

# Machbarkeitsstudie zur Prädiktion von Waldbränden aus Sentinel-2 Zeitreihen

JANIK STEIER<sup>1</sup>, LINA E. BUDDE<sup>1</sup> & DOROTA IWASZCZUK<sup>1</sup>

*Zusammenfassung: Eine frühzeitige Vorhersage von Waldbränden ist entscheidend, um die negativen Auswirkungen und Gefahren für Ökosysteme und Menschen zu minimieren. Herkömmliche Waldbrandprädiktionssysteme, wie das weitverbreitete Canadian Forest Fire Danger Rating System, generieren ihre benötigten Informationen in der Regel durch lokale Messstationen auf der Erdoberfläche. Dies führt zu hohen operativen Kosten und macht es daher kaum möglich diese Systeme flächendeckend zu unterhalten. In der vorliegenden Studie wird anhand von multispektralen Sentinel-2 Zeitreihen sowie verschiedener Maschine Learning Modelle, eine Waldbrandprädiktion vorgenommen und damit eine kostengünstige und flächendeckende Alternative zu herkömmlichen Waldbrandprädiktionssystemen bereitgestellt. Für die Evaluierung der erarbeiteten Methodik wird ein Waldbrandereignis im Mai 2021 in Griechenland untersucht. Das leistungsstärkste implementierte Modell prädiziert 81 % des tatsächlichen Waldbrandgebiets korrekt voraus.*

## 1 Einleitung

Waldbrände sind ein global auftretendes Phänomen und in vielen Regionen ein Bestandteil der natürlichen Prozesse in einem Ökosystem. Ökosysteme können von Waldbränden profitieren, da sie tote Vegetation beseitigen, eingeschlossene Nährstoffe freisetzen und neues Vegetationswachstum unterstützen.

Dennoch treten Waldbrände häufig in Gebieten auf in denen sie eine Gefahr für die natürliche Vegetation und den Lebensraum von Tieren und Menschen darstellen.

Desweiteren haben Waldbrände aufgrund der Freisetzung von Treibhausgasen einen signifikanten Anteil am Klimawandel. So lassen sich 15 % der globalen Treibhausgase auf Waldbrände zurückführen. Vor allem bei der Freisetzung von Kohlenstoffmonoxid und Methan, mit einem Anteil von 32 % und 10 % an den globalen Emissionen, spielen Waldbrände eine wichtige Rolle. Zudem erhöht ein wärmeres Klima das Waldbrandrisiko sowie die Ausbreitung und die Auftrettsfrequenz von Waldbränden. Das wiederum bedingt eine noch höhere Freisetzung von Treibhausgasen (HIRSCHBERGER 2016).

Eine frühzeitige Vorhersage von Waldbränden ist daher entscheidend, um die negativen Auswirkungen und Gefahren für Ökosysteme und Menschen zu minimieren.

Das weitverbreitetste Waldbrandprädiktionssystem ist das Canadian Forest Fire Danger Rating System (CFFDRS), welches von vielen Organisationen wie z.B. dem European Forest Fire Information System oder dem New Zealand Forest Service übernommen wird.

Herkömmliche Waldbrandprädiktionssysteme mit einem umfassenden Waldbrandvorhersagemodell arbeiten mit einer Vielzahl an wetter- und bodenbezogenen Variablen und den daraus

---

<sup>1</sup> Technische Universität Darmstadt, Fachbereich Bau- und Umweltingenieurwissenschaften, Fachgebiet Fernerkundung und Bildanalyse, Franziska-Braun-Straße 7, D-64287 Darmstadt, E-Mail: [janik.steier, lina.budde, dorota.iwaszczuk]@tu-darmstadt.de

entstehenden komplexen Beziehungen. So verwendet das CFFDRS unter anderem Informationen über das Entzündungsrisiko, das Wetter, die Topographie und die Vegetation, um das Waldbrandauftreten und das Brandverhalten vorherzusagen. Diese Art von Vorhersagemodellen leidet allerdings unter zwei wesentlichen Nachteilen. Zum einen müssen oftmals vereinfachte Annahmen getroffen werden, um die komplexen Beziehungen annähernd zu beschreiben. Zum anderen werden viele Informationen und Daten für die Modelle mit Instrumenten und lokalen Messstationen am Erdboden gewonnen. Das führt zu hohen operativen Kosten und zu einer Datengewinnung in einem beschränkten spezifischen Gebiet. Vor allem die hohen operativen Kosten können Entwicklungsländer wie beispielsweise Indonesien abschrecken, in flächendeckende Systeme zur Waldbrandprädiktion zu investieren (YANG et al. 2021).

Eine globale Prädiktionskarte des Waldbrandrisikos bietet das Global Wildfire Information System (GWIS) an. Dabei arbeitet das System auf Grundlage von meteorologischen Vorhersagedaten und stellt unter anderem den Candian Forest Fire Weather Index, welcher eine Subkomponente des CFFDRS ist, dar. Der Vorhersagezeitraum liegt bei GWIS zwischen einem und neun Tagen. Das Waldbrandrisiko wird in einer räumlichen Auflösung von etwa 8 km visualisiert.

Für die meisten Waldbrandrisikokarten werden statische Informationen wie Topographie, Vegetationsdichte und -feuchtigkeit aus satellitengestützten Fernerkundungsdaten bereits eingesetzt (MICHAEL et al. 2020). Ebenfalls sind Machine Learning Algorithmen in der Waldbrandprädiktion etabliert (ABID 2021). Dennoch ist die Prädiktion von Waldbränden ausschließlich aus satellitengestützten Fernerkundungsdaten und Machine Learning Modellen ein unbekannteres und neueres Forschungsfeld.

Die veröffentlichte Studie von YANG et al. (2021) erwies erst kürzlich, dass mittels neuronaler Netze und lediglich multispektraler Landsat 7 Daten eine effektive Prädiktion von Waldbränden möglich ist.

Daher wird in der vorliegenden Studie untersucht, ob auf Basis von lediglich multispektralen Sentinel-2 Daten in Kombination mit Machine Learning Modellen eine effektive, kostengünstige und flächendeckende Alternative zur Waldbrandprädiktion geschaffen werden kann.

Bei der Beantwortung dieser Forschungsfrage stehen, neben der eigentlichen Vorhersage, auch eine räumlich hohe Auflösung ( $< 30$  m) der Daten und die globale Anwendbarkeit der Methodik im Vordergrund. Dadurch lassen sich aus den Prädiktionsergebnissen hochauflösende und global verfügbare Waldbrandrisikokarten ableiten.

## 2 Methodik

In dieser Studie werden verschiedene Machine Learning Modelle zur Vorhersage eines binären numerischen Wertes, der das Auftreten bzw. das Nichtauftreten eines Waldbrandereignisses, repräsentiert, verglichen.

Die Vorhersage des Waldbrandes wird anhand der zeitlichen Entwicklung bzw. der Zeitreihen zweier Vegetationsindizes vor dem Brandereignis getroffen. Hierzu wird ein eigener Eingangsdatensatz, welcher die dynamische Entwicklung der Vegetationsindizes repräsentiert, sowie ein eigener Referenzdatensatz, der ein einzelnes Waldbrandgebiet abbildet, generiert.

Zur Prädiktion des Waldbrandgebiets werden die folgenden drei überwachten Machine Learning Modelle eingesetzt: eine logistische Regressionsanalyse und zwei künstliche neuronale Netze. Die künstlichen neuronalen Netze sind ein Fully Connected Network, mit einer verborgenen Schicht und ein Long Short Term Memory Network, welches eine spezielle Form des Recurrent Neural Networks ist.

Der untersuchte Waldbrand fand im Mai 2021 in der Region Attika und Peloponnes in Griechenland statt. Das gesamte Untersuchungsgebiet umfasst eine Fläche von 386 km<sup>2</sup>, davon sind ca. 51,3 km<sup>2</sup> Waldbrandgebiet.

## 2.1 Generierung der Eingangs- und Referenzdaten

### 2.1.1 Referenzdaten

Die Referenzdaten (engl.: Ground-Truth) enthalten Informationen über die wahren Begebenheiten anhand derer die Machine Learning Modelle in der Trainingsphase lernen und die vorhergesagten Ergebnisse der Modelle in der Testphase verglichen werden. Die im Referenzdatensatz enthaltenen Daten entsprechen der Definition des Labels in den Machine Learning Modellen. In dieser Studie enthält der Referenzdatensatz Informationen über das tatsächliche Waldbrandgebiet im Untersuchungsraum.

Die Kartierung der verbrannten Fläche und des Verbrennungsgrades des zu untersuchenden Waldbrandereignisses wird anhand des Indizes Normalized Burn Ratio (NBR) bzw. der Differenz von multitemporal aufgenommenen NBRs (dNBR) vorgenommen:

Der Index des NBR (1) macht sich die Eigenschaft zu Nutze, dass gesunde Vegetation eine hohe Reflektion der elektromagnetischen Strahlung im nahinfraroten Wellenlängenbereich (NIR) und eine geringe Reflektion im kurzwelligen infraroten Wellenlängenbereich (SWIR) aufweist, wohingegen kürzlich verbrannte Flächen sich genau umgekehrt verhalten. Sie besitzen eine geringe Reflektion im NIR und eine hohe Reflektion im SWIR. (SERCO ITALIA SPA 2017; UN-SPIDER o.D.)

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} = \frac{B_8 - B_{12}}{B_8 + B_{12}} = \frac{842 \text{ nm} - 2190 \text{ nm}}{842 \text{ nm} + 2190 \text{ nm}} \quad (1)^2$$

Die Identifikation einer kürzlich verbrannten Fläche und die Unterscheidung derselben von kahlem Boden und nicht bewachsenen Gebieten sowie die Bestimmung des Verbrennungsgrades geschehen anhand der dNBR. Die dNBR ist die Differenz zwischen der NBR vor dem Waldbrand und der NBR nach dem Waldbrandereignis (2). Der Wertebereich der dNBR liegt in der Regel zwischen -0,5 und 1,3, wobei ein hoher dNBR-Wert ein Indikator einer schweren Verbrennung ist und ein negativer Wert auf das Nachwachsen der Pflanzen nach dem Brand hindeuten könnte (SERCO ITALIA SPA 2017, UN-SPIDER o.D.).

$$dNBR = NBR_{\text{vor Brandereignis}} - NBR_{\text{nach Brandereignis}} \quad (2)$$

---

<sup>2</sup> In der Formel 1,3 und 4 entspricht die Variable B dem verwendeten multispektralen Kanal bzw. Band der Sentinel-2 Satelliten zur Berechnung des jeweiligen Index. Die Wellenlänge der Variable B ist im letzten Term der Formel beschrieben.

Anhand einer schwellenwertbasierten Klassifikation der dNBR wird das Untersuchungsgebiet in ein Waldbrandgebiet ( $dNBR \geq 0,27$ ) und ein vom Waldbrand nicht betroffenes Gebiet ( $dNBR < 0,27$ ) binär unterteilt. Eine  $dNBR \geq 0,27$  entspricht per Definition von UN-SPIDER (o.D.) einem moderaten bis leichtem Verbrennungsgrad.

Die verwendeten Bänder, für die Berechnung der NBR, der Sentinel-2 Satelliten liegen in einer maximalen räumliche Auflösung von 20 m vor. Somit weist der Referenzdatensatz ebenfalls eine räumliche Auflösung von 20 m auf.

### 2.1.2 Eingangsdaten

Für die Prädiktion des Waldbrandereignisses werden in dieser Studie Zeitreihen von Aufnahmen des Untersuchungsgebiets als Eingangsdaten für die Machine Learning Modelle verwendet. Die Eingangsdaten enthalten Informationen über die zeitlichen Verläufe der Vegetationsdichte und -gesundheit sowie der Vegetationsfeuchtigkeit im Untersuchungszeitraum. Zur Bestimmung dieser Informationen werden zwei Indizes gewählt: der Normalized Difference Vegetation Index (NDVI) und der Normalized Difference Infrared Index (NDII).

Der NDVI (3) wird in dieser Studie als Indikator für den Gesundheitszustand und die Dichte der Vegetation interpretiert. In Anbetracht eines Waldbrandes ist die Vegetationsdichte auch als hypothetische Brennstoffdichte zu werten.

$$NDVI = \frac{NIR - Rot}{NIR + Rot} = \frac{B 8 - B 4}{B 8 + B 4} = \frac{842 \text{ nm} - 665 \text{ nm}}{842 \text{ nm} + 665 \text{ nm}} \quad (3)$$

Der NDII (4) ist ein Indikator für den Feuchtigkeitszustand der Vegetation.

$$NDII = \frac{NIR - SWIR}{NIR + SWIR} = \frac{B 8 - B 11}{B 8 + B 11} = \frac{842 \text{ nm} - 1610 \text{ nm}}{842 \text{ nm} + 1610 \text{ nm}} \quad (4)$$

Die Nutzung von Zeitreihen für die Prädiktion von Waldbränden fußt auf der Annahme, dass sich durch die Betrachtung der Indizes NDVI und NDII über einen Beobachtungszeitraum bzw. die Inklusion dynamischer Informationen die Prädiktion von Waldbrandrisiken verbessert. Die dynamische Betrachtung der Indizes enthält Informationen über die Vegetationsstadien sowie den Trockenheitszustand der Vegetation über die Zeit. Die Vegetationsstadien sind ebenfalls ein Indikator für die verfügbare Menge und Typ des Brennstoffs für den Waldbrand (MICHAEL et al. 2020).

Die Eingangsdaten umfassen Informationen über die Vegetation des Untersuchungsgebiets für die Dauer von etwa einem Jahr vor dem Waldbrandereignis. Die Aufnahmezeitpunkte sind so gewählt, dass für jede Woche in dem Jahr vor dem Waldbrandereignis jeweils ein Indexwert in den Eingangsdatensatz einfließt. Der erste Zeitpunkt in dem Eingangsdatensatz liegt neun Tage vor dem Brandereignis. Somit generieren die Machine Learning Modelle eine theoretische Prädiktion der Labels „Waldbrandgebiet“ und „kein Waldbrandgebiet“ für neun Tage in der Zukunft für das Untersuchungsgebiet.

## 2.2 Machine Learning Modelle

Für die Vorhersage des Waldbrandgebiets werden eine logistischen Regressionsanalyse (LR), ein Fully Connected Network (FCN) mit einen Hidden Layer und ein Long Short Term Memory

Network (LSTM) anhand des Eingangs- und Referenzdatensatzes trainiert und getestet. Das Ausgabesignal der Modelle ist in dieser Studie als Vorhersage über das Auftreten eines Waldbrandes in einem Gebiet bzw. in einem Pixel zum Zeitpunkt des Waldbrandereignisses (WE) zu interpretieren.

Die logistische Regressionsanalyse ist ein „klassisches“ Model für die Anwendung der binären Klassifikation und wird als linearer Klassifikator bezeichnet. Das bedeutet, dass die logistische Regressionsanalyse sich besonders für die Vorhersage von linear trennbaren Klassen, in diesem Fall der Klassen „Waldbrandgebiet“ und „kein Waldbrandgebiet“, eignet. Ein neuronales Netzwerk, wie das in dieser Arbeit verwendete Fully Connected Network, besteht aus einer Serie von vollständig verbundenen Schichten. Die logistische Regressionsanalyse kann im Zusammenhang mit neuronalen Netzen als Teilmenge bzw. als eine Schicht des neuronalen Netzwerkes verstanden werden. Es ist weitverbreitet eine logistische Sigmoid-Funktion (zu der auch die logistische Funktion gehört) als Aktivierungsfunktion in den versteckten Schichten der neuronalen Netzwerke zu verwenden. Aktivierungsfunktionen definieren den Wertebereich der Ausgabe der jeweiligen Schicht. Neuronale Netzwerke haben den Vorteil gegenüber der logistischen Regressionsanalyse auch komplexere und nicht-lineare Zusammenhänge zu erkennen (MAHAJAN 2020; RASCHKA O.D.; RASHID 2017).

Die Modelle der logistischen Regressionsanalyse und des Fully Connected Network erhalten während der Prozessierung (Training- und Testphase) der Modelle als Input ein Array, in dem das NDVI- und die NDII-Werte je Pixel chronologisch angeordnet sind. Für einen Pixel  $i$  ergibt sich so ein 1D-Array mit 100 Input-Werten bzw. Features. Den Modellen ist weder bewusst, dass ein zeitlicher Zusammenhang zwischen den Input-Werten besteht, noch können sie zwischen der Featurekategorie „NDVI“ und „NDII“ unterscheiden. Die Prozessierung der Prädiktion anhand der LR und des FCNs wird in der Abb. 1 veranschaulicht.

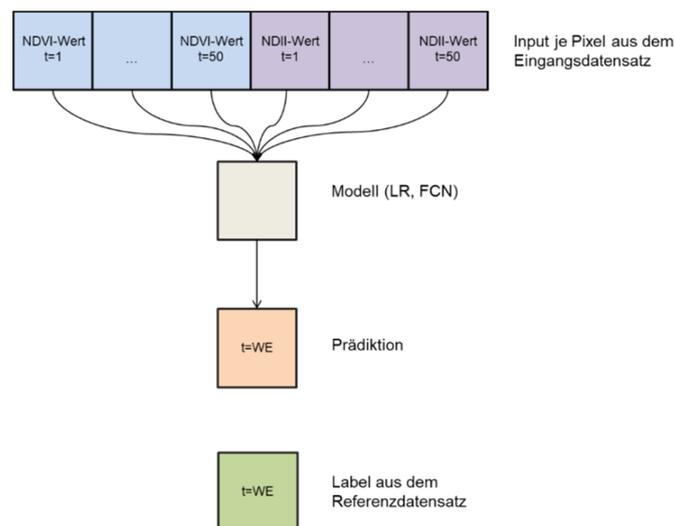


Abb. 1: Prozessierung der Prädiktion anhand der LR und des FCNs

Ein Long Short Term Memory Network (LSTM) wiederum besteht aus einzelnen „Wiederholungsmodulen“, die in einer kettenförmigen Struktur verbunden sind. In jedem Modul befinden

sich vier einzelne neuronale Netzwerkschichten, die miteinander interagieren, und wiederum sigmoidale Aktivierungsfunktionen beinhalten. Das LSTM lernt einen temporalen Zusammenhang aus historischen Daten herzustellen und eignet sich daher für die Prädiktion von Zeitreihen (OLAH 2015; YANG et al. 2021).

Im Vergleich zu der Prädiktion unter Anwendung der LR und des FCNs erhält das LSTM als Input in der Trainings- und Testphase ein 2D-Array je Pixel, welches 50 Zeilen und 2 Spalten aufweist. Die 50 Zeilen repräsentieren die 50 Aufnahmezeitpunkte bzw. die Zeitschritte in der Zeitreihe. Der Ablauf der Prädiktion mit Hilfe des LSTMs wird anhand der Abb. 2 veranschaulicht.

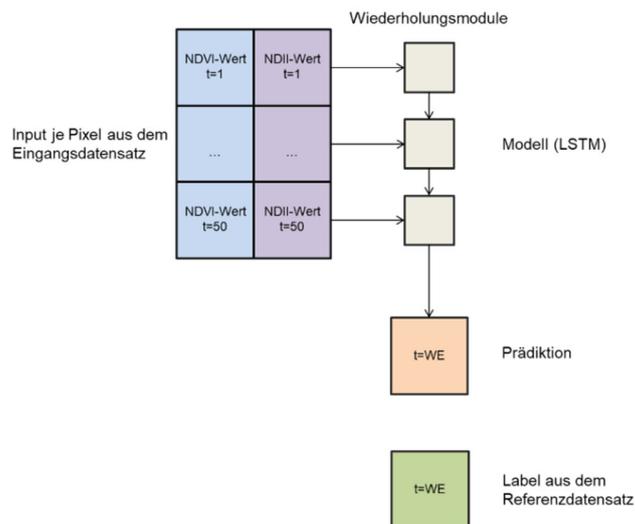


Abb. 2: Prozessierung der Prädiktion anhand des LSTMs

### 3 Referenz- und Eingangsdatensatz

Der generierte Referenzdatensatz besteht aus einer Aufnahme mit  $1181 \times 817$  Pixeln, wobei jeder Pixel die binäre Information 1 (=Waldbrandgebiet) oder 0 (=kein Waldbrandgebiet) enthält. Jeder Pixel weist eine räumliche Auflösung von 20 m auf.

Der Eingangsdatensatz enthält insgesamt 50 Aufnahmen (eine Aufnahme pro Beobachtungszeitpunkt). Jede Aufnahme besteht, wie der Referenzdatensatz, aus  $1181 \times 817$  Pixeln. Dadurch lässt sich für jeden Pixel eine Zeitreihe erstellen, die den dynamischen Verlauf der NDVI- und NDII-Werte vor dem Waldbrandereignis repräsentiert. Die Pixel weisen ebenfalls eine räumliche Auflösung von 20 m auf.

In der Abb. 3 wird der zeitliche Verlauf der NDVI- und NDII-Werte im Untersuchungsgebiet während des beobachteten Zeitraums grafisch dargestellt. In den Diagrammen wird zwischen dem durchschnittlichen NDVI- und NDII-Werten des Waldbrandgebiets und des Gebiets, das nicht vom Waldbrand betroffen war, unterschieden.

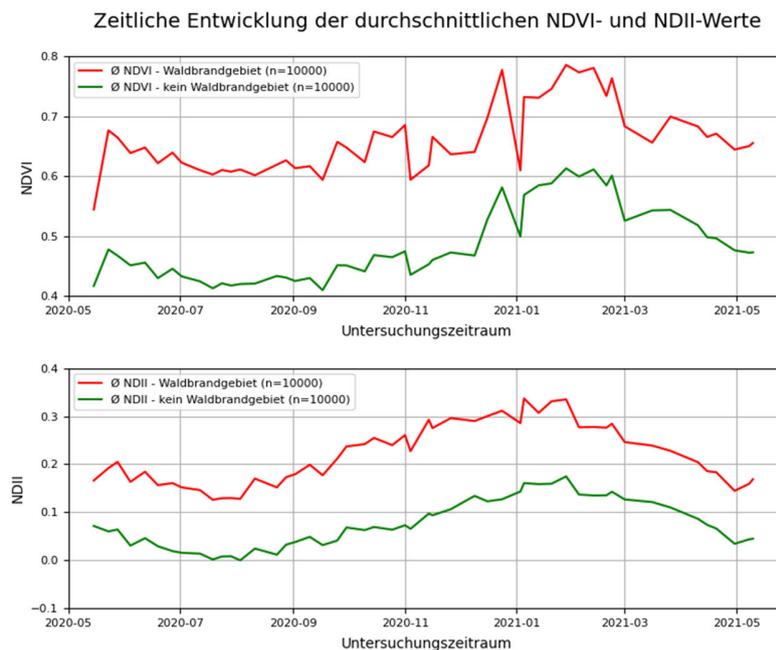


Abb. 3: Zeitliche Entwicklung der durchschnittlichen NDVI- und NDII-Werte im Untersuchungsgebiet

Die Diagramme ermöglichen einen Einblick in den jahreszeitlichen Verlauf der Vegetationsstadien bzw. des Gesundheitszustands der Vegetation und Vegetationsfeuchtigkeit. Hierbei ist zu beobachten, dass die generelle zeitliche Dynamik der NDVI-Werte und der NDII-Werte im Untersuchungszeitraum phasengleich verläuft. Jedoch ist ein deutlicher Versatz auf der Ordinate zwischen den NDVI- und NDII-Werten des Waldbrandgebiets und des nicht betroffenen Gebiets festzustellen.

## 4 Ergebnisse

### 4.1 Ergebnisse der Machine Learning Modelle

Für die Bewertung der Leistung der Machine Learning Modelle werden die Leistungskennzahlen (Metriken) Accuracy, Area Under the Curve (AUC), F1-Score und der Recall bestimmt. Vor allem der Recall (True Positive Rate) ist bei der Vorhersage einer Naturkatastrophe von hoher Wichtigkeit. Der Recall gibt den Anteil der tatsächlich positiven Klasse, die korrekt von den Modellen identifiziert werden, wieder. Auf diese Studie bezogen, beantwortet der Recall die wesentliche Fragestellung: „Wie hoch ist der Anteil der tatsächlich von einem Waldbrand betroffenen Gebiete, die als solche korrekt prädiert wurden?“. Im Umkehrschluss impliziert ein geringer Recall eine hohe False Negative Rate. Eine hohe False Negative Rate wiederum bedeutet, dass viele Gebiete, die tatsächlich von einem Waldbrandereignis betroffen sind, nicht als solche vom Modell prognostiziert werden. Das kann bei der Vorhersage von Waldbränden verheerende Folgen haben.

Die erzielten Metrikergebnisse der Modelle, welche anhand eines Testdatensatzes berechnet werden, sind in Tab. 1 aufgeführt.

Tab. 1: Aufführung der leistungsstärksten Metrikergebnisse der verwendeten Machine Learning Modelle

Modell	Accuracy	AUC	F1-Score	Recall
LR	0,87	0,91	0,64	0,58
FCN	0,88	0,92	0,68	0,67
LSTM	0,92	0,97	0,81	0,81

Die Accuracy bzw. das Verhältnis der Anzahl der korrekt ausgegeben Klassifizierungen des Modells zu der Gesamtanzahl an getätigten Klassifizierungen erreicht bei allen drei Modellen mindestens 87 %. Dies ist auf die sehr präzise Prädiktion ( $\geq 93\%$ ) aller Modelle des vom Waldbrand nicht betroffenen Gebiets zurückzuführen. Die AUC, als Metrik zur Abschätzung der generellen Leistungsfähigkeit eines Klassifikators zu verstehen, liegt bei den verwendeten Modellen ebenfalls in einem hohen Wertebereich von über 0,9. Wesentliche Unterschiede zwischen den Prädiktionsergebnissen zwischen den Modellen werden beim Recall sichtbar. Die logistische Regressionsanalyse und das Fully Connected Network sagen lediglich 58 % bzw. 67 % des tatsächlichen Waldbrandgebiets korrekt voraus bzw. es werden 42 % und 33 % der Klasse „Waldbrandgebiet“ fälschlicherweise als „kein Waldbrandgebiet“ prädiziert.

Das LSTM erreicht für den generierten Eingangs- und Referenzdatensatz für alle berechneten Metriken die leistungsstärksten Ergebnisse. Das vom Waldbrand nicht betroffene Gebiet wird zu 95 % richtig bestimmt und 81 % des tatsächlichen Waldbrandgebiets werden korrekt vom LSTM prognostiziert (Abb. 4).

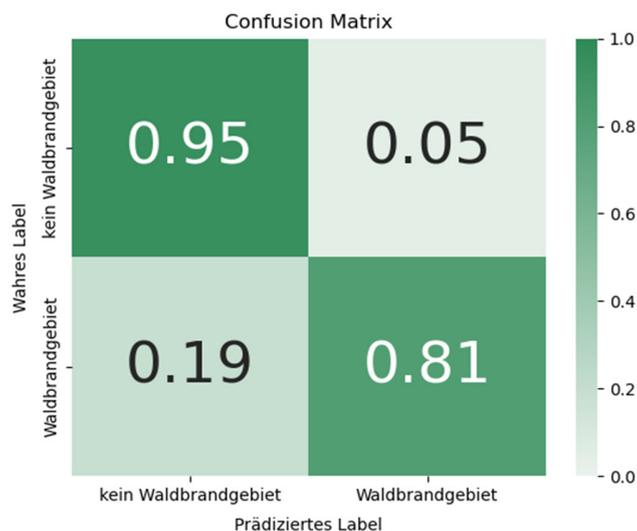


Abb. 4: Confusion Matrix in % des LSTMs

#### 4.2 Binäre Waldbrandprädiktionskarte

Anhand der Prädiktionsergebnisse des LSTMs wird eine binäre Waldbrandprädiktionskarte für das Untersuchungsgebiet erstellt. Dafür wird die ursprüngliche Methodik angepasst. Für eine vollständige Rekonstruktion der ursprünglichen Koordinaten der prädizierten Labels wird für die Testphase des Modells der vollständige Eingangs- und Referenzdatensatz verwendet. Die Vorhersage des Modells geschieht somit hauptsächlich auf Basis von Daten, mit denen es auch trai-

niert wird. Dadurch generiert das Modell zwar genauere Prädiktionsergebnisse, verfehlt allerdings die Aufgabe des Machine Learning Modells eine Prädiktion anhand eines ihm unbekanntem Datensatz vorzunehmen.

Der erzielte Recall des LSTMs liegt unter Anwendung dieser Methodik bei 84 %. Dies spiegelt sich in der in Abb. 5 visualisierten binären Waldbrandprädiktionskarte (räumliche Auflösung von 20 m) im Vergleich zum Referenzdatensatz, der das tatsächliche Waldbrandgebiet repräsentiert, wider (Abb. 6).

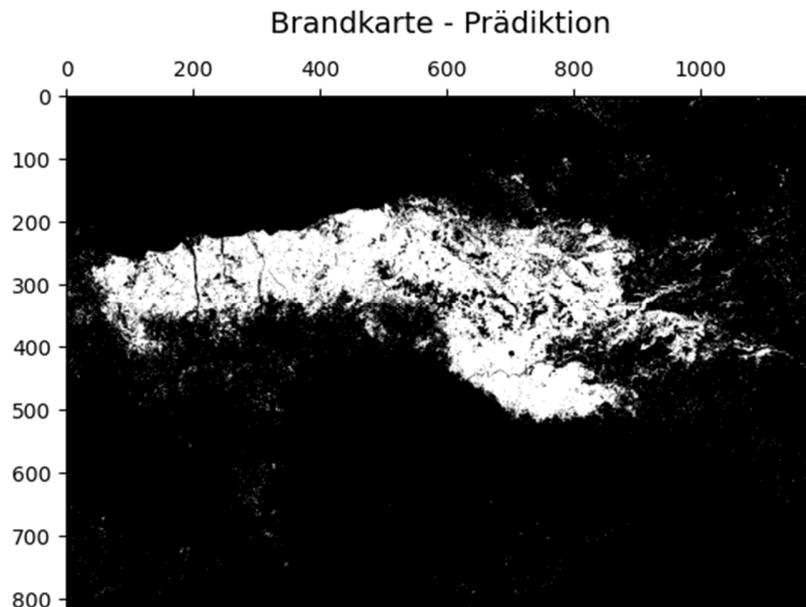


Abb. 5: Binäre Darstellung der Prädiktionsergebnisse. Weiße Fläche entspricht dem prädizierten Waldbrandgebiet.

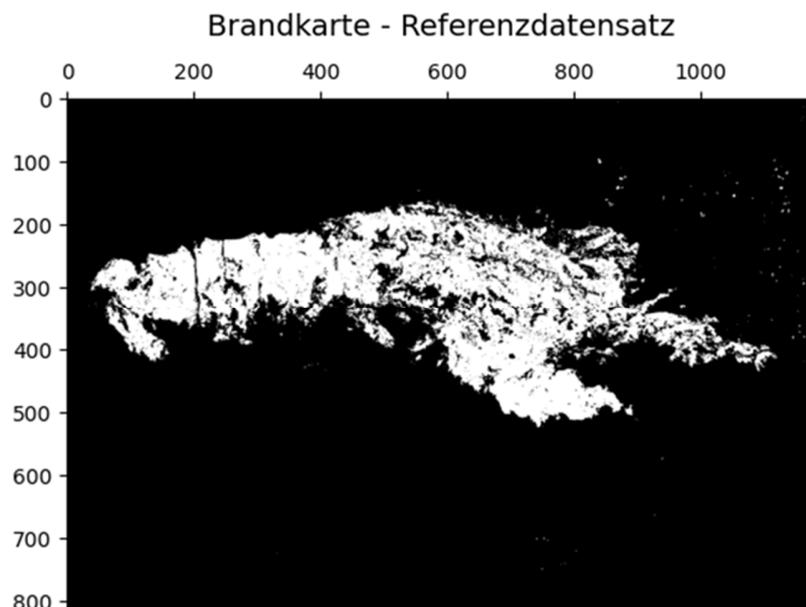


Abb. 6: Binäre Darstellung des Referenzdatensatzes. Weiße Fläche entspricht dem prädizierten Waldbrandgebiet.

## 5 Diskussion der Ergebnisse

Unter den drei verwendeten Machine Learning Modellen erwies das Long Short Term Memory Network die genauesten Prädiktionsergebnisse und bestätigt damit seine Anwendbarkeit auf Zeitreihen. Das LSTM erzielt für die Prädiktion des untersuchten Waldbrandereignisses für einen Testdatensatz ein AUC-Wert von 0,97 und einen Recall von 0,81. Die präzisen Ergebnisse lassen sich vermutlich dadurch begründen, dass eine klare Trennbarkeit der Features (NDVI- und NDII-Werte), die den Klassen „Waldbrandgebiet“ und „keine Waldbrandgebiet“ zugeordnet werden, über den gesamten Beobachtungszeitraum vorliegt (Abb. 3). Diese eindeutige Separation der Features scheint einen positiven Einfluss auf die Prädiktionsfähigkeit der Modelle zu haben. Die Trennbarkeit der NDVI- und NDII-Werte zwischen dem Waldbrandgebiet und dem Gebiet, das nicht vom Waldbrand betroffen ist, lässt sich anhand der unterschiedlichen Vegetationsbedingungen im Untersuchungsgebiet erläutern.

Vergleichbare Studien von MICHAEL et al. (2020) und YANG et al. (2021), die ebenfalls auf Grundlage von satellitengestützten Fernerkundungsdaten (in YANG et al. (2021) mit Multispektral-Daten von Landsat 7, in MICHAEL et al. (2020) mit Zeitreihen von Vegetationsindizes und Topographiedaten) und Machine Learning Modellen versuchen Waldbrände zu prognostizieren, erzielen mit ihren leistungsstärksten Modellen einen AUC-Werte von 0,81 (YANG et al. (2021)) und 0,8 (MICHAEL et al. (2020)). Zwar ist ein direkter Vergleich der vorliegenden Studie zu dieser Arbeit aufgrund der unterschiedlichen methodischen Ansätzen nicht zulässig, dennoch kann der sehr hohe erreichte AUC-Wert des LSTMs in dieser Studie als vielversprechender Ansatz für tiefere Bestrebungen in der Waldbrandprädiktion gewertet werden.

## 6 Fazit & Ausblick

In der vorliegenden Studie wird eine Methodik vorgestellt, um aus Zeitreihen, die aus multispektralen satellitengestützten Fernerkundungsdaten der Sentinel-2 Mission generiert werden, sowie der Implementierung verschiedener Machine Learning Modelle eine Waldbrandprädiktion anhand eines Waldbrandereignisses vorzunehmen.

Das leistungsstärkste LSTM Modell sagt für das untersuchte Waldbrandereignis 81% der Labels der Klasse „Waldbrandgebiet“ anhand des eigens erstellten Referenz- und Eingangsdatensatz korrekt voraus. Zudem kann durch die Verwendung eigener Datensätze eine Waldbrandprädiktion in einer räumlichen Auflösung von 20 m bzw. eine hochauflösende Waldbrandprädiktionskarte (Abb. 5) generiert werden.

Ebenfalls kann durch die Beobachtung der zeitlichen Entwicklung der Vegetationsindizes in den Zeitreihen, der Einfluss des Zustandes und die räumliche Verteilung der Vegetation auf das Waldbrandrisiko verdeutlicht werden. Zudem wird eruiert, dass ein Potential besteht eine Waldbrandprädiktion vorzunehmen, ohne auf weitere meteorologische und topographische Daten zugreifen zu müssen.

Die erarbeitete Methodik lässt sich aufgrund der globalen Landflächenabdeckung und der kostenlosen Bereitstellung der Sentinel-2 Produkte sowie der freien Verfügbarkeit von Software-Bibliotheken für maschinelles Lernen und Deep Learning wie z.B. Scikit-learn und Keras einfach reproduzieren und für Untersuchungsgebiete weltweit einsetzen.

Dennoch muss die Allgemeingültigkeit der Ergebnisse der verwendeten Methodik validiert werden. So müsste unter anderem die Methodik auf weitere Waldbrandereignisse und Untersuchungsgebiete angewendet, evaluiert und automatisiert werden. In Hinblick auf den Referenzdatensatz müsste validiert und erprobt werden, ob eine ausreichend präzise Prädiktion für einen weiter als neun Tage in der Zukunft gelegenen Zeitraum möglich ist.

## 7 Literaturverzeichnis

- ABID, F., 2021: A Survey of Machine Learning Algorithms Based Forest Fires Prediction and Detection Systems. *Fire Technology*, **57**, 559-590, <https://doi.org/10.1007/s10694-020-01056-z>.
- MAHAJAN, P., 2021: Fully Connected vs Convolutional Neural Networks. <https://medium.com/swlh/fully-connected-vs-convolutional-neural-networks-813ca7bc6ee5>, letzter Zugriff am 15.09.2021.
- MICHAEL, Y., HELMAN, D., GLICKMAN, O., GABAY, D., BRENNER, S. & LENSKY, I., 2020: Science of the Total Environment: Forecasting fire risk with machine learning and dynamic information derived from satellite vegetation index time-series. *Science of The Total Environment*, **764**, 142844, <https://doi.org/10.1016/j.scitotenv.2020.142844>.
- OLAH, C., 2015: Understanding LSTM Networks. Colah's Blog. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- RASCHKA, S., o.D.: What is the relation between Logistic Regression and Neural Networks and when to use which? <https://sebastianraschka.com/faq/docs/logisticregr-neuralnet.html>, letzter Zugriff am 17.10.2021.
- RASHID, T., 2017: Neuronale Netze selbst programmieren - Ein verständlicher Einstieg mit Python. O'Reilly.
- SERCO ITALIA SPA, 2017: Burned Area Mapping with Sentinel-2 (SNAP). RUS Lectures, <https://rus-copernicus.eu/portal/the-rus-library/learn-by-yourself/>
- UN-SPIDER, o.D.: Normalized Burn Ratio (NBR). UN-SPIDER Knowledge Portal, <https://un-spider.org/advisory-support/recommended-practices/recommended-practice-burn-severity/in-detail/normalized-burn-ratio>, letzter Zugriff am 06.10.2021.
- HIRSCHBERGER, P., 2016: Forests Ablaze: Causes and Effects of Global Forest Fires. Winter, S., von Laer, Y., Köberich, T., Eds., WWF Deutschland: Berlin, Germany, <https://www.wwf.de/fileadmin/fm-wwf/Publikationen-PDF/WWF-Study-Forests-Ablaze.pdf>.
- YANG, S., LUPASCU, M. & MEEL, K.S., 2021: Predicting Forest Fire Using Remote Sensing Data And Machine Learning. 35th AAAI Conference on Artificial Intelligence, arXiv preprint arXiv:2101.01975.