr 2050 abbildet. Bei erfolgreicher Implementierung erfolgt die planerische Interpretation der Ergebnisse und die Ableitung von Handlungsstrategien für eine klimaresiliente Verkehrsplanung. Erwartet wird ein Instrumentarium, das Kommunen, Infrastrukturbetreibende und Planungsinstitutionen bei der frühzeitigen Identifikation kritischer Straßenzüge unterstützt. Damit können Entscheidungen zu Priorisierung, Anpassungsmaßnahmen und langfristiger Investitionssteuerung im Sinne klimaresilienter Stadt- und Regionalentwicklung fundiert getroffen werden. Als Validierungsgrundlage für die aufgestellte These wird das Thema der Waldbrandgefahr behandelt, um eine erste Aussage zum laufenden Arbeitsprozess liefern zu können. Der fortschreitende Klimawandel verändert die Häufigkeit, Intensität und saisonale Verteilung von Vegetationsbränden in Europa und damit auch die Risikolage für verkehrliche Infrastrukturen. Für die Straßenverkehrsinfrastruktur entstehen Belastungen sowohl unmittelbar durch thermische Einwirkungen und potenzielle Fahrbahnschäden als auch mittelbar durch Rauch, eingeschränkte Sichtweiten, Sperrungen, Umleitungen sowie durch Folgegefahren nach Bränden, z. B. erhöhte Erosions- und Massenbewegungsneigung infolge einer veränderten Vegetation. In waldreichen Regionen wie Rheinland-Pfalz besitzt die Waldbrandgefährdung daher eine infrastrukturelle Relevanz, die im Rahmen des Dissertationskontexts „Der Klimatologische Verkehrsinfarkt“ als eigenständiger Stressor in ein datenbasiertes, KI-gestütztes Bewertungs- und Klassifikationssystem integriert werden kann. Ziel ist es, eine Brücke zwischen Waldbrand-Indikatoren und einer segmentierten Risikoanalyse entlang des Straßennetzes zu bauen. Diese dient sowohl als Ausgangsbasis für den Ist-Zustand, als auch für ein Zukunftsszenario 2050 unter einem moderaten Erwärmungspfad (ca. +1,9 °C bis Mitte des Jahrhunderts, konsistent zu SSP (SharedSocioeconomicPathways) 2-4.5/RCP (RepresentativeConcentrationPathways) 4.5-nahen Annahmen), um belastbare und erklärbare Aussagen zu ermöglichen. Der vorliegende Beitrag fokussiert die Waldbrandgefahr als Pilotanwendung zur methodischen Validierung des übergeordneten, multirisikoorientierten Ansatzes. Die Auswahl begründet sich durch die Verfügbarkeit etablierter Indikatorik und europaweit harmonisierter Datenprodukte, die eine prototypische Umsetzung im Sinne eines digitalen Risiko-Zwillings ermöglichen können. Klimabedingte Ausfälle der Straßenverkehrsinfrastruktur treten

jedoch auch durch weitere Gefährdungen auf, insbesondere Starkregen, Überflutungen, Hangrutschungen oder Windwurf, deren Integration als Anschlussarbeit konzeptionell vorgesehen ist.

Keywords: Waldbrandgefahr, digitale Risikoanalyse, Planung, Klimaanpassung, Klimawandel

2 METHODIK UND VORGEHENSWEISE

Das methodische Vorgehen dieser wissenschaftlichen Arbeit folgt einem mehrstufigen, interdisziplinär angelegten Forschungsdesign, das theoriegeleitete Grundlagenarbeit, räumlich differenzierte Datensammlung, algorithmische KI-gestützte Entwicklung sowie eine praxisorientierte Interpretation und Ableitung von Handlungsstrategien miteinander verbindet. Ziel ist es, durch die Entwicklung und Anwendung einer KI-gestützten Methodik zur Risikoklassifikation in Rheinland-Pfalz klimatisch gefährdeter Straßenzüge einen Beitrag zur klimaresilienten Verkehrs- und Raumplanung zu leisten. Der Forschungsprozess ist dabei in vier aufeinander aufbauende Hauptphasen (Kapitel 2.1 bis 2.4) gegliedert, wie Abbildung 1 schematisch visualisiert.

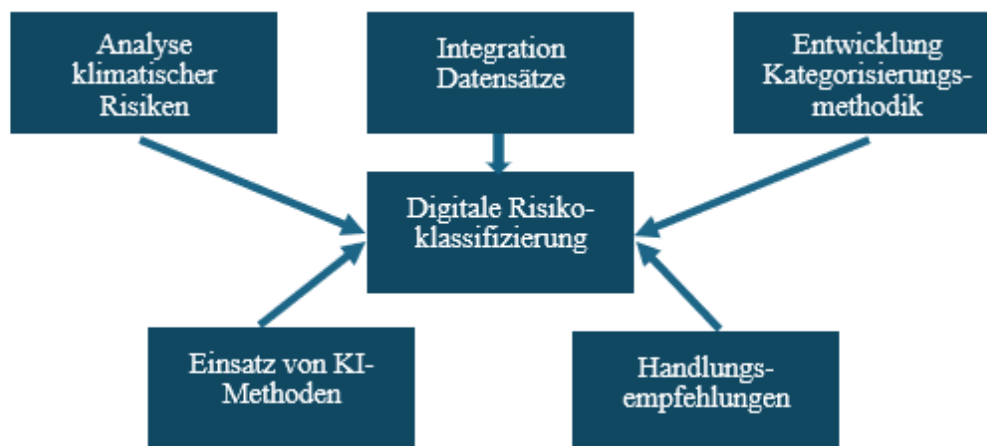


Abbildung 1 Übersicht der Methodik zur Erstellung einer KI-gestützten Risikoklassifizierung von Straßenzügen (eigene Darstellung)

2.1 Theoretische Fundierung und konzeptioneller Rahmen

In der ersten Phase werden die theoretischen Grundlagen erarbeitet, einschließlich Definitionen und Einordnung des Waldbrandkontextes sowie der Waldbrandgefahr. Zugleich wird der wissenschaftliche Konsens zum Klimawandel auf Basis aktueller Erkenntnisse zusammengeführt. Es folgen Prognosen zur Waldbrandgefährdung in Rheinland-Pfalz mit Blick auf geländeklimatologische Auswirkungen in urbanen und ruralen Räumen sowie Bedeutung, Funktion und Vulnerabilität der verkehrlichen Infrastruktur.

2.2 Datenbasiertes Referenzmodell

In der zweiten Phase erfolgt die empirisch-raumbezogene Operationalisierung durch die Auswahl geeigneter neuralgischer Referenzpunkte (Kreis-, Landes-, Bundesstraßen und Autobahnen). Hierbei werden die innerstädtische und ländliche Topografie berücksichtigt. Es wird eine strukturierte Datenerhebung durchgeführt, die alle für die Waldbrandgefahrenprognose relevanten Dimensionen abdeckt: Klimadaten topografische Daten, politische Grenzen (Rheinland-Pfalz), Infrastrukturdaten zum Zustand der Verkehrsanlagen, Waldkategorisierung, Waldbrandgefahrenindizes für Vergangenheit und Zukunft sowie rudimentär verfügbare Schadenshistorien früherer Waldbrandereignisse. Anschließend erfolgt eine qualitative Vor-Kategorisierung gefährdeter Straßenzüge ohne den Einsatz von KI auf Basis der Kriterienkataloge, die als Referenz für Trainings- und Validierungsdaten dient.

2.3 Entwicklung des KI-gestützten Analysemodells

Im dritten Schritt wird ein erklärbares Regressionsmodell entwickelt, das die Waldbrandgefährdung von Straßenzügen automatisiert bewertet und klassifiziert, indem die in Phase zwei erhobenen Daten prozessiert, harmonisiert und attributbezogen aufbereitet sowie FWI (Feuerwetterindex)-Abbildungsdateien, Topografie-, Vegetations- und Straßennetzdaten integriert werden. Hierzu kommt ein Supervised-Learning-Ansatz (Überwachtes Lernen) mit geobasierter Datenverknüpfung über GIS-Vektordaten zum Einsatz, um hochaufgelöste Gefährdungskartierungen zu erzeugen. Die Modellgüte wird anhand zuvor manuell

klassifizierter neuralgischer Punkte validiert, wobei Trainingsdaten sowohl synthetisch erzeugt als auch aus rudimentär dokumentierten Waldbrandereignissen abgeleitet werden. Die resultierende Risikoprofilierung wird als visuelle Ausgabekomponente gebildet, die straßengenau künftige besonders gefährdete Abschnitte identifizierbar macht.

2.4 Interpretation, Ableitung und Integration in Planungsstrategien

In der abschließenden Phase werden die mit dem KI-System generierten Risikobewertungen analysiert, evaluiert und in den planerischen Kontext eingeordnet. Ziel ist es, sowohl technisch belastbare als auch planerisch umsetzbare Handlungsempfehlungen abzuleiten. Die Arbeit mündet in eine strukturierte Synthese aus Analyseergebnissen, einem digitalen Modell und konzeptionellen Ansätzen, mit dem Ziel, einen konkreten Beitrag zur Verhinderung eines klimatologischen Verkehrsinfarkts zu leisten.

3 THEORETISCHE GRUNDLAGEN VON WALDBRANDGEFAHREN IN EUROPA

3.1 Problemstellung

Im Kontext des fortschreitenden Klimawandels gewinnt die Analyse von Extremwetterereignissen für die Resilienz der kritischen Infrastruktur zunehmend an Bedeutung. Während Starkregen und Hitze bereits intensiv beforscht werden, stellt die Waldbrandgefahr in Mitteleuropa eine wachsende, oft unterschätzte Bedrohung dar. Besonders in walddichten Bundesländern wie Rheinland-Pfalz (RLP) können Vegetationsbrände direkte physikalische Schäden an Fahrbahnen verursachen oder durch beispielsweise Rauchentwicklung zu gravierenden Verkehrsbeeinträchtigungen bis hin zum klimatologisch bedingten Verkehrsausfällen führen.

3.2 Wissenschaftliche Bedeutung der Waldbrandgefahr international und national

Grundsätzlich wird die meteorologische Komponente der Waldbrandgefährdung in der Praxis über Feuerwetter- bzw. Waldbrandindizes kategorisiert. Diese Indizes verdichten zentrale meteorologische Treiber der Zündwahrscheinlichkeit und Brandausbreitung zu einem skalierbaren Gefährdungsmaß. Hierunter fallen insbesondere Lufttemperatur, relative Luftfeuchte, Windgeschwindigkeit und Niederschlag (vgl. Tabelle 1). International gilt der kanadische „Fire Weather Index“ (FWI) als De-facto-Standard und wird in Europa beispielsweise über das „European Forest Fire Information System“ (EFFIS) des Copernicus Emergency Management Service bereitgestellt. Der FWI ist als System mehrerer Subindizes konzipiert, die unterschiedliche Feuchte- und Brennstoffeigenschaften abbilden und daraus Indikatoren der Ausbreitungsdynamik sowie potenziellen Brandintensität ableiten. Einfließende Attribute sind u. a. Fine Fuel Moisture Code, Duff Moisture Code oder Drought Code. Das Ergebnis ist ein sich kontinuierlich entwickelnder Index, der in operative Gefahrenklassen überführt werden kann und dadurch eine europaweite Vergleichbarkeit zum Thema „Waldbrandgefahren“ ermöglicht. (Umweltbundesamt 2023, S. 3–4; Europäische Kommission und European Environment Agency 2025).

Wetter	Klima	Vegetation	Topografie
Wind	Temperatur	Landnutzungsform	Entfernung zur Wegeinfrastruktur
Exposition des Waldes	Sonneneinstrahlung	Aufbau/Typ Wald	Hangneigung
Niederschlag	Saisonale Bodenfeuchte	Waldzustand/-dichte	Häufigkeit von Störungen
Luftfeuchte	Jahreszeiten	Wasserentnahmestelle	Höhenlage

Tabelle 1 Größen des Gefahrenpotenzials für Straßenverkehrsinfrastruktur eines Waldbrandes (eigene Darstellung; vgl. Landesforsten Rheinland-Pfalz, 2026)

In Deutschland wird die Waldbrandgefährdung traditionell durch den Waldbrand-Gefahrenindex (WBI) des Deutschen Wetterdienstes (DWD) kommuniziert. Der WBI ist historisch an nationale Indextraditionen (M-68-Ansatz) gekoppelt und wurde in den letzten Jahren konzeptionell modernisiert. Hierbei wurden Elemente des FWI-Systems und zugleich nationale Rahmenbedingungen, wie beispielsweise walddtyp- oder bodenbezogene Feuchtestrukturen stärker berücksichtigt. Der WBI wird in fünf Gefahrenstufen ausgewiesen und dient als etablierte Grundlage für forstliche und katastrophenschutzbezogene Lageeinschätzungen.

Ergänzend wird für offene Vegetationsformen (Gras- und Heideflächen) ein Grasland-Feuerindex (GLFI) verwendet, um brandrelevante Bedingungen außerhalb geschlossener Waldstrukturen adäquat abzubilden. Für eine wissenschaftlich fundierte Infrastruktur-Risikoanalyse ist entscheidend, dass beide Systeme WBI im nationalen und FWI im internationalen, kompatibel gedacht werden. Die Waldbrandlage lässt sich sinnvoll über Ereigniskennzahlen, wie Häufigkeit von Bränden und oder dem Expositionsmaße beschreiben. Da Brandhäufigkeit und Brandfläche regional und von Jahr zu Jahr stark schwanken sowie zudem durch Prävention sowie Waldmanagement beeinflusst werden, sind Jahresaggregate allein für Risikobewertungen nur bedingt aussagekräftig. Für infrastrukturelle Anwendungen ist insbesondere relevant, dass sich Auswirkungen häufig auf wenige, meteorologisch extreme Episoden konzentrieren. Dies bedeutet, dass einzelne intensive Brandlagen Verkehrsbeeinträchtigungen, Sperrungen und Störungsfolgen auslösen. Daher ist es methodisch zweckmäßig, feuermeteorologische Indikatoren wie Hochrisikotage als zentrale Prädiktoren in eine straßenbezogene Risikoanalyse aufzunehmen. Der DWD gibt aktuelle Waldbrandgefahrenkartierungen heraus aber keine langfristigen Risikoanalysen.

3.3 Datensätze zur Integration in GIS am Beispiel Rheinland-Pfalz

3.3.1 Zeitliche Modellierungsdatender Waldbrandgefahr mit Copernicus

Auf europäischer Ebene sind modellierte FWI-Datensätze des Copernicus Climate Data Store zu finden. Hierbei ist für die zeitlich konsistente Modellierung (Vergangenheit–Gegenwart–Zukunft) insbesondere der Copernicus-Datensatz “Firedangerindicatorsfor Europe from 1970 to 2098 derivedfromclimateprojections” einschlägig, da er FWI-basierte Indikatoren als Raster-Zeitreihen bereitstellt und damit sowohl Referenzperioden (ab 1970) als auch Projektionen bis 2098 in einem harmonisierten Datenmodell abbildet. Desweiteren können für das KI-Training auf Basis von Vergangenheitsdaten die Zeitintervalle von 1970 bis 2025 hinzugezogen werden, die ebenso das Worst-Case Szenario mit saisonalen in diesem Fall eigenständigen 4-Jahres Intervallen darstellt. Dabei wird der saisonal ermittelte FWI verwendet, um ein adäquates Abbild einer Bedrohungslage zu generieren. Zusätzlich werden von dem EFFIS bereitgestellte Downloaddaten des Wildfire Risk Viewers von Europa hinzugezogen und mehrere Parameter mit Bezug zur Risikoanalyse als separate Layer in GIS (Geoinformationssystem) eingearbeitet (u.a. High Risk Wildfire, Danger byweather und Basic Layer, wie Potential burnablelandproportion).(Copernicus 2026b, 2026a)

3.3.2 Straßennetz sowie straßenbezogene Vulnerabilitätslayermit Segment- und Objektattributen

Kernlayer für die spätere Modellierung ist die Segmentierung „RLP_Stressen_20mSegmentierung_OSM“ mit einer bewusst schlanken Attributtabelle (fid, osm_id, fclass, bridge, tunnel). Diese Minimalattribute sind für einen Prototypen vorteilhaft, weil sie die eindeutige Referenzierung über osm_id vorgibt. Zudem können sie eine erste Hierarchisierung über fclass (Straßenklassen) und eine strukturelle Kategorisierung über die Attribute bridge/tunnel ermöglichen. Die Herkunft aus OpenStreetMap ist für wissenschaftliche Reproduzierbarkeit geeignet, erfordert aber eine saubere Aufbereitung der vorliegenden Datensätze.Ergänzend liegen im Projekt straßenfachliche Layer des Landesbetriebes Mobilität Rheinland-Pfalz, mit deutlich reichhaltigeren Tabellen vor, u. a. „Strassennetz_RLP“ (z. B. Segment-/Abschnittslogik, Längen- und Knoteninformationsfelder) und „Netzknoten_RLP“ (Knotenattribute zur Netzlogik). Besonders relevant für die Ermittlung der Vulnerabilität sind die drei ermitteltenZustandslayer „Zustand_Bundesstrassen_2023“, „Zustand_Landstrassen_2022“, „Zustand_Kreisstrassen_2021“, deren Attributtabelle u. a. Klassen- und Segmentierungsfelder sowie Zustands-/Erfassungsvariablen enthalten (z. B. KLASSE, VNK/NNK, Stationierungslogik, Fahrstreifenzahl). Diese Layer erlauben eine direkte Abbildung infrastruktureller Anfälligkeiten, weil Brandfolgen für den Verkehr (Sperrungen, Einsatzverkehr, Sichtbehinderung) in der Praxis über Netzbedeutung und Zustand vermittelt werden und nicht allein über die existierende Brandgefahr. Als Objekt-Ergänzung liegt zudem „Strassenbauwerke_LBM“ vor (u. a. Bauwerkskennungen, Dimensionen wie Länge/Breite/Fläche), wodurch in der Klassifizierung kritische Einzelobjekte (Brücken/Ingenieurbauwerke) separat priorisierbar werden. Diese Straßen gelten als neuralgische Punkte, da sie eine große Menge an durchschnittlichem täglichem Verkehrsaufkommen (DTV) abdecken.Für eine netzrealistische Vulnerabilitätsbewertung sind zwei Erweiterungen zentral. Erstens die Wirkung eines Abschnittsausfalls auf die Netzfunktion, messbar über Umleitungsaufwand, Redundanz und potenzielle Abkopplung von Teilräumen. Zweitens die Nachfrageseite über Verkehrsbelastungen, etwa das DTV, wodurch die Bedeutung eines Abschnitts für die tägliche Mobilität quantitativ abgebildet werden kann.

Beide Größen sind grundsätzlich über Verkehrsmodelle, Verkehrszählungen oder modellbasierte Belastungskarten integrierbar und können im laufenden Forschungsprozess als zusätzliche Prädiktoren in das Regressionsmodell aufgenommen werden. (QuickOSM 2026; LBM Rheinland-Pfalz 2026)

3.3.3 Vegetations- und Landbedeckungslayer als Brandfläche

Genauere Datensätze lassen sich aus Landbedeckung und Vegetation sowie Zustandsdaten der Vegetation sowie Waldveränderungsdaten gewinnen. Zudem können diese sowohl mit topografischen Parametern (Höhenmodell, Hangneigung, Exposition) als auch mit Straßen- bzw. Infrastrukturdaten (OpenStreetMap, landesweite Open-Data-Geobasisbestände) verschnitten werden. Der Layer „RLP_Landbedeckung_mit_Attributen“ ergänzt diese Vegetationssicht um eine flächige Landbedeckungssystematik (Attributfelder sind u. a. LB_AKT, LN_AKT, SIE_AKT, VEG_AKT, METHOD_AKT, CLC21, Shape_Area), welche die einzelnen Vegetationsflächenarten widerspiegeln (Waldart und Landnutzungskategorisierung). Gerade „VEG_AKT“ und „CLC21“ sind für die Risikologik wertvoll, weil sie eine robuste Maskierung ermöglichen (z. B. Kategorisierung von Siedlung/ Verkehr vs. Vegetationsflächen) und die Expositionsrechnung gegen unbrauchbare Verknüpfungen absichern (z. B. keine Brennstoffzuweisung in versiegelten Bereichen).

3.3.4 Topografie- und Hydrographielayer als Bewertungsgrundlage

Im Projekt sind ein digitales Geländemodell „RLP_DGM_200“ (Raster) sowie kontextgebende Vektorlayer wie Höhenlinien, Flüsse und Seen eingebunden. Auch wenn dieser Layer nicht unmittelbar eine „Waldbrandgefahr“ darstellen, sind sie für eine wissenschaftlich belastbare Segmentbewertung zentral. Die Topografie beeinflusst Mikroklima und Austrocknung (z. B. Südhänge), Windkanalisierung und Erreichbarkeit für die Brandbekämpfung (Zugang, Barrieren, Wasserentnahmestellen). Methodisch werden aus dem DGM (Digitales Geländemodell) in GIS oder Python abgeleitete Sekundärvariablen erzeugt (u.a. Hangneigung, Exposition, Höhenlage, etc.). QGIS stellt hierfür reproduzierbare Processing-Algorithmen zur Verfügung. (QGIS 2026; LVermGeo Rheinland-Pfalz 2026)

3.3.5 Administrative Referenzlayer für das Bundesland Rheinland-Pfalz

Der drei eingebundenen „VG250“-Layer (Land, Kreise, Gemeinden) liefern die administrative Raumlogik und dienen dem Zuschnitt „Rheinland-Pfalz“, der aggregierten Ergebnisdarstellung (z. B. Risikoanalyse je Kreis oder Stadt). Die Datenbeschreibung der „VG250“ hebt genau diese hierarchischen Verwaltungsebenen und Schlüsselattribute als Kerninhalt hervor, sodass sich die oben beschriebenen Flächendaten auf die jeweiligen administrativen Grenzen zuschneiden lassen. (ebenda)

4 INTEGRATION UND VERARBEITUNG IN GIS

Ein belastbarer GIS-Workflow zur segmentbezogenen Bewertung entlang des Straßennetzes umfasst typischerweise folgende Schritte, die sich in GIS und Python reproduzierbar abbilden lassen. Zunächst wird ein konsistenter Untersuchungsraum definiert (hier: Rheinland-Pfalz) und das Straßennetz als Vektorlayer bereitgestellt. Um eine hochaufgelöste Bewertung des Gegenwartsmodells im Sinne infrastruktureller Vulnerabilität zu ermöglichen, kann das Straßennetz in regelmäßige Längensegmente, (in 20 m) unterteilt werden, sodass pro Segment ein eigener Attributsatz entsteht. Parallel werden die relevanten Waldbranddaten in GIS eingebunden, projektionstreu reprofilert und auf ein einheitliches Referenzsystem gebracht. In Rheinland-Pfalz befinden wir uns typischerweise in „ETRS89/UTM Zone 32N“. Anschließend erfolgt eine attributive Übertragung der genannten Rasterwerte auf die Straßensegmente, welches in Python zugeschnitten entsprechend der Zustandserfassungslayer angepasst wird. Dadurch erhält jedes Segment eine vorläufige Risikobeschreibung, die durch eine Vorgewichtung und Definition der Datensätze je Layer bestimmt wird. Ergänzend werden infrastrukturell und ökologisch relevante Layer erzeugt, die die Brandlast und die potenzielle Exposition beschreiben können. Darunter fallen, wie in Kapitel 3.2 erläutert wurde: Abstand zum Wald bzw. zur brandrelevanten Vegetationsklasse, Waldtypanteile (in %) im Umfeld (Nadel-/Laub-/Mischwald), topografische Parameter (Hangneigung, Höhenlinien, digitales Geländemodell), potenzielle Windkanalisierung in Tälern sowie straßenbezogene Merkmale (Straßenklasse, Verkehrsrelevanz, bauliche Charakteristika, Zustandsbewertung der Straße).

5 KLIMAPROJEKTION FÜR 2050

Die Projektion der Waldbrandgefährdung bis 2050 basiert auf einer Klimaprojektion, welche das Erwärmungsniveau um +1,9 °C bis Mitte des Jahrhunderts darstellt. Hierfür werden häufig SSP2-4.5/RCP4.5-nahe Pfade herangezogen, die eine fortschreitende, jedoch nicht extreme Zunahme thermischer Belastung und eine saisonal differenzierte Veränderung des Niederschlages abbilden. Für die Feueregefährdung sind dabei weniger Jahresmittelwerte entscheidend als die Kombination aus den genannten Größen des Gefahrenpotenzials für Straßenverkehrsinfrastruktur eines Waldbrandes aus Tabelle 1. In der praktischen Umsetzung werden daher aus Klimaprojektionen jene meteorologischen Parameter extrahiert, die für die Indexberechnung erforderlich sind (insbesondere Tageshöchsttemperatur, Niederschlag, Dürreindex, Wind, relative Feuchte bzw. abgeleitete Feuchtegrößen) (vgl. Kapitel 3.2). Liegen für den FWI keine frei verfügbaren, direkten Projektionraster vor, kann die Feueregefährdung für 2050 in einem transparenten Rechenweg aus den Projektionen abgeleitet werden, welches hier über die Copernicus-Daten angewandt wird. Entweder, indem FWI-Indikatoren aus frei verfügbaren Datensätzen direkt genutzt werden oder indem FWI/WBI-nahe Indikatoren mit Python-Bibliotheken berechnet und anschließend wieder als Rasterlayer bereitgestellt werden. Für eine wissenschaftliche Bewertung ist dabei die Unsicherheitsdimension mitzudenken, die ein KI-Algorithmus für die Zukunftsprojektion generieren kann. (IPCC 2026)

6 EINARBEITUNG IN PYTHON

6.1 Erklärung der IPCC-Logik Hazard-Exposure-Vulnerability und Vorgehensweise für Python

Für die Einarbeitung der Datenbasis in Python ist es methodisch sinnvoll, die in GIS bereits eingebundenen Layer als kohärentes Risikodatenpaket entlang der IPCC-Logik Hazard–Exposure–Vulnerability zu beschreiben. Die Gefährdung (Hazard) wird über Vergangenheitsdaten, feuermeteorologische Indizes (WBI/FWI) und deren Projektionen abgebildet, die Exposition (Exposure) über Vegetations-/Wald-/Landbedeckungs- und Topografielayer (Brennstoff, Austrocknung, Windkanalisierung) quantifiziert, und die Vulnerabilität (Vulnerability) wird über straßenbezogene Struktur- und Zustandsattribute operationalisiert. (Maarten K. van Aalst, Omar-Dario Cardona 2012, S. 69–72)

6.2 Darstellung in Python-Gegenwartsmodellierung

Für das Gegenwartsmodell wird die in GIS vorliegende Datenbasis in einen vollständig reproduzierbaren Python-Workflow überführt. Ziel ist ein prototypischer, segmentscharfer Risikoindex für das Straßennetz in Rheinland-Pfalz, der als Schulnote von 1 (sehr geringes Risiko) bis 5 (hohes Risiko) ausgegeben und als Attributspalte wieder in GIS visualisiert werden kann. Der Ansatz folgt der etablierten Risikologik, nach der klimabezogene Risiken aus dem Zusammenwirken von Hazard (Gefährdung), Exposure (Exposition/Brandlastnähe) und Vulnerability (Verwundbarkeit/Kritikalität) entstehen.

Die oben genannten Layer Straßenbasis (aufgeteilt in 20 m Segmente), Feuerwetter-Gefährdung (Hazard) mit den Gegenwartsindikatoren für Europa, Brennstoff-/Vegetationsaufbau des Landbedeckungslayers (Exposure), Topografie (A) aus dem DGM für Hangneigung sowie Höhenlinien (A) und zuletzt der Straßenzustand neuralgischer Punkte werden auf Kreis-, Land- und Bundesstraßen sowie deren Bauwerken (Vulnerability) abgebildet. Als zusätzliches Kriterium werden Wasserflächen hinzugezogen, da sie eine natürliche Risikoreduktion generieren.

Alle Teilindikatoren werden auf 0–1 skaliert (regelbasiert) und anschließend additiv zu einem Gesamt-Score aggregiert, welcher die Schulnotenbewertung wiedergibt. Die Startgewichtung priorisiert Hazard- und Exposure-Elemente, da Feuerwetter (Hazard) und Brandlastnähe (Exposition) primäre Treiber der Vegetationsbrandentwicklung sind. Vulnerability wird geringer gewichtet, weil sie im Gegenwartsmodell vor allem die infrastrukturelle Relevanz und Zustandserfassung des Straßensegments abbildet.

- Hazard H (0–1): H = (High Risk bis Low Risk Layer)
- Exposure E (0–1): Kombination aus
 - Waldnähe: Distanz zum nächsten Nadel- oder Laubwald-Polygon (Referenzdistanz 100 m als praxistaugliche Nähe-Schwelle, die auch in deutschen Waldbrandschutzkontexten als „Waldnähe“ verwendet wird) (stmelf Bayern 2026)

- Baumdichte: dichter Bewuchs > großflächige Vegetation
- Landbedeckung: Kategoriegewicht (Wald/ Heide > Gras > Siedlung/Gewässer)
- Vulnerability V (0–1):
 - Straßenkritikalität: Mapping aus fclass (Autobahn höher gewichtet als Anliegerstraße).
 - Zustand: normierte Zustandsnote (Note 1=gut bis 5=schlecht) aus ZEB-Daten
 - Bauwerke: bridge/ tunnel als Kritikalitätsmarker
- Topografie A (0–1): normierte Hangneigung, besonders Südhänge (aus DGM und Höhenlinienlayer abgeleitet)
- Gewässerflächen W (0-1): dargestellt in Flüssen, Seen und Wasserwegen (dargestellt im DGM und Landnutzungslayer)

Gesamt-Score für Gegenwartsmodellierung (eigene Darstellung):

$$R_{\text{now}} = 0,45 \cdot H + 0,30 \cdot E + 0,15 \cdot V + 0,10 \cdot A - 0,2 \cdot W$$

Diese Gewichtung ist als begründete Startannahmen zu verstehen (s. IPCC-Risikologik und FWI-Hazardpriorität) und werden für eine Zukunftsprojektion in Kapitel 6.3 über lineare Regression automatisiert „nachkalibriert“. Note=1 bei $R < 0,2$, 2 bei $0,2 - < 0,4$, 3 bei $0,4 - < 0,6$, 4 bei $0,6 - < 0,8$, 5 bei $\geq 0,8$. Diese Schwellen sind bewusst transparent und für Laien nachvollziehbar gestaltet. Alternativ sind Quantile-Berechnungen möglich, wenn eine gleichmäßige Klassenauslastung für schärfere Prognosen gewünscht ist.

6.3 Darstellung des KI-Algorithmus in Python für die Zukunftsprojektion

Der Einsatz von KI wird nicht als Selbstzweck verstanden, sondern als methodisches Instrument zur skalierbaren, konsistenten Gewichtung heterogener Einflussgrößen auf Segmentebene. Während eine regelbasierte Vorbewertung die Strukturierung und Nachvollziehbarkeit des Risikoansatzes ermöglicht, liefert ein erklärbares Regressionsmodell eine datenbasierte Kalibrierung der Parametergewichte und reduziert subjektive Setzungen. Der Mehrwert besteht damit in der transparenten Generalisierung von Einzelfallwissen auf die Fläche sowie in der späteren Erweiterbarkeit auf zusätzliche Gefährdungskategorien und Validierungsdaten. Im nächsten Schritt wird das Gegenwartsmodell nicht ersetzt, sondern als Trainings- und Referenzrahmen genutzt, um ein erklärbares, lineares Regressionsmodell zu erstellen. Die lineare Regression wird gewählt, weil sie auf Standardhardware effizient läuft und ihre Koeffizienten unmittelbar als nachvollziehbare Einflussgewichte interpretierbar bleiben. Für die Zukunftsprojektion wird der Hazard-Input durch den im Projekt vorhandenen Projektionslayer ersetzt (Danger- und Wildfireriskayer), der aus EFFIS-basierten Klimaprojektionen abgeleitet ist und Feuerwetterindikatoren bis zur Gegenwart bereitstellt. Darüber hinaus werden die statistischen Dokumentationen von historischen Waldbränden in Deutschland und Rheinland-Pfalz als vorgewichtete Zeitindikatoren zur Ableitung einer Zukunftsgefahr herangezogen. (BMEL-Statistik 2026; Landesforsten Rheinland-Pfalz 2026)

Praktische Mindestanforderung für den Test des KI-Modells im „Supervised Learning“:

Damit das Regressionsmodell „lernt“, wird eine Zielvariable benötigt. Da keine ausreichenden beobachteten Sperrungs-/Schadensdaten vorliegen, wird in GIS eine Referenzspalterisk_ref (1–5) für eine kleine, bewusst ausgewählte Stichprobe von Segmenten angelegt (20-m-Segment), basierend auf der Gegenwartslogik (Modellierung aus 6.2), lokaler Expertise (historische Statistiken) und Plausibilitätschecks (manuelles Gegenprüfen in Referenzregion) im laufenden Prozess. Das ist methodisch zulässig, solange die Konstruktion transparent dokumentiert wird, d.h. alle Zwischenschritte und Ergebnisse festgehalten werden. Ein erklärbares Kernmodell für die segmentbezogene Risikoklassifizierung ist die Ridge-Regression als lineares Regressionsmodell mit L2-Regularisierung. Dabei wird neben der Residuenquadratsumme ein Negativterm auf die Koeffizientengrößen minimiert, wodurch die Schätzungen bei korrelierten Prädiktoren (typisch bei Umwelt- und Infrastrukturdaten) stabilisiert und Überanpassung reduziert wird. Die Modellvorhersage ist ein kontinuierlicher Risiko-Score, der anschließend über transparente Übergangsergebnisse in das Schulnotensystem 1–5 überführt werden kann. Konzeptionell entspricht dies einer Risikofunktion, die Gefährdung, Exposition und Vulnerabilität systematisch zusammenführt, gemäß der Formel für den Gesamt-Score (vgl. Kapitel 6.2). Die Datenbasis wird hierfür als DataFrame organisiert („Frame“): Jede Zeile repräsentiert ein Straßensegment (optional je Jahr/Saison), jede Spalte einen

Visuelle und KI-gestützte Risikoanalyse von Ausfällen der Straßenverkehrsinfrastruktur zur Vermeidung klimabedingter Schadensereignisse durch eine erhöhte Waldbrandgefahr

modellrelevanten Prädiktor (z. B. Index-/Rasterwerte, Vegetations- und Infrastrukturmerkmale). Die zeitlich korrekte Validierung erfolgt als Rolling-Window-Ansatz: Für ein Zieljahr t wird das Modell mit den Jahren $t-10 \dots t-1$ trainiert und anschließend auf t getestet, um die Plausibilität bzw. Güte der Vorhersage außerhalb der Trainingsperiode zu prüfen. Für zeitgeordnete Daten ist diese Trennung zentral, um ein reines „Training auf Zukunftsdaten“ zu vermeiden. Letzendlich dient der KI-Algorithmus vereinfacht als Platzhalter für die gesamte Betrachtung der klimatisch bedingten Extremwetterereignissen und soll in dieser wissenschaftlichen Arbeit den Einsatz von Künstlicher Intelligenz in der Risikoanalyse zum Thema Waldbrandgefahr auf Plausibilität gegenprüfen, da sich die Finalisierung der gesamten Risikoanalyse noch im Arbeitsprozess befindet. (Pandas 2026; scikitlearn 2026)

7 AUFBAU DER PROGRAMMIERUNG ANHAND EINES BEISPIELS DER CODIERUNG:

Der folgende beispielhafte Teilprozess aus Abbildung 2 beschreibt den implementierten Workflow als reproduzierbare Prozesskette aus Datenharmonisierung, Feature-Extraktion und Ergebnisexport. Nach der Festlegung des Untersuchungsraums werden Straßenabschnitte als Segmentgeometrien bereitgestellt und mit Gefährdungs-, Expositions- und Vulnerabilitätsmerkmalen aus Raster- und Vektordaten angereichert. Die Merkmalermittlung erfolgt über Raster-Sampling sowie räumliche Joins und Zonenstatistiken; anschließend werden die Merkmale skaliert und zu einem Risiko-Score aggregiert. Der Ergebnislayer wird als GeoPackage exportiert und in GIS nach Notenklassen visualisiert. Durch den modularen Aufbau kann der Workflow um zusätzliche Variablen wie DTV oder Netzredundanz erweitert werden, ohne die Grundlogik zu ändern. Eine Veröffentlichung der Codierung ist zum jetzigen Zeitpunkt nicht geplant, da es sich hier um einen vorläufigen Prototyp handelt.

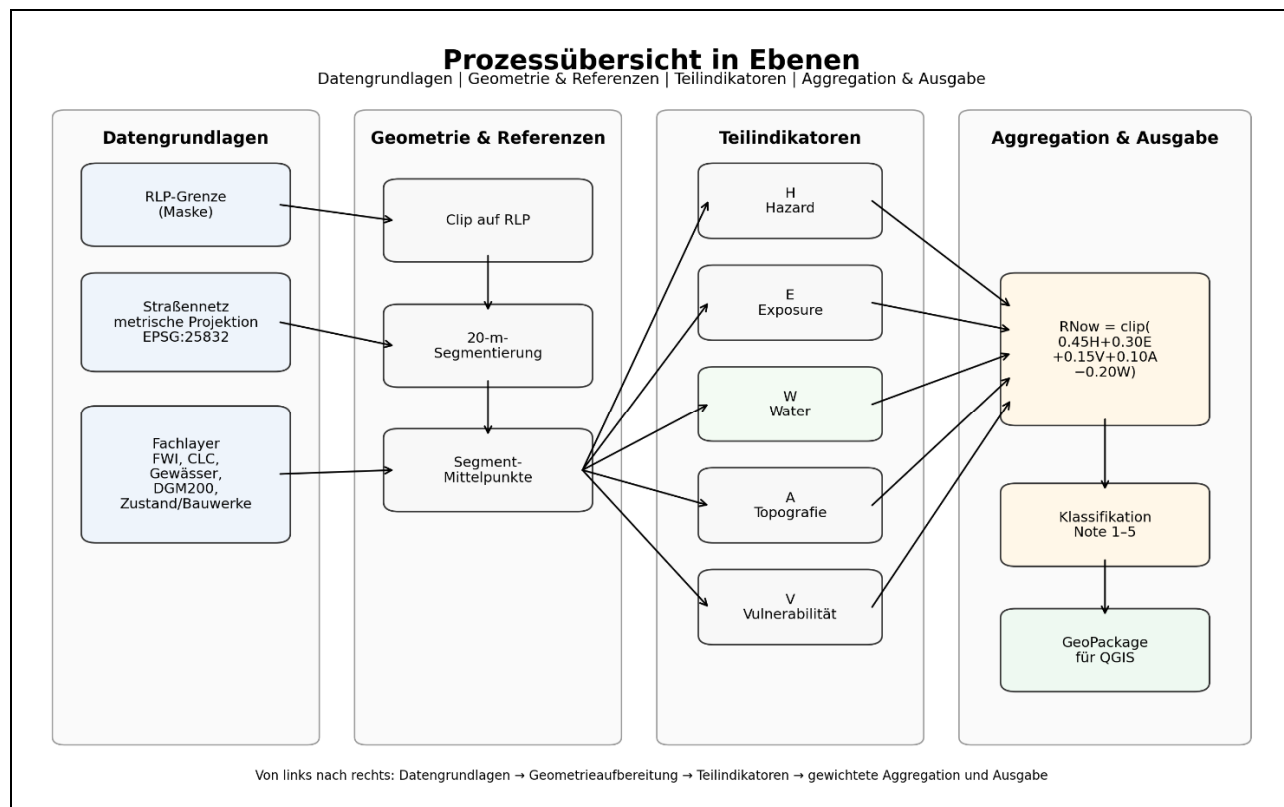


Abbildung 2 Prozessübersicht in Ebenen zur Erklärung der Codierung in Python (eigene Darstellung)

8 DARSTELLUNG DER ERGEBNISSE MIT KI-MODELLIERUNG

Der Kartenausschnitt der Bundesstraße 9 (B9) verdeutlichen die im Beitrag verfolgte Logik einer segmentscharfen Waldbrand-Risikoausgabe für Rheinland-Pfalz im Schulnotensystem (Note 1-5) der Gegenwart (vgl. Abbildung 3). Methodisch wird jedes Straßensegment als kleinste Bewertungseinheit genutzt, um eine priorisierbare Risikokarte zu erzeugen, die sich in GIS unmittelbar interpretieren lässt. Die räumlich kohärenten Bewertungen (z. B. Note 1-2 im städtischen Abschnitt Worms–Bobenheim-Roxheim) sind grundsätzlich den lokalen Gegebenheiten erwartbar und im Sinne des Beitrages plausibel, weil die

maßgeblichen Gefahrengrößen der Waldbrandgefährdung, insbesondere Feuerwetter-/Indexwerte (FWI bzw. FWI30 als kurzfristig wirksames Hazard-Signal) und großflächige Expositionsgrößen wie Vegetations- und Landbedeckungsklassen, räumlich nicht auf 20 m „sprunghaft“ wechseln, sondern typischerweise graduell variieren. So werden im unteren Abschnitt die Parameter Südhangexposition und größere Waldfläche im Gegensatz zum städtischen Raum um Worms herum mit seiner Nähe zum Rhein als plausible Ergebniswiedergabe für eine Risikoanalyse gewertet.



Abbildung 3 Ausschnitt der KI-gestützten Risikoanalyse in GIS für die Gegenwartsmodellierung im städtischen Raum: Worms B9 (eigene Darstellung).

Die Zukunftsprojektion für die B9 visualisiert die modellierte Veränderung der Waldbrandrisikoklassifizierung im Zieljahr 2050 (vgl. Abbildung 4). Im vorliegenden Scoring werden für die Zukunftsprojektion primär die Komponenten Hazard (H) und Exposure (E) angepasst, da insbesondere feuermeteorologische Bedingungen (z. B. Feuerwetterlagen) und vegetationsbezogene Expositionsmerkmale im Zuge des Klimawandels die stärksten systematischen Verschiebungen erwarten lassen.

Für die prototypische Zukunftsabbildung wurden bundesweite Waldbrandstatistiken auf den Untersuchungsraum Rheinland-Pfalz übertragen und im Rahmen eines linearen Regressionsansatzes zur Ableitung einer segmentscharfen Risikobewertung genutzt. Dabei ist methodisch hervorzuheben, dass Waldbrände in ihrer Realisierung häufig lokale Extremereignisse darstellen, deren Auftreten durch stochastische Faktoren und kleinräumige Randbedingungen geprägt ist. Eine realitätsnahe, flächendeckende Projektion auf ein gesamtes Infrastruktturnetz ist daher mit strukturellen Unsicherheiten verbunden. Vor diesem Hintergrund ist die in Abbildung 3 beobachtbare Verschlechterung der Noten gegenüber dem Gegenwartsmodell als Ausdruck einer moderaten Risikoerhöhung zu interpretieren, die vor allem durch einzelne, extremer werdende Trocken- und Hitzeepisoden plausibilisiert werden kann. Gleichzeitig bleibt der Unterschied zum Gegenwartsmodell insgesamt begrenzt. Dies wird als plausibel bewertet, da die Projektion im Prototyp keine abrupten Strukturbrüche des Gesamtsystems annimmt, sondern eine graduelle Verschiebung der dominanten Gefährdungs- und Expositionsparameter abbildet.

9 DISKUSSION UND FAZIT

Das Vorhaben konnte zeigen, dass sich aus einem begrenzten, in GIS verfügbaren Datenpaket, eine segmentscharfe Risikoanalyse für Straßeninfrastruktur ableiten und als Schulnotensystem von 1 bis 5 kartografisch darstellen lässt. Damit ist grundsätzlich nachweisbar, dass Zustandserfassungsdaten der Straßen gemeinsam mit Gefährdungs- und Expositionsparametern von einem Extremwetterereignis zu einem konsistenten Risikoabbild zusammengeführt werden können und eine verständliche räumliche Priorisierung

ermöglicht wird. Für Planungsbehörden ergibt sich daraus vor allem ein Orientierungsnutzen, da räumliche Muster sichtbar werden und eine erste Priorisierung von Prüf- und Maßnahmenbedarfen unterstützt wird. Für die Öffentlichkeit kann ein solcher Ansatz als Hinweisprodukt zur transparenten Risikokommunikation dienen, vergleichbar mit etablierten Gefahrenhinweiskarten (Hochwasser- oder Starkregengefahrenkarten), sofern Grenzen und Unsicherheiten klar benannt werden.



Abbildung 4 Ausschnitt der KI-gestützten Risikoanalyse in GIS für die Zukunftsprojektion: B9 bei Worms (eigene Darstellung)

Die Aussagekraft bleibt in der vorliegenden Form jedoch deutlicheingeschränkt.Viele Definitionen, Skalierungen und Gewichtungen wurden vereinfacht und das KI-Modell wurde nur rudimentär umgesetzt. So sind die Noten primär als plausibilisierte Klassifikation zu verstehen und nicht als belastbare Vorhersage realer Schadensereignisse. Hinzu kommen Risiken durch unvollständige oder fehlerhafte Eingangsdaten, durch Maßstabsunterschiede zwischen feiner Segmentierung und größeren Gefährdungsrastern sowie durch die grundsätzliche Schwierigkeit, lokal-extreme Waldbrandereignisse realitätsnah auf ein gesamtes Verkehrsinfrastruktturnetz zu übertragen. Segmentbezogene Handlungsempfehlungen konnten zudem nicht abgeleitet werden, da der Prototyp hierfür noch nicht ausreichend kalibriert, validiert und um wirksspezifische Entscheidungskriterien erweitert ist.

Für einen belastbaren, übertragbaren Prototyp sind daher eine systematische Datenharmonisierung, die Einbindung beobachteter Zielgrößen zur Validierung, eine empirische Kalibrierung der Gewichte mit erkläraren Modellen sowie eine explizite Unsicherheitsanalyse erforderlich. Zudem benötigt es ein Vielfaches an Rechenkapazität, wofür ein dafür ausgelegtes Rechenzentrum zum Einsatz kommen muss. Erst auf dieser Grundlage kann der Ansatz von einer demonstrierten Machbarkeit zu einem verlässlichen Instrument weiterentwickelt werden, das sowohl fachlich robuste Priorisierungen ermöglicht als auch die Grundlage für konkrete, segmentbezogene Maßnahmenentscheidungen liefert.

10 LITERATURVERZEICHNIS

- BKG (2025): Aufstellung der Datenurheber/Bereitsteller: Landbedeckungsmodell für Deutschland LBM-DE2021. ▪ ATKIS Basis-DLM: © GeoBasis-DE / BKG (2021) ▪ Digitale Orthophotos (DOPs): © GeoBasis-DE / BKG (2023) ▪ Landbedeckungsmodell für Deutschland 2018: © GeoBasis-DE / BKG (2020) ▪ Sentinel2 Satellitenbilder: © Europäische Union, enthält Copernicus Sentinel-2 Daten 2021 ▪ SPOT 6/7 Satellitenbilder: © Airbus DS/Spot Image (2021): BKG.
- BMEL-Statistik (2026): Waldbrandstatistik. Online verfügbar unter <https://www.bmel-statistik.de/forst-holz/waldbrandstatistik/>, zuletzt aktualisiert am 16.01.2026, zuletzt geprüft am 16.01.2026.

- CISA (2023): Wildfires | CISA. Hg. v. Cyber and Infrastructure Security Agency. Online verfügbar unter <https://www.cisa.gov/topics/critical-infrastructure-security-and-resilience/extreme-weather/wildfires>, zuletzt aktualisiert am 09.05.2025, zuletzt geprüft am 09.05.2025.
- Copernicus (2024): Forest Fires in Europe, Middle East and North Africa 2023. Unter Mitarbeit von Tracy Durrant, Roberto Boca, PIERALBERTO MAIANTI, GIORGIO LIBERTÀ, DUARTE OOM, ALFREDO BRANCO et al. Luxembourg: Publications Office. Online verfügbar unter https://data.effis.emergency.copernicus.eu/effis/reports-and-publications/annual-fire-reports/Annual_Report_2023.pdf, zuletzt geprüft am 03.01.2026.
- Copernicus (2026a): EFFIS Wildfire Risk Viewer mit Downloadbereich. EU Copernicus. Online verfügbar unter <https://forest-fire.emergency.copernicus.eu/apps/fire.risk.viewer/>, zuletzt aktualisiert am 31.07.2025, zuletzt geprüft am 13.01.2026.
- Copernicus (2026b): Your requests – Climate Data Store. Fire danger indicators for Europe from 1970 to 2098 derived from climate projections. Online verfügbar unter <https://cds.climate.copernicus.eu/requests?tab=all>, zuletzt aktualisiert am 09.01.2026, zuletzt geprüft am 09.01.2026.
- DWD (2020): Dokumentation Waldbrandgefahrenindex (WBI). Online verfügbar unter https://www.dwd.de/DE/fachnutzer/landwirtschaft/dokumentationen/allgemein/wbx_erlaeuterungen.pdf;jsessionid=E909D00818E026DE8A4BB8CDA6FFCCDC.live21062?__blob=publicationFile&v=12, zuletzt geprüft am 25.11.2025.
- DWD (2025a): Deutscher Wetterdienst – Waldbrand-Gefahrenindex. Online verfügbar unter <https://www.wettergefahren.de/warnungen/indizes/waldbrand.html>, zuletzt aktualisiert am 25.11.2025, zuletzt geprüft am 25.11.2025.
- DWD (2025b): Wetter und Klima – Deutscher Wetterdienst – Übersicht – Erläuterungen zum Waldbrandgefahrenindex. Online verfügbar unter https://www.dwd.de/DE/fachnutzer/landwirtschaft/dokumentationen/allgemein/basis_waldbrandgefahrenindex_doku.html.com, zuletzt aktualisiert am 25.11.2025, zuletzt geprüft am 25.11.2025.
- Europäische Kommission; European Environment Agency (2025): Fire Weather Index | Indicators | Discover the key services, thematic features and tools of Climate-ADAPT Climate-ADAPT. Online verfügbar unter <https://climate-adapt.eea.europa.eu/en/metadata/indicators/fire-weather-index>, zuletzt aktualisiert am 25.11.2025, zuletzt geprüft am 25.11.2025.
- IPCC (2026): Chapter 4 | Climate Change 2021: The Physical Science Basis. Online verfügbar unter <https://www.ipcc.ch/report/ar6/wg1/chapter/chapter-4/>, zuletzt aktualisiert am 04.10.2024, zuletzt geprüft am 20.01.2026.
- Landesforsten Rheinland-Pfalz (2026): Waldbrand. Landesforsten Rheinland-Pfalz. Online verfügbar unter <https://www.wald.rlp.de/bewahren/waldschutz-schutz-vor-gegenspielern/waldbrand>, zuletzt aktualisiert am 11.01.2026, zuletzt geprüft am 11.01.2026.
- LBM Rheinland-Pfalz (2026): Strassennetz RLP, Zustand_Bundesstrassen_2023 Zustand_Landstrassen_2022, Zustand_Kreisstrassen_2021, Netzknoten_RLP, Strassenbauwerke_LBM: LBM Rheinland-Pfalz. Nicht veröffentlichtes digitales Speichermedium, zuletzt geprüft am 13.01.2026.
- LVerGeo Rheinland-Pfalz (2026): Digitale Geländemodelle (DGM) [GeoShop RLP]. Online verfügbar unter https://geoshop.rlp.de/digitale_gelaendemodelle/digitale_gelaendemodelle_dgm.html, zuletzt aktualisiert am 14.01.2026, zuletzt geprüft am 14.01.2026.
- Maarten K. van Aalst, Omar-Dario Cardona (2012): 2 – Determinants of Risk: Exposure and Vulnerability. Online verfügbar unter https://www.ipcc.ch/site/assets/uploads/2018/03/SREX-Chap2_FINAL-1.pdf, zuletzt geprüft am 09.01.2026.
- Pandas (2026): pandas.DataFrame – pandas 2.3.3 documentation. Online verfügbar unter <https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.html.com>, zuletzt aktualisiert am 14.01.2026, zuletzt geprüft am 20.01.2026.
- QGIS (2026): 24.1. QGIS algorithm provider – QGIS Documentation documentation. Online verfügbar unter https://docs.qgis.org/3.40/en/docs/user_manual/processing_algs/qgis/index.html?utm_source=chatgpt.com, zuletzt aktualisiert am 07.01.2026, zuletzt geprüft am 09.01.2026.
- QuickOSM (2026): Map preset – QuickOSM- QGIS. Online verfügbar unter <https://docs.3liz.org/QuickOSM/user-guide/map-preset/>, zuletzt aktualisiert am 02.01.2026, zuletzt geprüft am 09.01.2026.
- scikitlearn (2026): 1.1. Linear Models. Online verfügbar unter https://scikit-learn.org/stable/modules/linear_model.html.com, zuletzt aktualisiert am 20.01.2026, zuletzt geprüft am 20.01.2026.
- stmelf Bayern (2026): Waldbrand – Bayerisches Staatsministerium für Ernährung, Landwirtschaft, Forsten und Tourismus. Online verfügbar unter <https://www.stmelf.bayern.de/wald/waldschutz/waldbrand-feuer-in-waldoekosystemen/index.html>, zuletzt aktualisiert am 15.01.2026, zuletzt geprüft am 15.01.2026.
- Umweltbundesamt (2016): Übersicht Klimawirkungen. Online verfügbar unter <https://www.umweltbundesamt.de/themen/klima-energie/klimafolgen-anpassung/werkzeuge-der-anpassung/klimalotse/uebersicht-betroffenheiten>, zuletzt aktualisiert am 08.05.2025, zuletzt geprüft am 08.05.2025.
- Umweltbundesamt (2023): FW-I-8_Indikator_Waldbrand_Waldbrandgefaehrdung. Bosch & Partner GmbH (Konstanze Schönthaler) i. A. des Umweltbundesamtes / KomPass, FKZ 3711 41 106. Online verfügbar unter https://www.umweltbundesamt.de/sites/default/files/medien/5612/dokumente/fw-i-8_indikator_waldbrand_waldbrandgefaehrdung.pdf, zuletzt geprüft am 28.12.2025.
- Umweltbundesamt (2024): Waldbrände. Online verfügbar unter <https://www.umweltbundesamt.de/daten/landforstwirtschaft/waldbraende#waldbrände-in-deutschland>, zuletzt aktualisiert am 09.05.2025, zuletzt geprüft am 09.05.2025.
- Umweltbundesamt (2026): Waldbrände. Online verfügbar unter <https://www.umweltbundesamt.de/daten/landforstwirtschaft/waldbraende#waldbrände-in-deutschland>, zuletzt aktualisiert am 03.01.2026, zuletzt geprüft am 03.01.2026.