


Die Beobachtung bewaffneter Konflikte aus dem All

Frei zugängliche Satellitenbilder und Deep Learning können Menschenrechts- und Hilfsorganisationen dabei unterstützen, schneller auf bewaffnete Konflikte zu reagieren. Um die Effektivität solch einer Fernüberwachung zu gewährleisten, müssen die Organisationen ihre Strategien an den technischen Begrenzungen Deep Learning-basierter Monitoringsysteme ausrichten.

Von Valerie Sticher, Olivier Dietrich, Birke Pfeifle und Jan Dirk Wegner

Vom Aufzug russischer Panzer entlang der ukrainischen Grenze bis hin zu zerstörten Städten und Dörfern – wir alle konnten den Krieg in der Ukraine über Bilder von oben mitverfolgen. Als Russland im März 2022 das Theater in Mariupol bombardierte, waren es nicht in erster Linie die Bilder der Opfer, die weltweites Aufsehen und Empörung erregten, sondern vielmehr ein Satellitenbild des Theaters kurz vor dem Angriff. Darauf zu lesen war das Wort «Kinder» auf Russisch, zweimal ausserhalb des Gebäudes auf den Boden geschrieben und selbst aus dem Weltraum deutlich sichtbar. Russische Kampfflugzeuge griffen trotzdem an. Für viele wurde dies zum Symbol dafür, in welcher eklatanter Weise Russland im Krieg in der Ukraine das Leben von Zivilisten missachtet – eine eindrucksvolle Demonstration davon, wie tiefgreifend Satellitenbilder den öffentlichen Diskurs prägen können.

Seit es Satellitenbilder gibt, beeinflussen sie den Verlauf bewaffneter Konflikte. Da es immer mehr kommerzielle Satellitenanbieter gibt, werden die Bilder jedoch nicht nur von Kriegsparteien genutzt, sondern auch von jenen, die darüber berichten oder die versuchen, den angerichteten Schaden zu mindern. Im Gegensatz zu anderen Fernerkundungsinstrumenten, etwa Drohnen, stellen Satelliten einen weniger invasiven Eingriff dar, da sie vom Weltraum aus



Aufsteigender Rauch in Mekelle, Äthiopien, am 20. Oktober 2021. Copernicus Sentinel 2-Bilder, verarbeitet von der EU-GD für Verteidigungsindustrie und Raumfahrt, zugänglich über Reuters.

betrieben werden. Für Menschenrechts- und Hilfsorganisationen wie das Internationale Komitee vom Roten Kreuz (IKRK) oder Amnesty International sind Satellitenbilder mittlerweile ein wichtiges Instrument, um Einblicke in das Geschehen in ansonsten unzugänglichen Gebieten zu erhalten. Sie nutzen Satellitenbilder für menschenrechtliche Untersuchungsarbeit, zum Beispiel um zu bestimmen, welcher Konfliktpartei das Gebiet kontrolliert hat, während eine Gräueltat verübt wurde. Allgemeiner helfen sie den Organisationen zu

verstehen, wo Gefechte stattfinden, bei der Priorisierung von Hilfsleistungen und bei der Überwachung humanitärer Korridore für den sicheren Transport von Flüchtlingen und Hilfsgütern.

Bislang verlassen sich die meisten Organisationen auf GeoanalystInnen, die die hochauflösenden Bilder akribisch auf Veränderungen untersuchen, etwa auf Schäden an Gebäuden oder auf zerstörte Infrastruktur. Die manuelle Bildannotation ist jedoch sehr arbeitsintensiv, was die


Fähigkeit der Organisationen für ein umfassendes Screening grösserer Konfliktgebiete einschränkt. Angesichts dieser Einschränkungen und der Fokussierung der Weltöffentlichkeit auf nur auf einige wenige Konflikte, bleiben viele andere Konflikte weitgehend unbeobachtet. Genau hier könnten die Fortschritte im Deep Learning-Bereich einen wichtigen Beitrag leisten.

Diese CSS-Analyse untersucht das Potenzial der automatisierten Analyse von Satellitenbildern mittels Deep Learning – einer Entwicklung, die Organisationen ein systematischeres und umfangreicheres Monitoring von Konflikten ermöglichen könnte. Der Artikel beleuchtet dabei aktuelle Herausforderungen bei der Nutzung automatisierter Analysen. Dazu zählen die Kosten für Screening mittels hochauflösender Bilder und, dass das Verifizieren der automatisch identifizierten Konfliktereignisse schnell zu einer Überforderung werden kann. Der Artikel empfiehlt, prioritär Anwendungen auf Basis frei zugänglicher Satellitenbilder zu entwickeln. Auch sollten Akteure sich bezüglich ihrer Erwartungen an die technischen Grenzen von Deep Learning-basierten Systemen anpassen. So können sie Vorteile aus der automatischen Analyse ziehen, ohne neue Engpässe zu schaffen. Während *Remote Monitoring* Menschenrechts- und Hilfsorganisationen bei ihrer Tätigkeit unterstützen können, werden andere Formen der Beobachtung weiterhin wichtig bleiben.

Das Versprechen von Monitoring

Der Begriff «*Remote Monitoring* bewaffneter Konflikte» bezieht sich auf ein kontinuierliches Screening ganzer Konfliktregionen per Satellitenbild. Ziel dieses Monitorings ist es, die Folgen von Konfliktereignissen, etwa die Zerstörung von Gebäuden, innerhalb weniger Tage festzustellen. Satellitenbilder werden auch dazu verwendet, die Auswirkungen von Katastrophen wie Erdbeben oder Überschwemmungen zu kartieren. Bewaffnete Konflikte erstrecken sich jedoch meist über viel längere Zeiträume als Naturkatastrophen. Sie erfordern also eher ein kontinuierliches Monitoring als Momentaufnahmen. Daher ist der Einsatz von automatisiertem *Remote Monitoring* bei bewaffneten Konflikten potentiell eher von Nutzen als bei Naturkatastrophen. Zugleich ist es eine grössere Herausforderung.

Die Fortschritte im Bereich Deep Learning und Rechenleistung eröffnen neue Perspektiven für eine solche Automatisierung.



Optische Satellitenbilder eines kommerziellen Anbieters (© Planet Labs PBC/Reuters).

Frei zugängliche optische Bilder (Copernicus Sentinel-2, verarbeitet von der ESA).

Frei zugängliche SAR-Bilder (Copernicus Sentinel-1, verarbeitet von der ESA).

Überwachtes Lernen könnte für *Remote Monitoring* besonders interessant sein: Das System lernt aus Referenzdaten, die von Menschen annotiert wurden, und überträgt die gewonnenen Erkenntnisse auf neue Daten. Ein grosser Vorteil ist, dass sich solche Systeme auf ganze Länder und potenziell global ausweiten lassen können. Deep Learning-Modelle, die sich auf ganze Konfliktregionen und darüber hinaus skalieren lassen, erfordern grosse Mengen an manuell annotierten Referenzdaten, die ein breites Spektrum an Szenarien abdecken. Einmal eingerichtet und sorgfältig durch ExpertInnen validiert, ist die regelmässige Verwendung von Deep Learning-basierten Systemen dann aber mit wenig Mehraufwand möglich. Dies erlaubt das kontinuierliche Monitoring von Konfliktgebieten in Quasi-Echtzeit anstelle von lediglich sporadischen Analysen.

Trotz vielversprechender Möglichkeiten im Bereich Deep Learning haben Menschenrechts- und Hilfsorganisationen bisher nur einige wenige Pilotprojekte durchgeführt. So erkundete Amnesty International zum Beispiel KI-Lösungen zur Satellitendatenanalyse, um die Zerstörung von Siedlungen in Darfur aufzudecken. Warum es an Anwendungen in der Praxis in grösserem Massstab mangelt, hat zwei wichtige Gründe. Zum einen ist es

der Fokus auf Bilder mit hoher räumlicher Auflösung. Zum anderen gibt es ein Missverhältnis bei den Erwartungen, was Deep Learning-Systeme leisten können und was nicht.

Arten von Satellitenbildern

Ein grosses Hindernis bei der Entwicklung von praxistauglichen *Remote Sensing* systemen ist, dass Modelle meist für die Arbeit mit Bildern mit hoher räumlicher Auflösung ausgelegt sind. Warum diese Art Bilder bevorzugt wird, liegt auf der Hand: Wenn Bilder einen hohen Detailgrad aufweisen, sind etwa Gräben oder beschädigte Gebäude leichter zu erkennen. Doch gleichzeitig stellen Bilder mit hoher räumlicher Auflösung automatisierte Screening-Lösungen vor einige Herausforderungen, allen voran die Anschaffungskosten. Die Geschäftsmodelle der meisten kommerziellen Satellitenanbieter erlauben KundInnen zu wählen, ob sie Satellitenaufnahmen von einem spezifischen Ort in Auftrag geben oder Archivbilder auswählen möchten. Andere bieten Abo-Modelle an, mit denen die NutzerInnen laufend Aufnahmen einer bestimmten Region abrufen können. Abo-Modelle sind kostspielig und Ortsaufnahmen von einem speziell beauftragten Satelliten erst recht. Archivbilder sind billiger, jedoch ohne Garantie, dass ein spezifischer Ort schon einmal abgedeckt wurde.

Ausserdem sind die Anschaffungskosten nur ein Teil des Problems. Hinzu kommen die eher versteckten Kosten für die Verarbeitung der hochauflösenden Bilder, die eine enorme Rechenleistung und eine hohe Download-Bandbreite erfordern.

Frei zugängliche Bilder mit einer geringeren räumlichen Auflösung sind eine vielversprechende Alternative. So erfassen die Sentinel-Satellitenkonstellationen der Europäischen Weltraumorganisation (ESA) kontinuierlich und engmaschig den ganzen Globus, selbst entlegene Konfliktgebiete. Die ESA-Bilder werden öffentlich und kostenlos zur Verfügung gestellt und decken in regelmässigen Abständen praktisch die ganze Welt ab. Die Bildverarbeitung erfordert bei mittlerer räumlicher Auflösung deutlich weniger Download-Bandbreite und Rechenleistung als bei hoher Auflösung.

Ein grosser Nachteil der frei zugänglichen Bilder ist ihr grösserer Bodenabstastabstand (*Ground Sampling Distance, GSD*), also der Abstand zwischen den Zentren zweier benachbarter Pixel, gemessen am Boden. Die Sentinel-2-Bilder der ESA haben eine GSD von 10 Metern, während diese bei einigen kommerziellen Anbietern nur 30 Zentimeter beträgt. Die grössere GSD der Open Access-Bilder erschwert es, diese zur Identifizierung von Objekten und Veränderungen am Boden zu nutzen. Dies wird am Beispiel des ukrainischen Kernkraftwerks Saporischschja in Enerhodar deutlich (Seite 2). Jedes der sechs Kraftwerksgebäude, die links in der oberen Reihe zu sehen sind, ist etwa 190 Meter lang und 70 Meter breit. So ein Gebäude könnte in einem kommerziellen Bild mit einer GSD von 50 Zentimetern in bis zu 53 200 Pixeln dargestellt werden. Auf optischen Bildern der Sentinel-Konstellation wird dasselbe Gebäude in lediglich 133 Pixeln dargestellt. Entsprechend sind Details der Gebäude auf den Open Access-Bildern viel schwerer zu erkennen als auf den hochauflösenden kommerziellen Aufnahmen. Schäden an kleineren Gebäuden sind mit blossen Auge auf den frei zugänglichen Satellitenbildern eventuell nicht einmal wahrnehmbar.

Deep Learning-Modelle können jedoch subtile Muster in den Satellitendaten erkennen, die dem menschlichen Auge entgehen. Eine besonders vielversprechende Datenquelle für gross angelegte Kartierungen sind Bilder von SAR-Satelliten (*Synthetic Aperture Radar*). SAR-Satelliten senden aktiv ein Mikrowellensignal aus,

anstatt wie optische Satelliten nur das sichtbare Licht zu nutzen. SAR-Daten sind also auch bei Bewölkung noch brauchbar. Im Gegensatz zu optischen Bildern, die reflektiertes Sonnenlicht aufnehmen, erfassen SAR-Bilder die vom SAR-Sensor zurückgestreuten Signale. Selbst kleine Objekte können zu signifikanten Veränderungen in den aufgezeichneten Signalen führen. Daher dürfte es irgendwann möglich werden, dass SAR-Daten Hinweise auf konfliktbedingte Zerstörungen liefern, selbst wenn die Schäden viel kleiner sind als ein Pixel in einem SAR-Bild. Darüber hinaus liefern SAR-Daten sogenannte Phaseninformationen. Diese wiederum ermöglichen eine Technologie namens SAR-Interferometrie (InSAR). Diese ist in Wissenschaft und Praxis bereits weit verbreitet, unter anderem, um die Auswirkungen von Erdbeben zu messen. In bestimmten elektromagnetischen Frequenzbereichen sind mit der InSAR-Methode Messungen im Zentimeterbereich möglich, auch wenn der Bodenabstastabstand viel grösser ist.

SAR-Daten und ihre mögliche Kombination mit vorhandenen Landbedeckungskarten und optischen Satellitenbildern, ermöglichen es, Veränderungen zu erkennen, die ansonsten nicht direkt in den Open Access-Bildern beobachtbar wären. Dieses Potential macht die Arbeit mit Open Access-Bildern zu einer attraktiven Alternative zu der kosten- und ressourcenintensiven Arbeit, die für räumlich hochauflösende Bilder notwendig ist. Nichtsdestotrotz bleiben hochauflösende Satellitenbilder für das *Remote Monitoring* bewaffneter Konflikte weiterhin wichtig, besonders, wenn Organisationen die Art und die Auswirkungen der Schäden näher untersuchen wollen, die zunächst auf Bildern mit mittlerer Auflösung identifiziert worden sind.

Die Herausforderung der Verifizierung

Eine zweite grosse Herausforderung von Deep Learning für die Satellitenbildanalyse sind die dem Output inhärenten Unsicherheiten. Algorithmus-basierte Systeme können bestenfalls den vermutlichen Ort und Zeitpunkt von Schäden oder anderer konfliktbedingter Auswirkungen angeben, zusammen mit einer geschätzten Wahrscheinlichkeit dieser. Solche Systeme können also nicht mit absoluter Sicherheit sagen, ob ein Ereignis stattgefunden hat. Genau darüber wollen Organisationen jedoch häufig Sicherheit. In dem Fall müssen die Organisationen, die Deep Learning-Tools verwenden, manuell überprüfen, ob das gemeldete Ereignis – etwa ein

Weiterführende Literatur

Mia Bennett et al., «**Improving Satellite Monitoring of Armed Conflicts**», in: *Earth's Future* 10:9 (2022).

Hannes Mueller et al., «**Monitoring War Destruction from Space Using Machine Learning**», in: *PNAS* 118:23 (2021).

Valerie Sticher / Aly Verjee, «**Do Eyes in the Sky Ensure Peace on the Ground? The Uncertain Contributions of Remote Sensing to Ceasefire Compliance**», in: *International Studies Review* 25:3 (2023).

Valerie Sticher / Jan Dirk Wegner / Birke Pfeifle, «**Toward the Remote Monitoring of Armed Conflicts**», in: *PNAS Nexus* 2:6 (2023).

Luftangriff auf ein ziviles Gebäude – tatsächlich stattgefunden hat. Dazu könnten Bilder mit hoher räumlicher Auflösung oder Quellen von vor Ort herangezogen werden.

Wenn *Remote Monitoring*-Anwendungen das manuelle Nachprüfen jedes gemeldeten Ereignisses erfordern, kann das bei regelmässigem Einsatz schnell überfordern. Das liegt daran, dass selbst in Kriegszeiten die Häufigkeit von Konfliktereignissen, etwa die Zerstörung oder Beschädigung von Gebäuden, relativ niedrig ist. Nach Schätzungen des *Economist* wurden beispielsweise in den ersten vier Kriegsmonaten in der Ukraine über 40 Prozent der bebauten Fläche von Mariupol zerstört. Doch selbst bei diesem enormen Ausmass der Zerstörung betraf dies jede Woche nur einen kleinen Teil der Gebäude. Bei den meisten Konflikten überwiegen die unveränderten und unbeschädigten Gebäude gegenüber den zerstörten noch weitaus mehr als in Mariupol, besonders wenn die Gewalthandlungen nur sporadisch stattfinden. In solchen Szenarien führt selbst eine niedrige Falsch-Positiv-Rate dazu, dass eine signifikante Anzahl Gebäude als wahrscheinlich beschädigt gemeldet wird, obwohl kein Schaden verursacht wurde. Dies stellt Organisationen vor eine erhebliche Herausforderung, wenn sie jeden Output des Modells überprüfen wollen, und kann ihre Arbeitslast sogar erhöhen statt sie zu erleichtern.

Methodisches Umdenken

Es gibt zwar Strategien und Technologien, um die Leistung von Deep Learning-Modellen zu verfeinern. Doch eine Herausforderung wie die Verifizierung lässt

sich nicht allein auf technischem Weg lösen. Es braucht auch einen Paradigmenwechsel in unserem Verständnis, welche Anwendungen des Konfliktmonitorings am effektivsten sind und was möglicherweise noch nicht erreicht werden kann. Mindestens drei Arten von Anwendungen, die die Notwendigkeit für Einzelprüfungen verringern, sind denkbar.

Die erste Art von Anwendungen hilft Organisationen dabei, ein Gefühl dafür zu bekommen, wo Gefechte stattfinden und welche Schäden sie verursachen. Statt sich auf einzelne, überprüfbare Konfliktereignisse zu fokussieren, würden die Deep Learning-Modelle Regionen sichtbar machen, in denen sich Schäden häufen. Das kann eine Orientierung für manuelle Kartierungsarbeiten sein oder ganz allgemein das Situationsbewusstsein der Organisation erhöhen, damit sie die humanitäre Hilfe besser priorisieren kann.

Der zweite Anwendungstyp betrifft Modelle zur Erkennung ungewöhnlicher zeitlicher oder geografischer Trends. Sie können die Nutzenden warnen und so als Frühwarnmechanismus dienen. Da sie auf Trends und nicht auf Einzelereignisse schauen, können sie für das Monitoring grosser Konfliktgebiete weltweit eingerichtet werden. Diese Meldungen müssten die Organisationen weiterhin manuell prüfen. Allerdings würde nur bei einem Trend und nicht bei einem Einzelereignis Alarm ausgelöst, und den menschlichen ExpertInnen damit Anhaltspunkte dafür liefern, wo sie Hinweise auf zunehmende Spannungen finden könnten.

Die dritte Art von Anwendungen sind Systeme, die mittels sekundärer Kriterien den Bedarf an manuellen Überprüfungen verringern. So sind humanitäre Akteure vielleicht besonders an dem Monitoring kritischer Infrastrukturen wie Krankenhäusern und Schulen interessiert. Die Anwendungen könnten so gestaltet werden, dass sie nur dann warnen, wenn an solchen vordefinierten Orten Schäden festgestellt werden. Jede einzelne Meldung müsste überprüft werden, aber die Anzahl der Meldungen könnte durch die

Einschränkung auf bestimmte Orte auf einem überschaubaren Niveau gehalten werden.

All diese Anwendungen sind insbesondere interessant für Konfliktgebiete, die relativ wenig Beachtung finden, wie die Zentralafrikanische Republik oder der Tschad. Die Medien greifen Ereignisse in diesen Konfliktgebieten häufig nicht auf, und die Menschenrechts- und Hilfsorganisationen haben oft keine Mittel für systematisches Monitoring solcher Kontexte. Leider sind dies auch Gebiete, von denen es keine umfassenden *Ground Truth*-Daten gibt, etwa manuell annotierte Bilder, mit denen die Deep Learning-Modelle für diese spezifischen Konflikte trainiert werden könnten. Die Beschaffung solcher Daten ist entscheidend für die effektive Anwendung der technischen Möglichkeiten des Deep Learning in der Praxis.

Ausblick

Hilfs- und Menschenrechtsorganisationen können frei zugängliche Satellitenbilder in Kombination mit Deep Learning-Modellen nutzen, um schneller und effektiver auf bewaffnete Konflikte zu reagieren. Um dieses Potenzial auszuschöpfen, sollten die Anwendungen die technologischen Grenzen der Deep Learning-Systeme, die operativen Grenzen der Organisationen und die Sensibilität der Kontexte, in denen sie eingesetzt werden, berücksichtigen. Darüber hinaus ist eine enge Zusammenarbeit der Forschenden mit Menschenrechts- und Hilfsorganisationen unerlässlich. Damit kann sichergestellt werden, dass der Austausch von Daten und Code auf eine Weise passiert, die die Entwicklung und Anwendung von Technologien zur Linderung der Auswirkungen bewaffneter Konflikte erleichtert, und gleichzeitig die Gefahr für daraus entstehenden Schaden minimiert.

Forschende sowie Menschenrechts- und Hilfsorganisationen sollten auch langfristigen Auswirkungen von *Remote Monitoring*-Lösungen auf bewaffnete Konflikte im Blick haben. Deep Learning-Modelle können bestimmte Formen der Gewalt, die schwere Schäden verursachen – wie Luftangriffe oder Granatenbeschuss – besser

erkennen als etwa Viehdiebstahl. Andere Formen, etwa geschlechtsspezifische Gewalt, werden nie per Satellitenbild erkannt werden können. Mit zunehmender Verbreitung des *Remote Monitoring* könnten sich die Ungleichheiten in den Nachweisfähigkeiten auf die Massnahmen der Menschenrechts- und Hilfsorganisationen auswirken. Dies könnte sogar bei jenen, die Gewalt ausüben, zu einem Taktikwechsel führen. Andere Beobachtungsformen, darunter auch die Zusammenarbeit mit den Akteuren vor Ort, bleiben weiterhin von zentraler Bedeutung. Wenn wir das *Remote Monitoring* mit Bedacht weiterentwickeln und einsetzen und dabei sowohl sein Potenzial als auch seine Grenzen berücksichtigen, können wir sicherstellen, dass es zu einem wirksamen Instrument zur Verringerung des Leids in bewaffneten Konflikten wird, ohne neue Wege zu Gewalt zu eröffnen.

Für mehr zu Perspektiven Mediation und Friedensförderung, siehe [CSS Themenseite](#).

Valerie Sticher ist Gastwissenschaftlerin an der School of Advanced International Studies der Johns Hopkins University.

Olivier Dietrich ist Doktorand in der Gruppe Photogrammetrie und Fernerkundung der ETH Zürich.

Birke Pfeifle ist Doktorandin am Center for Security Studies (CSS) der ETH Zürich.

Jan Dirk Wegner ist Inhaber des Lehrstuhls «Data Science for Sciences» und ausserordentlicher Professor der Abteilung «Mathematical Modeling and Machine Learning» (DM³L) der Universität Zürich.

Diese Analyse basiert auf folgendem Artikel: Valerie Sticher / Jan Dirk Wegner / Birke Pfeifle, «[Toward the Remote Monitoring of Armed Conflicts](#)», in: *PNAS Nexus* 2:6 (2023). Die zugrundeliegende Forschung ist Teil des gemeinsamen Projekts «Remote Monitoring of Armed Conflicts» des EcoVision Lab der ETH und der Universität Zürich, des Center for Security Studies der ETH Zürich und des IKRK, finanziert durch die Engineering for Humanitarian Action Initiative.

Die **CSS Analysen zur Sicherheitspolitik** werden herausgegeben vom Center for Security Studies (CSS) der ETH Zürich. Das CSS ist ein Kompetenzzentrum für schweizerische und internationale Sicherheitspolitik. Jeden Monat erscheinen zwei Analysen auf Deutsch, Französisch und Englisch.

HerausgeberInnen: Névine Schepers

Lektorat: Birke Pfeifle

Layout und Grafiken: Miriam Dahinden-Ganzoni, Rosa Guggenheim

Feedback und Kommentare: analysen@sipo.gess.ethz.ch

Weitere Ausgaben und Abonnement: www.css.ethz.ch/cssanalysen

Zuletzt erschienene CSS-Analysen:

Ukraine: Meinungsumfragen in Kriegszeiten Nr. 335
Geopolitische Auswirkungen des Berg-Karabach-Konflikts Nr. 334
Neue Dimensionen der Weltraummilitarisierung Nr. 333
Hybrider Krieg: Vorstellung und Wirklichkeit Nr. 332
Mediationsunterstützung: Strukturen und Rollen Nr. 331
UNO-Friedenssicherung Nr. 330

© 2024 Center for Security Studies (CSS), ETH Zürich
 ISSN: 2296-0236; DOI: 10.3929/ethz-b-000657790