

**Zeitschrift:** Geomatik Schweiz : Geoinformation und Landmanagement =  
Géomatique Suisse : géoinformation et gestion du territoire =  
Geomatica Svizzera : geoinformazione e gestione del territorio

**Herausgeber:** geosuisse : Schweizerischer Verband für Geomatik und  
Landmanagement

**Band:** 120 (2022)

**Heft:** 9-10

**Artikel:** Active Learning zur effizienten Erstellung fernerkundungsbasierter  
Karten

**Autor:** Rüetschi, Marius / Weber, Dominique / Ginzler, Christian

**DOI:** <https://doi.org/10.5169/seals-1033354>

### **Nutzungsbedingungen**

Die ETH-Bibliothek ist die Anbieterin der digitalisierten Zeitschriften. Sie besitzt keine Urheberrechte an den Zeitschriften und ist nicht verantwortlich für deren Inhalte. Die Rechte liegen in der Regel bei den Herausgebern beziehungsweise den externen Rechteinhabern. [Siehe Rechtliche Hinweise.](#)

### **Conditions d'utilisation**

L'ETH Library est le fournisseur des revues numérisées. Elle ne détient aucun droit d'auteur sur les revues et n'est pas responsable de leur contenu. En règle générale, les droits sont détenus par les éditeurs ou les détenteurs de droits externes. [Voir Informations légales.](#)

### **Terms of use**

The ETH Library is the provider of the digitised journals. It does not own any copyrights to the journals and is not responsible for their content. The rights usually lie with the publishers or the external rights holders. [See Legal notice.](#)

**Download PDF:** 08.02.2025

**ETH-Bibliothek Zürich, E-Periodica, <https://www.e-periodica.ch>**

# Active Learning zur effizienten Erstellung fernerkundungs-basierter Karten

Bei grossflächiger Kartierung von Bodenbedeckungen basierend auf Fernerkundungsdaten entstehen oft systematische Fehler. Um solchen entgegenzuwirken, können Active Learning-Verfahren eingesetzt werden, welche eine effiziente Verbesserung der Kartengenauigkeit ermöglichen. Für die Erstellung der fernerkundungsbasierten und schweizweiten Gebüschwaldkarte im Rahmen des Schweizerischen Landesforstinventars wurde ein solches Verfahren angewandt. Anhand dieses Beispiels soll aufgezeigt werden, wie mittels Active Learning der mittlere absolute Fehler einer grossflächigen Karte mit vertretbarem Aufwand von 6.04% auf 2.68% mehr als halbiert werden konnte.

*Lors de cartographies en grand format de couvertures du sol sur la base de données de télédétection apparaissent souvent des fautes systématiques. Afin de les pallier on peut utiliser la méthode de l'apprentissage actif qui permet une amélioration efficace de la précision de la carte. Pour l'établissement de la carte de végétation buissonnante sur la base de télédétection de l'ensemble du territoire suisse dans le cadre de l'inventaire forestier national un tel procédé a été utilisé. Par cet exemple on peut expliciter comment on peut réduire de moitié à l'aide de l'apprentissage actif l'erreur moyenne absolue d'une carte en grand format de 6.04% à 2.68% tout en respectant un investissement acceptable.*

La cartografia su larga scala delle coperture del suolo è spesso fonte gli errori sistemati dovuti a dati del telerilevamento. Per contrastare questo fenomeno basta ricorrere a processi di active learning che consentono un miglioramento sostanziale della precisione delle carte. Questo processo è stato impiegato per la realizzazione della carta svizzera degli arbusti boschivi, approntata in occasione dell'allestimento dell'inventario forestale nazionale svizzero. Ricorrendo a questo esempio si intende illustrare come attraverso l'active learning sia possibile dimezzare di oltre la metà l'errore assoluto mediano di una carta estremamente estesa, con valori che passano dal 6.04% al 2.68%.

M. Rüetschi, D. Weber, Ch. Ginzler

## Einleitung

In den letzten Jahren gab es grosse Fortschritte in der Fernerkundung bezüglich der grossflächigen und regelmässigen Aufnahme und der Verfügbarkeit der Daten. Dies verbessert die Erstellung von landesweiten Karten der Bodenbedeckung. Sehr wichtig dabei ist die Verfügbarkeit und Auswahl von repräsentativen Referenzdaten, welche für das Training von Klassifikationsalgorithmen benötigt

werden. Insbesondere, wenn eine Bodenbedeckungsklasse selten und räumlich heterogen verteilt ist, wird dies jedoch zu einer Herausforderung. Zufallsstichproben oder regelmässige Raster sind nicht geeignet, da für seltene Klassen die Stichprobe gross sein muss und so die Gewinnung einer ausreichenden Anzahl von Trainingsdaten sehr aufwändig und kostspielig ist. Daher wird in solchen Fällen häufig eine nicht-probabilistische Stichprobenstrategie gewählt, die jedoch zu systematischen Fehlern in der Karte führen kann. Um solche Fehler zu vermindern und die Kartengenauigkeit effizient

zu verbessern, gibt es Verfahren wie das *Active Learning* (AL). AL-Verfahren zielen darauf ab, optimale Standorte zur Erweiterung des Trainingsdatensatzes vorzuschlagen. Dabei soll die Anzahl Standorte minimiert und ihren Beitrag zur Verbesserung der Kartengenauigkeit maximiert werden (Tuia et al., 2011).

Gebüschwald ist ein typisches Beispiel einer seltenen und geklumpt auftretenden Bodenbedeckungsklasse. Er bedeckt gut 2% (719 km<sup>2</sup>) der Schweizer Landesfläche hauptsächlich in Höhen über 1000 m ü.M. (Cioldi et al., 2020). Anhand der Erstellung der landesweiten Gebüschwaldkarte im Rahmen des Schweizerischen Landesforstinventars (LFI) wird in der vorliegenden Arbeit aufgezeigt, wie mittels AL effizient fernerkundungsbasierte Karten verbessert werden können.

## Methoden

Der initiale Trainingsdatensatz für die Klassifizierung wurde durch die räumliche Abgrenzung von Gebüschwaldflächen auf SWISSIMAGE-Orthobildern der Jahre 2017–2019 erstellt. Als Hinweise für das Vorkommen von Gebüschwald wurden die Daten der Luftbildinterpretation des dritten LFI verwendet (Abb. 1). In unmittelbarer Nähe der LFI-Luftbildinformation wurden jeweils zwei Polygone manuell erstellt (Abb. 2a). Dabei wurden möglichst grosse und homogene Flächen von entweder Laub- oder Nadelgebüschwald und Nicht-Gebüschwald erfasst. Um die Vielfalt von Nicht-Gebüschwaldflächen abzudecken, wurden Flächen der fünf Bodenbedeckungsklassen «Laubwald», «Nadelwald», «Lärchenwald», «sonstige Vegetation» und «keine Vegetation» abgegrenzt.

Für die überwachte Klassifizierung wurden verschiedene landesweit verfügbare und fernerkundungsbasierte Prädiktoren verwendet (Tab. 1). Eine Vorstudie zeigte den Nutzen eines Multisensor-Ansatzes, bei welchem sich die Prädiktoren gegenseitig ergänzten, da sie jeweils auf unterschiedliche Gebüschwaldeigenschaften ansprachen (Weber et al., 2020). Somit




Abb. 1: LFI-Produktionsregionen, Auftreten des Gebüschwaldes laut der Luftbildinterpretation des dritten LFI und Darstellung der Fläche mit Gebüschwaldpotenzial definiert durch zwei Expertenregeln.




Abb. 2: Beispiele für generierte Trainingsdaten. a) zeigt die Erfassung von Polygonen für den initialen Trainingsdatensatz in der Nähe der Luftbildinformation des dritten LFI. In b) ist die Erfassung auf einem vom *Active Learning* vorgeschlagenen Standort dargestellt. Die SWISSIMAGE-Orthobilder im Hintergrund sind von a) 2018 und b) 2019. Koordinaten: CH1903+/LV95. © swisstopo.

wurden auch hier neben der Höheninformation des Geländes (DTM) und dem Vegetationshöhenmodell LFI (VHM LFI), *Synthetic Aperture Radar* (SAR)- und optische Daten der Copernicus-Missionen Sentinel-1 und -2 verwendet. Die Rasterweite der räumlich höher aufgelösten Datensätze DTM und VHM LFI wurden der Rasterweite der Sentinel-Daten von 10 m angepasst (siehe Rüetschi et al., (2021) für mehr Details).

Das überwachte Klassifikationsverfahren *Random Forest* (RF) wurde verwendet, um den Zusammenhang zwischen den Trainingsdaten und den Prädiktoren zu modellieren. Es wurden drei Bodenbedeckungsklassen definiert: «Laubgebüschwald», «Nadelgebüschwald» und «Nicht-Gebüschwald», bestehend aus allen fünf Nicht-Gebüschwaldklassen. Basierend auf dem erstellten RF-Modell wurde die gesamte Schweiz klassifiziert

und auf der generierten Karte zwei Expertenregeln angewandt. Da in den beiden Regionen Jura und Mittelland sowie in Gebieten unterhalb von 1000 und oberhalb von 2400 m ü.M. in der Regel kein Gebüschwald vorkommt (siehe Abb. 1), wurden alle vorhergesagten Gebüschwaldpixel innerhalb dieser beiden Regionen und dieser beiden Höhenstufen als «Nicht-Gebüschwald» reklassifiziert. Für den AL-Ansatz macht man sich dann die Angaben zur Modellunsicherheit der Klassifikation zunutze (Crawford et al., 2013). RF bietet dies, indem für jedes Pixel die Wahrscheinlichkeit berechnet wird, dass dieses zu einer bestimmten Klasse gehört. Diese Information bezüglich der Klassifikationsunsicherheit wurde für den folgenden halbautomatischen AL-Arbeitsfluss verwendet, welcher dreimal wiederholt wurde (Abb.3). In einem ersten Schritt wurden die Gebiete mit hohen Unsicherheiten identifiziert. Dazu wurde für jedes Pixel die *Margin Uncertainty* (MU) als die Differenz der Wahrscheinlichkeiten der zwei wahrscheinlichsten Klassen berechnet (Scheffer et al., 2001). Je kleiner diese Differenz, desto höher ist die Klassifikationsunsicherheit beim entsprechenden Pixel oder, anders formuliert, das Modell entschied sich aufgrund eines geringen Abstandes zwischen dem höchsten und zweithöchsten Wahrscheinlichkeitswert für eine der beiden Klassen. Um eine verarbeitbare Menge an Standorten zur Erstellung neuer Trainingsdaten zu erhalten, wurden zwei Schwellenwerte angewandt. Der erste Schwellenwert wurde anhand des MU-Werts definiert, um alle unsicheren Pixel mit einem Wert von weniger als 15% zu erhalten. Der zweite Schwellenwert bestand aus einer Mindestanzahl verbundener Pixel mit solch niedrigen MU-Werten. Diese Mindestanzahl wurde in jeder der drei AL-Iterationen verändert {300, 150, 130} um in jeder Wiederholung etwa 50 Flächen über die gesamte Schweiz zu erhalten. Auf diesen Standorten mit hoher Klassifikationsunsicherheit wurden in einem zweiten Schritt neue Trainingsdaten analog zur initialen Aufnahme generiert (Abb.2b). In einem letzten Schritt

ID	Art	Prädiktor	Quelle
1.1		Höhe	
1.2	Digitales Höhenmodell	Steilheit	swisstopo
1.3	swissALTI3D	Nordausrichtung	
1.4		Ostausrichtung	
2.1		25. Perzentil (2017–2019)	
2.2	Vegetationshöhenmodell LFI	75. Perzentil (2017–2019)	
2.3		Standardabweichung (2017–2019)	
3.1	Sentinel-1 SAR C-band	Komposit VV-Polarisation (Juli 2019)	Copernicus
3.2		Komposit VH-Polarisation (Juli 2019)	
4.1		Median pro Band (Juli–September, 2017–2019)	Copernicus
–			
4.10	Sentinel-2 L2A (Bänder 2-8a,	Median der absoluten Abweichungen des Medians pro Band (Juli–September, 2017–2019)	
4.11	11, 12)		
–			
4.20			

Tab. 1: Übersicht der verwendeten 10 m × 10 m-Prädiktoren.

wurde mittels der zusätzlichen Trainingsdaten ein neues RF-Modell erstellt und eine neue Gebüschwaldkarte generiert. Das AL-Verfahren wurde auf drei Iterationen beschränkt, da in einer vierten Iteration vor allem heterogene und damit schwer auf dem Luftbild zu interpretierende Gebiete vorgeschlagen wurden. Alle vier erstellten Gebüschwaldkarten (die initiale Karte und die drei mit AL ergänzten Karten) wurden mit unabhängigen und probabilistisch erhobenen Referenzdaten validiert. Dafür wurden die Luftbildinterpretationen des vierten LFI verwendet. Auf dem systematischen 1.4 km-Gitter der 20 638 LFI-Probeflächen wurde auf jeder

50 m × 50 m Interpretationsfläche für 25 regelmässig angeordnete Rasterpunkte die Bodenbedeckung auf Stereo-Luftbildern von 2006–2015 interpretiert (Ginzler, 2019). Für die Validierung wurden nur die 7640 LFI-Probeflächen verwendet, welche innerhalb der Fläche mit Gebüschwaldpotenzial zu liegen kamen. Auf jeder dieser Probeflächen wurde der Anteil der 25 Rasterpunkte mit Gebüsch mit dem Anteil klassifizierter Gebüschwaldfläche der Karte verglichen. Daraus wurden die beiden Statistiken Mittlerer Fehler (MF) und Mittlerer Absoluter Fehler (MAF) gerechnet, um die Kartengenauigkeit bei jeder Iteration zu beurteilen.

## Resultate

Die Resultate der Genauigkeitsanalyse sind dargestellt in Tabelle 2. Ohne die Verwendung von AL wurde die Gebüschwaldfläche stark überschätzt. Der klassifizierte Anteil Gebüschwald in der initialen Karte ist mit 127 640 ha um 78% grösser als die im Rahmen des vierten LFI publizierte Fläche von 71 900 ha (Cioldi et al., 2020). Diese Überschätzung wird auch durch den positiven MF von 4.68% gegenüber den LFI4-Referenzdaten widerspiegelt. Das AL-Verfahren verbesserte die Genauigkeit der Karte in Bereichen von hoher Modellunsicherheit deutlich und wirkte der initialen Überschätzung der Fläche entgegen (Abb. 4). An der Anzahl Trainingspolygone und -pixel ist zu erkennen, dass mit jeder AL-Iteration zusätzliche Trainingsdaten zur Verfügung standen. Diese zusätzlichen Trainingsdaten wirkten sich positiv auf die Genauigkeit aus, was am zu 0 annähernden MF und einem verminderten MAF zu erkennen ist. Der tiefste MAF von 2.68% wurde nach der dritten AL-Iteration erreicht, nach welcher der Anteil Gebüschwald bereits mit einem MF von –0.3% unterschätzt wurde. Dies ist auch an der klassifizierten Gebüschwaldfläche von 52 669 ha zu erkennen, welche nun kleiner ist als die geschätzte Fläche des vierten LFI.

Ohne AL wurde die Gebüschwaldfläche stark überschätzt, was die Grenzen einer nicht-probabilistischen Stichprobenstrategie für die überwachte Klassifikation deutlich aufzeigt (Stehman and Foody, 2019). AL bietet in Fällen, in denen es schwierig ist, einer probabilistischen Stichprobenstrategie zu folgen, eine effiziente Möglichkeit, die resultierenden systematischen Fehler zu vermindern. Die beobachtete Überschätzung des Gebüschwaldes mit MF-Werten grösser als 0 konnte so korrigiert werden. Die Kartengenauigkeit war bereits nach der ersten AL-Iteration deutlich höher. Die Erhöhung durch die beiden weiteren Iterationen war nicht mehr so ausgeprägt, was den Schluss zulässt, dass eine Sättigung der Modellernfähigkeit basierend auf den neu generier-

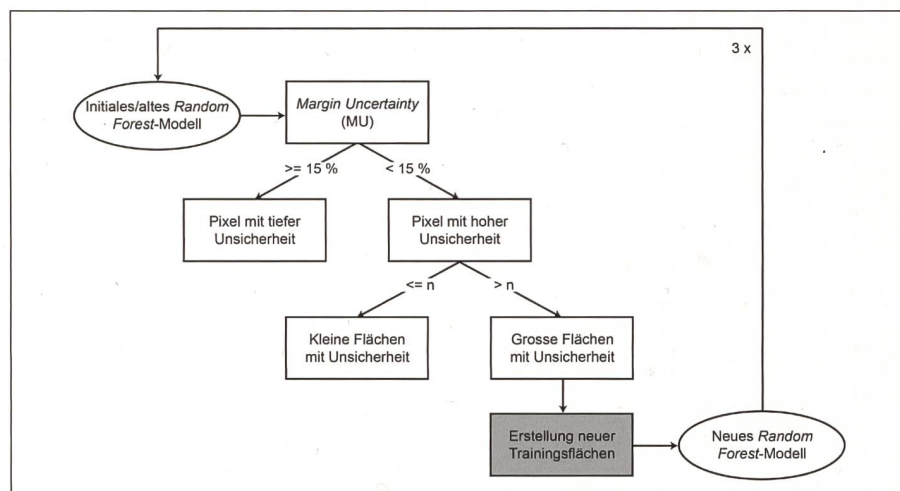


Abb. 3: Halbautomatischer AL-Arbeitsfluss (abgeändert nach Rüetschi et al., 2021). Die verwendeten n-Werte in den drei AL-Iterationen waren 300, 150 und 130.

	ohne AL	nach AL-Iteration 1	nach AL-Iteration 2	nach AL-Iteration 3
# Trainingspolygone	960	1120 (+ 160)	1254 (+ 134)	1455 (+ 201)
# Trainingspixel (10 m)	61 208	100 313 (+ 39 105)	110 775 (+ 10 462)	119 276 (+ 8501)
MF [%]	4.68	0.92	0.29	-0.3
MAF [%]	6.04	3.37	2.86	2.68
Gebüschwaldfläche [ha]	127 640	71 630	61 789	52 669

Tab. 2: Einfluss des *Active Learning* (AL) auf die Genauigkeitsstatistiken Mittlerer Fehler (MF) und Mittlerer Absoluter Fehler (MAF) sowie die klassifizierte Gebüschwaldfläche für die Schweiz.

ten Trainingsdaten rasch erreicht wurde. Dies machte sich auch bereits in der dritten AL-Iteration bemerkbar, bei welcher bereits schwer zu interpretierende Gebiete für die Erfassung zusätzlicher Trainingsdaten vorgeschlagen wurden. Sowohl stark heterogene Gebiete als auch solche mit schlechter Beleuchtung bis hin zu kompletter Beschattung erschwerten die Interpretation im SWISSIMAGE-Orthobild. Weiter ist zu beachten, dass die für die Validierung verwendeten LFI-Daten den Anteil Gebüsch pro Probestfläche beschreiben und nicht direkt die Gebüschwaldfläche. Dieser Unterschied muss bei der Interpretation der Kartengenauigkeit und des Einflusses des AL-Arbeitsflusses berücksichtigt werden.

## Fazit

Am Beispiel der fernerkundungsbasierten Gebüschwaldkarte für die gesamte Schweiz konnte der grossflächige Einsatz von AL gezeigt werden. Da die initialen Trainingsdaten aufgrund der Verteilung des Gebüschwaldes nicht nach einer Zufallsstichprobe erfasst wurden, wurde eine systematische Überschätzung der Gebüschwaldfläche in der Karte beobachtet. Dieser systematische Fehler, welcher bei grossflächiger Klassifikation häufig auftritt, wurde durch die Anwendung des AL-Arbeitsflusses, basierend auf der vom RF generierten Modellunsicherheit, vermindert. Dadurch konnte die Kartengenauigkeit auf eine effiziente Weise deutlich verbessert werden.

## Referenzen:

Cioldi, F., Brändli, U.-B., Didion, M., Fischer, C., Ginzler, C., Herold, A., Huber, M., Thürig, E., 2020. Waldressourcen, in: Brändli, U.-B., Abegg, M., Allgaier Leuch, B. (Eds.), Schwei-

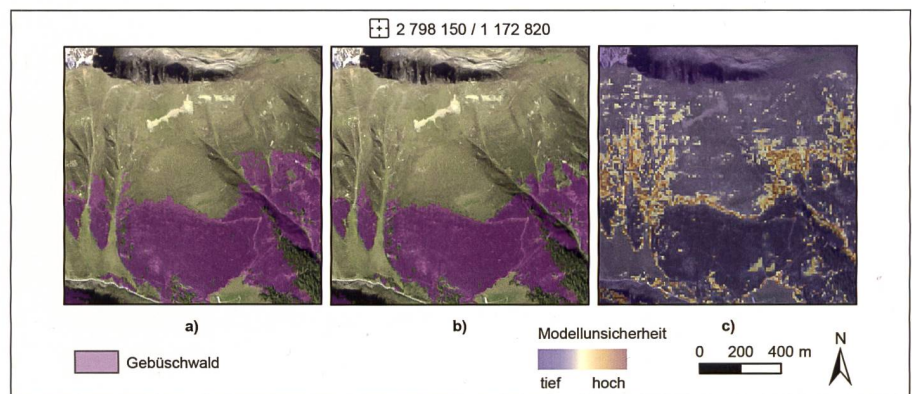


Abb. 4: Einfluss des AL auf die Gebüschwaldklassifikation. Dargestellt sind die Karten a) ohne AL und b) nach drei AL-Iterationen. c) zeigt die Modellunsicherheit (*Margin Uncertainty*) nach initialer Klassifikation. Das SWISSIMAGE-Orthobild im Hintergrund ist von 2019. Koordinaten: CH1903+/LV95. © swisstopo.

zerisches Landesforstinventar. Ergebnisse der vierten Erhebung 2009–2017. Birmensdorf, Eidgenössische Forschungsanstalt für Wald, Schnee und Landschaft WSL. Bern, Bundesamt für Umwelt, pp. 34–119.

Crawford, M.M., Tuia, D., Yang, H.L., 2013. Active Learning: Any Value for Classification of Remotely Sensed Data? Proc. IEEE 101, 593–608. <https://doi.org/10.1109/JPROC.2012.2231951>

Ginzler, C., 2019. Variables on the Sample Plot Captured by the Stereo GIS Application, in: Fischer, C., Traub, B. (Eds.), Swiss National Forest Inventory – Methods and Models of the Fourth Assessment. Managing Forest Ecosystems, Vol 35. Springer, Cham, pp. 111–124. [https://doi.org/10.1007/978-3-030-19293-8\\_6](https://doi.org/10.1007/978-3-030-19293-8_6)

Rüetschi, M., Weber, D., Koch, T.L., Waser, L.T., Small, D., Ginzler, C., 2021. Countrywide mapping of shrub forest using multi-sensor data and bias correction techniques. Int. J. Appl. Earth Obs. Geoinf. 105, 102613. <https://doi.org/10.1016/j.jag.2021.102613>

Scheffer, T., Decomain, C., Wrobel, S., 2001. Active Hidden Markov Models for Information Extraction, in: Hoffmann, F., Hand, D.J., Adams, N., Fisher, D., Guimaraes, G. (Eds.), Advances in Intelligent Data Analysis. IDA 2001. Lecture Notes in Computer Science, Vol 2189. Springer,

Berlin, Heidelberg, pp. 309–318. [https://doi.org/10.1007/3-540-44816-0\\_31](https://doi.org/10.1007/3-540-44816-0_31)

Stehman, S. V., Foody, G.M., 2019. Key issues in rigorous accuracy assessment of land cover products. Remote Sens. Environ. 231, 111199. <https://doi.org/10.1016/j.rse.2019.05.018>

Tuia, D., Pasolli, E., Emery, W.J., 2011. Using active learning to adapt remote sensing image classifiers. Remote Sens. Environ. 115, 2232–2242. <https://doi.org/10.1016/j.rse.2011.04.022>

Weber, D., Rüetschi, M., Small, D., Ginzler, C., 2020. Grossflächige Klassifikation von Gebüschwald mit Fernerkundungsdaten. Schweizerische Zeitschrift für Forstwes. 171, 51–59. <https://doi.org/10.3188/szf.2020.0051>

Marius Rüetschi  
Dominique Weber  
Christian Ginzler  
Forschungseinheit Landschaftsdynamik  
Eidg. Forschungsanstalt für Wald,  
Schnee und Landschaft WSL  
Zürcherstrasse 111  
CH-8903 Birmensdorf  
marius.rueetschi@wsl.ch