

Reitz, Oliver

Article

Erfassung von Ernteerträgen mit Satellitenbildern und Maschinellem Lernen - das Projekt FernEE 2.0

WISTA - Wirtschaft und Statistik

Provided in Cooperation with:

Statistisches Bundesamt (Destatis), Wiesbaden

Suggested Citation: Reitz, Oliver (2024) : Erfassung von Ernteerträgen mit Satellitenbildern und Maschinellem Lernen - das Projekt FernEE 2.0, WISTA - Wirtschaft und Statistik, ISSN 1619-2907, Statistisches Bundesamt (Destatis), Wiesbaden, Vol. 76, Iss. 4, pp. 29-38

This Version is available at:

<https://hdl.handle.net/10419/302057>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

ERFASSUNG VON ERNTEERTRÄGEN MIT SATELLITENBILDERN UND MASCHINELLEM LERNEN – DAS PROJEKT FernEE 2.0

Oliver Reitz

➤ **Schlüsselwörter:** Erntestatistik – Fernerkundung – Künstliche Intelligenz (KI) – Ackerbau – Sentinel-2

ZUSAMMENFASSUNG

Die Ernte- und Betriebsberichterstattung stützt sich auf Schätzungen erfahrener Landwirtinnen und Landwirte. Es wird jedoch immer schwieriger, diese zu gewinnen und damit die Basis für eine hochwertige Erntestatistik für Feldfrüchte bereitzustellen. Um diese Basis zu verbreitern, nutzt ein Pilotprojekt des Hessischen Statistischen Landesamtes Satellitendaten und Maschinelles Lernen und modelliert damit Ernteerträge für vier wichtige Kulturen auf kleinräumiger Ebene. Von dort aus können die Erträge auf beliebige Verwaltungsebenen aggregiert werden. Dieses weitgehend automatisierte Verfahren wurde in den Jahren 2022 und 2023 in sieben Bundesländern getestet. Es wird ab 2024 bundesweit eingeführt, damit es künftig in die statistische Produktion integriert werden kann.

➤ **Keywords:** *crop production statistics – remote sensing – artificial intelligence (AI) – farming – Sentinel-2*

ABSTRACT

Crop production reporting is based on estimates of experienced farmers. It is becoming increasingly difficult, however, to recruit such experts and provide the basis for generating high-quality crop production statistics. To broaden this basis, a pilot project by the Land Statistical Office of Hessen uses satellite data and machine learning to model crop yields for four key crops at a small area scale. From there, the yields can be aggregated to any administrative level. This largely automated procedure was tested in seven German Länder in 2022 and 2023. Starting in 2024, it will be rolled out across Germany for future integration into statistical production.

Dr. Oliver Reitz

ist Geograph und Referent im Referat „Competence Center Geoinformation und SAS, Auswertungsunterstützung“ des Hessischen Statistischen Landesamtes. Seine Aufgabenschwerpunkte liegen in den Bereichen Fernerkundung, Geoinformation und Maschinelles Lernen.

1

Einleitung

Unabhängige, flächendeckende und räumlich differenzierte Erntestatistiken sind eine wichtige Informationsbasis für Politik, Wirtschaft und die Öffentlichkeit. Sie bilden eine wesentliche Grundlage, um Versorgungsbilanzen zu erstellen und die Marktsituation auf nationaler und europäischer Ebene zu beurteilen. In der Erntestatistik basiert die Ermittlung von Ernteerträgen für Feldfrüchte auf zwei Erhebungen, der Ernte- und Betriebsberichterstattung (EBE) sowie der Besonderen Ernte- und Qualitätsermittlung (BEE). Die Besondere Ernte- und Qualitätsermittlung ist ein vergleichsweise aufwendiges Stichprobenverfahren zur Ermittlung von gewogenen Hektarerträgen auf Basis einer Zufallsauswahl an Feldern für die Hauptgetreidesorten, Winterraps und Kartoffeln. Die Ernte- und Betriebsberichterstattung basiert auf einer Vorausschätzung freiwillig meldender Berichterstatte(r)innen und Berichterstatte(r). (Breitenfeld, 2016). Aus methodischer Sicht betrachtet hängt die Güte der Schätzungen von den Erfahrungen und subjektiven Eindrücken der Meldenden ab. Sie ist damit mit mehr Unsicherheiten behaftet als das objektive Messverfahren der Besonderen Ernte- und Qualitätsermittlung. Beide Erhebungen liefern in Verbindung mit der Bodennutzungshaupterhebung zu einem frühen Zeitpunkt objektive und repräsentative Angaben über Menge und Qualität der Ernte ausgewählter wichtiger Fruchtarten für das gesamte Bundesgebiet und für die Länder.

Die BEE-Ergebnisse für die oben genannten Feldfrüchte werden ausschließlich auf Bundes- und Landesebene ausgewiesen; um die Erträge weiter zu regionalisieren, sind die Ergebnisse der Ernte- und Betriebsberichterstattung notwendig. Deren Verfahren ermöglicht eine Regionalisierung auf Kreisebene, jedoch aus Gründen der Geheimhaltung keine tiefere Unterteilung auf Gemeinde- oder Gitterzellenebene. Allerdings wurden selbst auf der Kreisebene in den letzten Jahren vermehrt fehlende Werte in der Erntestatistik verzeichnet. In Hessen betraf dies beispielsweise im Berichtsjahr 2023 durchschnittlich 38% aller Landkreise mit entsprechenden Anbauflächen (Hessisches Statistisches Landesamt, 2024). Ursache dafür ist, dass es zunehmend schwieriger wird, fachlich versierte Berichterstatte(r)nde zu gewinnen (Statistisches Bundesamt, 2024). In Hin-

blick auf deren Altersstruktur ist zudem davon auszugehen, dass sich dieses Problem weiter verschärfen wird.

Vor diesem Hintergrund ist die Nutzung von Satellitendaten in Kombination mit maschinellen Lernverfahren (ML) ein vielversprechender Ansatz, um eine flächendeckende Regionalisierung nicht nur zu gewährleisten, sondern Erntestatistiken auch auf noch kleinräumigeren Ebenen als bisher anbieten zu können. Dieses objektive Verfahren kann somit die subjektiven Schätzungen der Berichterstatte(r)nden ergänzen. Die Europäische Weltraumorganisation stellt durch das Copernicus-Erdbeobachtungsprogramm der Allgemeinheit kostenfrei und regelmäßig hochaufgelöste Satellitenbilder zur Verfügung. Dadurch bietet sich die Möglichkeit, den phänologischen Zustand¹ und die Entwicklung von Feldfrüchten effizient, flächendeckend und automatisiert zu erfassen, um so eine Datenbasis für maschinelle Lernverfahren zu schaffen. Eine Alternative zu solchen statistischen Modellen stellen prozessbasierte Ertragsmodelle dar (Arnold und andere, 2021). Diese sind jedoch von vordefinierten Annahmen der zugrunde liegenden komplexen pflanzenphysiologischen Prozesse abhängig (Leng/Hall, 2020). Daher sind sie im Vergleich zu maschinellen Lernverfahren tendenziell weniger flexibel und bedürfen in der Regel eines größeren Entwicklungsaufwandes.

Das Hessische Statistische Landesamt führte im Projekt FernEE (Fernerkundliche Erfassung von Ernteerträgen) ab 2018 Ertragsmodellierungen für vier wichtige Feldfrüchte – nämlich Wintergerste, Winterraps, Winterroggen und Winterweizen – für das Land Hessen durch (Ghosh und andere, 2022). Die Modellierung erfolgte retrospektiv, nachdem die Ernte eingefahren war. Hierfür wurden In-situ-Ertragsmessungen der Besonderen Ernte- und Qualitätsermittlung mit Satellitendaten und Schlaggeometrien aus dem Integrierten Verwaltungs- und Kontrollsystem (InVeKoS)² kombiniert, um statistische Ertragsmodelle zu trainieren. Ein Schlag ist hierbei eine zusammenhängende Fläche, die mit einer einheitlichen Kultur und von einem Betrieb bewirtschaftet wird.

1 Der phänologische Zustand bezieht sich auf äußerlich erkennbare Phasen im Jahreszyklus einer Pflanzenart.

2 System zur Verwaltung und Überwachung der Leistungen der Gemeinsamen Agrarpolitik der Europäischen Union. Antragstellende geben dort ihre landwirtschaftlichen Parzellen und angebauten Feldfrüchte an.

Ziel der in diesem Artikel vorgestellten nächsten Projektphase FernEE 2.0 ist, den vielversprechenden Ansatz für die Berichtsjahre 2022 und 2023 weiterzuentwickeln. Hierzu zählen vornehmlich die Ausweitung auf sieben am Projekt teilnehmende Länder, methodische Verbesserungen sowie die fortschreitende Automatisierung der Prozesskette. Die Ergebnisse sollen darüber hinaus als Entscheidungsgrundlage dienen, um eine Implementierung des fernerkundlichen Ansatzes in die operative Ertragsstatistik weiter voranzutreiben.

Kapitel 2 erläutert die verwendeten Daten und die Methodik des Verfahrens. Es folgt eine Darstellung der Validierungsergebnisse mit den gemessenen Erträgen auf Schlagebene sowie der Vergleich der amtlichen Statistik auf Kreisebene in Kapitel 3. In Kapitel 4 werden mögliche Fehlerquellen diskutiert und Kapitel 5 gibt einen Ausblick über anstehende Entwicklungen.

2

Daten und Methoden

Die Methodik des Projektes basiert auf der Verknüpfung mehrerer unterschiedlicher Datenquellen durch eine Vielzahl von Prozessschritten. Eine Übersicht hierzu bietet [➤ Grafik 1 auf Seite 32](#).

Die erste Säule der verwendeten Daten bilden georeferenzierte BEE-Volldrusch-Ertragsmessungen, die punktuell vorliegen und die Lernreferenz der statistischen Modelle darstellen. Ein Volldrusch bedeutet hierbei, dass ein gesamter Schlag und nicht bloß eine Probe gerodet wird. Die Daten haben die Statistischen Ämter der teilnehmenden Länder³ für die vier oben genannten Winterfeldfrüchte bereitgestellt.

Die zweite Säule sind Daten aus InVeKoS. Diese Daten umfassen für jeden enthaltenen Schlag eines Landes neben der Lage und Geometrie auch die angebaute Feldfrucht.

Die dritte Säule bilden flächendeckende Raster aus fernerkundlichen, meteorologischen und bodenkundlichen Daten, die die erklärenden Variablen für die Modelle darstellen:

- › Aus dem Copernicus-Dataspace wurden Bilder der optischen Sentinel-2-Satelliten heruntergeladen. Diese bieten in verschiedenen Bändern spektrale Informationen vom sichtbaren Licht bis in den Infrarotbereich mit einer räumlichen Auflösung von bis zu zehn Metern und liefern von jedem Ort Deutschlands mindestens alle fünf Tage eine Aufnahme.
- › Monatliche meteorologische Raster für die Monate April bis Juli hat der Deutsche Wetterdienst bereitgestellt; sie umfassen solare Einstrahlung, Bodenfeuchte, Niederschlag und Temperatur.
- › Von der Webseite der Bundesanstalt für Geowissenschaften und Rohstoffe wurden zudem bundesweite Raster der nutzbaren Feldkapazität und der Luftkapazität heruntergeladen.
- › Weiterhin gingen die Koordinaten sowie die Geländehöhe der Schläge in die Modelle ein, die aus dem digitalen Geländemodell (DGM200) des Bundesamtes für Kartographie und Geodäsie abgeleitet wurde.


Bei der optischen Erdbeobachtung sind Wolken eine große Herausforderung. Um den Informationsverlust durch Wolkenbedeckung zu minimieren, wurden möglichst wolkenfreie Sentinel-2-Szenen zunächst innerhalb eines großen Zeitraums zwischen dem 1. Mai und dem 10. Juli der Jahre 2022 und 2023 gesucht. Dieser Zeitraum wurde gewählt, da er für Winterfrüchte in der Regel die entscheidende Wachstumsphase vor der Ernte umfasst. Innerhalb dieses großen Zeitraums wurden daraufhin zwei kleinere, zweiwöchige Zeiträume identifiziert, die möglichst viele der wolkenfreien Bilder enthalten.

Für diese zwei Zeiträume wurden danach die Bilder für die gesamte Fläche automatisiert heruntergeladen, verbleibende Wolken maskiert, das heißt Wolken durch fehlende Werte ersetzt, und die Bilder zu zwei Mosaiken je Land zusammengefügt. Die Mosaiken umfassen somit möglichst wolkenfreie Bilder von verschiedenen Tagen, die jedoch höchstens 14 Tage auseinanderliegen. Diese Begrenzung soll verhindern, dass die Sentinel-2-Daten allein aufgrund ihres Aufnahmedatums allzu unterschiedliche phänologische Zustände im gleichen Mosaik enthalten. Von jeder Sentinel-Szene wurden neun verschiedene Bilder verschiedener spektraler Kanäle genutzt, die Informationen vom sichtbaren

³ Berlin-Brandenburg, Baden-Württemberg, Bayern, Hessen, Mecklenburg-Vorpommern, Niedersachsen, Saarland.

Grafik 1

Vereinfachte Darstellung der Prozesskette im Projekt FernEE



InVeKoS: Integriertes Verwaltungs- und Kontrollsystem; BEE: Besondere Ernte- und Qualitätsermittlung; ML: Maschinelles Lernen.

Licht bis Infrarot abbilden. Aus diesen fernerkundlichen Daten wurden schließlich sieben verschiedene spektrale Vegetations- und Feuchteindizes⁴ berechnet.

Um die Tabellen zum Training der maschinellen Lernverfahren zu erstellen, wurden die punktuellen BEE-Daten mit den flächigen InVeKoS-Daten zunächst räumlich verknüpft. Somit war es möglich, diejenigen Schlaggeome-

trien zu identifizieren, für die eine Ertragsmessung vorlag. Für jeden dieser Schläge wurde daraufhin der Mittelwert aller Pixel, die innerhalb seiner Grenzen lagen, je Raster berechnet. Um den Einfluss von Randbereichen der Felder zu minimieren, wurde eine zehn Meter breite Pufferzone am Rand der Schläge ausgeschlossen.

In der Tabelle sind damit jedem Schlag bodenkundliche, fernerkundliche und meteorologische Werte zugeordnet und zudem die Information, aus welchem Bundesland die Ertragsmessung kam. Im Modelltraining wurden ausschließlich Ertragsmessungen mit vollständigen, das heißt wolkenfreien, erklärenden Variablen genutzt.

⁴ Normalized Difference Vegetation Index, Enhanced Vegetation Index, Normalized Difference Moisture Index, Normalized Difference Red Edge Index, Anthocyanin Reflectance Index, Chlorophyll Red-Edge, Modified Chlorophyll Absorption in Reflectance Index. Siehe custom-scripts.sentinel-hub.com

Für jede der vier Feldfrüchte wurden eigene ML-Ertragsmodelle mithilfe des Caret-Toolkits in der Programmiersprache R trainiert (Kuhn, 2008). Dies geschah jeweils mit Daten aller sieben Länder, um eine möglichst große Trainingsbasis zu ermöglichen. Je Feldfrucht wurden verschiedene ML-Algorithmen⁵ mit den gleichen Daten trainiert und zu einem Ensemble zusammengefasst. Dadurch können die jeweiligen Stärken der Algorithmen zur Geltung kommen und kann eine insgesamt robustere Modellierung durchgeführt werden. Die Modellparameter der einzelnen Algorithmen wurden mit einer internen, fünffachen Kreuzvalidierung optimiert (Tuning). Eine externe, ebenfalls fünffache Kreuzvalidierung wurde zur Evaluation der Modellgüte herangezogen. Hierbei wurden jeweils 20 % der Daten als Testdaten vom gesamten Trainingsprozess ausgeschlossen und am Ende von den finalen Modellen vorhergesagt. Dieser Prozess wurde daraufhin fünfmal wiederholt, bis alle Daten einmal vom Training ausgeschlossen wurden. Diese Validierung simuliert den tatsächlichen Anwendungsfall auf unbekannte Daten, wobei die Qualität der Modellierung im Vergleich zu den tatsächlich gemessenen Erträgen evaluiert werden kann.

Die Modellierung für das Berichtsjahr 2022 fand nur mit Daten aus dem Jahr 2022 statt. Für das Berichtsjahr 2023 wurden hingegen zwei Modellierungen verglichen. Erstens nur mit Daten aus 2023 (Single) und zweitens mit Trainingsdaten aus 2022 und 2023 (Multi), wobei auch hier die Testdaten immer nur aus 2023 kamen, um zwischen Single und Multi vergleichbare Ergebnisse zu produzieren. Mit dem Multi-Modell soll hierbei untersucht werden, ob durch die Hinzunahme eines zurückliegenden Jahres der positive Effekt einer größeren Trainingsbasis den potenziell nachteiligen Effekt einer schlechten Übertragbarkeit auf das aktuelle Jahr überwiegt.

Für die tatsächliche Anwendung der Modelle wurden zunächst alle erklärenden Variablen für alle InVeKoS-Schläge extrahiert. Aufgrund von Wolkenbedeckung fehlende Werte in den fernerkundlichen Variablen wurden daraufhin mit einem Random-Forest-Modell je Zeitraum aus den lückenlosen meteorologischen und bodenkundlichen Variablen aufgefüllt. Dann wurden die trainierten Ertragsmodelle auf diese Daten angewendet, sodass für jeden Schlag eine Ertragsmodellierung vorlag. Es war

nun möglich, diese Hektarerträge auf die Kreisebene und Landesebene zu aggregieren, indem sie nach Größe der Schläge gewichtet wurden. Schläge auf einer Grenze zwischen zwei Landkreisen wurden hierbei dem Kreis mit der größeren Überlappung zugeordnet.

3

Ergebnisse

Die Ergebnisse der externen Kreuzvalidierung in [Tabelle 1](#) sind ein Indikator für die Qualität des Modells, auf bisher ungesehene Daten und Situationen zu reagieren. Ein niedriger sogenannter Generalisierungsfehler stellt sicher, dass die Modelle nicht nur die Trainingsdaten auswendig lernen, sondern den Ernteertrag auch in der Anwendung auf neue Schläge akkurat vorhersagen. Als Maß zur Evaluation der Modelle wurde der mittlere absolute Fehler (MAE) gewählt, da er direkt angibt, wie weit die Modellierungen im Mittel von den tatsächlichen Werten entfernt sind. Um die Fehler verschiedener Jahre und verschiedener Feldfrüchte miteinander vergleichen zu können, wurde zudem ein relati-

Tabelle 1

Ergebnisse der externen Kreuzvalidierung der Jahre 2022 und 2023¹

Feldfrucht	Training	MAE (mittlerer absoluter Fehler)	nMAE (normalisierter [relativer] Fehler)
		dt/ha	%
2022			
Wintergerste	Single	9,66	12,80
Winterraps	Single	4,78	11,48
Winterroggen	Single	9,72	17,37
Winterweizen	Single	8,69	11,23
2023			
Wintergerste	Single	9,11	13,08
	Multi	9,05	12,99
Winterraps	Single	4,45	12,44
	Multi	4,40	12,31
Winterroggen	Single	9,45	20,31
	Multi	9,23	19,84
Winterweizen	Single	9,65	13,57
	Multi	9,43	13,26

⁵ Neuronale Netze, Gradient Boosting, Random Forest, Gauß-Prozess, Support Vector Regression, Partial Least Square Regression.


¹ Für 2023 mit Trainingsdaten nur aus dem Bezugsjahr 2023 (Single) und mit Trainingsdaten aus 2022 und 2023 (Multi).

ver Fehler berechnet. Für diesen normalisierten Fehler (nMAE) wurde der MAE durch den mittleren Ertrag aller gemessenen Erträge geteilt und mit 100 multipliziert, um den prozentualen Anteil des Fehlers am Ertrag anzugeben.

Sowohl im Jahr 2022 als auch im Jahr 2023 weisen die Modelle für Wintergerste, Winterraps und Winterweizen ähnliche relative Fehler auf (zwischen 11,23 und 13,57%), für Winterroggen waren diese jedoch in beiden Jahren deutlich höher (17,37 bis 20,31%). Im Vergleich der beiden Jahre haben die Modellierungen für 2022 zudem leicht niedrigere Fehlerwerte als für 2023. Eine vorangegangene satellitengestützte Ertragsschätzung der Berichtsjahre 2018 und 2019 wies zum Vergleich höhere relative Abweichungen zwischen 14 und 18 % für Winterweizen und 42 und 43 % für Winterraps auf (Arnold und andere, 2021). Weiterhin wurde für 2023 untersucht, inwiefern die Hinzunahme von Trainingsdaten eines vergangenen Jahres Auswirkungen auf die Modellqualität hat. Für alle vier Feldfrüchte wurde durch das Multi-Modell der Fehler leicht verringert (siehe Tabelle 1).

Grafik 2

Verteilungsdichte der gemessenen und modellierten Ernteerträge für vier Winterfeldfrüchte im Jahr 2023
Ertrag in Dezitonnen je Hektar



Anmerkung: Je breiter die Form, desto mehr Daten gibt es in diesem Wertebereich.

Darüber hinaus ist es von Interesse, welche Wertebereiche maßgeblich zu diesen Fehlern beigetragen haben. **➤ Grafik 2** zeigt anhand der gestauchten Form der rechten Hälften, dass die modellierten Erträge eine geringere Spannweite als die tatsächlichen Erträge (linke Hälften) aufweisen. Für Ausreißer mit einem hohen Ertrag wurde also tendenziell ein zu niedriger Ertrag modelliert und für niedrige Ausreißer ein zu hoher, sodass es zu einer Stauchung um die ohnehin häufigen Werte kommt. Im Mittel und im Median wurden die Erträge durch die Modellierung hingegen sehr gut getroffen. Zu beachten ist zudem, dass sich diese Fehler bei Ausreißern auf der Schlagebene durch Aggregation auf die Kreisebene teilweise aufheben, sodass sich dieses Modellverhalten nicht eins zu eins auf höhere Ebenen überträgt.

➤ Tabelle 2 vergleicht zudem die finalen auf Kreisebene aggregierten Erträge mit den Kreiszahlen der amtlichen Statistik, sofern diese im Rahmen der Geheimhaltung verfügbar sind. Im Gegensatz zu den Fehlern in Tabelle 1 sind die Abweichungen hier jedoch keine Referenz zu den wahren Werten, sondern ein Vergleich mit einer anderen Schätzung. Sie gelten aufgrund einer unterschiedlichen Methodik eher als grober Richtwert, wie in Kapitel 4 näher ausgeführt wird. Generell sind die Abweichungen auf Kreisebene geringer als zu den gemessenen Erträgen auf Schlagebene. Auf Kreisebene sind die Abweichungen bei Roggen ebenfalls höher als bei den übrigen drei Feldfrüchten, für die zwischen den beiden Jahren keine deutlichen Unterschiede zu erkennen sind.

Tabelle 2

Abweichung der auf Kreisebene aggregierten Modellerträge von den EBE-Kreiszahl der Regionaldatenbank¹

Feldfrucht	Training	MAE (mittlerer absoluter Fehler)	nMAE (normalisierter [relativer] Fehler)
		dt/ha	%
2022			
Wintergerste	Single	5,19	7,46
Winterraps	Single	2,77	6,80
Winterroggen	Single	7,48	13,04
Winterweizen	Single	5,62	8,00
2023			
Wintergerste	Multi	4,88	7,42
Winterraps	Multi	2,68	7,27
Winterroggen	Multi	5,01	10,78
Winterweizen	Multi	5,15	8,02

¹ Die dargestellten Werte sind Mittelwerte über alle Kreise, für die entsprechende Statistiken vorhanden waren.

4

Diskussion

Eine Herausforderung des fernerkundlichen Ansatzes besteht in dem von Jahr zu Jahr variablen Informationsverlust durch Bewölkung. Der hier beschrittene Lösungsweg der Mosaikierung innerhalb eines begrenzten Zeitraums hat folgende Vorteile: Er stellt möglichst viele originäre, nicht interpolierte Daten den ML-Modellen zur Verfügung und geht durch die vergleichsweise kleine Datenmenge sparsam mit begrenzten Speicherplatz- und Rechenkapazitäten um. Dieser Ansatz ist jedoch immer ein Kompromiss zwischen Informationsverlust durch Wolken und der Inklusion unterschiedlicher phänologischer Zustände.

Eine Alternative wäre, alle Bilder innerhalb eines langen Zeitraums, etwa von April bis Juli, unabhängig von ihrer Wolkenbedeckung zu verwenden und die vielen fehlenden Werte durch Wolken zeitlich zu interpolieren. Damit könnte zwar die phänologische Entwicklung der Feldfrüchte umfassender abgebildet werden, aber die Modelle würden auch mit deutlich mehr interpolierten Daten trainiert werden. Zudem würde dieser Ansatz deutlich mehr Speicherplatz- und Rechenkapazitäten beanspruchen, daher hat er sich als vorerst nicht durchführbar erwiesen.


Verschiedene Gründe können zu den in Tabelle 1 dargelegten Modellabweichungen zu den tatsächlichen Ertragsmessungen der Besonderen Ernte- und Qualitätsermittlung beitragen. Die vergleichsweise geringe Zahl an BEE-Daten, die in das Modelltraining eingingen, hat wahrscheinlich dazu geführt, dass die Lernkurve der Modelle noch nicht ihr Optimum erreicht hat (Viering/Loog, 2023). Mehr Ertragsmessungen in den Trainingsdaten, vor allem des aktuellen Jahres, geben den Modellen diversere Beispiele, um die generellen statistischen Beziehungen zu den erklärenden Variablen lernen zu können und dadurch robustere Ergebnisse zu produzieren.

In der Modellierung traten hohe Fehler insbesondere bei sehr hohen und sehr niedrigen Erträgen auf. Die Spannweite der modellierten Erträge war dadurch geringer als diejenige der gemessenen Erträge. Dementsprechend gestaltet sich die Modellierung auf Schlagebene umso schwieriger, je höher die abzubildende Varianz in den

Ertragsdaten ist. Die Varianz war für Winterroggen und auch allgemein im Jahr 2023 vergleichsweise hoch, was die entsprechend höheren relativen Fehler erklären kann. [↗ Grafik 3](#)

Grafik 3

Variationskoeffizient je Winterfeldfrucht und Jahr in %



Anmerkung: Hohe Variationskoeffizienten sind ein Hinweis auf eine schwierigere Modellierung auf Schlagebene.

Weiterhin kann es andere wichtige erklärende Variablen geben, die bisher nicht in den Modellen berücksichtigt wurden. Zu nennen wäre hier die noch nicht flächendeckend vorliegende Information, ob ein Schlag ökologisch oder konventionell bewirtschaftet wird. In Einzelfällen kann auch der Ertrag schlecht mit den spektralen Satellitendaten korreliert sein. So sehen beispielsweise Schläge im Satellitenbild gleich oder sehr ähnlich aus, obwohl sie eigentlich einen unterschiedlichen Ertrag aufweisen. Darüber hinaus kann es nach dem letzten Satellitenbild noch zu lokalen Hagel- oder Sturmschäden an der Ernte gekommen sein. Solche Phänomene sind jedoch zu kleinräumig, um sie in den meteorologischen 1-km-Rasterdaten adäquat abbilden zu können.

Auch wenn sich die oben genannten Fehler bei der Aggregation größtenteils aufheben, können die auf Kreisebene aggregierten Ergebnisse von denen der amtlichen Statistik aus weiteren Gründen abweichen:

- › Zuerst wurde eine Vollerhebung aller verfügbaren InVeKoS-Schläge basierend auf den BEE-Volldruschmessungen modelliert. Die Schätzungen der Ernte- und Betriebsberichterstattung wurden daher in der Modellierung nicht berücksichtigt.

- › Die Aggregation auf höhere Ebenen erfolgte zudem nach Belegenheit des Schlages, die amtliche Erntestatistik folgt jedoch dem Betriebssitzprinzip. Technisch wäre eine Auswertung nach beiden Prinzipien zu realisieren, sofern Informationen zum Betriebssitz verfügbar sind.
- › Weiterhin geht aus den InVeKoS-Daten nicht hervor, ob die jeweiligen Flächen tatsächlich für den Korn-ertrag oder für die Ganzpflanzensilage genutzt wurden. Ob ein Schlag für den Korn-ertrag oder als Ganzpflanzensilage geerntet wird, ist eine individuelle Entscheidung der Landwirtinnen und Landwirte. Sie hängt neben dem erwarteten Ertrag auch von aktuellen Marktpreisen und Lagerbeständen ab und ist daher schwer in einem Modell abzubilden. Vor allem im Jahr 2023 kann dies aufgrund von verbreiteten Dauerniederschlägen zur Erntezeit zu Abweichungen von den tatsächlichen Korn-erträgen geführt haben.

Letztlich unterschied sich auch die Datenbasis der Besonderen Ernte- und Qualitätsermittlung zwischen FernEE 2.0 und der amtlichen Statistik. Aus vier verschiedenen Gründen wurde das Training der Modelle nicht mit allen theoretisch zur Verfügung stehenden BEE-Daten durchgeführt:

1. Es kamen aufgrund ihrer höheren Qualität ausschließlich Volldruschdaten zum Einsatz. In der Besonderen Ernte- und Qualitätsermittlung werden teilweise auch Probeschnitte durchgeführt.
2. Aus manchen Bundesländern wurden lediglich Daten verwendet, für deren Nutzung die Landwirtinnen und Landwirte ihr Einverständnis gegeben hatten.
3. Ertragsmessungen, deren Koordinaten nicht eindeutig einer InVeKoS-Geometrie der passenden Feldfrucht zugeordnet werden konnten (Koordinaten lagen zum Beispiel im Wald), konnten nicht weiterverwendet werden.
4. Für manche BEE-Daten waren aufgrund von Wolkenbedeckung keine entsprechenden fernerkundlichen Informationen verfügbar, weswegen sie vom Modelltraining ausgeschlossen wurden.

Trotz dieser Beschränkungen sind die Ergebnisse auf Kreisebene sehr vielversprechend. So konnten die relativen Abweichungen zu den Kreis- und Betriebsberichterstattungen im Vergleich zu den Ergebnissen in Arnold und andere (2021) zum Teil deutlich reduziert werden. Eine

exakte Übereinstimmung des fernerkundlichen Ansatzes mit den Kreis- und Betriebsberichterstattungen ist aus den oben genannten Gründen ohnehin nicht zu erwarten; vielmehr sind alle Methoden mit gewissen Unsicherheiten verbunden und weichen daher von den wahren Werten, also den tatsächlichen Erntemengen und Erträgen auf Kreisebene, ab.

5

Fazit und Ausblick

Dieses Pilotprojekt bestätigt, dass der fernerkundliche Ansatz für die Erntestatistik nützlich sein kann. Die Ergebnisse sind dabei nicht nur sehr vielversprechend, sondern es wurden auch verschiedene Neuerungen implementiert, darunter die Integration von meteorologischen und bodenkundlichen Variablen sowie die Anwendung neuer ML-Algorithmen. Dies hat die Ergebnisse noch einmal deutlich verbessert.

Eine Herausforderung bestand darin, dass mit der Einbeziehung von sieben Bundesländern die Wahrscheinlichkeit einer flächendeckend geringen Bewölkung in einem gegebenen Zeitraum abnahm. Dem wurde mit einer Mosaikierung der Satellitenbilder begegnet.

Infolge dieser erfolgreichen Projektphase beschloss der Statistische Verbund⁶ im April 2024, das Vorhaben für die Berichtsjahre 2024 bis 2026 fortzusetzen. Das Projekt wird vom Hessischen Statistischen Landesamt und dem Statistischen Bundesamt geleitet und wird drei maßgebliche Ziele umsetzen:

1. Das Verfahren zur retrospektiven Ertragserfassung wird auf die gesamte Bundesfläche ausgeweitet und weitere methodische Neuerungen werden eingeführt. Diese umfassen eine bereits in Erprobung befindliche komplexere Mosaikierung ebenso wie die Integration zusätzlicher Satellitenprodukte, wodurch der Informationsverlust durch Wolken weiter abnehmen wird.
2. Ein operativer Regelbetrieb wird erprobt und ein Verfahren erarbeitet, um den Ansatz dauerhaft in der amtlichen Statistik zu implementieren.

⁶ Den Statistischen Verbund bilden die Statistischen Ämter des Bundes und der Länder.

3. Das Verfahren wird in zwei Machbarkeitsstudien auf weitere Feldfrüchte der Besonderen Ernte- und Qualitätsermittlung erweitert (Hafer, Triticale, Sommergerste) und eine frühzeitige Ertragsprognose im Sommer des laufenden Berichtsjahres mit maschinellen Lernverfahren getestet.

Die den Modellen zur Verfügung gestellte Datenbasis wird sich weiter verbessern, da es mehr Ertragsmessungen des aktuellen Berichtsjahres aus mehr Ländern wie auch insgesamt mehr Datenjahre geben wird. Dieses innovative Vorhaben zeigt somit, wie der Einsatz neuer Technologien einen wichtigen Beitrag zur Statistikproduktion im 21. Jahrhundert leisten kann. 

LITERATURVERZEICHNIS

Arnold, Jasmin/Brandt, Patric/Gerighausen, Heike. *Erprobung der satellitengestützten Ertragsschätzung für die Agrarstatistik – Projekt SatAgrarStat*. In: WISTA Wirtschaft und Statistik. Ausgabe 6/2021, Seite 43 ff.

Breitenfeld, Jörg. *Wie erfolgt die statistische Ermittlung der Getreideernte?* In: Statistische Monatshefte Rheinland-Pfalz. Ausgabe 8/2016, Seite 760 ff. [Zugriff am 19. Juni 2024]. Verfügbar unter: www.statistischebibliothek.de

Ghosh, Parmita/Mandal, Dipankar/Wilfling, Sarah/Hollberg, Jens/Bargiel, Damian/Bhattacharya, Avik. *Synergy of optical and synthetic aperture radar data for early-stage crop yield estimation: a case study over a state of Germany*. In: Geocarto International. Jahrgang 37. Ausgabe 25/2022, Seite 10743 ff. DOI: [10.1080/10106049.2022.2039306](https://doi.org/10.1080/10106049.2022.2039306)

Hessisches Statistisches Landesamt. *Statistische Berichte: Die Ernte ausgewählter Feldfrüchte in Hessen 2023*. 2024. [Zugriff am 19. Juni 2024]. Verfügbar unter: statistik.hessen.de

Kuhn, Max. *Building Predictive Models in R Using the caret Package*. In: Journal of Statistical Software. Band 28. Ausgabe 5/2008. DOI: [10.18637/jss.v028.i05](https://doi.org/10.18637/jss.v028.i05)

Leng, Guoyong/Hall, Jim W. *Predicting spatial and temporal variability in crop yields: an inter-comparison of machine learning, regression and process-based models*. In: Environmental Research Letters. Band 15. Ausgabe 4/2020. DOI: [10.1088/1748-9326/ab7b24](https://doi.org/10.1088/1748-9326/ab7b24)

Statistisches Bundesamt. *Qualitätsbericht – Ernte- und Betriebsberichterstattung (EBE): Feldfrüchte und Grünland*. 2024. [Zugriff am 28. Juni 2024]. Verfügbar unter: www.destatis.de

Viering, Tom/Loog, Marco. *The Shape of Learning Curves: A Review*. In: IEEE Transactions on Pattern Analysis and Machine Intelligence. Band 45. Ausgabe 6/2023, Seite 7799 ff. DOI: [10.1109/TPAMI.2022.3220744](https://doi.org/10.1109/TPAMI.2022.3220744)

Herausgeber
Statistisches Bundesamt (Destatis), Wiesbaden

Schriftleitung
Dr. Daniel Vorgrimler
Redaktion: Ellen Römer

Ihr Kontakt zu uns
www.destatis.de/kontakt

Erscheinungsfolge
zweimonatlich, erschienen im August 2024
Ältere Ausgaben finden Sie unter www.destatis.de sowie in der [Statistischen Bibliothek](#).

Artikelnummer: 1010200-24004-4, ISSN 1619-2907

© Statistisches Bundesamt (Destatis), 2024
Vervielfältigung und Verbreitung, auch auszugsweise, mit Quellenangabe gestattet.