

# KI-Trainingsdaten enthalten private Informationen

[Originalartikel](#)

[Backup](#)

`<html> <div class=„seitenkopf“><div class=„seitenkopfmedia columns twelve m-twelve ts-picturewrapper“><noscript><img class=„ts-image“`  
`src=„https://images.tagesschau.de/image/c281fb7f-a960-4073-a4fb-7cea9953d84d/AAABiSsDtj4/AAABg8tMRzY/20x9-1280/monitor-daten-100.jpg“ alt=„Ein fiktives Programm ist auf zwei Bildschirmen eines Computers zu sehen.“ title=„Ein fiktives Programm ist auf zwei Bildschirmen eines Computers zu sehen. | picture alliance/dpa“ referrerpolicy=„no-referrer“ /></noscript></div></div><p`  
`class=„textabsatz columns twelve m-ten m-offset-one l-eight l-offset-two“><strong>Trainingsdaten`  
`sind der Rohstoff f&#252;r KI-Systeme. Sie bestehen aus riesigen Mengen an Bildern und Texten aus`  
`dem Netz. Eine <em>BR</em>-Recherche zeigt nun: Darunter sind viele privaten Daten - ein`  
`Problem f&#252;r den Datenschutz.</strong></p><p>Von Katharina Brunner und Elisa Harlan,`  
`BR</p><p class=„textabsatz m-ten m-offset-one l-eight l-offset-two columns twelve“>Das Nacktbild`  
`eines Niederl&#228;nders: In der Bildbeschreibung stehen sein Vor- und Nachname und die`  
`Geokoordinaten des Aufnahmeortes. Sucht man mit diesen Informationen im Internet nach dem`  
`Mann, ist er schnell gefunden.</p><p class=„textabsatz m-ten m-offset-one l-eight l-offset-two`  
`columns twelve“>Der Niederl&#228;nder ist kein Einzelfall. Bei der Analyse des weltweit wohl`  
`gr&#246;&#223;ten Trainingsdatensatzes f&#252;r KI-Bildgenerierung haben <em>BR-`  
`</em>Datenjournalistinnen massenweise Daten gefunden, mit denen sich Personen identifizieren`  
`lassen: Gesichter und Namen, Geokoordinaten oder E-Mails, sogar Kontonummern. Der LAION5B-`  
`Datensatz, eine Abk&#252;rzung f&#252;r „Large-scale Artificial Intelligence Open Network“,`  
`&#252;bersetzt: „Gro&#223; angelegtes offenes Netzwerk f&#252;r k&#252;nstliche Intelligenz“,`  
`besteht aus f&#252;nf Milliarden Links auf Bilder und ihren Beschreibungen im Internet. Er ist`  
`zugleich der einzige vergleichbare Trainingsdatensatz f&#252;r KI-Modelle, der &#246;ffentlich`  
`zug&#228;nglich ist.</p><h2 id=„Problematische-Daten-bereits-in-Stichprobe“`  
`class=„meldungsubhead columns twelve m-ten m-offset-one l-eight l-offset-two`  
`liveblog-anchor“>Problematische Daten bereits in Stichprobe</h2><p class=„textabsatz m-ten m-`  
`offset-one l-eight l-offset-two columns twelve“>KI-Trainingsdatens&#228;tze bestehen`  
`&#252;blicherweise aus enormen Mengen an Texten und Bildern. Sie liefern den Rohstoff f&#252;r`  
`KI-Systeme, die Texte und Bilder generieren, und derzeit von Millionen Menschen auf der Welt benutzt`  
`werden. Sogenannte Bildgeneratoren wie Stable Diffusion, Midjourney oder Dall-e von OpenAI`  
`funktionieren alle &#228;hnlich: Menschen beschreiben mit kurzen Texteingaben, sogenannten`  
`Prompts, welches Motiv auf dem gew&#252;nschten Bild zu sehen sein soll. Die Programme erstellen`  
`dann mit Hilfe der Trainingsdaten ein neues Bild, oder so viele man m&#246;chte.</p><p`  
`class=„textabsatz m-ten m-offset-one l-eight l-offset-two columns twelve“>Ende Juni 2023 reichte in`  
`den USA eine anonyme Gruppe Klage gegen das Unternehmen OpenAI ein, das unter anderem auch`  
`ChatGPT betreibt: Sie wirft der Firma unter anderem massenhafte Verletzungen der`  
`Privatsph&#228;re vor.</p><p class=„textabsatz m-ten m-offset-one l-eight l-offset-two columns`  
`twelve“>Die <em>BR-Analyse</em> zeigt, dass sich auch im deutschsprachigen Teil der LAION-`  
`Datens&#228;tze f&#252;r 20 Millionen Bilder Zusatzinformationen finden, sogenannte Exif-`  
`Metadaten. Exif steht f&#252;r „Exchangeable Image File Format“ und bezeichnet Informationen, die`  
`in den Bilddateien gespeichert sind. Das Aufnahmeger&#228;t h&#228;lt zum Beispiel`  
`zus&#228;tzlich zum Bild den Zeitpunkt der Aufnahme fest, das Modell der Kamera und oft auch den`  
`genauen Standort. Solche Positionsangaben k&#246;nnen automatisch bei allen Aufnahmen`  
`entstehen.</p><p class=„textabsatz m-ten m-offset-one l-eight l-offset-two columns twelve“>Ein`  
`Ergebnis der <em>BR-Analyse</em>: Zu 310.000 Bildverweisen im deutschsprachigen LAION-Teil`

konnte das Team von **BR Data** den exakten Aufnahmeort auslesen. Diese Exif-Daten, in denen die Ortsinformationen gespeichert sind, werden auch als „Restinformationen“ bezeichnet. Sofern es keine begründeten Argumente gibt, sollen solche Daten nach Meinung des Bundesamts für Sicherheit und Informationstechnik (BSI) vernichtet werden, wenn Dateien weitergegeben werden.

## Datenschützer-Kleinfeld-Hochproblematisch

Datenschützer Kleinfeld: „Hochproblematisch“ für Eike Kleinfeld, tätig beim Hamburger Datenschutzbeauftragten, ist die massenhafte Verbreitung von Ortsinformationen aus Exif-Metadaten ein Problem, sofern es sich um sensible Informationen handelt, die einen Rückschluss auf natürliche Personen erlauben: „Die absolute Zahl ist natürlich hoch problematisch, wenn man sich vergegenwärtigt, dass da Millionen Bilder mit solchen Informationen liegen.“

LAION-Mitgründer Christoph Schuhmann war sich bisher des Problems nicht bewusst: „Auf das Problem werden wir jetzt das erste Mal hingewiesen“, so Schuhmann gegenüber dem **BR**.

## LAION setzt auf Transparenz

LAION setzt auf Transparenz

LAION ist ein Zusammenschluss von Freiwilligen aus Europa und Nordamerika. Schuhmann sagt: „Wir haben LAION aus Begeisterung für diese KI-Technologie gegründet und dem Wunsch, dass das demokratisiert wird und es am Ende nicht nur zwei, drei großen Firmen gibt.“

Die Methode der radikalen Transparenz unterscheidet LAION von der Konkurrenz wie Microsoft, Google, Midjourney oder OpenAI. Über deren Trainingsmaterial und Methodik ist wenig bekannt. Die vier Unternehmen ließen Fragen, wie Trainingsdaten zusammengesetzt und verwendet werden, unbeantwortet. Will man die Lieferkette von populären KI-Bildgeneratoren untersuchen, sind LAIONs Datensätze, Modelle und Werkzeuge aktuell die einzige Möglichkeit für Wissenschaftler und Journalisten.

## EU-Gesetzgebung nimmt Trainingsdaten in den Blick

EU-Gesetzgebung nimmt Trainingsdaten in den Blick

Mehr Transparenz in Sachen Trainingsdaten sieht die EU in der geplanten Gesetzgebung zur Künstlichen Intelligenz vor, dem sogenannten AI Act. Unklar ist aber, wie genau die künftigen Regelungen aussehen sollen. Derzeit wird noch verhandelt: „Was im AI Act stehen wird, ist in Teilen noch offen. Momentan ist ein wichtiges Diskussionsthema, ob generative KI als Hochrisikogruppe gewertet und reguliert wird“, sagt Sandra Wachter, Professorin am Oxford Internet Institute. Bis Ende des Jahres sollen die EU-Regeln stehen und 2025 in Kraft treten. Bis dahin laufen die Systeme weiter wie bisher.

From:  
<https://schnipsl.qgelm.de/> - Qgelm

Permanent link:  
<https://schnipsl.qgelm.de/doku.php?id=wallabag:wb2ki-trainingsdaten-enthalten-private-informationen>

Last update: **2025/06/27 11:17**

