


Lehren mit dem All

Waldbrände mit Künstlicher Intelligenz erkennen

Auswertung von Satellitendaten



Eckdaten, Kurzbeschreibung, Lernziele	Seite 3
Zusammenfassung der Aufgaben	Seite 4
Verfügbare Downloads	Seite 4
Programmieroberfläche Open Roberta	Seite 5
Software	Seite 6
Material	Seite 6
Ziele des Kurses, Aufbau und Inhalt	Seite 7
Tipps und Varianten	Seite 8
Zusatz – Eigene Testbilder erzeugen	Seite 9

Lehren mit dem AI – Waldbrände mit Künstlicher Intelligenz erkennen
www.esa.int/education

Das ESA Education Office freut sich über Feedback und Kommentare
teachers@esa.int

Eine Produktion von ESA Education
Copyright 2025 © European Space Agency

Waldbrände mit Künstlicher Intelligenz erkennen

Auswertung von Satellitendaten

Kurzinformationen

Alter: 14-20 Jahre

Lehrplanbezug: Informatik, Geographie, Naturwissenschaften

Schwierigkeitsgrad: mittel

benötigte Zeit: 240-360 Minuten

Örtlichkeit: in einem Gebäude

Kosten: keine

Voraussetzungen: Computer mit Internetzugang, aktueller Webbrowser

Schlüsselbegriffe: Satellitendaten, Copernicus Browser, KI, Datenauswertung

Überblick

Dieser Kurs bietet Schülerinnen und Schülern (SuS) einen praxisnahen Einstieg in die satelliten-gestützte Erkennung von Waldbränden. Mit Sentinel-2-Daten im Copernicus Browser und Googles Teachable Machine bauen die Lernenden einen eigenen Datensatz auf, trainieren ein Bildklassifikationsmodell und bewerten dessen Aussagekraft an neuen Regionen. So verbinden sie geographisches und naturwissenschaftliches Hintergrundwissen mit Kompetenzen in Datenrecherche, Datenaufbereitung, KI-Grundlagen und kritischer Modellreflexion – vom SWIR-Export über das Training bis zur Auswertung in Google Colab.

Lernziele

- Die SuS verstehen Ursachen, Wirkungen und Trends von Waldbränden (Europa/Deutschland) und ordnen diese in den Kontext Klimawandel ein.
- Die SuS lernen, Satellitenbilder (Sentinel-2) im Copernicus Browser zu finden, zu visualisieren (SWIR) und zielgerichtet zu exportieren.
- Die SuS erstellen einen kleinen Datensatz (Klassen: *Waldbrand* vs. *kein Waldbrand*) mit vielfältigen Beispielen.
- Die SuS trainieren mit Googles Teachable Machine ein einfaches Bildklassifikationsmodell (Einstellungen anpassen, Training interpretieren).
- Die SuS evaluieren das Modell auf neuen Gebieten/Bildern, reflektieren Stärken/Schwächen (Fehlerquellen, Bias, Übertragbarkeit) und leiten Verbesserungen ab.
- Die SuS stärken Teamarbeit (Datenrecherche, Rollen verteilen) und Datenkompetenzen (Sorgfalt, Dokumentation, Reproduzierbarkeit).

Zusammenfassung der Aufgaben

	Bezeichnung	Beschreibung	Ergebnis	Voraussetzungen	Zeit
1	Thematischer Einstieg Waldbrände	Es soll ein kurzer Einstieg in die Thematik Waldbrände erfolgen. Dies kann lehrkraftzentriert oder im Unterrichtsgespräch erarbeitet werden, gestützt durch die Folien (Einstieg, Europa/Deutschland, Klimawandel).	Die Lernenden erhalten ein grundlegendes Verständnis zu Ursachen, Folgen und Trends von Waldbränden und kennen die Zielsetzung des Kurses.	Keine speziellen Vorkenntnisse	ca. 20 Minuten
2	Einführung in den Copernicus Browser	Kurzer geführter Block: Sentinel-2 L2A auswählen, SWIR aktivieren, Datum & Wolkenfilter $\leq 30\%$ setzen; Beispielregion zeigen. SWIR-Lesart erklären (<i>Brand=rot, nass=grün, Wasser=blau/schwarz</i>)	SuS finden geeignete Szenen, können Brandflächen im SWIR erkennen und Zeitpunkte/Orte gezielt auswählen	Grundlegende Bedienung eines PC; einfaches Kartenverständnis	20-30 Minuten
3	Datensatz-aufbau: Exporte erstellen	Arbeitsphase beginnt: Teams sammeln Trainingsdaten und halten sich an Exportregeln	Ausbalancierter, vielfältiger Datensatz je Team	Dateiverwaltung (Ordner/Dateien), Sorgfalt beim Labeln, Teamabsprachen	50-90 Minuten
4	Modell trainieren	Projekt anlegen, Bilder importieren, kurz trainieren (≈ 8 Epochen), in der Vorschau testen und typische Fehlbilder notieren	Erstes funktionsfähiges Modell mit erkennbaren Stärken/Schwächen	Grundidee „KI = Mustererkennung“, Datei-Uploads	ca. 30 Minuten
5	Modell verbessern & exportieren	Gezielt Gegenbeispiele ergänzen, erneut trainieren; fertiges Modell als TF-Lite (quantisiert) exportieren	Stabileres Modell; exportierte Dateien liegen vor	Fähigkeit zur einfachen Fehleranalyse	50-90 Minuten
6	Auswertung in Google Colab	Jupyter-Notebook öffnen, Modell / Labels / Testbilder laden, ausführen	Objektive Testergebnisse auf neuen Bildern; reflektierte Einschätzung	Strukturierte Arbeitsweise	50-80 Minuten
7	Abschlussdiskussion	Plenumsrunde: Aufwand der Datensatzerstellung und unbeabsichtigte Muster reflektieren; gemeinsam abschätzen, welche Vielfalt an Trainingsbildern für ein sehr gutes Ergebnis nötig ist	SuS verstehen zentrale Qualitätsfaktoren (Vielfalt, Balance, Datenqualität) und leiten konkrete Verbesserungen für Datensatz/Workflow ab	Schritte 1-6 abgeschlossen	ca. 20 Minuten

Verfügbare Downloads

Lernmaterialien

	1_Waldbranderkennung_Handreichung_für_Lehrkräfte.pdf
	2_Waldbranderkennung_Lernmaterialien.pptx
	3_Waldbranderkennung_Lernmaterialien.pdf
	Bilder_zur_Auswertung.zip
	Auswertung.ipynb
	Zusatz_Programm_zur_Erzeugungweiterer_Testbilder.py
	Zusatz_Beispieldateien.zip

Software

Keine Installation nötig: Alle Werkzeuge laufen im Browser.

Copernicus Browser (Sentinel-2, SWIR)

Der Copernicus Browser ist eine webbasierte Plattform zur Visualisierung und Analyse von Erdbeobachtungsdaten (u. a. Sentinel-2). Er eignet sich hervorragend für den Unterricht, um reale Satellitenbilder zu recherchieren, zu vergleichen und gezielt als Trainingsdaten zu exportieren. Die Oberfläche ist intuitiv, filterbar nach Datum/Wolkenbedeckung, und erlaubt das Umschalten auf SWIR-Darstellungen, in denen Brandflächen deutlich hervortreten.

Zum Vorgehen: Browser öffnen, Datensatz Sentinel-2 L2A wählen, SWIR aktivieren, Datum/Wolkenfilter setzen, einheitlich exportieren (identische Zoomstufe/Maßstab, Beschriftungen aus).

Hinweis Bildgröße: Export möglichst in 1086 × 729 px; falls größer/abweichend, die Bilder vor dem Training einheitlich zuschneiden oder skalieren, damit Maßstab und Seitenverhältnis konsistent bleiben.

Teachable Machine (Bildklassifikation)

Googles Teachable Machine ist eine cloudbasierte Umgebung zum schnellen Trainieren einfacher Bildklassifikationsmodelle – ohne Installation und mit niedrigem Einstieg. Sie eignet sich gut, um den kompletten KI-Workflow sichtbar zu machen: Daten importieren, kurz trainieren, erste Ergebnisse direkt testen und gezielt nachbessern.

Zum Vorgehen: Neues Bildprojekt anlegen, Klassen (z. B. Waldbrand / Kein Waldbrand) erstellen, Bilder importieren, Training starten; Ergebnisse in der Vorschau prüfen und typische Fehlerbilder sammeln. Für fortgeschrittene Gruppen lassen sich Trainingsparameter (z. B. Epochen) diskutieren und variieren.

Google Colab (Auswertung)

Google Colab ist ein webbasierter Dienst von Google, mit dem interaktive Programmier-Notizbücher (Jupyter-Notebooks) direkt im Browser ausgeführt werden können. Die Berechnungen laufen dabei auf Googles Servern, eine lokale Installation ist nicht nötig. In diesem Kurs wird Colab genutzt, um das in Teachable Machine trainierte Modell mit dem bereitgestellten Notebook *Auswertung.ipynb* auf neue Sentinel-2-Bilder (SWIR) zu testen: Das Notebook führt die Schritte strukturiert aus und schreibt die Ergebnisse in eine Tabelle, die heruntergeladen werden kann.

Zum Vorgehen: Notebook öffnen, benötigte Dateien laden, Zellen ausführen, Ergebnisse (z. B. Konfidenzen) sichern und interpretieren.

Wichtig: Die Dateien *Auswertung.ipynb* und *Bilder_zur_Auswertung.zip* müssen den SuS vorab bereitgestellt werden (Schulcloud/Drive/QR-Link), damit die Auswertung unmittelbar gestartet werden kann.

Material

- Endgeräte: 1 Laptop/PC pro 2 SuS (Partnerarbeit empfohlen), Lehrkraft-PC mit Beamer
- Maus pro Gerät empfohlen
- Internet & Browser: Stabile Verbindung; aktueller Browser
- Plattformzugänge:
 - Copernicus Browser (für Sentinel-2, SWIR-Ansicht)
 - Google Teachable Machine (zum Training)
 - Google Colab (für die Auswertung)
- Kursdateien: *Auswertung.ipynb* und *Bilder_zur_Auswertung.zip* den SuS vorab bereitstellen
- ZIP-Tool: Zum Entpacken/Packen von Dateien

Ziel des Kurses, Aufbau und Inhalt

Die Schülerinnen und Schüler sollen ein fundiertes Verständnis dafür entwickeln, wie satellitengestützte Fernerkundung und einfache KI-Methoden zur Erkennung von Waldbränden eingesetzt werden – und was dafür in der Praxis nötig ist. Ziel ist es, den kompletten Weg vom Suchen und Exportieren geeigneter Bilddaten über das Zusammenstellen eines Datensatzes bis hin zum Trainieren, Exportieren und Testen eines Modells nachzuvollziehen. Dabei erleben die Lernenden, wie aufwendig und entscheidend gute Daten sind, welche unbeabsichtigten Muster (z. B. Wasserflächen, Wolken, Schatten) ein Modell „mitlernen“ kann und warum klare Regeln und saubere Dateistrukturen für belastbare Ergebnisse unverzichtbar sind.

Im theoretischen Abschnitt wird zunächst in die Thematik Waldbrände eingeführt: Ursachen, räumliche Muster und Entwicklungen in Europa und Deutschland sowie der Bezug zur Klimakrise. Anschließend lernen die Schülerinnen und Schüler die Grundidee der SWIR-Darstellung kennen, mit der sich Brand- und Feuchtesignaturen deutlich unterscheiden lassen (rot \approx verbrannt/Brandfläche, grün/braun \approx nicht verbrannt). Darauf aufbauend wird der Copernicus Browser (Sentinel-2 L2A) als Arbeitsumgebung vorgestellt: Auswahl geeigneter Szenen, Datum und Wolkenfilter sowie die Konsistenzregeln für Exporte (identische Darstellung, feste Zoomstufe/Maßstab, Beschriftungen aus).

Wichtig für Training und Auswertung:

Im Kursordner liegen für Gebiete in Sardinien, Portugal, Griechenland und Brandenburg jeweils dieselben Bildausschnitte über mehrere Jahre, erstellt mit identischen Einstellungen (SWIR, gleiche Zoomstufe/Maßstab, Beschriftungen aus). So bleiben Trainings- und Testdaten vergleichbar und es lässt sich prüfen, ob sich die Brandhäufigkeit über die Jahre verändert hat. Würden die Testbilder anders erzeugt (z. B. anderer Zoom oder andere Darstellung), sähen sie für das Modell grundlegend anders aus – die Ergebnisse könnten verzerrt sein (Train-Test-Mismatch).

Die praktische Arbeit beginnt mit der kuratierten Datensammlung: Teams exportieren SWIR-Ausschnitte und beschriften sie in zwei Klassen (z. B. Waldbrand / Kein Waldbrand). Im Fokus stehen Vielfalt (verschiedene Regionen, Hintergründe, Jahreszeiten) und Sorgfalt beim Labeln. Partnerarbeit wird empfohlen. Anschließend wird in Googles Teachable Machine ein Bildklassifikationsmodell erstellt: Bilder importieren, kurz trainieren und erste Ergebnisse in der Vorschau prüfen. Begleitend reflektieren die Lernenden, welche Bildmerkmale zu Fehlklassifikationen führen und wie sich durch gezielt ergänzte Gegenbeispiele die Qualität verbessern lässt.

Je nach Vorwissen kann die Lehrkraft das KI-Thema vertiefen (z. B. Epochen, Batch-Größe, Verlustfunktion und deren Einfluss auf Lernverhalten und Stabilität).

Für die übertragbare Bewertung wird das trainierte Modell exportiert (z. B. als TF-Lite) und in Google Colab auf neuen, fremden Bildern getestet. Hier zeigt sich, inwiefern das Gelernte über die Trainingsgebiete hinaus funktioniert. Wichtig sind dabei einheitliche Dateinamen und Ordnerstrukturen, damit die Auswertung reibungslos funktioniert.

Die Dateien *Auswertung.ipynb* und *Bilder_zur_Auswertung.zip* müssen den Schülerinnen und Schülern vorab bereitgestellt werden (z. B. über Schulcloud/Drive/QR-Link), damit die Evaluation direkt durchgeführt werden kann.

Hinweis zur Bildgröße:

Die Trainingsbilder sollten 1086 \times 729 Pixel groß sein. Teachable Machine skaliert zwar intern auf die Modell-Eingabegröße, uneinheitliche Auflösungen oder Seitenverhältnisse ändern jedoch den abgebildeten Maßstab/Feldausschnitt und können die Ergebnisse spürbar verschlechtern; auch das Colab-

Notebook geht von einer einheitlichen Vorverarbeitung aus.

Daher: Export konsequent nach einheitlichen Regeln; falls Bilder größer sind, diese vor dem Training einheitlich auf 1086 × 729 zuschneiden oder skalieren.

Den Abschluss bildet eine geleitete Reflexion: Die Klasse diskutiert, wie viel Aufwand im Datensatz steckt, welche Muster das Modell möglicherweise „falsch“ gelernt hat, wie sich das in den Beispielbildern zeigt und welche zusätzlichen Bilder (andere Hintergründe, Regionen, Jahreszeiten, „schwierige“ Negativbeispiele) nötig wären, um ein wirklich robustes Ergebnis zu erzielen. Es gibt dabei kein richtig oder falsch im Sinne eines einzig wahren Ergebnisses – es geht um Ausprobieren, Beobachten und Verstehen, welche Daten welche Wirkung haben und wie man den eigenen Ansatz schrittweise verbessert.

In Summe vermittelt der Kurs einen realistischen, motivierenden Einblick in datengetriebene KI-Arbeit: Vom SWIR-gestützten Erzeugen guter Trainingsdaten über einfaches, webbasiertes Training bis hin zur objektiven Prüfung auf neuen Bildern. Je nach Schwerpunkt können Lehrkräfte entweder den Waldbrand-/Klimabezug stärker betonen oder das KI-Handwerk (Hyperparameter, Training, Loss) vertiefen – die Struktur des Kurses trägt beide Varianten.

Tipps und Varianten

Klein starten, iterativ verbessern:

Für den Einstieg genügt ein überschaubarer Datensatz von etwa 20 Bildern pro Klasse. Nach einer ersten kurzen Trainingsrunde werden die Ergebnisse gemeinsam betrachtet: Welche Motive funktionieren, wo gibt es Fehlklassifikationen? Anschließend wird der Datensatz gezielt erweitert – z. B. um passende Gegenbeispiele und verschiedene Hintergründe – und erneut trainiert. Mehrere kurze Iterationen statt einer großen Sammelaktion erhöhen meist die Motivation und machen den Einfluss der Daten unmittelbar erfahrbar.

Mehrfach trainieren – Unterschiede diskutieren:

In Teachable Machine kann das Training mehrfach gestartet werden. Auch bei gleichen Trainingsdaten können die Resultate variieren (z. B. durch zufällige Initialisierung oder unterschiedliche Mini-Batch-Reihenfolgen). Diese Schwankungen bieten einen guten Anlass, über Zufallseinflüsse, Stabilität und Streuung zu sprechen und die Ergebnisse bewusst zu vergleichen und zu protokollieren.

Erwartungen an die Auswertung:

In der Praxis fallen die Ergebnisse auf Sardinien und Griechenland oft besser aus, weil dort großflächige, klar abgegrenzte Brandflächen vorliegen, die weniger von Bebauung oder Landwirtschaft überlagert sind. Brandenburg ist häufig anspruchsvoller: Die Brände sind kleiner und liegen in heterogenen Umgebungen (Siedlungen, Felder, Wege), die in den Trainingsbeispielen der SuS anfangs oft fehlen. Das eignet sich, um zu diskutieren, welche zusätzlichen Motive – etwa mehr Beispiele mit bebauten oder landwirtschaftlich genutzten Flächen – in den Datensatz sollten, damit das Modell besser generalisiert.

Zusatz – Eigene Testbilder erzeugen

Lehrkräfte können mit dem bereitgestellten Python-Skript (*Zusatz_Programm_zur_Erzeugung_weiterer_Testbilder.py*) selbst weitere Testbilder erzeugen.

Dafür benötigen sie ein Sentinel-Hub-Konto sowie Client ID und Client Secret. Im Skript werden diese in der Konfiguration hinterlegt; anschließend können Zeitraum (TIME_INTERVAL) sowie Koordinaten (BBox) und passende UTM-Zone angepasst werden. Das Skript lädt die Sentinel-2-Daten und speichert JPEG-Kacheln in fester Größe 1086×729 px (konstanter Maßstab), sodass die neuen Bilder konsistent zum Trainingsmaterial sind und sich direkt für die Auswertung eignen.

Bitte eigene Zugangsdaten verwenden und nicht weitergeben.