

CLIMATE CHANGE

23/2026

Abschlussbericht

KI zur Verwaltungsautomatisierung und zur Erkennung krimineller Aktivitäten im Emissionshandel

von:

Christian Winger, Johanna Cludius, Jakob Graichen, Nora Wissner
Öko-Institut, Berlin

Raphaela Kotsch, Regina Betz

ZHAW, Winterthur

Manuel Günther

Universität Zürich, Zürich

Herausgeber:

Umweltbundesamt

CLIMATE CHANGE 23/2026

REFOPLAN des Bundesministeriums für Umwelt,
Naturschutz, nukleare Sicherheit und Verbraucherschutz

Forschungskennzahl 3722 42 506 0

FB001909

Abschlussbericht

KI zur Verwaltungsautomatisierung und zur Erkennung krimineller Aktivitäten im Emissionshandel

von

Christian Winger, Johanna Cludius, Jakob Graichen, Nora
Wissner

Öko-Institut, Berlin

Raphaela Kotsch, Regina Betz

ZHAW, Winterthur

Manuel Günther

Universität Zürich, Zürich

Im Auftrag des Umweltbundesamtes

Impressum

Herausgeber

Umweltbundesamt
Wörlitzer Platz 1
06844 Dessau-Roßlau
Tel: +49 340-2103-0
Fax: +49 340-2103-2285
buergerservice@uba.de
Internet: www.umweltbundesamt.de

Durchführung der Studie:

Öko-Institut
Borkumstr.2
13189 Berlin
Deutschland

ZHAW

Bahnhofplatz 12
8001 Winterthur
Schweiz

Abschlussdatum:

April 2025

Redaktion:

Fachgebiet V 3.4 Registerführung
Julien Hauth
Jan Erik Fischer

Fachgebiet V 3.2 Chemische Industrie und industrielle Feuerungsanlagen

Lars Langefeld
Hans-Jürgen Garvens

DOI:

<https://doi.org/10.60810/openumwelt-8130>

ISSN 1862-4359

Dessau-Roßlau, April 2026

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autorinnen*Autoren.

Kurzbeschreibung: KI zur Verwaltungsautomatisierung und zur Erkennung krimineller Aktivitäten im Emissionshandel

Dieses Projekt untersucht, inwieweit bestimmte Methoden der künstlichen Intelligenz (KI) genutzt werden können, um die Verwaltungsaufgaben der DEHSt als zuständige nationale Behörde für den europäischen Emissionshandel zu unterstützen. Um den komplexen Vollzug in diesen verschiedenen Systemen zu unterstützen und die Integrität der Emissionshandelssysteme zu sichern, werden die Prozesse der Kontoeröffnung, fachliche Verwaltungsentscheidungen wie z.B. die Prüfung von Emissionsberichten sowie das Risiko krimineller Aktivitäten, speziell beim Handel in diesem Projekt in den Fokus genommen. Es wird analysiert, inwieweit die Vollzugsprozesse anhand von künstlicher Intelligenz gestaltet werden können, um Ressourcen effizienter einzusetzen oder für andere Bereiche verfügbar zu machen. Mit historischen Daten z.B. für die Kontoeröffnung oder Emissionsberichte werden passende Algorithmen entwickelt und erprobt. Außerdem werden Algorithmen zur Erkennung von ungewöhnlichen Transaktionen entwickelt.

Abstract: AI for administrative automation and detection of criminal activities in the emissions trading system

This project investigates the extent to which some selected methods of artificial intelligence (AI) can be used to support the administrative tasks of the DEHSt as the competent national authority for European emissions trading. In order to support the complex enforcement in these different systems and to ensure the integrity of the emissions trading systems, the project focuses on the processes of account opening, technical administrative decisions, e.g. emissions reporting, as well as the risk of criminal activities, especially in trading. It will be analysed to what extent the enforcement processes can be supported by artificial intelligence in order to use resources more efficiently or make them available for other areas. Historical data, e.g. for account opening or emission reports, will be used to develop and test suitable algorithms. In addition, algorithms for recognising unusual transactions are being developed.

Inhaltsverzeichnis

Abbildungsverzeichnis.....	8
Tabellenverzeichnis.....	9
Zusammenfassung.....	11
Summary.....	13
1 Einleitung.....	15
2 Arbeitspaket 1 - Kontoeröffnungen.....	16
2.1 Datenaufbereitung.....	19
2.2 Training.....	20
2.3 Auswertung.....	20
2.4 Fazit.....	23
3 Arbeitspaket 2 - Automatisierte Vorprüfung von fachlichen Verwaltungsentscheidungen.....	24
3.1 Datenaufbereitung/-analyse.....	24
3.2 Training.....	27
3.3 Auswertung.....	28
3.3.1 Vergleich der Modellergebnisse.....	28
3.3.2 Einfluss der Struktur und Konfiguration des neuronalen Netzes.....	30
3.4 Fazit.....	37
4 Arbeitspaket 3 - Automatisierte Prüfung von Registerdaten als Teil der Geldwäscheprävention.....	39
4.1 Hintergrund.....	39
4.2 Das Unionsregister und Marktteilnehmende im EU-ETS.....	42
4.3 Datenbasis.....	44
4.3.1 Datensammlung.....	44
4.3.2 Konzernstrukturen im Unionsregister.....	45
4.3.3 Datenaufbereitung.....	46
4.4 Methode.....	47
4.4.1 Indikatoren und Merkmalsauswahl.....	48
4.5 Ergebnisse und Auswertung.....	49
4.5.1 Ausreißer im zeitlichen Ablauf: Monat und Jahr.....	49
4.5.2 Geografische Verteilung der Ausreißer.....	52
4.5.3 Fokus auf Luftfahrzeugbetreiber.....	54
4.6 Zusammenfassung und Fazit.....	59
5 Schlussfolgerungen.....	62
6 Quellenverzeichnis.....	64

A	Datenschema AP 1	66
B	Datenschema AP 2	70
B.1	Stoffströme	70
B.2	Lernen_Stoffströme	77
B.3	Prüfmeldungen	83
B.4	Produktmengen	84
C	Detaillierte Ergebnistabellen AP3.....	85
C.1	Gesamte Beobachtungen, Ausreißer und Ausreißerquote pro Land	85
C.2	Gesamte Beobachtungen, Beobachtungen Luftfahrt, Aureißerquote gesamt und Luftfahrt	89
C.3	Ausreißerquote in unterschiedlichen Zeiträumen.....	93

Abbildungsverzeichnis

Abbildung 1:	Schematischer Überblick der Arbeitsschritte	16
Abbildung 2:	Verteilung der Ergebnisse aller Modelle von accuracy_rejected und accuracy_approved	31
Abbildung 3:	Einfluss der Aktivierungsfunktion auf die Mindestgenauigkeit	32
Abbildung 4:	Einfluss der Lernalgorithmus (Solver) auf die Mindestgenauigkeit	32
Abbildung 5:	Einfluss Änderung der Lernrate	33
Abbildung 6:	Einfluss der Anzahl der versteckten Schichten auf die Mindestgenauigkeit	34
Abbildung 7:	Einfluss der Features mit Zeitreihen-Information	36
Abbildung 8:	Stufen der Geldwäsche und Bezug zum EU-ETS	39
Abbildung 9:	Übersicht über die Kontoarten und zugehörigen Marktteilnehmer*innen im Unionsregister	43
Abbildung 10:	Eigentumsstruktur bei ORBIS am Beispiel von UNIPER	45
Abbildung 11:	Aggregation der Transaktionen auf täglicher Ebene	47
Abbildung 12:	Handelsaktivitäten pro Monat, Ausreißer und Ausreißerquote	50
Abbildung 13:	Handelsaktivitäten in den Jahren 2011-2020, Ausreißer und Ausreißerquote	51
Abbildung 14:	Preisverlauf EUAs und EUAAs 2011-2020	52
Abbildung 15:	Anzahl Beobachtungen und Ausreißer in den Top-30 Ländern mit den meisten Ausreißern	53
Abbildung 16:	Ausreißerquote in den Top-30 Ländern mit der höchsten Ausreißerquote	54
Abbildung 17:	Anzahl der Ausreißer nach Land des Kontoinhabers und Anteil in den Top-30 Ländern mit den meisten Ausreißern	55
Abbildung 18:	Anzahl der Beobachtungen nach Land und Luftfahrzeugbetreiber in den Top-30 Ländern mit den meisten Ausreißern	56
Abbildung 19:	Anzahl der Ausreißer nach Register und Anteil Luftfahrzeugbetreiber	57
Abbildung 20:	Anzahl der Beobachtungen und Ausreißer für Luftfahrzeugbetreiber und andere regulierte Kontotypen	58
Abbildung 21:	Vergleich der Ausreißer-Anteile in drei verschiedenen Zeiträumen für die Top-30 Länder mit höchster Ausreißerquote 2011-2020	59

Tabellenverzeichnis

Tabelle 1:	Ergebnisse der Erkennung von Anträgen	20
Tabelle 2:	Felder die im SVM-Ansatz zur Ablehnung beitragen.....	21
Tabelle 3:	Felder die im SVM-Ansatz zur Annahme beitragen.....	21
Tabelle 4:	Ergebnisse der Erkennung von Fehlern in den verifizierten Emissionsberichten.....	28
Tabelle 5:	Features mit größtem Einfluss auf das Ergebnis im SVM-Ansatz	29
Tabelle 6:	Häufigkeit der wichtigsten Features in allen drei ML-Ansätzen (alphabetische Reihenfolge ohne Gewichtung)	38
Tabelle 7:	Relevante Variablen für die Erkennung von Geldwäsche	40
Tabelle 8:	Anhangstabelle zum Datenschema	66
Tabelle 9:	Gesamte Beobachtungen, Ausreißer und Ausreißerquote pro Land	85
Tabelle 10:	Gesamte Beobachtungen, Beobachtungen Luftfahrt, Ausreißerquote gesamt und Luftfahrt	89
Tabelle 11:	Ausreißerquote in unterschiedlichen Zeiträumen	93

Abkürzungsverzeichnis

Abkürzung	Erläuterung
DEHSt	Deutsche Emissionshandelsstelle
DT	Entscheidungsbaum (engl. Decision Tree)
DUO	Domestic Ultimate Owner
ESMA	Europäische Wertpapier- und Marktaufsichtsbehörde
EU	Europäische Union
EU-ETS	Europäischer Emissionshandel
EUAs	European Union Allowances (Emissionsberechtigungen im EU-ETS)
EUAAs	European Union Allowances for Aviation (Emissionsberechtigungen im Luftverkehr im EU-ETS)
EUTL	EU Transaction Log
FATF	Financial Action Taskforce
KI	Künstliche Intelligenz
ML	Machine Learning
MWSt	Mehrwertsteuer
NN	Neural Network (Neuronale Netze)
SVM	Support Vector Machine

Zusammenfassung

Die Anwendung von Künstlicher Intelligenz (KI) auf Register-, Transaktions- und Emissionsberichtsdaten im EU-Emissionshandel (EU-ETS) kann automatisierte Hinweise auf fehlerhafte Einträge oder sogar Betrugsversuche im Sinne eines Frühwarnsystems geben. Sie kann idealerweise dabei helfen, Ressourcen effizienter einzusetzen oder für andere Bereiche verfügbar zu machen. Allerdings hat die vorliegende Analyse auch Grenzen aufgezeigt.

In Arbeitspaket 1 wurden Kontoeröffnungsanträge sowie in Arbeitspaket 2 verifizierte Emissionsberichte von Anlagenbetreibern untersucht. Idealerweise könnten durch die Untersuchungen Methoden entwickelt werden, die z.B. fehlerhafte Antragsdaten oder Inkonsistenzen in Emissionsberichten automatisiert erkennen können. Zur Verfügung standen dafür in AP 1 ein Datensatz von 1.694 Anträgen zur Kontoeröffnung, von denen ca. 20 % abgelehnt wurden. Insgesamt gibt es 110 unterschiedliche Felder/Elemente in Kontoeröffnungsanträgen, ein Teil davon wird aber nur bei bestimmten und nicht bei allen Kontotypen verwendet. In AP 2 umfasst der Datensatz die Brennstoffströme von Energieanlagen der Jahre 2005 bis 2022 sowie Daten zu deren Produktion an Strom und Wärme auf anonymisierter Basis. Nach Bereinigung der Daten verblieben 42.296 Stoffströme aus 847 individuellen Anlagen, von denen 186 bzw. 0,4 % durch die DEHSt als fehlerhaft deklariert waren.

Für beide Arbeitspakete wurden drei Machine Learning (ML)-Ansätze unter verschiedenen Parametrisierungen getestet. Die ML-Ansätze *Support Vector Machine* (SVM) und *Decision Tree* (DT) konnten dabei nicht so gute Ergebnisse liefern wie *Neural Networks* (NN). SVM und DT haben allerdings den Vorteil, dass sie leichter verständlich und nachvollziehbar sind. Aber auch bei NN konnte maximal eine richtige Erkennungsquote von 95 % erreicht werden. Die Qualität der Ergebnisse war in AP1 und AP2 durch den kleinen Trainingsdatensatz sowie, in AP 2, durch die sehr geringe Anzahl an fehlerhaften Einträgen im Datensatz begrenzt. Auch in AP 1 war aus dem vorliegenden Datensatz oft nicht erkenntlich, warum ein Antrag abgelehnt wurde. Da die Fehlerrate in den manuell geprüften Datensätzen deutlich kleiner als in den drei verschiedenen ML-Ansätzen (SVM, DT und NN) war, kommt es zu einer hohen Anzahl von *false positives*, d.h. fälschlicherweise als fehlerhaft deklarierte Datensätze. Von den 2.453 Datenzeilen, die in AP 2 im besten Modell als fehlerhaft klassifiziert wurden, waren gerade einmal 181 im Lerndatensatz fehlerhaft. Müssten diese alle händisch überprüft werden, würde dies zu erheblichem Mehraufwand führen. Erschwerend kommt hinzu, dass es keine Information zu den Gründen der Klassifizierung durch die ML-Ansätze gibt, auf denen eine manuelle Prüfung aufbauen könnte. Eine der ursprünglichen Zielsetzungen – effizientere Verwendung von Ressourcen – könnte damit nicht erreicht werden. Außerdem ist unklar, ob die so trainierten ML-Systeme tatsächlich in der Lage sind, auch neue Datensätze mit der gleichen Genauigkeit zu analysieren. Es besteht die Gefahr, dass es wegen der kleinen Datensätze zu einer Überanpassung kam (Overfitting), d.h. dass die KI auf zufällige Muster im vorliegenden Datensatz optimiert wurde. Dies müsste mit zukünftigen Datensätzen aus Folgejahren geprüft werden.

Machine Learning kann unter den gegebenen Bedingungen in AP 1 und AP 2 eventuell genutzt werden, um einzelne Elemente der Antragsdaten bzw. Emissionsberichte zu identifizieren, die einen hohen Einfluss auf die Kategorisierung als genehmigt oder abgelehnt haben. Dies kann aber höchstens dafür genutzt werden, die regelbasierten aktuellen Ansätze in der DEHSt zu verbessern. Diese regelbasierte Klassifikation auf Basis des Expertenwissens liefert nachvollziehbare und gut begründbare Ergebnisse.

In Arbeitspaket 3 wurde ein ML-Ansatz eingesetzt, um auffällige Transaktionen im Unionsregister des EU-ETS zu identifizieren, die möglicherweise ein Geldwäscherisiko

aufweisen. In der Literatur werden drei Stufen der Geldwäsche benannt: Placement, Layering und Integration. Während die Literatur aufzeigt, dass das Placement den wichtigsten Schritt bei der Erkennung von Geldwäsche darstellt, sind die für die Analyse verwendeten Register-Transaktionsdaten nicht geeignet, diesen Schritt zu untersuchen. Aus diesem Grund konzentriert sich die ML-gestützte Datenanalyse in diesem Arbeitspaket auf den Schritt des Layerings und lotet Möglichkeiten für die automatisierte Untersuchung der Registerdaten aus, die der zuständigen Behörde Hinweise auf Fälle liefert, welche einer weiteren Prüfung bedürfen.

Die ML-gestützte Analyse beruht auf öffentlich verfügbaren Transaktions- und Kontodaten des EU-Emissionshandelsregisters (EUTL) der Jahre 2011-2020. Diese Daten werden mit Informationen zu Besitzstrukturen auf Basis des ORBIS-Datensatzes angereichert. Als Methode wird der Isolation Forest angewandt. Bei der Bestimmung geeigneter Indikatoren und Merkmale wird auf die bestehenden Erkenntnisse zum Geldwäscherisiko im EU-ETS zurückgegriffen.

Im Rahmen der bestehenden Analyse konnten weder Verdachts- noch bestätigte Fälle zum Training des ML-Ansatzes verwendet werden. Die Güte der Identifikationsstrategie könnte mit Hilfe eines solchen Trainingsdatensatzes deutlich verbessert werden, da der ML-Ansatz weniger auf manuellen Vorgaben operieren würde, sondern vielmehr die Muster des Trainingsdatensatzes anwenden könnte.

Hauptergebnis der Analyse im dritten Arbeitspaket ist die Identifikation von Ausreißern, welche mit Hilfe des Isolation Forest als auffällige Transaktionen identifiziert werden. In einigen Fällen lassen sich Ausreißer durch externe Ereignisse erklären: beispielsweise ist das besonders auffällige Jahr 2016 auch das Jahr des Brexit-Referendums, was Verschiebungen in der Nutzung europäischer Börsen nach sich zog. Auch einige Nicht-EU Länder, in denen Kontoinhaber ansässig sind, stechen mit einem hohen Anteil auffälliger Transaktionen heraus. Das gleiche gilt für „Luftfahrzeugbetreiber“ als Kontotyp mit einem besonders hohen Anteil an Ausreißern.

Sensitivitätsanalysen in Bezug auf den betrachteten Zeitraum, die betrachteten Variablen, sowie ausgeschlossenen Kontotypen und Transaktionen liefern teilweise deutlich unterschiedliche Ergebnisse zur Verteilung der identifizierten Ausreißer, weshalb die hier vorgestellte Analyse nicht abschließend beantworten kann, welche Transaktionen Geldwäscherisiko aufweisen. Die Analyse liefert aber wertvolle Ansatzpunkte, die nun einer weitergehenden Verifizierung bedürfen. Ein iterativer Prozess zwischen manueller Überprüfung und Weiterentwicklung des ML-gestützten Ansatzes kann die ML-gestützte Vorprüfung weiter verbessern, um die zentralen Ziele einer effizienten automatisierten Vorprüfung zu erreichen:

- ▶ die zuverlässige Identifizierung auffälliger Transaktionen und
- ▶ die Begrenzung der Anzahl der identifizierten Fälle auf ein handhabbares Maß.

Die im Rahmen des Projekts vergebene Bachelorarbeit, als Teil derer eine Literaturanalyse und Experten-Interviews durchgeführt wurden, zeigt einige weitere Grenzen der ML-gestützten automatisierten Prüfung von Transaktionsdaten auf. Die oft hohe Anzahl von *false positives* aus einer automatisierten Vorprüfung macht eine detaillierte Verifizierung zuweilen unmöglich. Deshalb wird in der Finanzbranche die Analyse der Transaktionsdaten nicht nur als Vorprüfung genutzt, sondern um Transaktionen auffälliger Personen und Unternehmen, die mit Hilfe anderer Informationsquellen (z.B. Finanzaufsicht, Interpol, Medien) identifiziert werden, zu überprüfen. Auch die von der Financial Action Taskforce (FATF) geführte schwarze und graue Liste für Länder mit höheren Risiken für Geldwäschereiaktivitäten und Terrorismusfinanzierung kann sowohl im Rahmen der Vorprüfung wie auch der Verifizierung auffälliger Transaktionen genutzt werden.

Summary

The application of artificial intelligence (AI) to registry, emissions and transaction data in the EU emissions trading system (EU ETS) can provide automated information in the sense of an early warning system. It can help to deploy resources more efficiently or make them available for other areas. However, the present analysis has also revealed limitations.

In work package 1, account opening applications were analysed; in work package 2, the verified emission reports of plant operators were examined. Ideally, methods could be developed which would for example recognise incorrect application data or inconsistencies in emission reports automatically. A data set of 1,694 applications to open an account was available for this purpose in WP 1, of which approx. 20 % were rejected. There is a total of 110 different fields/elements in account opening applications, but some of these are only required for certain account types. In WP 2, the data set comprises the fuel flows of energy installations from 2005 to 2022 together with data on their production of electricity and heat on an anonymised basis. After cleansing the data, 42,296 material flows from 847 individual installations remained, of which 186 or 0.4 % were identified as incorrect by the DEHSt.

For both work packages, three machine learning (ML) approaches were tested under different parameterisations. The *Support Vector Machine* (SVM) and *Decision Tree* (DT) approaches were not able to deliver as good results as *neural networks* (NN). However, SVM and DT have the advantage that they are easier to understand and comprehend. But even with NN, a maximum correct recognition rate of 95 % could be achieved. The quality of the results was limited in WP 1 and WP 2 by the small training data set, but also by the very small number of incorrect entries in the data set for WP 2. Even in WP 1, it was often not clear from the available data set why an application was rejected. However, as the error rate in the manually checked data sets was significantly lower, there was a high number of false positives, i.e. data sets that were falsely declared as incorrect. Of the 2,453 data rows that were classified as rejected in the best ML-model in WP 2, just 181 were incorrect in the training data set. If these all had to be checked manually, this would lead to considerable additional work. To make matters worse, there is no information on the reasons for the classification by the ML approaches on which a manual check could be based. One of the original objectives - more efficient use of resources - could therefore not be achieved. It is also unclear whether the ML systems trained in this way are actually able to analyse new data sets with the same accuracy. There is a risk of overfitting due to the small data sets, i.e. that the AI was optimised for random patterns in the available data set. This would have to be checked with future data sets from subsequent years.

Under the given conditions in WP 1 and 2, machine learning can possibly be used to identify individual elements of the application data or emissions reports that have a high influence on the approved/rejected categorisation. However, this can at most be used to improve the current rule-based approaches at DEHSt. This rule-based classification based on expert knowledge provides comprehensible and well-founded results.

In work package 3, ML was used to identify suspicious transactions in the Union registry of the EU ETS that may pose a risk of money laundering. The literature identifies three stages of money laundering: Placement, Layering and Integration. While the literature shows that placement is the most important step in recognising money laundering, the registry transaction data used for the analysis is not suitable for investigating this step. For this reason, the ML-supported data analysis in this work package focuses on the layering step and explores possibilities for the automated examination of registry data, which provides the regulating authority with indications of cases that require further examination.

The ML-supported analysis is based on publicly available transaction and account data from the EU Emissions Trading Registry (EUTL) for the years 2011-2020. This data is enriched with information on ownership structures based on the ORBIS dataset. The Isolation Forest method is used. Existing findings on the risk of money laundering in the EU ETS are used to determine suitable indicators and characteristics.

In the existing analysis, neither suspected nor confirmed cases could be used to train the ML approach. The quality of the identification strategy could be significantly improved with the help of such a training dataset, as the ML approach would operate less on manual specifications and could instead apply the patterns of the training dataset.

The main result of the analysis in the third work package is the identification of outliers, which are identified as conspicuous transactions with the help of the Isolation Forest. In some cases, outliers can be explained by external events: for example, the particularly conspicuous year 2016 is also the year of the Brexit referendum, which led to shifts in the use of European stock exchanges. Some non-EU countries in which account operators are based also stand out with a high proportion of conspicuous transactions. The same applies to 'aircraft operators' as an account type with a particularly high proportion of outliers.

Sensitivity analyses in relation to the period and the variables under consideration and the excluded account types and transactions provide significantly different results related to the distribution of the identified outliers, which is why the analysis presented here cannot provide a conclusive answer as to which transactions represent a risk of money laundering. However, the analysis provides valuable starting points that now require further verification. An iterative process between manual verification and further development of the ML-supported approach can further improve the ML-supported preliminary check in order to achieve the central objectives of an efficient automated preliminary check:

- ▶ the reliable identification of conspicuous transactions and
- ▶ limiting the number of identified cases to a manageable level.

The bachelor's thesis commissioned as part of the project, which included a literature analysis and expert interviews, highlights some further limitations of ML-supported automated verification of transaction data. The often high number of false positives from an automated preliminary check sometimes makes detailed verification impossible. Therefore, in the financial sector, the analysis of transaction data is not only used as a preliminary check, but also to verify transactions of suspicious persons and companies that are identified with the help of other sources of information (e.g. financial supervisory authorities, Interpol, media). The black and grey lists maintained by the Financial Action Taskforce (FATF) for countries with higher risks of money laundering activities and terrorist financing can also be used both for preliminary checks and for the verification of suspicious transactions.

1 Einleitung

Der europäische Emissionshandel (EU-ETS) wurde 2005 eingeführt und ist ein zentrales Klimaschutzinstrument der Europäischen Union (EU). Die europäische Emissionshandelsrichtlinie (2003/87/EC) sieht vor, dass nationale Behörden den EU-ETS auf nationaler Ebene umsetzen bzw. verwalten. Die Deutsche Emissionshandelsstelle im Umweltbundesamt (DEHSt) ist die zuständige, nationale Behörde für den Emissionshandel in Deutschland.

Die Umsetzung des EU-ETS erfordert einen erheblichen Verwaltungsaufwand. Im Unionsregister werden beispielsweise ca. 2.260 aktive deutsche Betreiberkonten (ca. 2.056 Anlagebetreiberkonten; ca. 202 Luftfahrzeugbetreiberkonten) für das Jahr 2022 aufgeführt, hinzukommen ca. 480 Handels- und Personenkonten sowie ca. 130 Prüferkonten.¹ Im ersten Jahr der vierten Phase des EU-ETS (2021-2030) wurden 124 Millionen Emissionsberechtigungen (EUAs) und 3,3 Millionen Luftverkehrsberechtigungen (EUAs) kostenlos zugeteilt (DEHSt 2022b). Die jährliche Versteigerungsmenge für Phase 4 in Deutschland lag bei etwa 84 Millionen EUAs und 586.500 EUAs für das Jahr 2021 (DEHSt 2022a). Außerdem wurden ca. 360 Millionen EUAs zur Erfüllung der Verpflichtungen von in Deutschland gemeldeten Betreibern² im Jahr 2021 abgegeben (DEHSt 2022b). Jährlich werden etwa 17.000 Transaktionen vorgenommen und das Handelsvolumen von EUAs erreichte im 4. Quartal 2021 ca. 3,37 Milliarden EUAs in Europa, wobei die Preise bei ca. 90 Euro/EUA lagen (Marcu et al. 2022). Seit dem Jahr 2021 ist der nationale (deutsche) Emissionshandel hinzugekommen, der über 2.000 Konten umfasst.

Als zuständige Behörde ist die DEHSt für die Verwaltung der Konten im deutschen Teil des Unionsregisters, die Zuteilung von Emissionsberechtigungen und für die Überwachung der jährlichen Emissionsberichterstattung zuständig. Alleine für diese Aufgaben müssen in der DEHSt jährlich mehrere tausend Berichte und Anträge geprüft und beschieden werden. Um den komplexen Vollzug in diesen verschiedenen Systemen zu unterstützen und die Integrität der Emissionshandelssysteme zu sichern, sollen sowohl die Prozesse der Kontoeröffnung und fachlicher Verwaltungsentscheidungen, z.B. bei der Prüfung der Emissionsberichte, als auch das Risiko krimineller Aktivitäten, speziell beim Handel, in diesem Projekt untersucht werden. Dabei soll analysiert werden, inwieweit die Vollzugsprozesse mit künstlicher Intelligenz (KI) gestaltet werden können, um somit Ressourcen effizienter einzusetzen oder für andere Bereiche verfügbar zu machen. Es werden dabei historische Daten, z.B. für die Kontoeröffnung oder Zuteilungsentscheide, verwendet, um passende Algorithmen zu entwickeln und zu erproben. Außerdem sollen Algorithmen zur Erkennung von ungewöhnlichen Transaktionen entwickelt werden.

¹ Union Registry: <https://ec.europa.eu/clima/ets/>

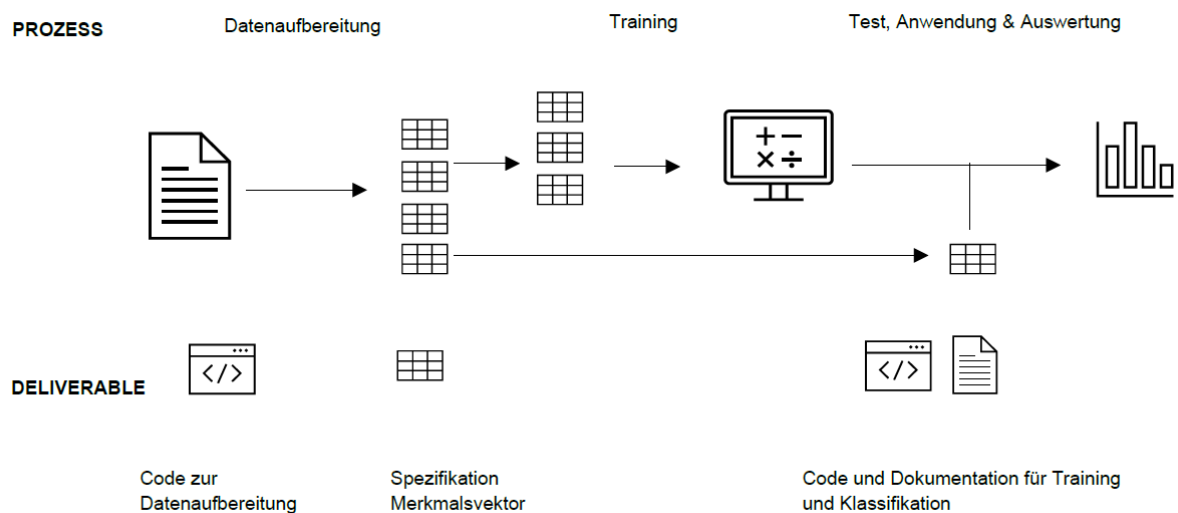
² Die Worte „Betreiber“ (z.B. Luftfahrzeugbetreiber) oder auch Kontoinhaber werden in diesem Bericht nicht gegendert, da es sich um feste in den relevanten Regulierungen definierte Begriffe handelt.

2 Arbeitspaket 1 - Kontoeröffnungen

Dieses Arbeitspaket unterstützt die DEHSt bei der automatisierten Vorprüfung von Anträgen auf Kontoeröffnung. Es wird ein Merkmalsvektor entwickelt, der Hinweise auf fehlerhafte Antragsdaten oder andere Unstimmigkeiten bei Kontoeröffnungen geben soll. Dieser soll zusammen mit der Implementierung einer Deep-Learning Matrix zur Identifizierung von auffälligen Merkmalen verdächtige Anträge dienen. Eine solche Identifizierung und Einordnung kann dann der zuständigen Person in der DEHSt Hinweise für die Prüfung geben.

In der folgenden Abbildung 1 werden die Arbeitsschritte (Datenaufbereitung, Definition Methoden/Merkmale, Implementierung KI-Algorithmus) schematisch dargestellt.

Abbildung 1: Schematischer Überblick der Arbeitsschritte



Quelle: Eigene Abbildung, Öko-Institut

Für die Bearbeitung des Arbeitspakets wurden drei „supervised Machine Learning“ (ML)-Ansätze getestet, jeweils mit verschiedenen Parametrisierungen (für eine Erläuterung siehe Box 1):

- ▶ Support vector machine (SVM),
- ▶ Entscheidungsbaum / Decision tree (DT),
- ▶ Neural Network (NN) mit Kombinationen aus:
 - Drei verschiedenen Algorithmen (Pedregosa et. al. 2011)
 - adam (Adaptive Moment Estimation)
 - sgd (Stochastic Gradient Descent)
 - l-bfgs (Limited-memory Broyden-Fletcher-Goldfarb-Shanno)
 - verschiedenen Schichtenarchitekturen (1-3 versteckte Schichten mit Variation der Anzahl der Knoten, aber immer in abfallender Anzahl je Schicht);
 - 0,

- (12,)
- (5, 2),
- (10, 5),
- (20, 12, 4)
- Variation der “learning rate” (Lernrate) und “regularization parameters” (techn. Parametern).

SVM und DT dienen hier eher einer explorativen Untersuchung der potenziellen Bedeutung einzelner Features (d.h. die einzelnen Einträge/Elemente) im Merkmalsvektor. Um ein besseres Verständnis für Daten (Spalten) zu erhalten eignen sich SVM und DT gut. Für die eigentliche Klassifikation und somit dem Einsatz für die eigentlichen Antragsprüfung ist vermutlich der NN-Ansatz am besten geeignet. Die Ansätze wurden durch weitere Testläufe weiter ausgearbeitet. Dabei wurden die Ergebnisse durch folgende Ansätze verbessert:

- ▶ Tiefere Netzwerke (mehr Schichten),
- ▶ Besseres Balancing der Inputdaten,
- ▶ Variation der Aktivierungsfunktionen.

Die finalen Ergebnisse sind in Kapitel 2.1.3 und 2.1.4 dargestellt.

Box 1: Übersicht über die verwendeten „Machine Learning“-Ansätze

Die verwendeten Modelle umfassten Support-Vektor-Machine (SVM), Entscheidungsbäume / Decision Tree (DT) und neuronale Netze /neural network (NN). Jedes dieser Modelle wurde hinsichtlich seiner Stärken und Schwächen evaluiert, wobei die Wahl des Modells stark von den spezifischen Anforderungen an Interpretierbarkeit und Komplexität der Daten abhängt.

Support-Vektor-Machine (SVM):

Die SVM wurde mit linearen Kernelfunktionen eingesetzt, um den Einfluss einzelner Features quantitativ zu bewerten. Während die SVM bei der Abbildung komplexer Zusammenhänge begrenzt ist, eignet sie sich gut, um lineare Trennungsmerkmale zu identifizieren und die Bedeutung von Features zu analysieren. Die Ergebnisse sind für Menschen leicht interpretierbar. Es besteht aber die Gefahr des Overfittings (s.u.).

Entscheidungsbaum / Decision Tree (DT):

Entscheidungsbäume bieten die Möglichkeit, wichtige Features anhand ihrer Position im Baum und somit in der Entscheidungshierarchie zu identifizieren. Obwohl Entscheidungsbäume theoretisch mit unendlicher Tiefe nahezu 100 % Genauigkeit erreichen können, besteht hierbei die Gefahr des Overfittings. Deshalb wurde besonderer Wert daraufgelegt, die Baumtiefe zu begrenzen und die Modelle auf ihre Generalisierbarkeit zu testen.

Neuronale Netze / Neural Network (NN):

Neuronale Netze standen im Mittelpunkt der Analyse, da sie besonders gut für die Modellierung komplexer Zusammenhänge geeignet sind. Es wurden verschiedene Konfigurationen untersucht, darunter:

- ▶ Aktivierungsfunktionen: Drei unterschiedliche Aktivierungsfunktionen wurden getestet, um die Nichtlinearität der Daten besser zu modellieren.

- ▶ **Solver:** Drei Optimierungsalgorithmen wurden evaluiert, um die Trainingsstabilität und Konvergenz zu maximieren.
- ▶ **Lernraten:** Variationen in der Lernrate ermöglichten die Anpassung an unterschiedlich komplexe Datenstrukturen.
- ▶ **Schichtenarchitekturen:** Es wurden vier verschiedene Architekturen in Bezug auf Tiefe und Anzahl der Knoten je Schicht getestet. Dabei stellte sich heraus, dass ein zu flaches Netzwerk die Komplexität der Daten nicht ausreichend abbilden kann, während ein zu tiefes Netzwerk häufig nicht konvergierte.

Aktivierungsfunktionen spielen eine zentrale Rolle in NN, da sie die Nichtlinearität in das Modell einbringen und dadurch komplexe Muster lernen lassen. Die *tanh* Funktion (hyperbolischer Tangens) transformiert Eingaben auf einen Bereich zwischen -1 und 1 und eignet sich besonders, wenn eine symmetrische Skalierung um Null wichtig ist. Sie kann jedoch bei großen oder kleinen Eingabewerten Sättigungseffekte zeigen, was das Training erschwert (Vanishing Gradient Problem). Die *logistic* Funktion (auch Sigmoid genannt) begrenzt Werte auf den Bereich zwischen 0 und 1 und ist nützlich für Wahrscheinlichkeitsinterpretationen, leidet aber ebenfalls unter Sättigungsproblemen und nicht-symmetrischer Skalierung. Die *ReLU* Funktion (Rectified Linear Unit) hingegen gibt Eingabewerte über 0 unverändert weiter und setzt negative Werte auf 0. Dadurch ist sie sparsamer in der Aktivierung und verhindert Sättigungseffekte, was sie besonders effizient für tiefe Netzwerke macht. Allerdings kann es bei ReLU zu "toten Neuronen" kommen, wenn Eingaben konstant negativ bleiben.

Die **Lernalgorithmen (Solver)** *Adam*, *LBFGS* und *SGD* repräsentieren unterschiedliche Ansätze zur Optimierung von NN. *Adam* (Adaptive Moment Estimation) passt die Lernrate für jedes Gewicht individuell an. Es ist besonders effektiv bei großen und unstrukturierten Datensätzen und ermöglicht schnelles und stabiles Training. *LBFGS* (Limited-memory Broyden–Fletcher–Goldfarb–Shanno) ist besonders für kleinere Netze geeignet. Er verwendet eine Näherung der zweiten Ableitung (Hessian-Matrix), um präzisere Updates zu berechnen. Dies führt häufig zu schnellerer Konvergenz, benötigt aber mehr Speicher und Rechenzeit pro Schritt. *SGD* (Stochastic Gradient Descent) aktualisiert Gewichte basierend auf einem zufälligen Teil der Daten (Mini-Batches) anstelle des gesamten Datensatzes, was das Training effizient macht und besser für große Datensätze skaliert. Allerdings ist SGD empfindlich gegenüber der Wahl der Lernrate.

Die Wahl der **Lernrate** beeinflusst entscheidend, wie schnell und stabil ein NN trainiert wird. Drei häufig verwendete Ansätze zur Anpassung der Lernrate sind *adaptive*, *constant* und *invscaling*. Bei einer *konstanten Lernrate* bleibt der Wert während des gesamten Trainingsprozesses unverändert, was für stabile, aber potenziell langsamere Konvergenz sorgt und empfindlich gegenüber einer falschen Wahl der Lernrate ist. Der *adaptive* Ansatz passt die Lernrate dynamisch an, indem er sie reduziert, wenn das Modell in aufeinanderfolgenden Iterationen keine Verbesserung erzielt. Dies verhindert Overshooting und ermöglicht, dass das Modell feiner optimiert wird, wenn es sich einem Minimum nähert. Der *invscaling* Ansatz reduziert die Lernrate schrittweise während des Trainings. Dies führt zu einem schnelleren Start bei anfänglichen Iterationen und einem langsameren Lernen gegen Ende. Dies erhöht die Stabilität, kann aber bei zu starker Reduktion auch zu einem frühzeitigen Stoppen des Lernens führen.

Die **Schichtenarchitektur**, d.h. die Anzahl der Schichten und der Knoten pro Schicht in einem NN, ist entscheidend für dessen Leistungsfähigkeit. Tiefere Netze mit mehr Schichten können komplexere Muster und Abhängigkeiten in den Daten lernen, da sie höhere Abstraktionsebenen abbilden. Allerdings können zu viele Schichten zu einer schlechteren Generalisierung und

Überanpassung führen. Mehr Knoten pro Schicht ermöglichen es dem Modell, detailliertere Beziehungen zwischen den Eingabedaten zu erfassen, erfordern jedoch mehr Rechenleistung und erhöhen das Risiko von Overfitting, insbesondere bei kleinen Datensätzen. Gleichzeitig können zu wenige Knoten oder Schichten dazu führen, dass das Modell nicht genügend Kapazität hat, um die Daten korrekt zu modellieren (Underfitting). Die optimale Kombination hängt stark von der Datenkomplexität, der Netzarchitektur und der verfügbaren Rechenressource ab.

Mit **Overfitting** wird das Problem bezeichnet, dass ein Modell genau auf die Trainingsdaten einschließlich zufälliger Schwankungen und irrelevanter Details optimiert. Das führt dazu, dass es bei neuen unbekanntem Daten schlechte Ergebnisse erzeugt. Ein überangepasstes Modell liefert zwar sehr gute Ergebnisse auf den Trainingsdaten, versagt jedoch bei der Vorhersage auf neuen Datensätzen. **Balancing** bezüglich der Zielklassen genehmigt/abgelehnt bedeutet, dass im Trainingsdatensatz beide Klassen möglichst gleichmäßig vertreten sein sollten. Ist eine Klasse stark unterrepräsentiert (z. B. viel mehr genehmigt als abgelehnt), kann das Modell eine Verzerrung entwickeln und die Minderheitsklasse schlechter vorhersagen. Durch Techniken wie Oversampling der Minderheitsklasse oder Undersampling der Mehrheitsklasse wird ein Gleichgewicht hergestellt, um die Vorhersagequalität für beide Klassen zu verbessern.

2.1 Datenaufbereitung

Die Inputdaten wurden am 29.06.2023 von der DEHSt den Forschungsnehmern übergeben. Insgesamt gibt es 110 verschiedene Felder/Elemente bei der Beantragung eines Kontos, wobei nicht jedes Feld für jeden Antrag benötigt wird (siehe Annex A). Wird die Eröffnung eines neuen Kontos bei der DEHSt beantragt, werden diese Informationen manuell geprüft. Zu den Prüfschritten gehören u.a. eine Prüfung der Identitäts- und Legitimitätsdaten der Antragstellenden und Bevollmächtigten sowie ein Abgleich der Informationen mit Informationen im Handelsregister und öffentlich zugänglichen Informationen wie der Webseite einer Firma. Werden dabei Fehler oder Inkonsistenzen festgestellt, können diese in manchen Fällen von den Antragstellenden korrigiert werden oder es kommt zu einer Ablehnung des Antrags (und ggf. zu einem neuen Antrag mit korrekten Informationen).

In einem ersten Schritt wurden die Daten geprüft und bereinigt (z.B. Entfernung von Duplikaten und ungültigen Werten). Hierbei wurden auch den Kontoeröffnungen die entsprechenden „Account Representatives“ (AR) zugeordnet (1-n). Nach der Bereinigung ergibt sich ein Datensatz mit 1694 Einträgen, wovon 1359 angenommene Anträge und 335 abgelehnte Anträge darstellen.

In einem zweiten Schritt wurde ein Merkmalsvektor wie folgt entwickelt:

- ▶ Nicht leere und zulässige Felder werden mit jeweils geeigneter Methode auf Wertebereich \mathbb{R} abgebildet,
- ▶ Kategorische Felder (d.h. Felder mit vorgegebenen Antwortmöglichkeiten) werden numerisch klassifiziert (ggf. randomisiert),
- ▶ Freitextfelder werden als boolesche Felder (existiert/existiert nicht) klassifiziert,
- ▶ Verknüpfte Felder aus 1-n Relation werden auf \mathbb{R} aggregiert, z.B. als Anzahl oder Anzahl ohne Duplikate.

Auf eine Analyse des Inhalts der Freitextfelder wurde verzichtet. Inhalt dieser Felder sind z. B. Vor- und Nachnamen, Adressen oder das Identifikationscodes einer Fluggesellschaft. Hier ist unklar, auf welche inhaltlich sinnvollen Muster ein Machine Learning Ansatz trainieren könnte. Hinzu kommt, dass die Anzahl der Features u.a. von der Größe des Trainingsdatensatzes abhängt. Je mehr Features der Merkmalsvektor bekommen soll, umso größer muss auch der Datensatz sein, um ausreichend trainieren zu können. Aufgrund des eher kleinen Datensatzes wurde der Vektor so kurz wie möglich gehalten.

Für den Merkmalsvektor wurden nur Antragsfelder berücksichtigt, die von mind. 1/3 aller Anträge ausgefüllt wurden. Da es deutlich weniger Luftfahrzeugbetreiber unter den Antragsstellenden gibt, könnten in späteren Durchgängen diese getrennt betrachtet/angelern bzw. mit einem anderen Schwellwert betrachtet werden. Im Annex A ist eine Übersicht über das Datenschema angehängt.

Iterativ wurden einige weitere Felder entfernt bzw. wieder hinzugefügt, um die Robustheit der Verfahren zu testen und ein Verständnis für die Relevanz der Felder zu gewinnen.

In der finalen Konfiguration hat der Merkmalsvektor 45 Felder, davon 13 kategorische, 3 numerische, 27 boolesche und 2 aggregierte Felder.

2.2 Training

Es wurden vorläufig alle Daten als Trainingsdaten genutzt (keine Trennung von Trainings- und Testdaten), um die maximal mögliche Performance der verschiedenen Verfahren in einem ersten Durchlauf zu erkunden. Hierbei wurde darauf trainiert, genehmigte und abgelehnte Anträge richtig zu erkennen.

Die drei ML-Ansätze Support vector machine (SVM), Decision tree (DT) und Neural Network (NN) wurden in einer Vielzahl von Konfigurationen getestet (z.B. verschiedene Schichtenarchitekturen oder Aktivierungsfunktionen bei NN (siehe Box 1)).

2.3 Auswertung

Im Folgenden werden die Ergebnisse der verschiedenen ML-Ansätze zusammengefasst.

Tabelle 1: Ergebnisse der Erkennung von Anträgen

	Gesamt				Genehmigt				Abgelehnt			
	richtig		falsch		richtig		falsch		richtig		falsch	
(Daten)	1694				1359				335			
SVM	1481	87.4%	213	12.6%	1345	99.0%	14	1.0%	136	40.6%	199	59.4%
DT	1613	95.2%	81	4.8%	1350	99.3%	9	0.7%	263	78.5%	72	21.5%
NN	1569	92.6%	125	7.4%	1325	97.5%	34	2.5%	244	72.8%	91	27.2%

Quelle: Öko-Institut

Die Einordnung „richtig“ / „falsch“ bedeutet hier, dass ein Datensatz korrekt durch den ML-Ansatz vorhergesagt wurde. Die Werte sind jeweils die absoluten Zahlen und der Prozentwert zur jeweiligen Basis. Dies wird am Beispiel der genehmigten Anträge im SVM-Ansatz erläutert: Insgesamt wurden bei der Prüfung durch die DEHSt 1.359 Anträge als richtig eingestuft und

bildeten die Grundlage für das Training. Von dieser Anzahl wurden im SVM-Ansatz 14 bzw. 1 % fälschlicherweise als fehlerbehaftet erkannt und abgelehnt.

Support Vector Machine (SVM)

Die Vorhersageergebnisse dieses Ansatzes sind nicht besonders präzise, aber das Verfahren erlaubt es, potenziell wichtige Felder im Merkmalsvektor zu identifizieren (bei Verwendung eines linearen Kernels).

Der Wert des Koeffizienten im SVM-Ansatz zeigt den Einfluss des jeweiligen Feldes auf das Ergebnis (genehmigt/abgelehnt). Dabei bedeutet ein negatives Vorzeichen, dass dieses Feld das Ergebnis Richtung Annahme beeinflusst. Ein positives Vorzeichen bedeutet entsprechend, dass dieses Feld zu einer Ablehnung des Antrags beiträgt. Die einzigen drei Felder (innerhalb der Gruppe der relevanten Felder), die über diesen Ansatz als Beitrag zur Ablehnung identifiziert wurden, sind in Tabelle 2 aufgelistet. Tabelle 3 zeigt die Felder, die den größten Einfluss in Richtung Annahme hatten.

Tabelle 2: Felder die im SVM-Ansatz zur Ablehnung beitragen

Feldbezeichnung	Erläuterung	Koeffizient
AH_BIRTH_COUNTRY	Geburtsland des Kontoinhabers	0.5352
AH_IDENTITY_DOCUMENT_TYPE	Art des Ausweisdokuments	0.1567
AH_TYPE	Typ Kontoinhaber, juristische oder natürliche Person)	0.1051

Quelle: Eigene Berechnung, Öko-Institut

Tabelle 3: Felder die im SVM-Ansatz zur Annahme beitragen

Feldbezeichnung	Erläuterung	Koeffizient
ACCOUNT_EU_ACCOUNT_TYPE	Kontotyp, Handelskonto, Personenkonto oder Betreiberkonto	-1
AH_IDENTITY_DOCUMENT_OTHER_DESC	Von Standardausweisdokumenten (Personalausweis / Reisepass) abweichendes Dokument	-0,6514
ACCOUNT_KYOTO_ACCOUNT_TYPE	Kennzeichnung Kontotyp, Konto im Kyoto-Register	-0,625
ACCOUNT_GROUP_NAME	Name des Mutterunternehmens	-0,2187
CONTACT_PERSON_FIRST_NAME	Ansprechpartner Vorname	-0,1597
CONTACT_PERSON_LAST_NAME	Ansprechpartner Nachname	-0,1597
CONTACT_PERSON_PHONE_NUMBER_1	Ansprechpartner Telefonnummer 1	-0,1597
CONTACT_PERSON_PHONE_NUMBER_2	Ansprechpartner Telefonnummer 2	-0,1597
CONTACT_PERSON_EMAIL_ADDRESS	Ansprechpartner Mail Anschrift	-0,1597

Feldbezeichnung	Erläuterung	Koeffizient
AIRCRAFT_OPERATOR_IDENTIFIER	Luftfahrzeugbetreiber-Nummer des Unionsregisters	-0,1526
AIRCRAFT_OPERATOR_EUROCONTROL_CODE	Code des Luftfahrzeugbetreiber nach Verordnung (EG) Nr. 748/2009	-0,1526
AIRCRAFT_OPERATOR_MONITORING_PLAN_IDENTIFIER	Luftfahrzeugbetreiber Monitoringkonzept Kennung	-0,1526

Quelle: Eigene Berechnung, Öko-Institut

Aus der Liste der Feldbezeichnungen wird deutlich, dass die Ergebnisse nur begrenzt aussagekräftig sind. Ein wesentlicher Teil der Elemente, der zu einer Annahme des Antrags führt, basiert auf der Prüfung, ob Vor- und Nachname sowie Kontaktinformationen überhaupt ausgefüllt sind.

Entscheidungsbaum / Decision Tree (DT)

Die Ergebnisse scheinen zwar gut zu sein, können aber vermutlich nicht verwendet werden. Prinzipiell kann mit entsprechender Tiefe beliebig genau gefittet werden, was aber nicht zielführend ist, weil es keine gute Vorhersagekraft für neue Daten hat (overfitting). Dennoch kann auch dieses Verfahren besonders interessante Merkmale sichtbar machen. Dies sind insbesondere die Knoten, die am Anfang des Entscheidungsbaums stehen und zu unterschiedlichen Ergebnissen führen, d.h. bei denen der Wert eines Features großen Einfluss auf das Ergebnis hat.

Nach dieser Implementierung des DT-Ansatzes sind die folgenden Felder besonders wichtig für das Ergebnis:

- ▶ ACCOUNT_KYOTO_ACCOUNT_TYPE (Kennzeichnung Kontotyp, Konto im Kyoto-Register)
- ▶ ACCOUNT_EU_ACCOUNT_TYPE (Kontotyp, Handelskonto, Personenkonto oder Betreiberkonto)
- ▶ AH_BIRTH_COUNTRY (Geburtsland Kontoinhaber)
- ▶ AR_CONTACT_COUNTRY_unique (Kontaktdaten der kontobevollmächtigten Person, Land)
- ▶ AIRCRAFT_OPERATOR_MONITORING_PLAN_FIRST_YEAR_OF_APPLICABILITY (Monitoringkonzept Luftfahrzeugbetreiber Anlaufjahr)
- ▶ INSTALLATION_FIRST_YEAR_OF_VERIFICATION (Anlagenbetreiber Jahr der ersten Emission)
- ▶ INSTALLATION_CONTACT_PHONE_NUMBER_1 (Ansprechpartner der Anlage, Telefonnummer 1)

Wichtig ist dabei zu beachten, dass Entscheidungsbäume mit komplett anderer Entscheidungshierarchie der Variablen gebildet werden könnten, die trotzdem ein ähnliches Fitting hätten. Dies zeigt, dass die Ergebnisse höchstwahrscheinlich auf Overfitting beruhen und die einzelnen Felder keine echte Aussage über Genehmigung/Ablehnung enthalten. Wie bei SVM erschließt sich zumindest fachlich kein klarer Zusammenhang zwischen den oben gelisteten Feldern und Gründen für den Ausgang der Vorprüfung.

Neuronale Netze (NN)

Der NN-Ansatz ist vermutlich der geeignetste Ansatz, auch wenn er eine etwas schlechtere Erkennungsquote als DT erreicht. Die DT-Ergebnisse sind höchstwahrscheinlich das Ergebnis von Overfitting auf den kleinen Datensatz. Der NN-Ansatz würde bei weiteren Daten aus Folgejahren vermutlich zu deutlich besseren Ergebnissen führen. Gleichzeitig sind hier die Gründe für das Ergebnis nicht mehr wirklich nachvollziehbar. Anders als bei linearen Modellen oder Entscheidungsbäumen (DT), bei denen klare Zusammenhänge zwischen Eingabe und Ausgabe identifiziert werden können, sind die Entscheidungen neuronaler Netze das Ergebnis komplexer Wechselwirkungen vieler Knoten und Schichten. Diese Interaktionen sind oft nicht manuell nachvollziehbar. Einzelne Gewichte oder Aktivierungen in einem NN haben selten eine direkte Bedeutung, da sie in Kombination mit anderen Komponenten wirken. Ein weiteres Problem ist die inhärente Nichtlinearität, die es erschwert, allgemeingültige Regeln aus einem NN abzuleiten. Für Anwendungen, in denen Transparenz entscheidend ist, können diese Interpretationsprobleme ein Hindernis sein. Entsprechend können die Ergebnisse dieses ML-Ansatzes nicht automatisch zu einer Verwaltungsentscheidung führen, sondern müssen immer von Menschen geprüft und bestätigt werden. Letztlich kann das NN also lediglich auf „verdächtige“ oder fehlerhafte Antragsdaten hinweisen.

2.4 Fazit

Von den verschiedenen untersuchten Ansätzen hat der NN-Ansatz mit dem Limited-memory Broyden–Fletcher–Goldfarb–Shanno Algorithmus die besten Ergebnisse produziert. Sowohl für die Klassifikation genehmigt als auch abgelehnt konnten damit über 90% korrekte Klassifikation erreicht werden. Dabei hat sich gezeigt, dass zwei bis drei versteckte Schichten ausreichend sind. Mehr Schichten führten zu längeren Trainingszeiten, ohne die Ergebnisse noch zu verbessern.

Die Qualität des Ergebnisses ist durch die geringe Anzahl von Datensätzen limitiert. Es besteht die Gefahr, dass ein Overfitting auf den Trainingsdatensatz erfolgte. Dies würde bedeuten, dass die hohe „korrekte“ Klassifikation bei neuen Daten so nicht reproduziert würde. Dies könnte bei zukünftigen Anträgen für Kontoeröffnungen durch die DEHSt getestet werden, indem wieder die Ergebnisse des hier entwickelten ML-Ansatzes mit der manuellen Prüfung verglichen werden.

3 Arbeitspaket 2 - Automatisierte Vorprüfung von fachlichen Verwaltungsentscheidungen

In diesem Arbeitspaket wurde geprüft, inwiefern eine Deep Learning Matrix die automatisierte Vorprüfung von Verwaltungsentscheidungen unterstützen kann. Dafür wurde vorab entschieden, dass die verifizierten Emissionsberichte der Anlagenbetreiber untersucht werden. Grundlage der Entscheidung war die größtmögliche Grundgesamtheit an Daten, die für das Lernen der Systeme zur Verfügung gestellt werden konnten, um möglichst aussichtsreiche Ergebnisse in diesem Projekt zu erzielen. Untersucht wurden die einzelnen Brennstoffströme aus den Emissionsberichten von Energieanlagen der Jahre 2005 bis 2022 zusammen mit Daten zu deren Produktion an Strom und Wärme auf anonymisierter Basis.

Aktuell findet in der DEHSt eine zentrale, teilweise automatisierte Vorprüfung der verifizierten Emissionsberichte statt, die im Wesentlichen Auffälligkeiten in der Zeitreihe identifiziert. Geprüft wird aber auch auf Auffälligkeiten, beispielsweise ob bestimmte Parameter wie z.B. Emissionsfaktoren und Brennwert bestimmte Plausibilitätsgrenzen überschreiten. Diese Auffälligkeiten sind nur ein Indiz für einen möglichen Fehler, können aber auch andere Gründe wie z.B. einen Brennstoffwechsel oder längere Auszeiten haben. Entsprechend werden die Daten dieser Anlagen von den Sachbearbeiter*innen manuell geprüft. Ziel des Arbeitspakets ist es, die automatisierte Vorprüfung durch eine Deep Learning Matrix zu ergänzen. Idealerweise könnte durch einen geeigneten Ansatz der Bearbeitungsaufwand in der DEHSt reduziert und zusätzliche Fälle von möglicherweise inkorrekten Daten identifiziert werden. Eine echte Unterstützung wäre dies allerdings nur, wenn die Anzahl der *false positive*, also fälschlicherweise markierte aber eigentlich korrekten Daten, nicht zu hoch ist.

3.1 Datenaufbereitung/-analyse

Als Inputdaten wurden von der DEHSt den Forschungsnehmern vier Datensätze übergeben. Zwei dieser Datensätze (*Stoffströme* und *Lernen_Stoffströme*) folgen der gleichen Struktur und enthalten Daten aller Stoffströme, Mengen, Parameter und Emissionen der abschließenden Emissionsberichte. Dabei kann es zu einer Anlage viele Stoffströme mit jeweils eigenen zugehörigen Daten wie Energieeinsatz und Emissionen geben. Andere Informationen liegen nur einheitlich auf Ebene der Gesamtanlage vor. Dazu gehören insbesondere Informationen über die Anlage wie die Branche und andere hier nicht berücksichtigte Daten (Adressen, zuständige Personen). Der Datensatz *Lernen_Stoffströme* ist ein Untersatz und zeigt nur die Daten, bei denen es zu Änderungen (Korrekturen) an den Daten kam. Insgesamt gibt es drei Bezeichnungen, die nicht in beiden Datensätzen enthalten sind: Hier sind sowohl der ursprüngliche als auch der korrigierte Datensatz enthalten.

Die automatischen Prüfmeldungen zu den Emissionsberichten sind in dem Datensatz *Prüfungen* enthalten. Als vierter Datensatz wurden Berichtsdaten der Zuteilung übergeben, die die *Produktionsmengen* (Wärme bzw. Strom) der Anlagen mit kostenloser Zuteilung enthalten.

In einem ersten Schritt wurden die Daten geprüft und bereinigt (z.B. Entfernung von Duplikaten und ungültigen Werten). Parallel dazu wird geprüft, ob eine Vorauswahl relevanter Felder für den Merkmalsvektor aus fachlicher Sicht möglich ist.

Von ursprünglich 42.708 Zeilen in *Stoffströme* verbleiben nach data cleaning 42.296 Zeilen mit einzelnen Stoffströmen, mit 847 individuellen Anlagen für die Jahre 2005-2022. Nach Verschneiden mit *Lernen_Stoffströme* werden davon 186 als abgelehnt klassifiziert (Änderung in CO₂). Viele Zeilen in *Lernen_Stoffströme* liefern keine zusätzlichen Informationen, da alle Stoffströme einer Anlage in beiden Versionen gelistet werden. In der Regel gibt es aber nur bei

einem Eintrag in einem Stoffstrom eine Änderung, so dass der größte Teil der Daten redundant ist. Aus der Aufbereitung von Produktmengen ergeben sich Zeitreihen für 780 Anlagen für die Jahre 2012-2022. Im Annex B ist eine Übersicht über das Datenschema der vier Datensätze angehängt.

Als Ergebnis der Datenaufbereitung wurden aus verschiedenen zusammenhängenden Rohdaten ein Klassifikationsvektor und eine zugehörige Featurematrix zu jedem Datensatz erzeugt. Der Klassifikationsvektor hat den Wertebereich {0, 1} und drückt aus, ob ein Datensatz korrigiert wurde oder nicht. Als Label (1 = APPROVED - genehmigt) wurden Zeilen klassifiziert, für welche die Spalte „CO2“ zwischen der ursprünglichen und der Arbeitsversion unverändert geblieben sind. Zeilen mit Änderung – d.h. in denen ursprüngliche Daten korrigiert wurden – wurden als (0 = REJECTED - abgelehnt) gelabelt.

Für die Featurematrix wurden die verschiedenen Rohdaten miteinander verschnitten und gezielt einzelne Parameter (Spalten) ausgewählt, um möglichst gute Ergebnisse zu erhalten. Jedes Feature wird auf einen Wertebereich [0,1] gebracht:

- ▶ Numerische Daten ohne Vorzeichenwechsel werden direkt auf den Wertebereich [0,1] skaliert.
- ▶ Numerische Daten mit Vorzeichenwechsel erhalten zwei verschiedene Skalierungen: die negativen Skalen auf den Wertebereich [0,0.5] und [0.5,1]. Dieser Ansatz verstärkt eine Unterscheidung zwischen negativen und positiven Skalen, wenn der Wertebereich asymmetrisch um die Null verteilt ist.
- ▶ Kategorische Daten wie z.B. die Liste der 19 verschiedenen Branchen oder drei Einheiten für Stoffströme wurde der *One hot encoding* Ansatz gewählt. Für jede Kategorie (z.B. Branche „HKW, Steinkohle“ oder Einheit „GWh“) wurde ein eigenständiges Feature genutzt.
- ▶ Binäre bzw. boolesche Daten (Ja/Nein) wurden direkt auf [0,1] übertragen.

Die zentrale Herausforderung für die weiteren Schritte ist die Anzahl und Auswahl der Features für das Training und Auswertung. Dabei werden idealerweise nur die Features mit Relevanz für die Klassifikation ausgewählt. Aufgrund der letztlich sehr geringen Anzahl insbesondere an korrigierten Datensätzen besteht die Gefahr des Overfittings, insbesondere wenn sehr viele Features ausgewählt werden. Dabei könnte die KI über fachliche irrelevante aber im ausgewählten Datensatz korrelierte Eigenschaften lernen und bei neuen Daten sehr schlechte Ergebnisse produzieren. Je mehr Features aufgenommen werden, umso schlechter ist das Verhältnis zwischen Anzahl Datenpunkte und Größe des Datenraums. Dadurch wird es für den KI- bzw. ML-Algorithmus schwerer, gemeinsame relevante Eigenschaften zu identifizieren. Die initiale Auswahl der Features wurde anhand der folgenden Regeln erstellt:

- ▶ Ausschluss von Freitextfeldern wie z. B. Bearbeitungsvermerke. Der Inhalt lässt sich in den gewählten ML-Ansätzen nicht nutzen. Die reine Information, ob ein Vermerk eingetragen ist, ist zur Ermittlung falscher Datensätze nicht hilfreich.
- ▶ Ausschluss von redundanten Feldern wie z.B. der Klarname zu Codes (KEY), wenn dieser existiert.
- ▶ Ausschluss von Spalten, die die abschließenden Ergebnisse der Prüfung durch die DEHSt enthalten wie z.B. KEY Status oder KEY Ursache sowie Versionsnummern. Diese Informationen stehen bei neuen Datensätzen nicht zur Verfügung, letztlich soll der ML-Algorithmus diese Prüfungen ersetzen.

- ▶ Ausschluss von Spalten mit sehr geringer Füllrate. In ersten Tests wurden nur Felder verwendet, die eine Füllrate von mindestens 2 Prozent hatten (s.u.).

Der wesentliche Unterschied in dem ML-Ansatz zwischen AP 1 und AP 2 ist die Zeitdimension. Theoretisch könnte dem Merkmalsvektor einfach für jedes Jahr eine (bzw. mehrere) Spalten hinzugefügt werden, um alle Jahre abzubilden. In diesem Ansatz würde aber die Information des zeitlichen Verlaufs und zeitlicher Abhängigkeiten vollständig verloren gehen. Das KI-Modell würde jede Spalte als eigenen, unabhängigen Datensatz interpretieren und keine Verknüpfung zwischen den Jahren und in Reihenfolge erstellen. Damit könnten keine Trends, Muster, Zyklen und Anomalien im Zeitverlauf erkannt werden.

Eine Herausforderung für die Zeitreihenanalyse ist die Erstellung von Kennzahlen im Preprocessing, die die zeitliche Entwicklung parametrisieren. Dies muss als Input in das KI-Modell eingegeben werden. Um die Informationen der Zeitreihen nutzen zu können, muss diese wieder in einen Skalar mit Wertebereich [0,1] übertragen werden. Der Skalar ist dabei ein Indikator, der den aktuellen Wert eines Feldes mit der Zeitreihe vergleicht. Die Kennzahlen umfassen sowohl klassische Elemente statistischer Analysen (z.B. Erwartungswert, Standardabweichung, Varianz), relative Informationen (z.B. Änderung gegenüber Vorjahr/Vorjahren/Referenzjahr, Änderung gegenüber Vergleichsgruppe/Grundgesamtheit) als auch Kennzahlen, die sich aus dem Verständnis der Datensätze ergeben (z.B. Änderung Emissionsmenge versus Änderung Produktionsmenge). Die Indikatoren können auf Zeitreihen aus Stoffströmen selbst aufbauen und dabei alle vergleichbaren Daten von den vorherigen Jahren für jeden Stoffstrom nutzen. Indikatoren können aber auch auf Ebene der gesamten Anlage entwickelt werden. In diesem Fall ist der Indikator dann identisch für alle Zeilen (Stoffströme) einer Anlage.

Für das Training wurden die folgenden vier Zeitreihen-Features untersucht:

- ▶ *REL_CHANGE_COMP_BRANCHE: Änderung in „Energie“ zum Vorjahr im Vergleich zur Änderung der Summe aus der gleichen Branche. Hier wird untersucht, ob die Entwicklung einer Anlage atypisch zur Entwicklung der gesamten Branche ist. Dieser Indikator betrifft den jeweiligen Stoffstrom im Verhältnis zu allen aus derselben Branche der Anlage.
- ▶ *REL_CHANGE_INTENSITY_INST: Änderung der CO₂-Emissionen pro Produktionsmenge aus dem Datensatz zu Produktmengen. Die CO₂-Intensität hängt von vielen Faktoren ab, u.a. vom verwendeten Energiemix und der Auslastung der Anlage. Trotzdem können Sprünge im Emissionsfaktor ein Indiz für Datenprobleme sein. Dieser Indikator betrifft die gesamte Anlage.
- ▶ *REL_CHANGE_PROD_INST: Änderung der Produktionsmenge. Ähnlich wie der vorherige Indikator kann es verschiedene Gründe für eine Änderung der Produktionsmenge geben, eine atypische Änderung kann aber ein Indiz für ein Datenproblem sein. Dieser Indikator betrifft die gesamte Anlage.
- ▶ *REL_CHANGE_INTENSITY: Änderung der CO₂-Emissionen pro eingesetzter Energie. Dieser Indikator betrifft die gesamte Anlage.

Die so erstellte initiale Featurematrix hatte über 200 verschiedene Features und wurde im Laufe des Trainings weiterentwickelt.

3.2 Training

Im Rahmen des Trainings wurde ein umfassender Ansatz gewählt, um möglichst gute ML-Ansätze zu entwickeln. Dabei kamen verschiedene Methoden und Modelle zum Einsatz, die über mehrere Iterationen hinweg verfeinert wurden. Der Fokus lag darauf, sowohl die Struktur der Daten zu analysieren als auch geeignete Modellkonfigurationen zu identifizieren, um Fehler und Inkonsistenzen möglichst präzise zu erkennen.

Die Arbeit begann mit einer explorativen Phase, in der zahlreiche Variationen von Modellkonfigurationen, Trainingsmethoden und Features getestet wurden. Ziel war es, potenziell vielversprechende Ansätze zu identifizieren und diese iterativ zu verbessern. Dieser Schritt war essenziell, um ein fundiertes Verständnis der Datenstruktur und der modellseitigen Herausforderungen zu entwickeln. Durch eine iterative Optimierung konnte sukzessive die Performanz der Modelle gesteigert werden. Insbesondere wurde geprüft, ob das Weglassen einzelner Features einen Einfluss auf die Qualität der Ergebnisse hatte. War dies nicht der Fall, wurden diese Features entfernt. Andere Methoden zur Reduzierung der Features wie z. B. eine Principle Component Analyses wurden nicht verwendet. Diese Methoden haben zum Ziel, die Performance einer KI mit möglichst geringem Verlust der Qualität der Ergebnisse zu erreichen. Dafür werden u.a. Features kombiniert oder auch komplett entfernt, was immer zu einem Informationsverlust führt und die Interpretation der Ergebnisse erschwert. Dies war hier nicht notwendig, da die verwendeten ML-Ansätze in Kombination mit der Menge an Daten auch auf handelsüblichen Computern ausreichend schnell trainiert und angewendet werden können.

Die explorative Phase umfasste unter anderem Experimente mit unterschiedlichen Balancierungsmethoden für die Daten sowie die Analyse der Feature-Relevanz. Dabei zeigte sich, dass eine gezielte Auswahl und Transformation der Features entscheidend für die Modellgüte waren. Parallel dazu wurden verschiedene Sampling-Strategien untersucht, um die Trainings- und Testdaten so aufzubereiten, dass die Verteilung der Klassen (abgelehnt und genehmigt) stets ausgeglichen war. Diese Balancierung war notwendig, um Verzerrungen in der Modellbewertung zu vermeiden und robuste Ergebnisse zu gewährleisten.

In der finalen Iteration der Analyse wurden insgesamt 1.248 Modellvariationen trainiert und ausgewertet. Diese Variationen basierten auf einer Kombination aus Modelltyp, Konfigurationsparametern und Datenaufbereitungsstrategien. Der Fokus lag darauf, die Leistungsfähigkeit der Modelle zu vergleichen und diejenige Konfiguration zu identifizieren, die sowohl eine hohe Genauigkeit als auch eine gute Generalisierbarkeit gewährleistet.

NN zeigten sich insgesamt als der leistungsstärkste Ansatz, insbesondere bei der Erkennung komplexer Zusammenhänge im Datensatz. Allerdings ist die Interpretation der Entscheidungen von NN eine Herausforderung, was ihre Anwendung in erklärungsbedürftigen Kontexten einschränkt. Anders als bei linearen Modellen oder Entscheidungsbaum (DT), bei denen klare Zusammenhänge zwischen Eingabe und Ausgabe identifiziert werden können, sind die Entscheidungen neuronaler Netze das Ergebnis komplexer Wechselwirkungen vieler Knoten und Schichten. Diese Interaktionen sind oft nicht manuell nachvollziehbar. Einzelne Gewichte oder Aktivierungen in einem NN haben selten eine direkte Bedeutung, da sie in Kombination mit anderen Komponenten wirken. Ein weiteres Problem ist die inhärente Nichtlinearität, die es erschwert, allgemeingültige Regeln aus einem NN abzuleiten. Für Anwendungen, in denen Transparenz entscheidend ist, können diese Interpretationsprobleme ein Hindernis sein. Entsprechend können die Ergebnisse dieses ML-Ansatzes nicht automatisch zu einer Verwaltungsentscheidung führen, sondern müssen immer von Menschen geprüft und bestätigt werden. Letztlich kann das NN also lediglich auf „verdächtige“ Datensätze hinweisen.

Die finale Featurematrix hatte noch 106 Einträge.

3.3 Auswertung

3.3.1 Vergleich der Modellergebnisse

Im Folgenden werden die Ergebnisse der verschiedenen ML-Ansätze zusammengefasst. Dabei wird für jeden Ansatz das beste Ergebnis gezeigt.

Tabelle 4: Ergebnisse der Erkennung von Fehlern in den verifizierten Emissionsberichten

(Data)	Gesamt				Genehmigt				Abgelehnt			
	richtig		falsch		richtig		falsch		richtig		falsch	
	42.296				42.110				186			
SVM	36.723	86,8%	5.573	13,2%	36.554	86,8%	5.556	13,2%	169	90,9%	17	9,1%
DT	35.155	83,1%	7.141	16,9%	35.003	83,1%	7.107	16,9%	152	81,7%	34	18,3%
NN	40.019	94,6%	2.277	5,4%	39.838	94,6%	2.272	5,4%	181	97,3%	5	2,7%

Quelle: Öko-Institut

Die Einordnung „richtig“ / „falsch“ bedeutet hier, dass ein Datensatz korrekt durch den ML-Ansatz vorhergesagt wurde. Die Werte sind jeweils die absoluten Zahlen und der Prozentwert zur jeweiligen Basis. Dies wird am Beispiel der genehmigten Berichte im SVM-Ansatz erläutert: Insgesamt wurden bei der Prüfung durch die DEHSt 42.110 Berichte als richtig eingestuft und bildeten die Grundlage für das Training. Von dieser Anzahl wurden im SVM-Ansatz 5.556 bzw. 13,2 % fälschlicherweise als fehlerbehaftet erkannt und abgelehnt. Selbst im NN, dem mit Abstand besten Ergebnis, ist die Fehlerquote mit 5,4 % noch sehr hoch. Konkret wurden durch das Neuronale Netz 2.453 Datensätze abgelehnt, wovon allerdings nur 181 tatsächlich fehlerbehaftet waren. Diese große Menge von Ablehnungen müsste händisch geprüft werden, ohne dass der zuständigen Person Gründe für diese Klassifikation vorliegen.

Im Folgenden werden die Ergebnisse jedes Ansatzes diskutiert.

Support Vector Machine (SVM)

Mit einer Fehlerquote von 13,2 % sind die Ergebnisse dieses Ansatzes nicht besonders gut, aber noch besser als bei Entscheidungsbaum / Decision Tree (DT). Der Wert des Verfahrens in diesem Vorhaben ist primär unterstützend: es erlaubt, potenziell wichtige Felder im Merkmalsvektor zu identifizieren. Diese sind in Tabelle 3 dargestellt. Der Betrag des Koeffizienten im SVM-Ansatz zeigt den Einfluss des jeweiligen Feldes auf das Ergebnis (angenommen/abgelehnt). Dabei bedeutet ein negatives Vorzeichen, dass dieses Feld das Ergebnis Richtung Ablehnung beeinflusst. Ein positives Vorzeichen bedeutet entsprechend, dass dieses Feld zu einer Annahme des Antrags beiträgt.

Die Parameter, die den größten Einfluss auf das Ergebnis des SVM-Ansatzes haben, sind: Branche, Tätigkeit nach Anhang IV MVO, Menge.Ebene ÜP, EF.Ebene ÜP, EF zulässig, Messung, Unterer Heizwert.Ebene ÜP, Berechnen. Diese Parameter bezeichnen die Spalte im ursprünglichen Datensatz. So ist die absolute Summe der Features zur Branche am größten, gefolgt von der Tätigkeit nach Anlage IV MVO.

Tabelle 5: Features mit größtem Einfluss auf das Ergebnis im SVM-Ansatz

Feature	Koeffizient
EF zulässig	-1
Messung	0,7009
Berechnen	0,5794,,
EF.Meth. genehmigt	0,4599
Unterer Heizwert zulässig	0,4206
Biogener Anteil plausibel	0,4096
Branche=KW, Erdgas	0,376
Tätigkeit nach Anhang IV MVO=1 - Verbrennung - Fackeln	0,3558,
Branche=KW, Braunkohle	-0,325,
Menge.Ebene ÜP=3	-0,3183
EF.Ebene ÜP=2	0,278
Biogener Anteil.Einheit=% C	-0,2568
Biogener Anteil.Einheit=[1]	0,2568,
Menge.Meth. genehmigt	-0,2533,

Anmerkung: Es wurden die Features ausgewählt, die einen Koeffizienten mit Betrag von mindestes 0,25 aufzeigen.

Quelle: Öko-Institut

Decision Tree (DT)

In diesem Arbeitspaket ist der DT-Ansatz der schlechteste der untersuchten KI-Modelle. Prinzipiell könnte mit ausreichender Tiefe zwar beliebig genau gefittet werden, dies wäre aber nicht zielführend. Die Vorhersagekraft für neue Daten wäre sehr schlecht, da auf zufällige einzelne Features gelernt würde (overfitting). Dennoch kann auch dieses Verfahren besonders interessante Merkmale sichtbar machen. Dies sind insbesondere die Knoten, die am Anfang des Entscheidungsbaums stehen und zu unterschiedlichen Ergebnissen führen, d.h. bei denen der Wert eines Features großen Einfluss auf das Ergebnis hat. Dies sind bei dem besten DT-Ergebnis:

- ▶ Biogener Anteil.Einheit=%C
- ▶ EF.Ermittlungsmethode=Standardwert
- ▶ Unterer Heizwert.Ebene ÜP=Schätzwert
- ▶ EF.KEY Parameter = EF_VM
- ▶ Branche=KW, Braunkohle
- ▶ *REL_CHANGE_INTENSITY

Wichtig ist dabei zu beachten, dass Entscheidungsbäume mit komplett anderer Entscheidungshierarchie der Variablen gebildet werden könnten, die trotzdem ein ähnliches Fitting hätten.

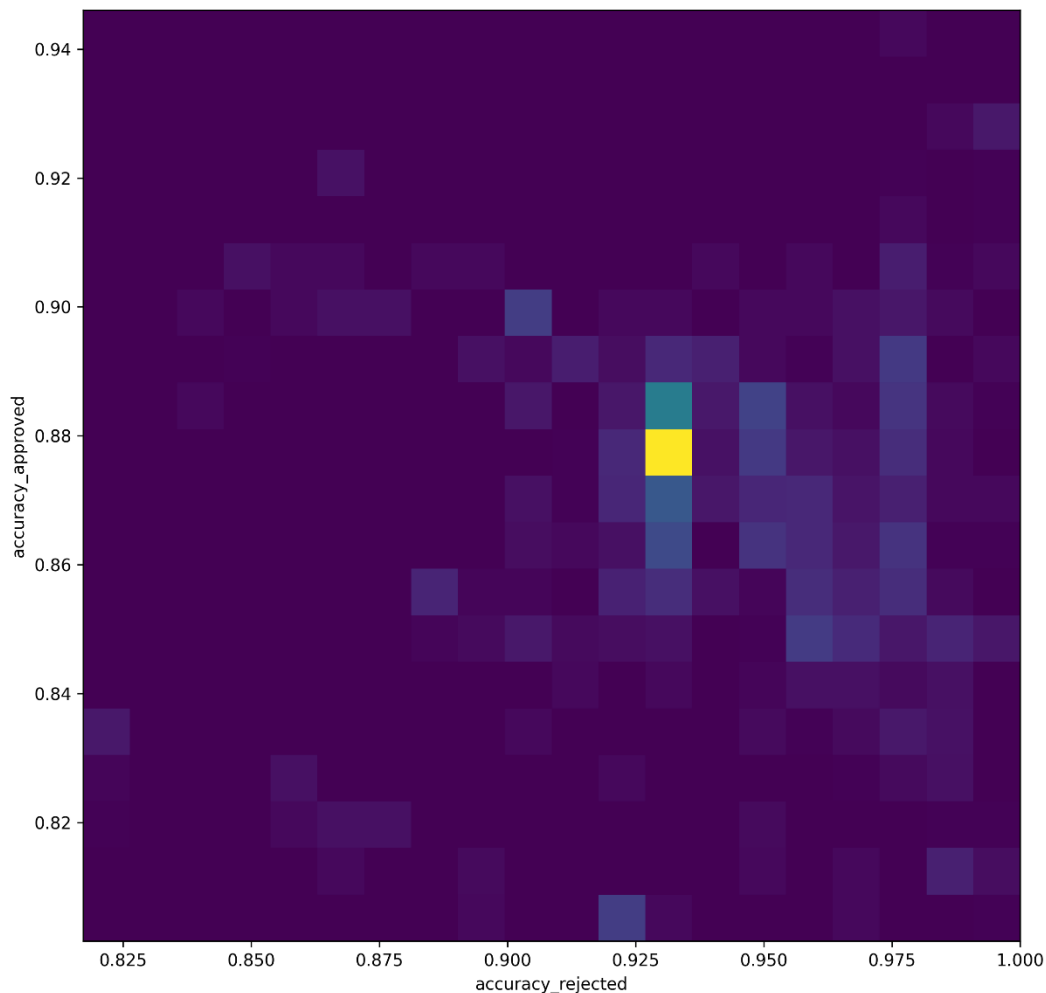
Neural Network (NN)

Wie schon im Arbeitspaket 1 ist der NN-Ansatz der vermutlich geeignetste Ansatz, auch wenn die Interpretation der Ergebnisse schwierig bis unmöglich ist (siehe oben). So wie im Arbeitspaket 1 ist bei NN die Gefahr des Overfittings am geringsten. Insbesondere beim DT-Ansatz können sehr unterschiedliche Pfade zu sehr ähnlicher Güte des Ergebnisses führen. Das beste Trainingsergebnis wurde durch ein NN mit vier versteckten Schichten (Schichten 2 bis 5) erreicht. Dabei haben die Schichten 1 bis 4 jeweils zwanzig Knoten, die letzte Schicht noch vier. Bei den Features mit der höchsten Gewichtung in Schicht 1 gibt es Überschneidungen mit den per SVM identifizierten wichtigsten Features. So wurde auch hier z.B. die „Branche KW, Braunkohle“ oder „EF.Meth.genehmigt“ deutlich identifiziert. Auch der erste Schritt im Entscheidungsbaum („Biogener Anteil.Einheit = %C“) wurde deutlich im NN identifiziert. Dies gilt aber nicht für alle Features. So ist im NN-Ansatz- „Messung“ in der ersten Schicht eher unauffällig, während es im SVM der wichtigste Beitrag zur Annahme (genehmigt) ist.

3.3.2 Einfluss der Struktur und Konfiguration des neuronalen Netzes

Für den ML-Ansatz neuronales Netz wurden die Auswirkungen verschiedener Konfigurationen auf die Qualität der Ergebnisse untersucht. Dabei wurden verschiedene Aktivierungsfunktionen, Solver, Lernraten und Schichtenarchitekturen geprüft (siehe Kapitel 3.1). Abbildung 2 zeigt ein 2D-Histogramm über alle Modell-Trainingsläufe. Dabei korrespondiert eine höhere Helligkeit mit einer höheren Anzahl von Läufen, die in den Block fallen. Bei der allermeisten Zahl von Modellen ist die `accuracy_approved` (genehmigt), also die Wahrscheinlichkeit, dass ein Datensatz richtigerweise als korrekt identifiziert wird, unter 90 %. Im Umkehrschluss bedeutet dies, dass über 10 % aller Datensätze als fehlerhaft markiert wird, was bei der hohen Zahl der Fälle zu einer unrealistisch großen Anzahl von manuellen Prüfungen führen würde. Einzelne Modelle erreichen eine hohe Genauigkeit insbesondere bei `accuracy_rejected` (abgelehnt). Dies ist vermutlich das Ergebnis von Overfitting, da es nur sehr wenige Lerndaten für die Ablehnung gab.

Abbildung 2: Verteilung der Ergebnisse aller Modelle von accuracy_rejected und accuracy_approved




Quelle: Eigene Abbildung, Öko-Institut

Einfluss der Aktivierungsfunktion

Abbildung 3 zeigt die Güte der Modellergebnisse in Abhängigkeit der Aktivierungsfunktion. Der Box-Plot zeigt Verteilung der 0 %, 25 %, 50 %, 75 %, 100 % Perzentile (Strichenden, Box, Mittellinie) sowie von Ausreißern (Kreis) für den Wert accuracy_lowest für die ausgewählten Modell-Trainingsläufe. Accuracy_lowest ist der niedrigere Wert von accuracy_approved und accuracy_rejected. In den meisten Fällen ist accuracy_approved schlechter als accuracy_rejected (Abbildung 2).

Die Aktivierungsfunktion *logistic* ist für den hier untersuchten Datensatz klar die am wenigsten geeignete mit den schlechtesten Ergebnissen. *Relu* zeigt die wenigste Streuung um den Median und erzeugt damit die stabilsten Ergebnisse. Die Funktion *tanh* liefert in manchen Kombinationen mit den anderen Eigenschaften des NN die besten Ergebnisse, zeigt aber auch die größte Streuung. Der Median von *relu* und *tanh* ist praktisch identisch.

Abbildung 3: Einfluss der Aktivierungsfunktion auf die Mindestgenauigkeit




Quelle: Eigene Abbildung, Öko-Institut

Einfluss des Lernalgorithmus (Solver)

Auch beim Lernalgorithmus führt der Solver mit der höchsten Streuung (*LBFGS*) zu den besten Ergebnissen in ausgewählten Fällen (Abbildung 4). Der Median des Algorithmus mit der geringsten Streuung ist deutlich schlechter als der fast identische Median der beiden anderen Solver. Auch in AP 1 führte *LBFGS* zu den besten Ergebnissen.

Abbildung 4: Einfluss der Lernalgorithmus (Solver) auf die Mindestgenauigkeit




Quelle: Eigene Abbildung, Öko-Institut

Einfluss der Lernrate

Erwartungsgemäß hat die Lernrate keinen nennenswerten Einfluss auf die Ergebnisse (Abbildung 5), nur der Ressourcenbedarf jedes Trainingslaufs wird davon beeinflusst. Neuronale Modelle konvergieren auch mit unterschiedlichen Lernraten, wenn die Lernrate gut auf die Architektur, die Daten und die gewählte Optimierungsstrategie abgestimmt ist.

Abbildung 5: Einfluss Änderung der Lernrate




Quelle: Eigene Abbildung, Öko-Institut

Schichtenarchitektur

Die Anzahl der verdeckten Schichten im Neuronalen Netz hat in dem untersuchten Datensatz einen deutlichen Einfluss auf die Güte der Ergebnisse. Bei drei verdeckten Schichten ist der Medianwert am höchsten und die Streuung am geringsten (Abbildung 6). Modelle mit nur zwei verdeckten Schichten können anscheinend die Komplexität des Datensatzes nicht richtig abbilden, während bei vier Schichten die Ergebnisse stärker streuen. Dies kann auf eine erhöhte Instabilität oder Empfindlichkeit des Modells hindeuten, z. B. durch Overfitting oder Schwierigkeiten bei der Konvergenz. Bei 2 und 3 Schichten sind die Ergebnisse konsistenter, da die Boxen enger sind und weniger Ausreißer sichtbar sind. Der beste Wert – ein Ausreißer bei vier verdeckten Schichten – könnte wieder auf ein Overfitting hinweisen. Bei vier Schichten treten Ausreißer häufiger auf, was möglicherweise auf Trainingseffekte wie vanishing/exploding gradients hindeutet.

Abbildung 6: Einfluss der Anzahl der versteckten Schichten auf die Mindestgenauigkeit



Quelle: Eigene Abbildung, Öko-Institut

Einfluss der Zeitreihen-Features

Abbildung 7 untersucht die Auswirkungen verschiedener Zeitreihen-Features auf die Genauigkeit (`accuracy_lowest`), wobei der Ausgangsfall (BASE) (ohne Zeitreihen-Features) ganz rechts dargestellt ist. Der Base-Case erreicht eine mediane Genauigkeit von 0,8752, mit einem Maximum von 0,8953. Die Ergebnisse sind relativ stabil, mit einer moderaten Streuung und wenigen Ausreißern. Dies repräsentiert die Ausgangsleistung des Modells ohne die Berücksichtigung von Zeitreihen-Features.


Die Kombination aller Zeitreihen-Features (zweiter Boxplot von links) verbessert die Median-Genauigkeit leicht auf 0,8787 und führt zu einem deutlich höheren Maximum (0,9460). Dies zeigt, dass die Einbeziehung aller Zeitreihen-Features dem Modell ermöglicht, komplexere Muster zu lernen und in den besten Fällen eine erheblich bessere Performance zu erzielen. Allerdings führt die breite Verteilung auch zu einer gewissen Instabilität im Training.

Die Zeitreihen-Features `REL_CHANGE_COMP_BRANCHE**` und `REL_CHANGE_INTENSITY_INST` (erster und vierter Boxplot von links) erzielen ähnliche Medianwerte wie der Ausgangsfall (beide 0,8676) und zeigen keinen wesentlichen Vorteil im Vergleich zur Ausgangssituation. Sie haben jedoch etwas höhere Maximalwerte, was auf eine geringfügige Verbesserung in den besten Modellen hinweist. `REL_CHANGE_PROD_INST` (fünfter Boxplot von links) zeigt eine Median-Genauigkeit von 0,8711, etwas schlechter als der Ausgangsfall-Median. Es scheint im Vergleich zu den anderen Einzel-Features stabiler zu sein und insbesondere die unteren Werte sind deutlich besser als in den anderen Modellen. `REL_CHANGE_INTENSITY**` (dritter Boxplot von links) zeigt die schwächste Performance mit einem Median von 0,8544 und geringem Maximum (0,8927), beide Werte sind schlechter als im Ausgangsfall.

Die Kombination aller Zeitreihen-Features bietet die beste Gesamtleistung, insbesondere in Bezug auf die maximal erreichbare Genauigkeit. Einzelne Features allein haben nur begrenzten Einfluss, und einige (z. B. `REL_CHANGE_INTENSITY`) könnten das Modell sogar leicht

verschlechtern. Der Ausgangsfall ohne Zeitreihen-Features liefert stabile Ergebnisse, die Kombination aller Features führt zu einer höheren Variabilität im Training.

Abbildung 7: Einfluss der Features mit Zeitreihen-Information



Quelle: Eigene Abbildung, Öko-Institut

3.4 Fazit

Die hier durchgeführten Analysen zeigen, dass KI-Modelle prinzipiell in der Lage sein sollten, automatisiert verdächtige oder fehlerhafte Daten zu identifizieren. Gleichzeitig zeigen die Ergebnisse aber auch die erheblichen Restriktionen und Schwierigkeiten, um einen ML-Ansatz zur Erkennung von Fehlern in den verifizierten Emissionsberichten in der DEHSt zu nutzen. Die zentralen Ergebnisse sind:

- ▶ NN liefern wie im ersten Arbeitspaket die besten Ergebnisse. Durch die Anzahl der verschiedenen Modellvarianten mit unterschiedlicher Schichtenstruktur und Modellparametern (Aktivierungsfunktion, Lernalgorithmus, Lernrate) konnten die Parameter identifiziert werden, die vermutlich zu den besten Ergebnissen führen können.
- ▶ Die zeitlichen Informationen (Zeitreihen-Features) haben die Qualität des Ergebnisses leicht verbessert. Dies gilt insbesondere für das beste einzelne Modell, das fünf Prozentpunkte höhere Genauigkeit liefert. Es ist aber unklar, ob dieser Wert unter echten Bedingungen auch gelten würde, oder es sich um ein Overfitting handelt. Der Medianwert aller Modelle unter Berücksichtigung aller Zeitreihen-Features ist lediglich einen halben Prozentpunkt besser als der Ausgangsfall (Base-Case). Es könnte sein, dass durch eine Auswahl weiterer Zeitreihen-Features die Qualität des Ergebnisses noch weiter verbessert werden könnte.
- ▶ NN haben den Nachteil, dass ihre Ergebnisse manuell nicht wirklich nachvollziehbar sind. Es ist entsprechend schwierig, aus den Darstellungen der Ergebnisse Schlussfolgerungen für die Prüfung der Emissionsberichte in der DEHSt zu ziehen.
- ▶ Die Ergebnisse des SVM- und DT-Ansatzes sind besser verständlich. Gleichzeitig ist die Fehlerrate bei beiden Ansätzen deutlich höher. Das beste NN-Modell hat eine Fehlerrate von 5,4 %, während bei SVM die beste Rate nur noch 13,2 % und bei DT sogar 16,9 % beträgt (Tabelle 4). Es ist unklar, ob es sich dabei um reproduzierbare Ergebnisse handelt, die auch mit zukünftigen Datensätzen zu dieser Erkennungsrate führen würden. DT schneidet bei den *false_rejected* noch schlechter ab als bei den *false_approved*, die anderen beiden Modelle haben bei den Ablehnungen eine höhere Trefferquote. Aber auch da stellt sich die Frage, ob dies nicht nur das Ergebnis eines Overfittings ist. Auch hier müssten weitere Tests mit neuen Datensätzen durchgeführt werden.
- ▶ Es wurde deutlich, dass auf Basis des aktuellen Datensatzes kein KI-Modell ausreichend trainiert werden kann. Die Anzahl der korrigierten Einträge ist zu gering, so dass die Fehlerrate insbesondere für *false positives*, also fälschlicherweise als abgelehnt klassifizierte Einträge, deutlich zu hoch ist. Sollten alle abgelehnt-Meldungen von Hand geprüft werden, würde dies erhebliche personelle Kapazitäten erfordern. Von den 2.453 Datenzeilen, die als abgelehnt im besten Modell klassifiziert wurden, waren gerade mal 181 im Lerndatensatz fehlerhaft. Eine manuelle Prüfung der 2.453 Datensätze wäre aufwändig, u.a. weil die ML-Ansätze keine Begründung für die Klassifizierung angeben.
- ▶ Tabelle 6 zeigt die Liste der Features mit dem höchsten Einfluss auf das Gesamtergebnis bzw. Gewichtung in der ersten Schicht im NN-Ansatz. Dafür wurden für das beste SVM-Modell alle Features mit absolutem Beitrag über 0,15 (28 Einträge) und für das beste DT-Modell alle verwendeten Features (14 Einträge) genutzt. Für das beste NN-Modell wurde die Wurzel aus den quadratischen Beiträgen der ersten Schicht für jedes Feature berechnet und analog zu SVM die 28 Einträge ausgewählt, die das höchste Gewicht hatten. Die Tabelle zeigt

diejenigen Features aus der Auswahl, die mindestens in zwei der drei ML-Ansätze zum Tragen kamen. Sie zeigt, dass sechs Features in allen drei Modellen eine wichtige Rolle spielen, weitere 11 in zwei der Modelle.

- Machine Learning kann unter den gegebenen Bedingungen eventuell genutzt werden, um einzelne Felder zu identifizieren, die einen hohen Einfluss auf die Kategorisierung haben (Tabelle 6). Dies kann aber höchstens dafür genutzt werden, die regelbasierten aktuellen Ansätze in der DEHSt zu verbessern. Diese regelbasierte Klassifikation auf Basis des Expertenwissens liefert nachvollziehbare und gut begründbare Ergebnisse.

Tabelle 6: Häufigkeit der wichtigsten Features in allen drei ML-Ansätzen (alphabetische Reihenfolge ohne Gewichtung)

Feature	SVM	DT	NN	Häufigkeit
Berechnen	x	x	x	3
Biogener Anteil plausibel	x	x	x	3
Biogener Anteil.Einheit=% C	x	x	x	3
Branche=KW, Braunkohle	x	x	x	3
EF.Meth. genehmigt	x	x	x	3
Menge.Ebene ÜP=3	x	x	x	3
*REL_CHANGE_INTENSITY_INST		x	x	2
Biogener Anteil.Einheit=[1]	x		x	2
Branche=HKW, Biomasse	x	x		2
Branche=sonstige Energieanlage		x	x	2
EF zulässig	x		x	2
EF.Ermittlungsmethode=Analyse		x	x	2
Material EF	x	x		2
Menge.Ebene ÜP=1	x		x	2
Menge.Ebene ÜP=4	x		x	2
Menge.Ebene ÜP=Schätzwert	x	x		2
Menge.Meth. genehmigt	x		x	2

Quelle: Öko-Institut

4 Arbeitspaket 3 - Automatisierte Prüfung von Registerdaten als Teil der Geldwäscheprävention

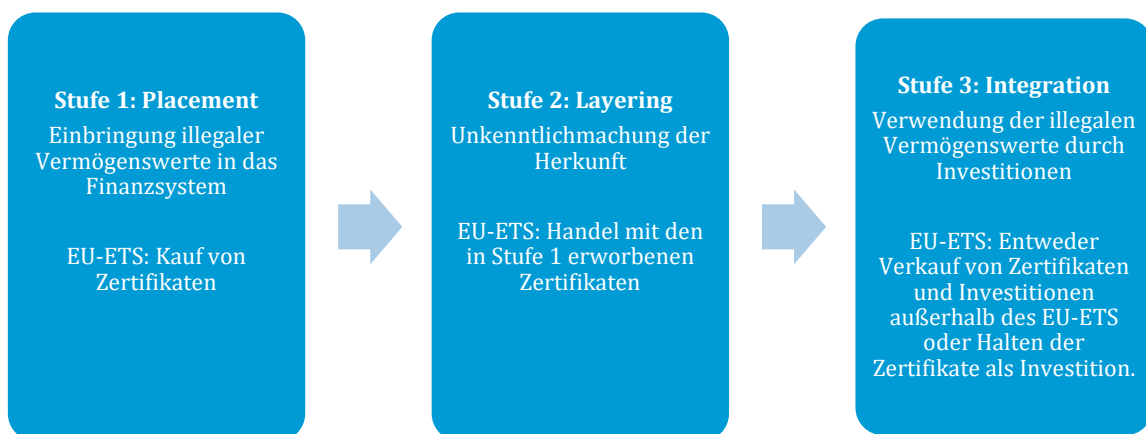
4.1 Hintergrund

Im Arbeitspaket 3 wurden Transaktionsdaten auf verdächtige Transaktionen hin untersucht. Von möglichen Formen kriminellen Handels im Unionsregister wurde Geldwäsche als Untersuchungsobjekt ausgewählt. Geldwäsche bezeichnet einen Vorgang, bei dem illegal erworbene Vermögenswerte in den legalen Wirtschaftskreislauf integriert werden. Im Rahmen dieses Projekts wurde 2023 eine Bachelorarbeit (Krähenbühl 2023) geschrieben, die auf Basis einer Literaturrecherche und Interviews der Frage nachgeht, wie sich Geldwäsche erkennen lässt.

In der Bachelorarbeit werden die verschiedenen Stufen der Geldwäsche, das Placement, Layering und die Integration beschrieben. Beim Placement werden illegal erworbene Vermögenswerte ins Finanzsystem integriert. In Bezug auf den EU-ETS kann dies durch den Erwerb von Emissionszertifikaten geschehen. Die zweite Stufe - das Layering - dient der Unkenntlichmachung der Herkunft der Vermögenswerte. In Bezug auf den EU-ETS kann dies z.B. geschehen, in dem die in Stufe 1 erworbenen Zertifikate oder Zertifikatsblöcke so lange gehandelt werden und über unterschiedliche Konten wandern, bis ihre Herkunft schwer nachzuvollziehen ist. In der dritten Stufe - der Integration - werden die illegalen Vermögenswerte in den legalen Wirtschaftskreislauf zurückgeführt, indem sie investiert werden. Dies umfasst Investitionen in materielle Güter, wie auch in Finanzanlagen, Firmenanteile oder ähnliches (Bongard 2001). In Bezug auf den EU-ETS könnten in diesem Schritt die Zertifikate verkauft und der Erlös für den Kauf von Investitionsgütern genutzt werden. Es könnte auch sein, dass die Zertifikate selbst als Investition gehalten werden.

Abbildung 8 fasst die verschiedenen Stufen der Geldwäsche in Bezug auf den EU-ETS zusammen.

Abbildung 8: Stufen der Geldwäsche und Bezug zum EU-ETS



Quelle: Eigene Abbildung, ZHAW

Die Literatursauswertung der Bachelorarbeit zeigt, dass die erste Stufe des Placements diejenige Stufe im Geldwäschekreislauf ist, zu der die Aufdeckungswahrscheinlichkeit am höchsten ist. Allerdings ist dies genau diejenige Stufe, die sich anhand der aktuell vorliegenden Registerdaten,

die keine Informationen zum Finanzgeschäft³ beinhalten, nicht untersuchen lässt.⁴ In der folgenden Analyse konzentrieren wir uns deswegen insbesondere auf die Stufe 2, das Layering – also die Unkenntlichmachung der Herkunft des Geldes, mit dem die Zertifikate in Stufe 1 erworben wurden. Die Annahme ist, dass sich Teilnehmer*innen des Marktes, die einen Geldwäschezweck verfolgen, auf dem Markt anders verhalten als solche, die z.B. als Betreiber Compliance verfolgen.

In seiner Studie zum Geldwäscherisiko im EU-Emissionshandel, kommt Bussmann (2020) zu dem Ergebnis, dass das Risiko für Geldwäsche im EU-ETS signifikant ist, da der Emissionshandel verschiedene Eigenschaften aufweist, die ihn attraktiv für Geldwäsche machen:

- i) Emissionsberechtigungen sind leicht handelbare Finanzprodukte, ii) Emissionsberechtigungen sind sichere Wertanlagen, iii) das Unionsregister ist relativ intransparent, iv) das AML-Compliance-Management⁵ der am Emissionshandel beteiligten Unternehmen ist unzureichend und v) die in den letzten Jahren steigenden Preise erhöhen die Attraktivität des Emissionshandels für Geldwäsche.

Der Autor schlägt eine Reihe von Maßnahmen vor, um diesem Risiko entgegenzutreten, u.a. softwaregestützte Analysen des Unionsregisters. In der Studie von Bussmann (2020) werden auf Basis von Interviews und Befragungen eine Reihe auffälliger Merkmale und Transaktionsmuster herausgearbeitet. Aus diesen Merkmalen und Transaktionsmustern lassen sich, als Startpunkt für die ML-gestützte Analyse in den folgenden Kapiteln, die in Tabelle 7 aufgeführten Variablen ableiten:

Tabelle 7: Relevante Variablen für die Erkennung von Geldwäsche

Variable	
Kontoführendes Land	Höheres Risiko, wenn Nicht-EU
Kontotyp	Höheres Risiko, wenn Luftfahrzeugbetreiber und Händler
Firmengröße beider Handelspartner*innen	Höheres Risiko, wenn kleinere Firmen
OTC-Handel	Höheres Risiko beim Handel über den OTC-Markt
Handelsvolumina im Vergleich zu Emissionen	Höheres Risiko, wenn Handelsvolumina signifikant die Compliance-Menge übersteigt
Transaktionsfrequenz	Höheres Risiko, wenn in ungewöhnlichen Abständen gehandelt wird

Quelle: Eigene Zusammenstellung basierend auf Bussmann (2020)

Auf Basis der Ergebnisse der Interviews und Befragungen berichtet Bussmann (2020) von hochgerechnet 300 Verdachtsfällen für den deutschen Teil des Unionsregisters pro Jahr. Er geht

³ Welche Informationen im Unionsregister erfasst werden, wird in der Registerverordnung (EU 2019/1122) festgelegt.

⁴ Bussmann (2020) gibt in seiner Studie zum Geldwäscherisiko im EU-Emissionshandel Empfehlungen für weitere Angaben, die im Register gemacht werden sollten, um die Erkennung von Geldwäsche zu erleichtern. Dazu gehören: i) Information über den Geschäftszweck der Kontoinhaber, ii) Preisangaben der gehandelten Emissionszertifikate und Datum des Vertragsschlusses, iii) Angabe der Finanztransaktionswege bei Transaktionen (BIC und IBAN bzw. Barzahlung), iv) Für die handelnden Kontoinhaber zu der Kontonummer des Counterparts auch Sichtbarkeit des Kontoinhabers, Kontotyps und des registerführenden Landes. Bussmann (2020) nennt weitere wichtige Verdachtsmomente, die nicht im Register erfragt werden können, aber insbesondere helfen würden die Stufe des Placements zu erkennen und so zu Meldungen seitens der Handelspartner*innen führen könnten: i) Auftreten als reiner Intermediär ohne Konto, ii) Kontakt nur über Mobiltelefon und iii) Nicht aus Energie-/CO₂-Branche bekannt.

⁵ Anti-Money-Laundering Compliance –Management

davon aus, dass sich der Großteil dieser Verdachtsfälle auf Basis der aktuell verfügbaren Daten im Unionsregister nicht ermitteln lässt. Der Autor gibt an, dass in seiner Studie, die rein auf Befragungen beruht, keine Datenanalyse mit Informationen zum Abgabe-Bedarf der Kontoinhaber, den Handelsvolumina oder Informationen zur Größe von Firmen erfolgte. Die vorliegende Studie ist somit die erste, die eine ML-gestützte Analyse der Transaktionsmuster durchführt und somit verdächtige Muster systematisch prüft.

Bussmann (2020) identifiziert sowohl das Volumen der Käufe und Verkäufe als auch Frequenz der Käufe und Verkäufe als wichtige Variablen. Ungewöhnlich hohe oder niedrige Handelsvolumina können auf verdächtige Aktivitäten wie Geldwäsche oder Marktmanipulation hinweisen.

Eine ungewöhnlich hohe Handelsfrequenz könnte auf Techniken wie "Smurfing" (z.B. eine große Menge wird in mehreren kleineren Transaktionen übertragen, um die wahre Größe der Transaktion zu verschleiern) oder "Wash Trading" (gleichzeitiger Kauf und Verkauf) hinweisen, die häufig bei Geldwäsche verwendet werden. Auch die Netto-Handelsposition pro Tag (Holdings) liefert wichtige Erkenntnisse. Extreme Abweichungen, sei es auf der Kauf- oder Verkaufsseite, können auf künstlich erzeugte Handelsmuster hindeuten, die für Geldwäsche genutzt werden könnten.

Die Europäische Wertpapier- und Marktaufsichtsbehörde (ESMA) betont in ihrem Abschlussbericht die Bedeutung der Überwachung solcher Positionen zur Erkennung von Marktmissbrauch (ESMA 2015). Die kumulative Netto-Handelsposition pro Tag (cumulative holdings) ermöglicht die Identifizierung langfristiger Muster, die auf verschleierte Aktivitäten hinweisen könnten. Durch die Aggregation von Handelsdaten über längere Zeiträume hinweg können saisonale Schwankungen und kurzfristige Fluktuationen ausgeglichen werden, was die Erkennung von Trends und Anomalien erleichtert. Geografische Merkmale spielen ebenfalls eine wesentliche Rolle.

Das Land des Sitzes des Kontoinhabers kann auf regulatorische Arbitrage hinweisen, da einige Länder möglicherweise weniger strenge Geldwäschevorschriften oder weniger gute institutionelle Umsetzung dieser Regelungen haben, was sie für Geldwäscheakteure attraktiver macht. Es gibt zudem keine einheitliche Harmonisierung in der rechtlichen und steuerlichen Behandlung von Emissionszertifikaten zwischen den Mitgliedstaaten des EU-ETS. Die rechtliche Einstufung variiert von finanziellen Instrumenten über immaterielle Vermögenswerte bis hin zu Eigentumsrechten und Handelswaren. Ebenso unterscheiden sich steuerliche Regelungen: Während nur wenige Mitgliedstaaten Mehrwertsteuer (MWSt) auf die Ausgabe von Emissionszertifikaten erheben, wird diese auf dem Sekundärmarkt in den meisten Ländern fällig. Die Anwendung des Reverse-Charge-Verfahrens zur MWSt-Abrechnung in vielen Mitgliedstaaten des EU-ETS bietet Schutz vor MWSt.-Betrug, wird jedoch unterschiedlich gehandhabt. Diese Unterschiede erhöhen das Risiko regulatorischer Arbitrage und machen einige Länder attraktiver für potenzielle Geldwäscheakteure (vgl. EC 2018). Aufgrund dieser Unterschiede zwischen EU- und nicht EU-Ländern wird das Risiko durch Luftfahrzeugbetreiber und Händler als höher eingeschätzt, da diese im Gegensatz zu Anlagenbetreibern auch aus Nicht-EU Ländern stammen können.

Während es zwischen den EU-Mitgliedstaaten in vielen Bereichen des Emissionshandels zu einer zunehmenden rechtlichen Integration gekommen ist, gilt dies nicht für Nicht-EU-Staaten, was das Risiko weiter erhöht. Nicht-EU-Staaten sind bspw. über das Linking ihres Emissionshandelssystems mit dem EU-ETS eingebunden, wie dies bei der Schweiz seit 2020 der Fall ist. Im Schweizer Register gibt es nur Betreiber- und Personenkonten, also keine

Unterscheidung zwischen Handels- und Personenkonten, was das Risiko erhöht, da Handelskonten restriktiveren Regelungen unterliegen im Vergleich zu Personenkonten.

Der Zertifikatstyp ist relevant, da Emissionszertifikate aus unterschiedlichen Jurisdiktionen stammen und somit verschiedenen regulatorischen Vorgaben (EU versus UNFCCC) unterliegen. Internationale Zertifikate wie CERs und ERUs kamen für den Beobachtungszeitraum meist aus dem EU-Ausland und setzen somit einen Handel mit Nicht-EU-Partnern voraus, was das Handelsrisiko beeinflusst. Zudem konnte der Austausch oder die Umwandlung bestimmter Zertifikate zur Verschleierung von Handelsaktivitäten genutzt werden. Auch regulatorische Unterschiede zwischen EU- und Nicht-EU-Zertifikaten (z.B. CHUs aus der Schweiz) boten potenzielle Schlupflöcher. Die Berücksichtigung dieses Merkmals hilft, verdächtige Muster und mögliche Umgehungen regulatorischer Vorschriften frühzeitig zu erkennen. Mittlerweile können keine Internationalen Zertifikate wie CERs und ERUs mehr im Unionsregister gehalten werden, dennoch kann die Analyse zum Zertifikatstyp wichtige Hinweise zu historischen Auffälligkeiten liefern.

Diese Merkmale bilden die Grundlage für die datengetriebene Erkennung potenzieller Anomalien im EU-ETS und stellen sicher, dass sowohl kurzfristige Abweichungen als auch langfristige Muster erfasst werden. Zeitliche Muster können saisonale oder unregelmäßige Anomalien aufdecken.

4.2 Das Unionsregister und Marktteilnehmende im EU-ETS

Im Unionsregister wird der Handel zwischen verschiedenen Konten abgebildet, die von Unternehmen und Einzelpersonen eröffnet werden können. Es umfasst insgesamt 45.532 Konten, 20.406 Kontoinhaber und 34 unterschiedliche Kontoarten (Stand 2024). Jede juristische Person oder jedes Unternehmen, welches Emissionszertifikate halten möchte, muss mindestens ein Konto im Unionsregister besitzen, kann jedoch auch mehrere Konten verschiedener Typen führen.

Die Kontennamen und Regeln wurden im Laufe der Zeit immer wieder angepasst. Vor der Harmonisierung der europäischen Register mussten alle Konten innerhalb eines nationalen Registers eröffnet werden. Mit der Überarbeitung der EU-Richtlinie im Jahr 2009 wurden alle Konten der nationalen Register im Jahr 2012 in ein übergreifendes Unionsregister migriert, das von der EU-Kommission entwickelt und verwaltet wird. Die Mitgliedstaaten sind jedoch weiterhin allein für die Eröffnung, Verwaltung und Aktualisierung der Konten in ihren nationalen Sektionen des Unionsregisters verantwortlich. Die Kontoarten unterscheiden sich in ihrer Funktion und Nutzung. Unternehmen, die im EU-ETS reguliert sind, müssen ein Betreiberkonto eröffnen, haben jedoch auch die Möglichkeit, zusätzliche Kontoarten, wie etwa Handelskonten, zu eröffnen. Betreiber mit höheren Emissionen oder hoher Anzahl an regulierten Anlagen, und daher auch mehreren Betreiberkonten, verfügen typischerweise über eine Kombination aus Betreiber- und Handelskonten.

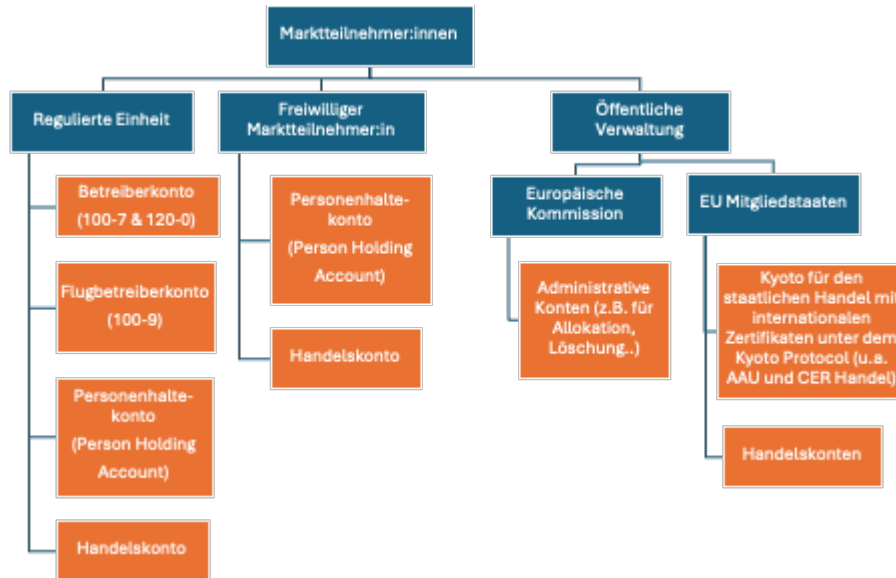
Das Unionsregister deckt nun alle Betreiber aus 31 Ländern ab, die am EU-ETS teilnehmen, sowie alle weiteren Konten der öffentlichen Verwaltung und freiwillig eröffnete Konten aller Marktteilnehmer*innen.

Um potenzielle Abweichungen vom normalen Handelsverhalten oder Anzeichen für Geldwäsche zu erkennen, ist eine genaue Analyse der Unternehmensstruktur und Handelsaktivitäten im Register erforderlich. Informationen zu Kontoinhaber, Kontoarten und Transferarten helfen bei

der Unterscheidung zwischen Betreibern, freiwilligen Marktteilnehmern und administrativen Einheiten.

Abbildung 9 gibt eine Übersicht über die verschiedenen Marktteilnehmer*innen und die dazugehörigen Kontoarten, die im Folgenden detailliert beschrieben werden.

Abbildung 9: Übersicht über die Kontoarten und zugehörigen Marktteilnehmer*innen im Unionsregister



Quelle: Eigene Darstellung, ZHAW

Betreiber

Alle Betreiber, die durch die Richtlinie (Directive 2003/87/EG) des EU-ETS reguliert werden, müssen laut Registerverordnung (COM Delegated Regulation 2019/1122) entweder ein:

1. **Betreiberkonto** (Operator Holding Account, OHA) oder
2. **Luftfahrzeugbetreiberkonto** (Aircraft Operator Account, AOHA) halten.

Neben den OHAs und/oder AOHAs können bzw. konnten Betreiber auch Konten wie Personenkonten (Person Holding Accounts, PHAs) oder Handelskonten (Trading Accounts, TAs) freiwillig eröffnen.

Freiwillige Marktteilnehmer*innen

Juristische Personen oder natürliche Personen, die nicht durch die Richtlinie des EU-ETS reguliert werden, aber am Markt teilnehmen möchten, können entweder auch ein Personenkonto (PHA) oder ein Handelskonto (TA) eröffnen. Auch Betreiber und nationale Administratoren können freiwillige Kontoarten eröffnen. Das Datenset enthält folgende freiwillige Kontoarten:

3. Personenkonto (Person Holding Account)

Transfers von einem Personenkonto unterliegen seit 2013 einer Verzögerung von 26 Stunden. Überweisungen können nur an Konten erfolgen, die in der Vertrauenskontenliste aufgeführt sind. Die Genehmigung durch einen zusätzlichen autorisierten Vertreter ist nicht erforderlich, es sei denn, dies wird beantragt. Seit 2021 sind die Personenkonten in Handelskonten umgewandelt worden.

4. Handelskonto (Trading Account)

Handelskonten können ebenfalls eine Vertrauenskontenliste haben. Wie bei den Personenkonten können Transfers durch einen zusätzlichen autorisierten Vertreter bestätigt werden. Überweisungen von einem Handelskonto zu einem Konto auf der Vertrauenskontenliste unterliegen keiner Verzögerung. Im Gegensatz zu den Personenkonten dürfen Handelskonten jedoch auch Transfers an Konten außerhalb ihrer Vertrauenskontenliste vornehmen; in diesem Fall unterlagen die Transfers bis 2019 der 26-stündigen Verzögerung, mittlerweile einer Verzögerung von entweder einem oder zwei Arbeitstagen, und müssen von einem zusätzlichen autorisierten Vertreter bestätigt werden.

5. Administrative Konten

Verwaltungseinheiten sind entweder die Europäische Kommission oder eine der zuständigen nationalen Stellen eines EU-Mitgliedsstaates, die das Register innerhalb des EU-ETS verwalten. In den Mitgliedsstaaten sind die zuständigen Stellen für die nationalen Verwaltungskonten an unterschiedlichen Stellen der Verwaltung angesiedelt (z. B. Ministerium, Abteilung oder nationales Amt) und sind im EU-Emissionshandelsregisters (EUTL) in der jeweiligen Landessprache benannt, was die Identifizierung anhand des Kontoinhabernamens erschwert.

Während der Pilotphase des EU-ETS in den Jahren 2005-2007 hatten die europäischen Verwaltungskontoinhaber den Kontoartencode 100 und konnten dadurch leicht als solche identifiziert werden. Seit 2012 wurden neue Kontoarten eingeführt, und nationale Behörden sowie die Europäische Kommission halten nun verschiedene Kontoarten, um verschiedene administrative Prozesse wie die Zuteilung vorzunehmen. Bestimmte Kontoarten dürfen nur von Verwaltungseinheiten gehalten werden (Abbildung 9). Nationale Behörden können jedoch auch freiwillige Konten wie Handelskonten eröffnen, und einige halten sogar regulierte Kontoarten (z. B. hält das deutsche Luftfahrt-Bundesamt ein Luftfahrzeugbetreiberkonto).

4.3 Datenbasis

In diesem Kapitel wird die Datensammlung, sowie die Aufbereitung der Datenbasis beschrieben.

4.3.1 Datensammlung

Die Datensammlung umfasst Transaktionsdaten und Kontoinformationsdaten aus dem Unionsregister. Für die Analyse nutzen wir die öffentlichen Daten, die im EUTL publiziert sind und die von Abrell (2024) heruntergeladen und zur Verfügung gestellt wurden. Das EUTL wird regelmäßig aktualisiert. Wir verwenden für die Analyse die Daten mit der neusten Aktualisierung, die von Abrell im Oktober 2024 veröffentlicht wurden.

Der Datensatz enthält Transaktions- und Kontoinformationen aus den Jahren 2005 bis 2021 (die Daten von 2021 sind noch vorläufig und noch nicht vollständig), daher verwenden wir die Transaktionsdaten nur für den Zeitraum von 2011 bis 2020. Diese Daten umfassen rund 850.350 Transaktionen und ca. 31.000 Konten. Zusätzlich wurde ein Datensatz mit Informationen über die Kontoinhaber importiert. Die beiden Datensätze wurden miteinander über die Konto-ID verknüpft, um einen vollständigen Datensatz zu erhalten. Die Kontoinhaberdatei enthält Informationen zur Adresse des Kontoinhabers und somit auch Angaben zum jeweiligen Land.

Ergänzende Informationen zur Eigentümerstruktur und wirtschaftlichen Aktivität der Akteure lieferte der ORBIS-Datensatz. ORBIS ist eine umfassende, internationale Datenbank, die detaillierte Unternehmensinformationen enthält und Einblicke in die Besitzverhältnisse und Geschäftstätigkeiten von Unternehmen weltweit ermöglicht. Die ORBIS-Daten zur

Eigentümerstruktur der Kontoinhaber wurden mit den bestehenden Kontodaten abgeglichen, um ein vollständiges Bild über die Unternehmensstruktur und die Eigentumsverhältnisse der am Emissionshandel beteiligten Akteure zu erhalten.

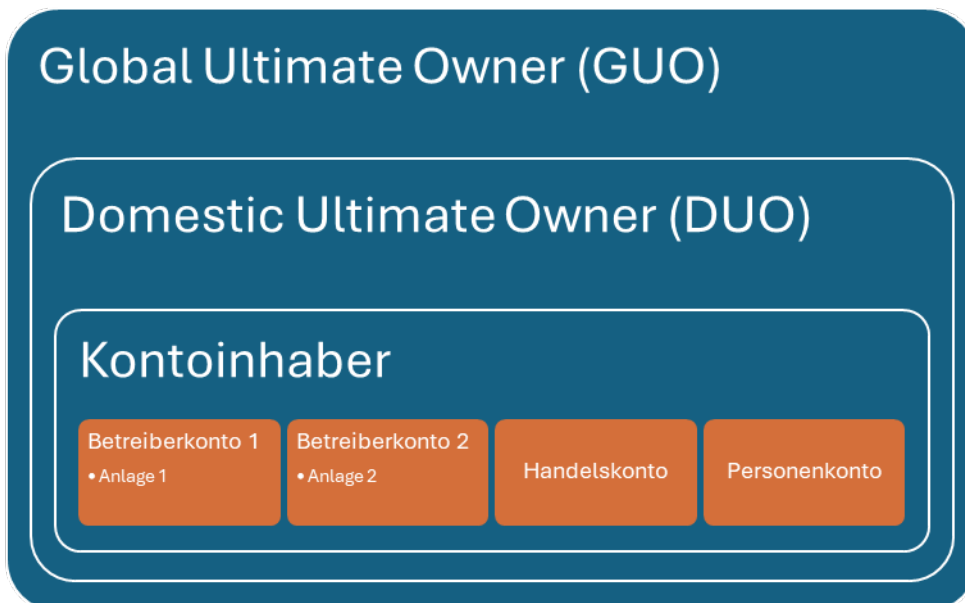
Die Datenaufbereitung für die Analyse der Emissionshandelsdaten des EU-ETS umfasst mehrere Schritte, um die Transaktions- und Kontoinformationen zu bereinigen und zu strukturieren.

4.3.2 Konzernstrukturen im Unionsregister

Ein Kontoinhaber kann mehrere Konten innehaben. Der Kontoinhaber kann einem nationalen oder einem globalen Konzern angehören. Für die Erkennung von potenziellen Geldwäscheaktivitäten wurden interne Transfers zwischen Konten desselben Kontoinhabers von der Analyse ausgeschlossen, da diese keinen Mehrwert bezüglich der Erkennung des Layering erbringen. Die Aggregation erfolgte auf Kontoinhaberebene, so dass interne Bewegungen innerhalb eines Konzerns oder Unternehmens ausgeschlossen werden und nur Transfers berücksichtigt werden, die zwischen unabhängigen Marktteilnehmern erfolgen. Dies verringert das Risiko, dass alltägliche, interne Geschäftstransaktionen fälschlicherweise als potenziell verdächtig eingestuft werden und erhöht damit die Wahrscheinlichkeit ungewöhnliche Aktivitäten aufzudecken.

Auf Basis der unter 4.3.1 beschriebenen Einzeldatensätze wurde ein umfassender Kontodatensatz erstellt, indem die Kontodaten mit Informationen zu Kontotypen und Inhabern kombiniert und mit den ORBIS-Daten ergänzt wurden, um die Besitzverhältnisse auf DUO-Ebene (Domestic Ultimate Owner) abzubilden. In den ORBIS-Daten ist außerdem der GUO (Global Ultimate Owner) enthalten. In Abbildung 10 werden die Strukturen am Beispiel von UNIPER illustriert. Es ist anzunehmen, dass Handelsentscheidungen auf Ebene der DUO getroffen werden, weswegen die Einteilung in interne und externe Transaktionen auf dieser Ebene vorgenommen wird.

Abbildung 10: Eigentumsstruktur bei ORBIS am Beispiel von UNIPER





Quelle: Eigene Darstellung, ZHAW

4.3.3 Datenaufbereitung

Durch die Anreicherung der Transaktionsdaten mit den DUO-Informationen wird sichergestellt, dass in der Analyse nur externe Transaktionen zwischen verschiedenen Konzernstrukturen berücksichtigt werden. Interne Transfers innerhalb derselben DUO-Identität werden von der Analyse ausgeschlossen.

Für die Berechnung der Bestände (Holdings) wurden die Transaktionsdaten sowohl jährlich als auch monatlich aggregiert. In dieser Aggregation wurden Volumen und Häufigkeit von Käufen und Verkäufen pro Jahr und pro Tag pro DUO zusammengefasst. Anhand dieser Daten wurden der Nettobestand (Differenz zwischen erworbenen und verkauften Volumen) sowie die kumulierten Bestände über die Zeit berechnet, um langfristige Muster im Bestandsverhalten der Akteure aufzeigen zu können.

Ein wesentlicher Bestandteil der Datenaufbereitung war der Ausschluss von staatlich kontrollierten Konten und anderen spezifischen Akteuren wie Verifizierenden, da diese die Ergebnisse potenziell verzerren könnten. Um diesen Ausschluss zu erleichtern, wurde für jedes Konto ein Indikator eingeführt, der staatlich kontrollierte Konten kennzeichnet. Der Ausschluss bedeutet jedoch nicht, dass die Transaktionen von staatlich kontrollierten Konten ausgeschlossen werden, denn diese werden wie in Abbildung 11 gezeigt auch für die Berechnung der Holdings benötigt, sondern vielmehr, dass solche Konten nicht als verdächtige Konten identifiziert werden. Zusätzlich zu den Handelsvariablen wurden zeitliche Variablen wie Wochentag, Tag des Monats, Monat, Quartal und Jahr für jede Transaktion berechnet. Diese Variablen ermöglichen es, spezifische zeitliche Muster und Anomalien aufzudecken, die auf auffälliges Verhalten hinweisen könnten.

Um potenziellen MWSt-Betrug auszuschließen, wurden nur Transaktionen ab dem Jahr 2011 in die Analyse mit aufgenommen. Hintergrund dieser Entscheidung ist die Einführung verschärfter Regelungen zur Verhinderung von MWSt-Betrug im Emissionshandel in der EU ab 2010 (ESMA 2022). Durch die Beschränkung auf Transaktionen nach 2011 wurde sichergestellt, dass die analysierten Daten bereits unter den neuen Regulierungen erfasst wurden und somit eine

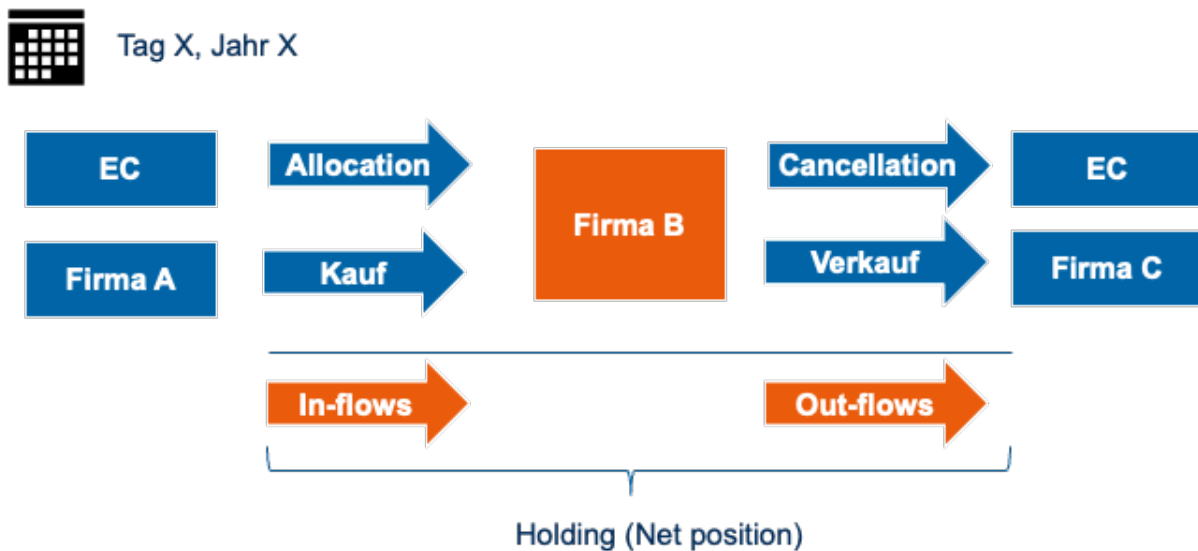
höhere Datensicherheit und Verlässlichkeit im Hinblick auf steuerliche Compliance gewährleistet ist.

Abschließend wurden die Transaktionen sowohl auf jährlicher Ebene als auch auf täglicher Basis aggregiert. Abbildung 11 zeigt die Aggregation der Transaktionen auf täglicher Ebene. Die gesamten In-Flows setzen sich aus der Summe aller an einem Tag getätigten Käufe sowie aus den Emissionsberechtigungen und Zertifikaten zusammen, die einer Firma an diesem Tag zugewiesen wurden (d.h. auch Transaktionen zur Allokation von Emissionsberechtigungen von staatlich kontrollierten Konten). Analog dazu werden die gesamten Out-Flows pro Tag berechnet. Diese umfassen alle Verkäufe sowie administrative Tätigkeiten, die den Bestand an Zertifikaten reduzieren, wie beispielsweise Löschungen.

Die täglichen Holdings, also die Netto-Position jeder Firma, werden als Differenz zwischen In-Flows und Out-Flows berechnet.

Auf Basis des jährlich aggregierten Datensatzes wurden vorbereitende Analysen durchgeführt, während die hier präsentierten Ergebnisse auf Basis des täglich aggregierten Datensatzes generiert wurden. Der täglich aggregierte Datensatz bildet die Grundlage für die weiterführende Analyse der Emissionshandelsaktivitäten und das Erkennen von Auffälligkeiten im Handelsverhalten.

Abbildung 11: Aggregation der Transaktionen auf täglicher Ebene



Quelle: Eigene Darstellung, ZHAW

4.4 Methode

Bei der Erkennung von verdächtigen Handelsmustern spielen die beiden zentralen Metriken **Präzision** und **Sensitivität** eine entscheidende Rolle. **Sensitivität** beschreibt die Fähigkeit des Modells, alle tatsächlichen Verdachtsfälle korrekt zu identifizieren, während **Präzision** angibt, wie viele der als verdächtig markierten Fälle tatsächlich korrekt sind. Im Rahmen dieses Arbeitspakets wird ein unsupervised Ansatz zur Erkennung verdächtiger Handelsmuster angewandt, da keine bekannten Verdachtsfälle als Trainingsdaten vorliegen. Bei Nutzung eines unsupervised-Ansatz sind die Metriken Präzision und Sensitivität schwer direkt messbar, da keine annotierten Daten für die Validierung verfügbar sind. Stattdessen konzentriert sich die Analyse auf die Identifikation von Anomalien, die als potenziell verdächtig eingestuft werden.

Der **Isolation Forest** wurde als Methode gewählt, da er besonders gut für die Erkennung von Anomalien in hochdimensionalen Daten geeignet ist (Daten mit einer großen Anzahl an Variablen/Merkmalen). Der Algorithmus arbeitet, indem er Datenpunkte auf Basis ihrer Isolierbarkeit in zufällig generierten Entscheidungsbäumen bewertet. Anomalien – also seltene und ungewöhnliche Muster – werden schneller isoliert als reguläre Datenpunkte (Liu et al. 2008). Diese Funktionsweise ist effizient, skaliert gut mit großen Datensätzen und erfordert keine Kenntnis spezifischer Muster oder Beispiele für verdächtige Fälle, was ihn ideal für den unsupervised Ansatz macht. Zudem ermöglicht der Isolation Forest eine direkte Steuerung der Ausreißerquote, was ihn flexibel anpassbar macht.

Ein unsupervised Modell wie der Isolation Forest markiert Abweichungen vom normalen Verhalten, was das Risiko von **False Positives** birgt – Fälle, die zwar als verdächtig erscheinen, aber legitim sind. Solche False Positives erfordern eine manuelle Nachprüfung, um sicherzustellen, dass keine unnötigen Maßnahmen ergriffen werden. Auch die Vertreter*innen von Finanzinstitutionen, die im Rahmen der Bachelorarbeit interviewt wurden (Krähenbühl 2023), berichten von False Positives im Rahmen der standardmäßigen Prüfungen, die dann per Hand nachgeprüft werden müssen. In dieser Arbeit wurde darauf hingewiesen, dass bei zu vielen *false positive* Meldungen, welche die Finanzintermediäre und Finanzaufsicht abklären müssen, die Gefahr besteht, dass die Qualität der Kontrollen abnimmt und Geldwäschefälle folglich nicht aufgedeckt werden. Die Generierung von einer hohen Anzahl von *false positive* Meldungen ist daher im Interesse der Geldwäscher, um bewusst die Aufsicht zu überfordern und so unentdeckt Geld zu waschen.

Gleichzeitig ist der unsupervised Ansatz anfällig für **False Negatives**, bei denen tatsächliche Verdachtsfälle übersehen werden, da das Modell keine expliziten Muster von Geldwäsche kennt.

Ohne Trainingsdaten liegt der Schwerpunkt darauf, ein Modell zu entwickeln, das ein breites Spektrum an Anomalien erkennt, um sicherzustellen, dass verdächtige Fälle in nachgelagerten Prozessen geprüft werden können. Dieses Vorgehen ermöglicht es, trotz fehlender Trainingsdaten erste Einblicke in potenziell risikobehaftetes Verhalten zu gewinnen und die Grundlage für zukünftige, datenbasierte Optimierungen zu schaffen.

4.4.1 Indikatoren und Merkmalsauswahl

Im Einklang mit den Ausführungen in Kapitel 4.1 und Tabelle 7, konzentriert sich die Analyse die folgenden Indikatoren, um Abweichungen vom normalen Marktverhalten zu erkennen:

- ▶ Volumina der Käufe und Verkäufe pro Tag
- ▶ Frequenz der Käufe und Verkäufe pro Tag
- ▶ Netto-Handelsposition pro Tag (Holdings)
- ▶ Kumulative Netto-Handelsposition pro Tag (cumulative Holdings)
- ▶ Zertifikattyp
- ▶ Land (Sitz des Kontoinhabers)
- ▶ Jahr
- ▶ Monat
- ▶ Wochentag

► Tag im Monat

Der Datensatz enthält 462.362 Beobachtungen. Eine Beobachtung repräsentiert die Handelsaktivitäten und weiteren Merkmale eines an einem bestimmten Tag aktiven Kontos. Die Gesamtzahl der Beobachtungen entspricht also den aggregierten pro Tag aktiven Konten über die gesamte Beobachtungsperiode 2011 bis 2020.

Die Daten wurden in numerische und kategorische Merkmale unterteilt, wobei numerische Merkmale skaliert und kategorische Merkmale (wie Land und Wochentag) durch One-Hot-Encoding in numerische Variablen umgewandelt wurden.

In einer ersten Analyse, in der die Merkmale noch nicht so stark differenziert wurden und außerdem die Transaktionen pro Jahr und nicht pro Tag aggregiert wurden, ließen sich einige Muster erkennen, mit Hilfe derer die Analyse weiter verfeinert wurde. Dabei wurde z.B. die Analyse von Register auf kontoführendes Land umgestellt, sowie die Wichtigkeit der verschiedenen Kontotypen, insbesondere Luftfahrzeugbetreibern, herausgearbeitet.

Konten, die durch den Isolation Forest Algorithmus als Ausreißer klassifiziert werden, sind durch ungewöhnliche Handelsmuster gekennzeichnet. Beim Isolation Forest Modell wird die Anzahl der Ausreißer vorgegeben. Im vorliegenden Fall wurde die Anzahl auf 5% der Gesamtbeobachtungen gesetzt.

Ein Ausreißer ist eine Beobachtung, die signifikant vom normalen Handelsverhalten abweicht und nicht mit den typischen Mustern übereinstimmt. In dieser Analyse werden die aggregierten Transfers eines Kontos (DUO level falls vorhanden) als Ausreißer markiert, wenn sein Handelsverhalten hinsichtlich Volumina, Frequenz oder zeitlicher Muster auffällige Abweichungen zeigt. Dies kann beispielsweise der Fall sein, wenn ein Konto plötzlich ein ungewöhnlich hohes Handelsvolumen in kurzer Zeit aufweist, unerwartet oft Transaktionen durchführt oder auffällige Handelsaktivitäten zu ungewöhnlichen Zeiten, wie an Wochenenden, aufzeigt. Dabei betrachtet die Analyse nicht einzelne Transaktionen isoliert, sondern die kumulierten Handelsmuster eines Kontos über einen bestimmten Zeitraum hinweg.


4.5 Ergebnisse und Auswertung

In diesem Kapitel werden die Ergebnisse zu den Ausreißern gezeigt und ausgewertet. Wir fokussieren unsere Auswertung auf i) die zeitliche Dimension der Ausreißer, ii) ihre geographische Verteilung und iii) Kontotypen mit hoher Ausreißerquote.

4.5.1 Ausreißer im zeitlichen Ablauf: Monat und Jahr

Besonders handelsintensive Monate sind laut der vorliegenden Analyse der April, gefolgt von März, Februar und Dezember (Abbildung 12). Im April eines jeden Jahres müssen die Zertifikate für die Emissionen des Vorjahres eingereicht werden. Die besonders hohe Aktivität in den Monaten Februar bis April kann somit erklärt werden. Im Dezember werden häufig die Derivate fällig, insbesondere trifft dies auf Futures zu (Cludius und Betz 2020). Die größte Quote an Ausreißern befindet sich allerdings nicht in den handelsintensivsten Monaten, sondern im Juni mit 9,8 % gefolgt von Juli mit 8,5 %. Hier könnte die Vermutung naheliegen, dass in den Ferienzeiten eine geringere Überwachung und Prüfung von Transaktionen erwartet wird.

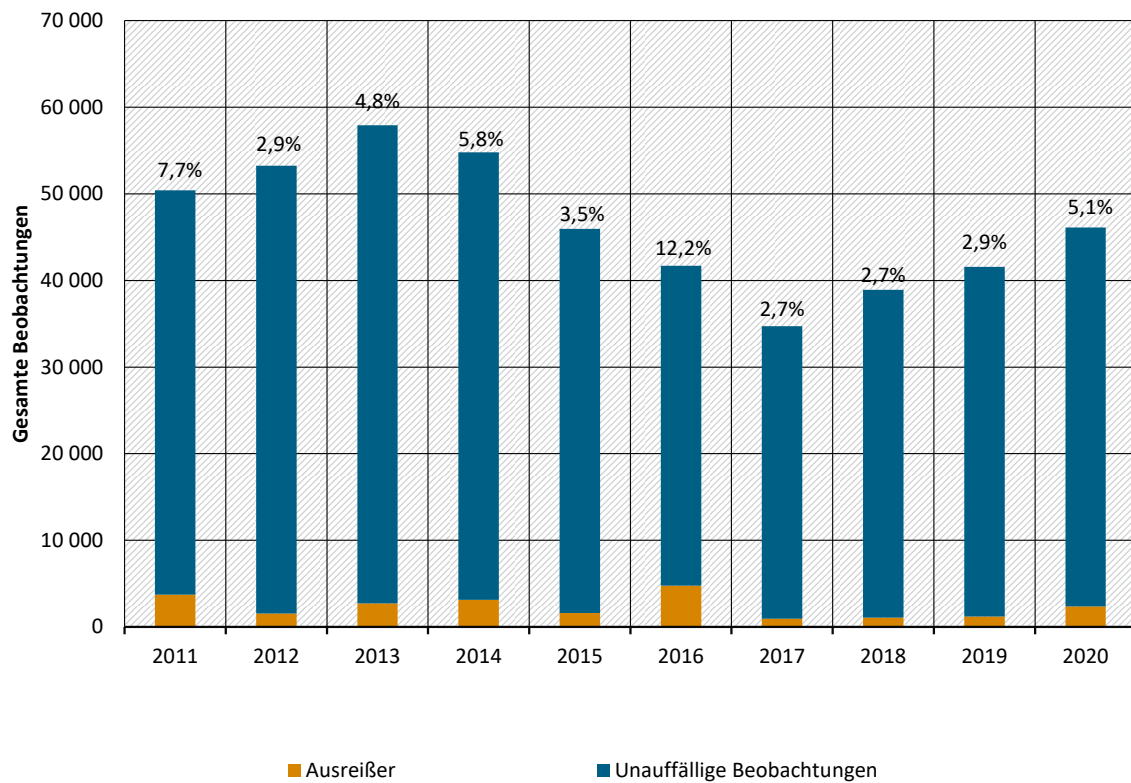
Abbildung 12: Handelsaktivitäten pro Monat, Ausreißer und Ausreißerquote



Anmerkung: Die Prozentangaben über den Balken geben den relativen Anteil der Ausreißer pro Monat an.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

Abbildung 13: Handelsaktivitäten in den Jahren 2011-2020, Ausreißer und Ausreißerquote



Anmerkung: Die Prozentangaben über den Balken geben den relativen Anteil der Ausreißer pro Jahr an.

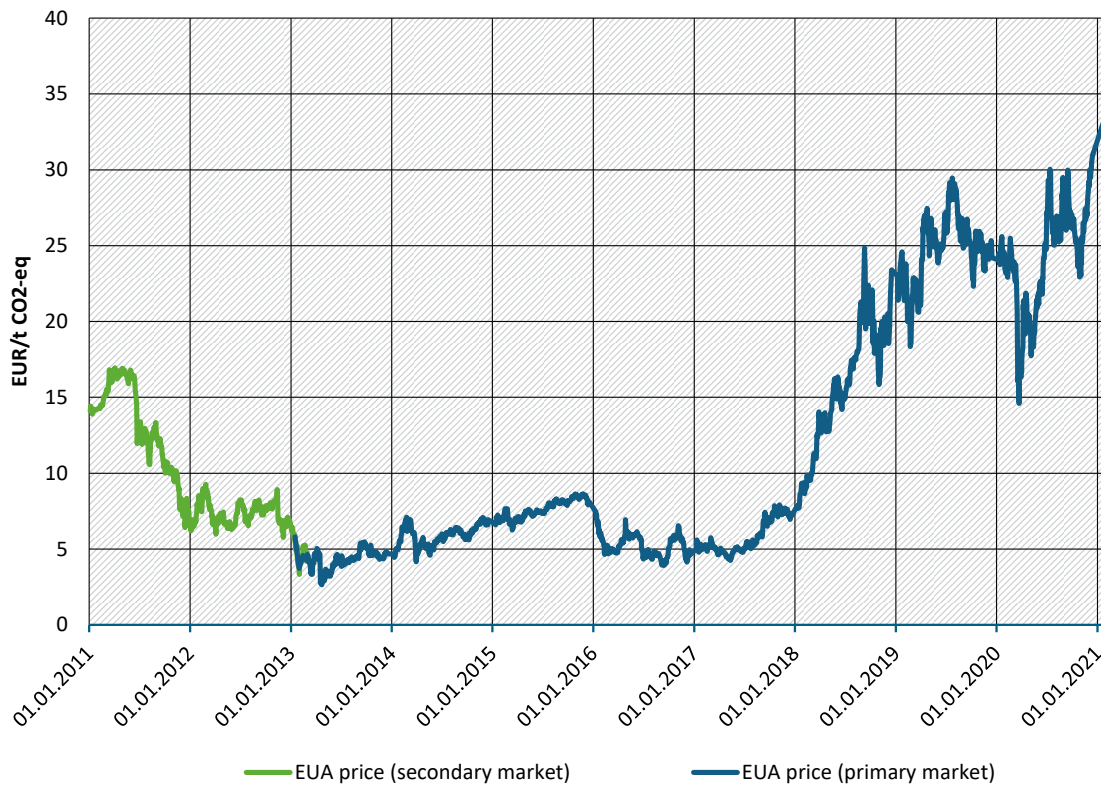
Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

Über den Verlauf unseres Beobachtungszeitraums von 2011 bis 2020, verzeichnen die ersten fünf Jahre (2011-2015) eine größere Anzahl an täglichen Handelsaktivitäten. Der Tiefpunkt der täglichen Handelsaktivitäten ist im Jahr 2017 erreicht. In den Jahren 2018-2020 stieg die Anzahl der täglichen Handelsaktivitäten wieder an. Eine besonders große Anzahl an Ausreißern wird mit 12,2 % im Jahr 2016 ausgewiesen, gefolgt vom Jahr 2011 mit 7,7 %.

Eine Reihe Erklärungsansätze des Verlaufs der Handelsaktivitäten und Ausreißer sind möglich:

- ▶ Der Verlauf der Handelsaktivitäten (Abbildung 13) folgt mit etwas Verzögerung dem Verlauf der EUA bzw. EUAA-Preise (Abbildung 14).
- ▶ Nach dem Brexit-Referendum im Juni 2016 stieg das Transaktionsvolumen der ICE-Futures-Börse in den Niederlanden deutlich an, was in den Daten als Ausreißer erschien.
- ▶ Im Jahr 2011 könnte es noch Fälle von MWSt-Betrug im System gegeben haben. Laut des Europäischen Rechnungshofs hatten 2015 noch ein Drittel der Mitgliedsländer das Reverse-Charge Verfahren für die MWSt nicht umgesetzt, speziell in Italien wurde dieses Risiko noch als substantiell angesehen (European Court of Auditors, 2015).

Abbildung 14: Preisverlauf EUAs und EUAAs 2011-2020




Quelle: Point Carbon (2012), EEX (2024), ICE (2021)

4.5.2 Geografische Verteilung der Ausreißer

Zur Bestimmung der geographischen Verteilung der Ausreißer stellen wir auf die Adresse der Kontoinhaber ab und nicht auf das Register, in dem sie ihr Konto eröffnet haben. Deshalb sind in Abbildung 15 viele weitere Länder vertreten, die nicht Teil des EU-ETS sind. Die meisten Transaktionen verzeichnen Teilnehmende mit deutschen, britischen, spanischen und italienischen Adressen. Abbildung 16 zeigt nur den Anteil der Ausreißer pro Land, beginnend mit dem Land, das die größten Anteile an Ausreißern aufweist. Die Liste wird angeführt von Venezuela, gefolgt von Norwegen und den USA. Venezuela wird von FATF (2024) als eines der Länder mit erhöhtem Risiko aufgeführt, das daher unter besonderer Beobachtung steht.


Abbildung 15: Anzahl Beobachtungen und Ausreißer in den Top-30 Ländern mit den meisten Ausreißern



Anmerkung: Die gesamte Liste der Länder über die Top-30 hinaus ist in Anhang C zu finden.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

Abbildung 16: Ausreißerquote in den Top-30 Ländern mit der höchsten Ausreißerquote



Anmerkung: Die gesamte Liste der Länder über die Top-30 hinaus ist in Anhang C zu finden.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

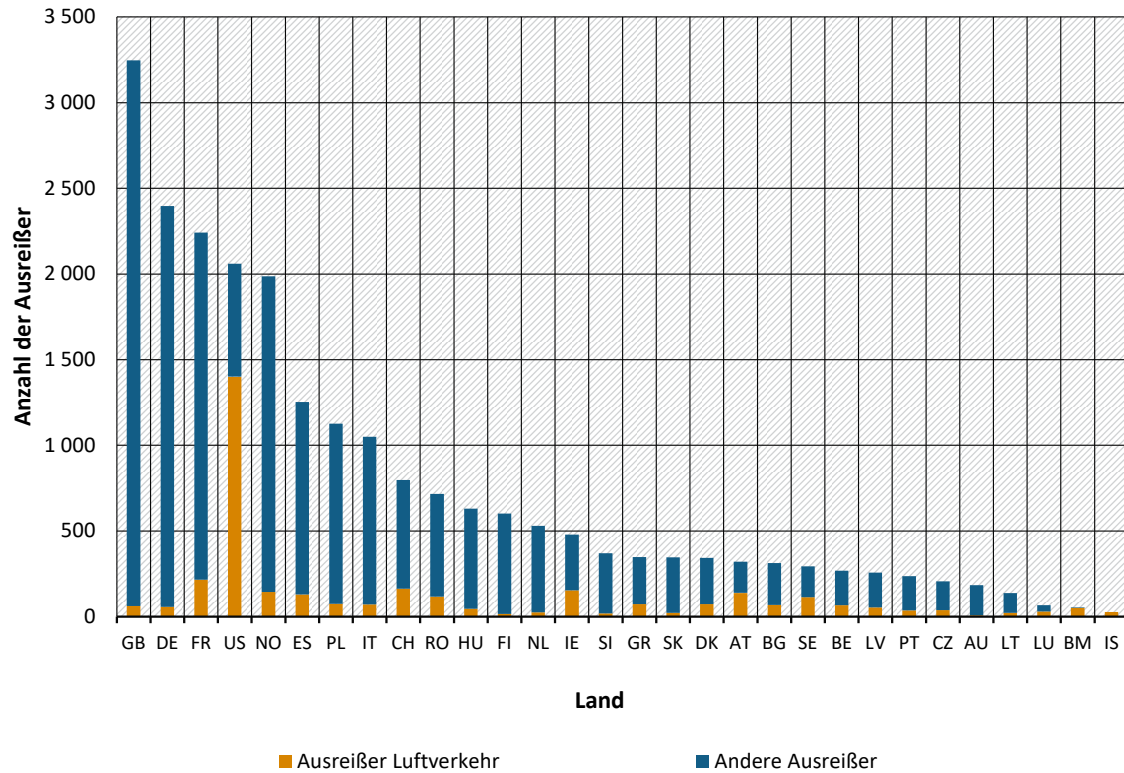
4.5.3 Fokus auf Luftfahrzeugbetreiber

In diesem Kapitel legen wir den Fokus auf die Luftfahrzeugbetreiber und zeigen die Anzahl der Ausreißer nach Land und dabei die Aufteilung auf Luftfahrzeugbetreiber und andere Marktteilnehmer*innen (Abbildung 17). Zum Vergleich sind in Abbildung 18 alle Beobachtungen pro Land und ihre Aufteilung in die Kontotypen dargestellt. Dabei wird deutlich, dass die Luftfahrzeugbetreiber eine erhöhte Anzahl an Ausreißern aufweisen. In Abbildung 19 wird die gleiche Analyse nach Register durchgeführt.

Die Ergebnisse werden durch die Aufstellung in Abbildung 20 bestätigt: Fast 25 % der Transaktionen durch Luftfahrzeugbetreiber im Beobachtungszeitraum werden als Ausreißer eingestuft.

Luftfahrzeugbetreiber fallen dabei durch besonders hohe Handelsvolumina oder ungewöhnliche Handelsfrequenzen auf. Die hohe Handelsaktivität dieser Kontotypen könnte auf spezifische Handelsstrategien, regulatorische Besonderheiten oder – im Extremfall – auf Strategien zur Marktmanipulation oder Geldwäsche hindeuten. Dies kann nur in einer Einzelprüfung herausgearbeitet werden, die auf unsere Art der automatisierten Prüfung folgen würde.

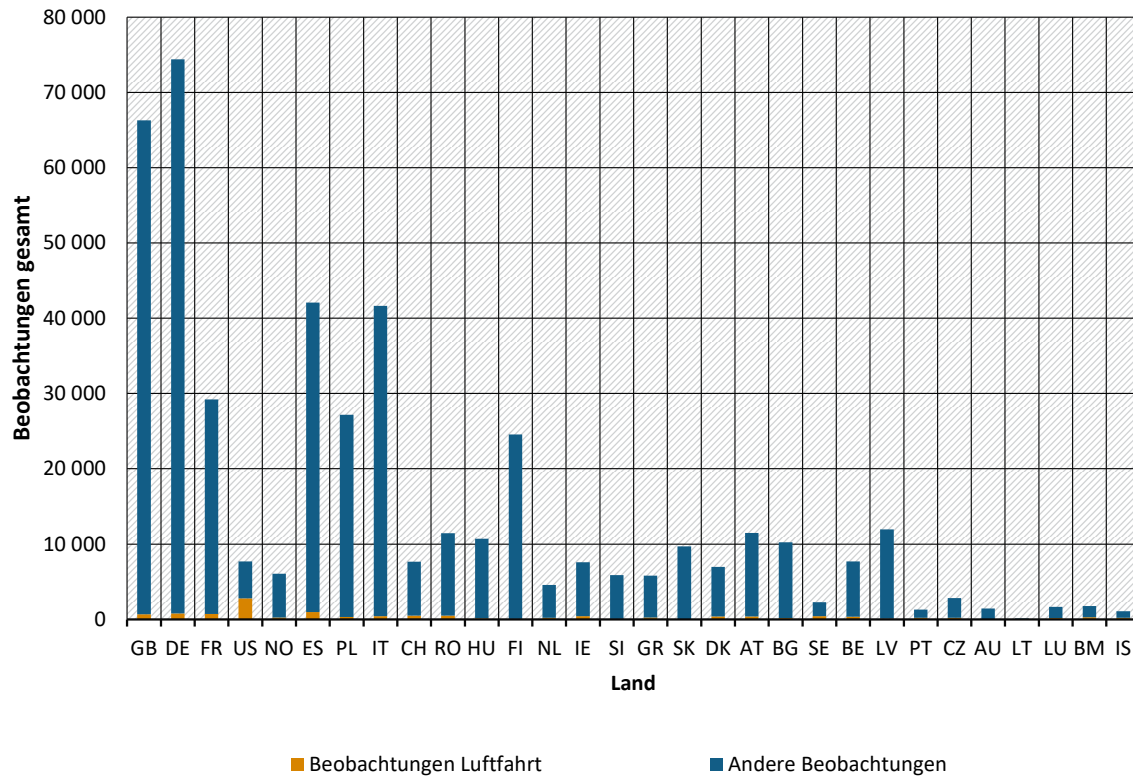
Abbildung 17: Anzahl der Ausreißer nach Land des Kontoinhabers und Anteil in den Top-30 Ländern mit den meisten Ausreißern



Anmerkung: Die gesamte Liste der Länder über die Top-30 hinaus ist in Anhang C zu finden.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

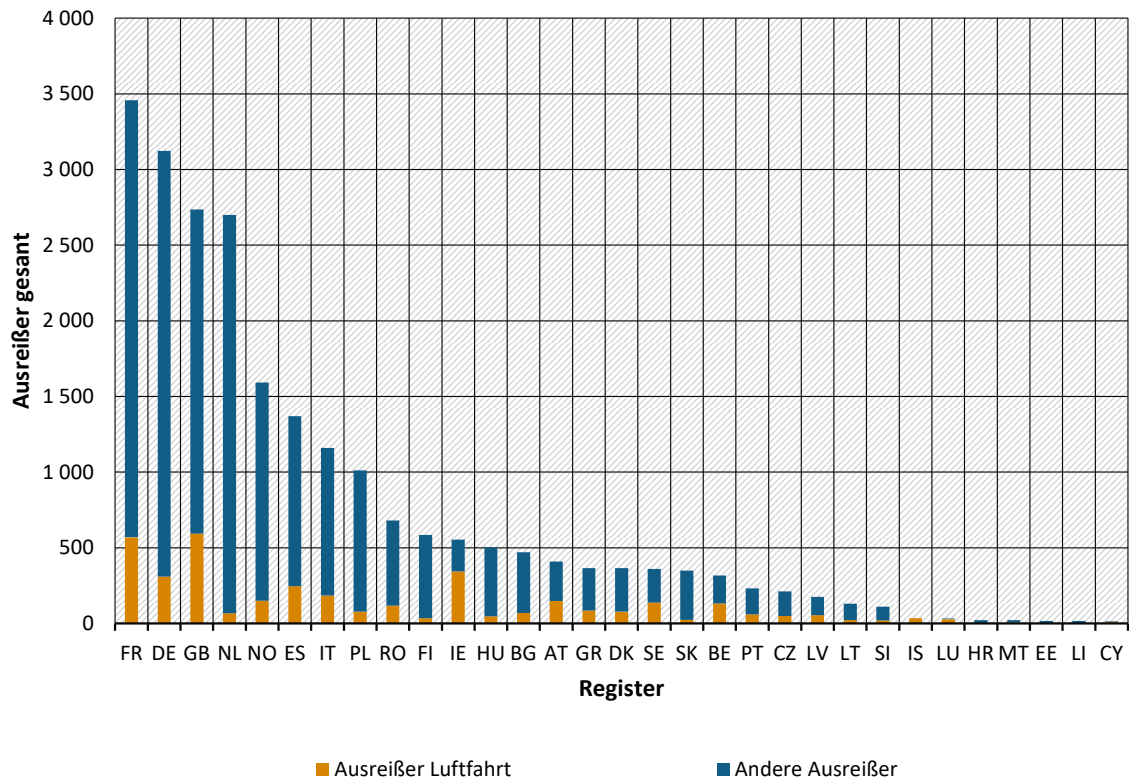
Abbildung 18: Anzahl der Beobachtungen nach Land und Luftfahrzeugbetreiber in den Top-30 Ländern mit den meisten Ausreißern



Anmerkung: Die gesamte Liste der Länder über die Top-30 hinaus ist in Anhang C zu finden.

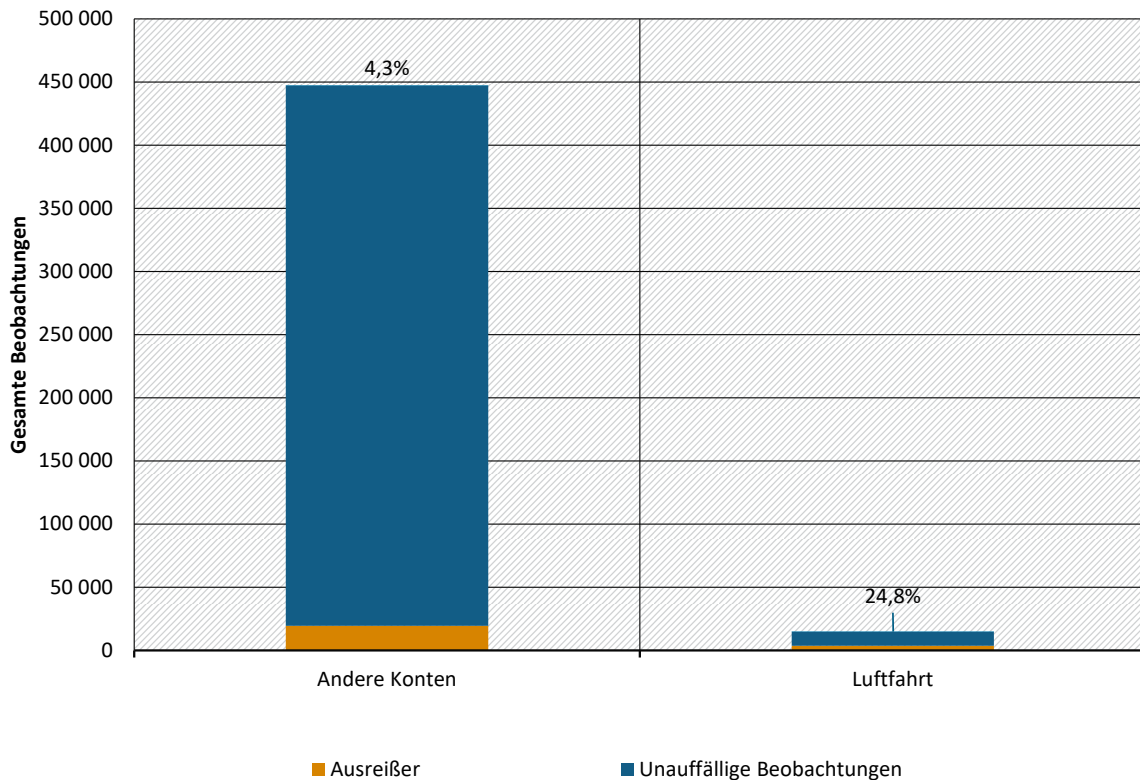
Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

Abbildung 19: Anzahl der Ausreißer nach Register und Anteil Luftfahrzeugbetreiber



Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

Abbildung 20: Anzahl der Beobachtungen und Ausreißer für Luftfahrzeugbetreiber und andere regulierte Kontotypen



Anmerkung: Die Prozentangaben über den Balken (4,3% bzw. 24,8%) geben den relativen Anteil der Ausreißer pro Gruppe an.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

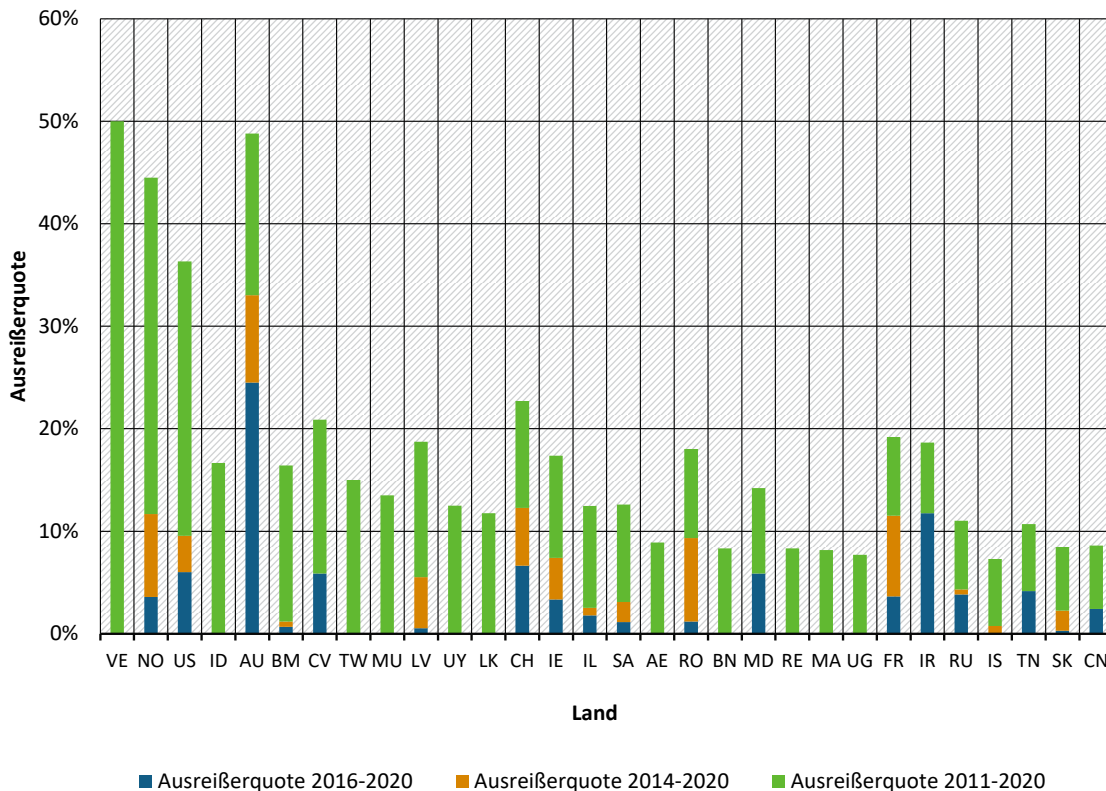
Abbildung 25 zeigt, dass Luftfahrzeugbetreiber nur einen kleinen Anteil am Handel im EU-ETS ausmachen. Allerdings ist der Anteil an Ausreißern in dieser Gruppe besonders hoch – fast ein Viertel der Beobachtungen. Ein Grund, weshalb Luftfahrzeugbetreiber so prominent vertreten sind, könnte der Umstand sein, dass der Flugverkehr erst ab dem Jahr 2012 am EU-ETS teilnimmt. Im Jahr 2012 wurde außerdem im November 2012 rückwirkend durch die ‚stop-the-clock‘ Entscheidung, der Scope des teilnehmenden Luftverkehrs verändert, d.h. bereits für 2012 mussten nur noch für innereuropäische Flüge Emissionszertifikate eingereicht werden, für internationale Flüge wurde die Abgabe von Zertifikaten gestoppt (EC 2012).

Um zu überprüfen, ob die Auswertung anderer Beobachtungszeiträume andere Ergebnisse liefert, zeigt Abbildung 21 den Anteil der Ausreißer an den gesamten Beobachtungen pro Land für drei verschiedene Zeiträume: 2011-2020, 2014-2020 und 2016-2020. Es wird deutlich, dass einige Länder mit besonders hohen Anteilen an Ausreißern im 2011-2020-Beobachtungszeitraum in den weiteren Zeiträumen **keinerlei** Ausreißer mehr aufweisen. Dies trifft z.B. auf Venezuela, Indonesien, Uruguay und Sri Lanka zu. Es ist gut möglich, dass diese Länder nach der ‚stop-the-clock‘ Entscheidung mit ihren Fluggesellschaften nicht mehr am EU-ETS teilgenommen haben.

Andere Länder haben in den alternativen Beobachtungszeiträumen **viel niedrigere Anteile** an Ausreißern als im Basis-Beobachtungszeitraum. Dazu gehört z.B. Norwegen, die USA, die Bermudas, Cap Verde und Lettland.

Weitere Länder, wie Österreich, Ungarn, Singapur und Slowenien weisen in den weiteren Zeiträumen größere Anteile an Ausreißern auf als im Original-Beobachtungszeitraum. Während Mutmaßungen zu dieser Dynamik angestellt werden können, wären diese Verschiebungen im Rahmen von weiteren, tiefergehenden Analysen der ermittelten Ausreißer zu untersuchen.

Abbildung 21: Vergleich der Ausreißer-Anteile in drei verschiedenen Zeiträumen für die Top-30 Länder mit höchster Ausreißerquote 2011-2020



Anmerkung: Die gesamte Liste der Länder über die Top-30 hinaus ist in Anhang C zu finden.

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

4.6 Zusammenfassung und Fazit

Ziel dieses Arbeitspakets war es, den Nutzen eines ML-Ansatzes in Bezug auf die Erkennung von Geldwäsche durch Identifizierung auffälliger Transaktionen im Unionsregister auszuloten, geeignete Algorithmen anzuwenden und konkrete Analysen durchzuführen. Dadurch sollten bestehende Merkmalslisten zur Erkennung eines erhöhten Geldwäscherisikos ergänzt werden und Algorithmen zur Erkennung von ungewöhnlichen Transaktionen weiterentwickelt werden.

In der Literatur werden drei Stufen der Geldwäsche benannt: Placement, Layering und Integration. Während die Literatur aufzeigt, dass das Placement den wichtigsten Schritt bei der Erkennung von Geldwäsche darstellt, sind die für die Analyse verwendeten Register-Transaktionsdaten nicht geeignet diesen Schritt zu untersuchen. Dazu wären weitere Angaben im Register notwendig, etwa zum Geschäftszweck der Handelnden, zu den dahinterliegenden Geldflüssen oder zu verwendeten Zahlungsmitteln. Aus diesem Grund konzentriert sich die ML-gestützte Datenanalyse auf den Schritt des Layerings und lotet Möglichkeiten für die

automatisierte Untersuchung der Registerdaten aus, die der regulierenden Behörde Hinweise auf Fälle liefert, welche einer weiteren Prüfung bedürfen.

Im Rahmen der bestehenden Analyse konnten weder Verdachts- noch bestätigte Fälle zum Training der KI verwendet werden. Die Güte der Identifikationsstrategie könnte mit Hilfe eines solchen Trainingsdatensatzes deutlich verbessert werden, da die KI weniger auf manuellen Vorgaben operieren würde, sondern vielmehr die Muster des Trainingsdatensatzes anwenden könnte.

Die ML-gestützte Analyse beruht auf öffentlich verfügbaren Transaktions- und Kontodaten des EU-Emissionshandelsregisters (EUTL) der Jahre 2011-2020. Diese Daten werden mit Informationen zu Besitzstrukturen auf Basis des ORBIS-Datensatzes angereichert und auf die Ebene des Domestic Ultimate Owner (DUO) aggregiert, um eine umfassendere und effektivere Analyse durchführen zu können. Als Methode wird der Isolation Forest angewandt. Bei der Bestimmung geeigneter Indikatoren und Merkmale wird auf die bestehenden Erkenntnisse zum Geldwäscherisiko im EU-ETS zurückgegriffen.

Hauptergebnis der Analyse ist die Identifikation von Ausreißern, welche mit Hilfe des Isolation Forest als auffällige Transaktionen identifiziert werden. Diese Ausreißer werden im vorliegenden Bericht nach ihrer zeitlichen und geographischen Dimension aufgeführt und separat für verschiedene Kontotypen analysiert. Das Jahr 2016 sticht mit einem hohen Anteil Ausreißern im Zeitverlauf besonders hervor. In einigen Fällen lassen sich Ausreißer durch externe Ereignisse erklären, beispielsweise war 2016 das Jahr des Brexits-Referendums, was Verschiebungen in der Nutzung europäischer Börsen nach sich zog.

Bei der Betrachtung der geographischen Verteilung der Ausreißer stechen insbesondere nicht-EU Länder hervor, darunter Venezuela, Norwegen und die USA. Dies sind jeweils die Länder, in denen der identifizierte DUO ansässig ist. Luftfahrzeugbetreiber sind viel häufiger auffällig als andere regulierte Sektoren. Bei Norwegen kann dabei der verspätete Start der Handelsaktivitäten nach Eintritt in den EU ETS ein Grund sein, bei Luftfahrzeugbetreibern die Aufnahme des Flugverkehrs im Jahr 2012 und die ‚stop-the-clock‘ Entscheidung im gleichen Jahr. Eine Analyse anderer Beobachtungszeiträume (2014-2020 und 2016-2020) deutet darauf hin, dass zumindest ein Teil der Ausreißer auf diese Faktoren zurückzuführen sein können, allerdings bleiben die Luftfahrzeugbetreiber und bestimmte Länder auch in den anderen Zeiträumen auffällig.

Neben Veränderungen im betrachteten Zeitraum zeigen auch weitere Sensitivitätsanalysen, dass die Zahl und Verteilung der Ausreißer deutlich variiert, je nachdem welche Variablenkombinationen untersucht werden oder welche Beobachtungen aus der Analyse ausgeschlossen werden. Die hier vorgestellte Analyse kann also nicht abschließend beantworten, welche Handelsmuster auf Geldwäscherisiko hinweisen, liefert aber wertvolle Ansatzpunkte, die nun einer weitergehenden Verifizierung bedürfen. Eine umfassendere Überprüfung wäre insbesondere durch Emissionsregulierungs- oder Geldwäscheaufsichtsbehörden erforderlich, um die als Ausreißer identifizierten Fälle gezielt zu untersuchen. Ein erster Schritt wäre über eine Internetrecherche zu den auffälligen Konten die Geschäftszwecke zu ermitteln, um die Relevanz der Teilnahme am Emissionshandel abzuklären. Die durch eine manuelle Überprüfung als unbedenklich eingestuft Fälle können von der Analyse ausgeschlossen werden, wodurch die Identifikation tatsächlicher Ausreißer weiter verfeinert werden kann. Dieser iterative Prozess kann in einem fortlaufenden „Back-and-Forth“-Verfahren stetig verbessert werden. Am Ende des iterativen Prozesses könnte damit ein Trainingsdatensatz generiert werden, der die ML-gestützte Vorprüfung, soweit verbessert, dass die Anzahl der false positives reduziert wird.

Ergänzende Datenanalysen oder qualitative Bewertungen – beispielsweise durch die Einbeziehung zusätzlicher Transaktionsdetails oder Hintergrundinformationen zu den betroffenen Händlern – könnten die Validierung der Ergebnisse weiter unterstützen. Zudem könnte eine engere Zusammenarbeit mit den zuständigen Aufsichtsbehörden dazu beitragen, die Relevanz der identifizierten Auffälligkeiten besser einzuordnen und gezielte Maßnahmen abzuleiten. Die im Rahmen der Bachelorarbeit von Krähenbühl (2023) geführten Interviews mit Experten aus der Finanzbranche haben außerdem gezeigt, dass es sich neben einer automatisierten Transaktionsanalyse lohnen könnte, die von der FATF geführte schwarze und graue Liste für Länder mit höheren Risiken für Geldwäschereiaktivitäten und Terrorismusfinanzierung heranzuziehen und auf den Datensatz anzuwenden. Die befragten Expert*innen geben außerdem an, dass Transaktionsanalysetools teuer sind und schnell veralten und daher von ihnen auch andere Informationsquellen genutzt werden, wie Hinweise von verschiedenen Behörden (z.B. Finanzaufsicht, Interpol) oder aus Medien, um auffällige Personen zu identifizieren. In diesem Fall können die Transaktionsanalysetools genutzt werden, um gezielt bei den verdächtigen Personen die Transaktionsauffälligkeiten zu identifizieren.

5 Schlussfolgerungen

Ziel dieses Projektes war, den Nutzen der Künstlichen Intelligenz (KI) in Bezug auf die Prüfung von Anträgen und fachlichen Entscheidungen sowie die die Erkennung kriminellen Handelns unterschiedlicher Aktivitäten innerhalb des deutschen Teils des EU-Emissionshandelsregisters auszuloten, geeignete Algorithmen zu entwickeln und konkrete Analysen durchzuführen.

Vorteile des Einsatzes von KI in Bezug auf automatisierte Prüfung und Betrugserkennung im Register

Die Anwendung von KI auf Register- und Transaktionsdaten kann automatisierte Hinweise im Sinne eines Frühwarnsystems geben, welche dann als Verdachtsfälle an die relevanten Behörden weitergegeben werden können. Sie kann helfen Ressourcen effizienter einzusetzen oder für andere Bereiche verfügbar zu machen. Wichtig ist dabei, einerseits eine effektive Identifikation der Verdachtsfälle zu gewährleisten und andererseits die Anzahl der gemeldeten Verdachtsfälle auf ein handhabbares Maß zu begrenzen, so dass eine weitergehende Prüfung aller Verdachtsfälle möglich ist.

Grenzen der KI in Bezug auf automatisierte Prüfung und Geldwäscheerkennung im Register

Sowohl bei der automatisierten Prüfung von Anträgen zur Kontoeröffnung als auch von fachlichen Verwaltungsentscheidungen konnten verschiedene „Machine Learning (ML)“-Ansätze auf dem existierenden Datensatz trainiert werden. In beiden Fragestellungen erzeugten Neuronale Netze die besten Ergebnisse. Durch den relativ kleinen Trainingsdatensatz und insbesondere die sehr wenigen fehlerhaften Datensätze konnte die Fehlerrate allerdings nicht unter 10 % reduziert werden. Die Anzahl der *false positives* wäre entsprechend sehr hoch, so dass ein direkter Einsatz zur Prüfung nicht geeignet erscheint. Machine Learning kann unter den gegebenen Bedingungen eventuell genutzt werden, um einzelne Felder zu identifizieren, die einen hohen Einfluss auf die Kategorisierung haben. Dies kann aber aktuell höchstens dafür genutzt werden, die regelbasierten aktuellen Ansätze in der DEHSt zu verbessern. Diese regelbasierte Klassifikation auf Basis des Expertenwissens liefert nachvollziehbare und gut begründbare Ergebnisse.

Die ML-gestützte Analyse der Unionsregisterdaten zur Identifizierung Geldwäsche-relevanter Verdachtsfälle liefert eine Reihe von Merkmalen (etwa Land des Betreibers, Kontotyp) und Muster, die die automatisierte Erkennung von Verdachtsfällen unterstützen. Allerdings stand für die Analyse kein Trainingsdatensatz von Geldwäschefällen oder -verdachtsfällen zur Verfügung, so dass eine Reihe händischer Vorgaben für die Analyse gemacht werden musste. Auch musste der Anteil der zu identifizierenden Ausreißer exogen vorgegeben werden. Die Ergebnisse der Analyse reagierten sensibel auf die verschiedenen Vorgaben zu analysiertem Zeitraum, Variablenkombinationen und ausgeschlossenen Beobachtungen, so dass die vorliegende Analyse zwar wertvolle Ansatzpunkte liefert, diese nun aber einer weitergehenden Verifizierung bedürfen.

Zentrale Ziele einer effizienten automatisierten Vorprüfung sind i) die zuverlässige Identifizierung auffälliger Transaktionen und ii) die Begrenzung der Anzahl der identifizierten Fälle auf ein handhabbares Maß. Diese Ziele sind in der vorliegenden Analyse und in Ermangelung eines Trainingsdatensatzes nicht abschließend erreichbar. Auch aus der Finanzbranche ist bekannt, dass die oft hohe Anzahl von *false positives* aus Transaktionsanalysetools ihren Nutzen im Sinne einer Vorprüfung beschränken kann. Deshalb wird in der Finanzbranche die Analyse der Transaktionsdaten nicht nur als Vorprüfung genutzt, sondern um Transaktionen auffälliger Personen und Unternehmen, die mit Hilfe anderer Informationsquellen (z.B. Finanzaufsicht, Interpol, Medien) identifiziert werden, zu überprüfen.

Des Weiteren gilt in Bezug auf Geldwäsche der Schritt des Placements, also die Integration illegal erworbener Vermögenswerte ins Finanzsystem, als wichtigster für die Erkennung der Geldwäsche. Dieser Schritt der Geldwäsche kann allerdings mit der vorliegenden Analyse öffentlich verfügbarer Registerdaten nicht überprüft werden, die sich auf die Stufe des Layerings bezieht. Dies zeigt, dass die automatisierte Prüfung von Registerdaten nur einen Teil des Problems der Geldwäsche erkennen und adressieren kann.

6 Quellenverzeichnis

Abrell, J. (2024): Database for the European Union Transaction Log. Online verfügbar unter: www.euets.info, zuletzt geprüft am 06.10.2025.

Bongard, K. (2001): Wirtschaftsfaktor Geldwäsche, Analyse und Bekämpfung (DUV Wirtschaftswissenschaft Ser). Wiesbaden: Deutscher Universitäts Verlag. Online verfügbar unter <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=6295652>.

Bussmann, K.-D. (2020): Erkennung von Geldwäsche im Emissionshandel, Abschlussbericht (Texte, 19/2020). Umwelt Bundesamt (Hg.). Online verfügbar unter <https://www.umweltbundesamt.de/publikationen/erkennung-von-geldwaesche-im-emissionshandel>, zuletzt geprüft am 28.11.2024.

Cludius, J.; Betz, R. (2020): The Role of Banks in EU Emissions Trading. In: The Energy Journal 41 (2), S. 275–299. Online verfügbar unter <https://www.jstor.org/stable/26902806>, zuletzt geprüft am 28.11.2024.

DEHSt - Deutsche Emissionshandelsstelle (2022a): Deutsche Versteigerungen von Emissionsberechtigungen, Auktionierung (EU-ETS) August 2022. Online verfügbar unter https://www.dehst.de/SharedDocs/downloads/DE/versteigerung/2022/2022_Bericht_08.pdf?__blob=publicationFile&v=2, zuletzt geprüft am 05.09.2023.

DEHSt - Deutsche Emissionshandelsstelle (2022b): Treibhausgasemissionen 2021, Emissionshandelspflichtige stationäre Anlagen und Luftverkehr in Deutschland (VET-Bericht 2021). Online verfügbar unter https://www.dehst.de/SharedDocs/downloads/DE/publikationen/VET-Bericht-2021.pdf?__blob=publicationFile&v=6, zuletzt geprüft am 05.09.2023.

EEX - European Energy Exchange (2024): EUA Primary Market Auction Report, European Energy Exchange. Online verfügbar unter <https://www.eex.com/de/marktdaten/umweltprodukte/eex-eua-primary-auction-spot-download>, zuletzt geprüft am 27.08.2024.

ESMA - European Securities and Markets Authority (2015): ESMA's technical advice on possible delegated acts concerning the Market Abuse Regulation; <https://www.esma.europa.eu/sites/default/files/library/2015/11/2015-224.pdf>, zuletzt geprüft am 06.10.2025.

ESMA - European Securities and Markets Authority (2022): Emission allowances and associated derivatives, Final report (ESMA 70-445-38). Online verfügbar unter https://www.esma.europa.eu/sites/default/files/library/esma70-445-38_final_report_on_emission_allowances_and_associated_derivatives.pdf, zuletzt geprüft am 28.11.2024.

European Court of Auditors (2015) The integrity and implementation of the EU ETS; https://www.eca.europa.eu/lists/ecadocuments/sr15_06/sr15_06_en.pdf, zuletzt geprüft am 06.10.2025.

EC - European Commission (2012): Stopping the clock of ETS and aviation emissions following last week's International Civil Aviation Organisation (ICAO) Council; https://ec.europa.eu/commission/presscorner/detail/fr/memo_12_854https://ec.europa.eu/commission/presscorner/detail/fr/memo_12_854, zuletzt geprüft am 06.10.2025.

EC - European Commission (2018): Report on the functioning of the European carbon market, COM(2018) 842 final; https://climate.ec.europa.eu/system/files/2018-12/com_2018_842_final_en.pdf, zuletzt geprüft am 06.10.2025.

FATF - Financial Action Task Force (2024): <https://www.fatf-gafi.org/en/publications/High-risk-and-other-monitored-jurisdictions/increased-monitoring-october-2024.html>, zuletzt geprüft am 06.10.2025.

ICE - Intercontinental Exchange (2021): Auctions - EUA UK, Market Data, Intercontinental Exchange. Online verfügbar unter <https://www.theice.com/marketdata/reports/148>, zuletzt geprüft am 14.07.2021.

Krähenbühl, M. (2023): Wie lässt sich Geldwäscherei erkennen?, Eine Analyse der von Schweizer Finanzintermediären angewandten Handlungspraktiken zur Erkennung und Prävention von Geldwäscherei. Bachelorarbeit, betreut von Regina Betz, ZHAW. Winterthur, 2023.

F. T. Liu, K. M. Ting and Z. -H. Zhou, (2008): "Isolation Forest," 2008 Eighth IEEE International Conference on Data Mining, Pisa, Italy, 2008, pp. 413-422, doi: 10.1109/ICDM.2008.17

Marcu, A.; Lopez Hernandez, J. F.; Alberola, E.; Fare, A.; Qin, B.; O'Neill, M.; Schleicher, S.; Caneill, J.; Bonfiglio, E.; Vollmer, A. (2022): 2022 State of the EU ETS Report. ERCST; BloombergNEF; Wegener Center, Ecoact. Online verfügbar unter <https://ercst.org/state-of-the-eu-ets-report-2022/>, zuletzt geprüft am 05.09.2023.

Pedregosa F.; Varoquaux, G.; Gramfort A.; Michel, V.; Thirion, B.; Grisel O.; Blondel M.; Prettenhofer P.; Weiss, R.; Dubourg, V.; Vanderplas, J.; Passos, A.; Cournapeau, D.; Brucher, M.; Perrot, M., Duchesnay, E. (2011): Scikit-learn: Machine Learning in Python. In: Journal of Machine Learning Research 12 (85), S. 2825-2830.

Point Carbon (2012): Carbon Project Manager. Point Carbon. Online verfügbar unter <http://www.pointcarbon.com/trading/>.

A Datenschema AP 1

Tabelle 8: Anhangstabelle zum Datenschema

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
ACCOUNT_CREATION_REQUEST_ID	integer	1716	1.000	0.997
ACCOUNT_CREATION_REQUEST_ID	integer	1716	1.000	0.352
AR_URID	text	2333	1.000	0.479
AR_FIRST_NAME	text	784	1.000	0.161
AR_LAST_NAME	text	1785	1.000	0.366
AR_ROLE	text	7	1.000	0.001
AR_CONTACT_ADDRESS_LINE_1	text	1333	1.000	0.274
AR_CONTACT_POST_CODE	text	884	1.000	0.181
AR_CONTACT_CITY	text	625	1.000	0.128
AR_CONTACT_COUNTRY	text	40	1.000	0.008
AR_CONTACT_PHONE_NUMBER_1	text	2224	1.000	0.456
AR_CONTACT_PHONE_NUMBER_2	text	2193	1.000	0.450
AR_CONTACT_EMAIL_ADDRESS	text	2181	1.000	0.448
REQUEST_IDENTIFIER	integer	1716	1.000	0.890
REQUEST_DATE	text	1716	1.000	0.890
REGISTRY_CODE	text	1	1.000	0.001
REQUEST_STATUS	text	4	1.000	0.002
ACCOUNT_NUMBER	text	1716	1.000	0.890
ACCOUNT_NAME	text	1536	1.000	0.796
ACCOUNT_EU_ACCOUNT_TYPE	text	9	1.000	0.005
ACCOUNT_KYOTO_ACCOUNT_TYPE	text	6	1.000	0.003
ACCOUNT_COMMITMENT_PERIOD_CODE	integer	3	1.000	0.002
ACCOUNT_GROUP_NAME	text	8	1.000	0.004
AH_NAME	text	1113	1.000	0.577
AH_TYPE	text	2	1.000	0.001

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
AH_IDENTIFIER	integer	1286	1.000	0.667
AH_CONTACT_ADDRESS_LINE_1	text	1029	1.000	0.533
AH_CONTACT_POST_CODE	text	797	1.000	0.413
AH_CONTACT_CITY	text	538	1.000	0.279
AH_CONTACT_COUNTRY	text	40	1.000	0.021
AH_CONTACT_PHONE_NUMBER_1	text	1076	1.000	0.558
AH_CONTACT_PHONE_NUMBER_2	text	1094	1.000	0.567
AH_CONTACT_EMAIL_ADDRESS	text	1029	1.000	0.533
TAL_TWO_EYES_PRINCIPLE_ALLOWED	integer	2	1.000	0.001
OUTSIDE_TAL_ALLOWED	integer	2	1.000	0.001
AH_COMPANY_REGISTRATION_NUMBER	text	1056	0.962	0.547
REQUESTOR	text	775	0.799	0.402
AR_EMPLOYER_NAME	text	1092	0.797	0.224
AH_VAT_NUMBER	text	727	0.732	0.377
APPROVER	text	51	0.665	0.026
AR_DEPARTMENT_OF_THE_EMPLOYER	text	705	0.510	0.145
AH_PREFERRED_LANGUAGE	text	2	0.425	0.001
AR_CONTACT_ADDRESS_LINE_2	text	495	0.415	0.102
INSTALLATION_FIRST_YEAR_OF_VERIFICATION	float	12	0.368	0.006
INSTALLATION_NAME	text	616	0.368	0.319
INSTALLATION_IDENTIFIER	float	638	0.368	0.331
INSTALLATION_PERMIT_PERMIT_IDENTIFIER	text	632	0.368	0.328
INSTALLATION_PERMIT_PERMIT_STATUS	text	2	0.368	0.001
INSTALLATION_PERMIT_ENTRY_DATE	text	264	0.368	0.137
INSTALLATION_ACTIVITY	text	26	0.368	0.013
INSTALLATION_CONTACT_ADDRESS_LINE_1	text	458	0.368	0.237
INSTALLATION_CONTACT_POST_CODE	text	351	0.368	0.182

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
INSTALLATION_CONTACT_CITY	text	291	0.368	0.151
INSTALLATION_CONTACT_COUNTRY	text	1	0.368	0.001
INSTALLATION_CONTACT_PHONE_NUMBER_1	text	421	0.368	0.218
INSTALLATION_CONTACT_PHONE_NUMBER_2	text	427	0.368	0.221
INSTALLATION_CONTACT_EMAIL	text	389	0.368	0.202
AR_CONTACT_REGION	text	103	0.342	0.021
AH_CONTACT_REGION	text	76	0.334	0.039
AR_JOB_TITLE	text	614	0.313	0.126
INSTALLATION_CONTACT_REGION	text	40	0.272	0.021
CONTACT_PERSON_FIRST_NAME	text	186	0.227	0.096
CONTACT_PERSON_LAST_NAME	text	282	0.227	0.146
CONTACT_PERSON_EMAIL_ADDRESS	text	283	0.220	0.147
CONTACT_PERSON_PHONE_NUMBER_1	text	296	0.219	0.153
AH_CONTACT_ADDRESS_LINE_2	text	184	0.208	0.095
AH_CONTACT_PUBLISH_PHONE_1	float	2	0.122	0.001
AH_CONTACT_PUBLISH_PHONE_2	float	2	0.122	0.001
AH_CONTACT_PUBLISH_EMAIL	float	2	0.122	0.001
CONTACT_PERSON_PHONE_NUMBER_2	text	150	0.113	0.078
AH	text	4	0.112	0.002
AIRCRAFT_OPERATOR_FIRST_YEAR_OF_VERIFICATION	float	11	0.111	0.006
AIRCRAFT_OPERATOR_IDENTIFIER	float	189	0.111	0.098
AIRCRAFT_OPERATOR_EUROCONTROL_CODE	text	188	0.111	0.097
AIRCRAFT_OPERATOR_MONITORING_PLAN_IDENTIFIER	text	187	0.111	0.097
AIRCRAFT_OPERATOR_MONITORING_PLAN_FIRST_YEAR_OF_APPLICABILITY	float	12	0.111	0.006
AIRCRAFT_OPERATOR_MONITORING_PLAN_STATUS	text	2	0.111	0.001
INSTALLATION_PARENT_UNdertaking_NAME	text	94	0.092	0.049
AIRCRAFT_OPERATOR_CALL_SIGN	text	89	0.055	0.046
INSTALLATION_EPRTR_IDENTIFICATION	text	73	0.052	0.038

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
INSTALLATION_PERMIT_PERMIT_EXPIRY_DATE	text	10	0.046	0.005
AH_LEI	text	53	0.042	0.027
CONTACT_PERSON_COUNTRY	text	13	0.040	0.007
CONTACT_PERSON_CITY	text	48	0.039	0.025
CONTACT_PERSON_POST_CODE	text	54	0.039	0.028
CONTACT_PERSON_ADDRESS_LINE_1	text	56	0.039	0.029
AH_CONTACT_BIRTH_DATE	text	32	0.038	0.017
AH_BIRTH_COUNTRY	text	10	0.038	0.005
AH_BIRTH_PLACE	text	32	0.038	0.017
AH_IDENTITY_DOCUMENT_TYPE	text	3	0.038	0.002
AH_IDENTITY_DOCUMENT_IDENTIFIER	text	33	0.038	0.017
AH_IDENTITY_DOCUMENT_EXPIRY_DATE	text	19	0.030	0.010
CONTACT_PERSON_REGION	text	22	0.027	0.011
INSTALLATION_CONTACT_ADDRESS_LINE_2	text	39	0.024	0.020
AH_IDENTITY_DOCUMENT_OTHER_DESC	text	2	0.022	0.001
AH_NATIONAL_REGISTRATION_NUMBER	text	2	0.017	0.001
CONTACT_PERSON_ADDRESS_LINE_2	text	19	0.015	0.010
AIRCRAFT_OPERATOR_MONITORING_PLAN_YEAR_OF_EXPIRY	float	4	0.011	0.002
INSTALLATION_PARENT_UNdertaking_Regno	text	12	0.007	0.006
INSTALLATION_LONGITUDE	float	6	0.004	0.003
INSTALLATION_LATITUDE	float	6	0.004	0.003
INSTALLATION_LAST_YEAR_OF_VERIFICATION	float	2	0.001	0.001
INSTALLATION_PERMIT_PERMIT_REVOCATION_DATE	text	2	0.001	0.001
AIRCRAFT_OPERATOR_LAST_YEAR_OF_VERIFICATION	float	1	0.001	0.001

Erläuterungen: Dtype: Data type (Text, Ganzzahl, Kommazahl); n_distinct_vals: Anzahl unterschiedlicher Einträge; fill ratio: Anteil der aufgefüllten Zellen (1.000: in allen Anträgen ist die Zelle ausgefüllt, 0.001: nur 1 Promille der Anträge enthält Information); distinct_ratio: Anzahl der unterschiedlichen Einträge/Anzahl der Einträge (1.000: jeder Antrag enthält einen unterschiedlichen Eintrag)

B Datenschema AP 2

B.1 Stoffströme

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Jahr Ereignis	integer	18	1.000	0.000
Szenario-ID	integer	847	1.000	0.020
Branche	text	19	1.000	0.000
CO2-Berichtsanlageanteil	text	2528	1.000	0.059
Postleitzahl	text	700	1.000	0.016
Bundesland	text	16	1.000	0.000
Pruefstelle	float	755	0.568	0.018
Eingangsdatum	datetime	993	1.000	0.023
Feuerungswärmeleistung	float	925	0.999	0.022
VET Abgabezeitpunkt	float	11899	0.998	0.279
aktuell geprüfte Emissionen	float	11908	0.999	0.279
KEY Version	text	1	1.000	0.000
KEY Status	text	4	1.000	0.000
KEY Ursache	text	10	1.000	0.000
Ursache	text	10	1.000	0.000
Herkunft	text	5	0.998	0.000
Gültig von	datetime	146	0.998	0.003
Gültig bis	datetime	155	0.998	0.004
Stoffstrom Nr.	text	1347	0.998	0.032
Stoff Katalog	text	179	0.998	0.004
Bezeichnung	text	2697	0.998	0.063
Stoffstrom.Menge	float	27636	0.998	0.647
Stoffstrom.Einheit	text	3	0.998	0.000
Tätigkeit nach Anhang IV MVO	text	23	0.997	0.001
Weiterleitung	text	2	0.010	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Messung	text	2	0.998	0.000
Bezug	text	2	0.566	0.000
Klassifizierung	text	3	0.566	0.000
Handelt es sich um flüssige Biomasse oder Biokraftstoff?	text	2	0.566	0.000
Aus ÜP EmB	text	3	0.566	0.000
Fehlerstatus	text	3	0.566	0.000
Berechnen	text	2	0.998	0.000
Wurde der Stoff im Berichtszeitraum eingesetzt?	text	2	0.566	0.000
Wird der Stoff auch als Brennstoff eingesetzt?	text	2	0.037	0.000
Kennzeichnung als Bilanzglied	text	3	0.010	0.000
Emissionen (t CO2)	float	19710	0.998	0.462
Menge.Ebene ÜP	text	5	0.566	0.000
Menge.KEY Parameter	text	1	0.566	0.000
Menge.Menge	text	15339	0.566	0.359
Menge.Einheit	text	2	0.566	0.000
Menge.AB man. Parameter	float	1	0.566	0.000
Menge.Ermittlungsmethode	float	0	0.000	0.000
Menge.Datenquelle	float	0	0.000	0.000
Menge.AB man. Methode	float	1	0.566	0.000
Menge.Meth. genehmigt	text	2	0.523	0.000
CO2 FMS.KEY Parameter	text	1	0.998	0.000
CO2 FMS.Parameter	text	1	0.998	0.000
CO2 FMS.CO2 (FMS)	float	31244	0.998	0.732
CO2 FMS.Einheit	text	2	0.998	0.000
C-Gehalt.KEY Parameter	text	1	0.014	0.000
C-Gehalt.Parameter	text	1	0.014	0.000
C-Gehalt	text	354	0.014	0.008

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
C-Gehalt.Einheit	text	2	0.014	0.000
C-Gehalt.AB man. Parameter	float	2	0.014	0.000
C-Gehalt.Ermittlungsmethode	text	2	0.009	0.000
C-Gehalt.Datenquelle	text	3	0.003	0.000
C-Gehalt.AB man. Methode	float	2	0.014	0.000
C-Gehalt.Meth. genehmigt	text	2	0.009	0.000
C-Gehalt.Ebene ÜP	text	8	0.014	0.000
Material C-Gehalt	text	8	0.005	0.000
C-Gehalt.Material Minimum zulässig	text	9	0.014	0.000
C-Gehalt.Material Maximum zulässig	text	10	0.014	0.000
C-Gehalt zulässig	text	2	0.014	0.000
EF.KEY Parameter	text	3	0.984	0.000
EF.Parameter	text	2	0.984	0.000
EF	float	4023	0.984	0.094
EF.Einheit	text	4	0.984	0.000
EF.AB man. Parameter	float	2	0.984	0.000
EF.Ermittlungsmethode	text	2	0.501	0.000
EF.Datenquelle	text	3	0.358	0.000
EF.AB man. Methode	float	2	0.984	0.000
EF.Meth. genehmigt	text	2	0.513	0.000
EF.Ebene ÜP	text	13	0.982	0.000
Material EF	float	57	0.734	0.001
EF.Material Minimum zulässig	float	17	0.951	0.000
EF.Material Maximum zulässig	float	27	0.951	0.001
EF zulässig	text	2	0.948	0.000
Unterer Heizwert.KEY Parameter	text	1	0.992	0.000
Unterer Heizwert.Parameter	text	1	0.992	0.000
Hu	float	12189	0.992	0.285

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Unterer Heizwert.Einheit	text	3	0.992	0.000
Unterer Heizwert.AB man. Parameter	float	2	0.992	0.000
Unterer Heizwert.Ermittlungsmethode	text	2	0.476	0.000
Unterer Heizwert.Datenquelle	text	3	0.334	0.000
Unterer Heizwert.AB man. Methode	float	1	0.992	0.000
Unterer Heizwert.Meth. genehmigt	text	2	0.492	0.000
Unterer Heizwert.Ebene ÜP	text	15	0.952	0.000
Material Unterer Heizwert	float	81	0.732	0.002
Unterer Heizwert.Material Minimum zulässig	float	10	0.992	0.000
Unterer Heizwert.Material Maximum zulässig	float	10	0.992	0.000
Unterer Heizwert zulässig	text	2	0.962	0.000
Faktor (OxF, UmF).KEY Parameter	text	2	0.984	0.000
Faktor (OxF, UmF).Parameter	text	2	0.984	0.000
Faktor	float	60	0.984	0.001
Faktor (OxF, UmF).Einheit	text	1	0.984	0.000
Faktor (OxF, UmF).AB man. Parameter	float	1	0.984	0.000
Faktor (OxF, UmF).Meth. genehmigt	text	2	0.028	0.000
Faktor (OxF, UmF).Ebene ÜP	text	9	0.202	0.000
Biogener Anteil.KEY Parameter	text	1	0.998	0.000
Biogener Anteil.Parameter	text	1	0.998	0.000
Biogener Anteil	float	591	0.998	0.014
Biogener Anteil.Einheit	text	2	0.998	0.000
Biogener Anteil.AB man. Parameter	float	2	0.998	0.000
Biogener Anteil.Ermittlungsmethode	float	0	0.000	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Biogener Anteil.Datenquelle	float	0	0.000	0.000
Biogener Anteil.AB man. Methode	float	1	0.998	0.000
Biogener Anteil.Meth. genehmigt	text	2	0.330	0.000
Biogener Anteil.Ebene ÜP	text	4	0.111	0.000
Biogener Anteil plausibel	text	2	0.998	0.000
Kons An.Key Parameter	text	1	0.052	0.000
Kons. Anpassung Parameter	text	1	0.052	0.000
Kons. Anpassung Wert	text	18	0.052	0.000
Kons. Anpassung Einheit	text	2	0.052	0.000
Kons An Manuell Parameter	float	1	0.052	0.000
Kons. Anpassung Ermittlungsmethode	float	0	0.000	0.000
Kons. Anpassung Datenquelle	float	0	0.000	0.000
Kons An Ab man Methode	float	1	0.052	0.000
Kons An.Meth. Genehmigt	float	0	0.000	0.000
Kons An.Ebene Üp	float	0	0.000	0.000
Kons An Biogen Plausibel	float	0	0.000	0.000
Nachh. Biom..KEY Parameter	text	1	0.566	0.000
Nachh. Biom..Parameter	text	1	0.566	0.000
Nachh. Biom..Nachh. Biom.	text	48	0.566	0.001
Nachh. Biom..Einheit	text	1	0.566	0.000
Nachh. Biom..AB man. Parameter	float	2	0.566	0.000
Nachh. Biom..Ermittlungsmethode	text	1	0.000	0.000
Nachh. Biom..Datenquelle	float	0	0.000	0.000
Nachh. Biom..AB man. Methode	float	1	0.566	0.000
Nachh. Biom..Meth. genehmigt	text	1	0.000	0.000
Nachh. Biom..Ebene ÜP	float	0	0.000	0.000
Biomasse nachhaltig.KEY Parameter	text	1	0.566	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Biomasse nachhaltig.Parameter	text	1	0.566	0.000
Biomasse nachhaltig.Nachh. Biom.	float	2	0.566	0.000
Biomasse nachhaltig.Einheit	text	1	0.566	0.000
Lager.Wie wird die Verbrauchsmenge bestimmt?	text	2	0.098	0.000
Lager.Flag Manuell	float	1	0.784	0.000
Lager.Liefer- oder Berichtsmenge / Verkaufsmenge	text	855	0.784	0.020
Lager.Einheit_Liefer- oder Berichtsmenge / Verkaufsmenge	float	3	0.784	0.000
Lager.Menge Abgang/ Zugang	text	126	0.784	0.003
Lager.Einheit_Menge Abgang/ Zugang	float	3	0.784	0.000
Lager.Sind Lagerbestandsänderungen zu berücksichtigen?	text	2	0.103	0.000
Lager Anfangsbestand	text	678	0.784	0.016
Lager.Einheit_Lager Anfangsbestand	float	3	0.784	0.000
Lager Endbestand	text	688	0.784	0.016
Lager.Einheit_Lager Endbestand	float	3	0.784	0.000
Datum von	datetime	143	0.998	0.003
Datum bis	datetime	154	0.998	0.004
CO2	float	31280	0.998	0.732
CO2.Einheit	text	1	0.998	0.000
CO2 (FMS).CO2 (FMS)	float	31244	0.998	0.732
Expr1150	text	2	0.998	0.000
CO2 (FMS).Einheit	text	2	0.998	0.000
CO2 Biogen	float	2509	0.998	0.059
CO2 Biogen.Einheit	text	1	0.998	0.000
Energie	float	29785	0.992	0.697
Energie.Einheit	text	2	0.992	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Energie Biogen	float	3004	0.992	0.070
Energie Biogen.Einheit	text	1	0.992	0.000

B.2 Lernen_Stoffströme

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Jahr Ereignis	integer	18	1.000	0.004
Szenario-ID	integer	187	1.000	0.039
Branche	text	14	1.000	0.003
CO2-Berichtsanlageanteil	text	275	1.000	0.057
Postleitzahl	integer	161	1.000	0.034
Bundesland	text	16	1.000	0.003
Pruefstelle	float	57	0.483	0.012
Eingangsdatum	datetime	297	1.000	0.062
Feuerungswärmeleistung	float	187	1.000	0.039
VET Abgabezeitpunkt	float	393	0.985	0.082
aktuell geprüfte Emissionen	float	630	0.986	0.132
KEY Version	text	2	1.000	0.000
KEY Status	text	3	1.000	0.001
KEY Ursache	text	4	0.504	0.001
Ursache	text	4	0.504	0.001
Vorgangsart	text	18	0.990	0.004
Herkunft	text	4	0.999	0.001
Gültig von	datetime	22	0.999	0.005
Gültig bis	datetime	21	0.999	0.004
Stoffstrom Nr.	text	469	0.999	0.098
Stoff Katalog	text	115	0.999	0.024
Bezeichnung	text	630	0.999	0.132
Stoffstrom.Menge	float	2253	0.999	0.471
Stoffstrom.Einheit	text	3	0.999	0.001
Tätigkeit nach Anhang IV MVO	text	19	0.998	0.004
Weiterleitung	text	2	0.015	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Messung	text	2	0.999	0.000
Bezug	text	2	0.483	0.000
Klassifizierung	text	3	0.483	0.001
Handelt es sich um flüssige Biomasse oder Biokraftstoff?	text	2	0.483	0.000
Aus ÜP EmB	text	3	0.483	0.001
Fehlerstatus	text	3	0.483	0.001
Berechnen	text	2	0.999	0.000
Wurde der Stoff im Berichtszeitraum eingesetzt?	text	2	0.483	0.000
Wird der Stoff auch als Brennstoff eingesetzt?	text	2	0.049	0.000
Kennzeichnung als Bilanzglied	text	3	0.015	0.001
Emissionen (t CO2)	float	1769	0.999	0.369
Menge.Ebene ÜP	text	5	0.482	0.001
Menge.KEY Parameter	text	1	0.483	0.000
Menge.Menge	text	1050	0.483	0.219
Menge.Einheit	text	3	0.483	0.001
Menge.AB man. Parameter	float	1	0.483	0.000
Menge.Ermittlungsmethode	float	0	0.000	0.000
Menge.Datenquelle	float	0	0.000	0.000
Menge.AB man. Methode	float	1	0.483	0.000
Menge.Meth. genehmigt	text	2	0.429	0.000
CO2 FMS.KEY Parameter	text	1	0.999	0.000
CO2 FMS.Parameter	text	1	0.999	0.000
CO2 FMS.CO2 (FMS)	float	2240	0.999	0.468
CO2 FMS.Einheit	text	2	0.999	0.000
C-Gehalt.KEY Parameter	text	1	0.034	0.000
C-Gehalt.Parameter	text	1	0.034	0.000
C-Gehalt	text	81	0.034	0.017

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
C-Gehalt.Einheit	text	3	0.034	0.001
C-Gehalt.AB man. Parameter	float	2	0.034	0.000
C-Gehalt.Ermittlungsmethode	text	2	0.013	0.000
C-Gehalt.Datenquelle	text	1	0.001	0.000
C-Gehalt.AB man. Methode	float	1	0.034	0.000
C-Gehalt.Meth. genehmigt	text	2	0.015	0.000
C-Gehalt.Ebene ÜP	text	5	0.034	0.001
Material C-Gehalt	text	2	0.019	0.000
C-Gehalt.Material Minimum zulässig	text	5	0.033	0.001
C-Gehalt.Material Maximum zulässig	text	6	0.033	0.001
C-Gehalt zulässig	text	2	0.033	0.000
EF.KEY Parameter	text	3	0.965	0.001
EF.Parameter	text	2	0.965	0.000
EF	float	1045	0.965	0.218
EF.Einheit	text	4	0.965	0.001
EF.AB man. Parameter	float	2	0.965	0.000
EF.Ermittlungsmethode	text	2	0.388	0.000
EF.Datenquelle	text	3	0.195	0.001
EF.AB man. Methode	float	2	0.965	0.000
EF.Meth. genehmigt	text	2	0.414	0.000
EF.Ebene ÜP	text	11	0.953	0.002
Material EF	float	40	0.641	0.008
EF.Material Minimum zulässig	float	15	0.919	0.003
EF.Material Maximum zulässig	float	23	0.919	0.005
EF zulässig	text	2	0.908	0.000
Unterer Heizwert.KEY Parameter	text	1	0.984	0.000
Unterer Heizwert.Parameter	text	1	0.984	0.000
Hu	float	1362	0.984	0.284

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Unterer Heizwert.Einheit	text	3	0.984	0.001
Unterer Heizwert.AB man. Parameter	float	2	0.984	0.000
Unterer Heizwert.Ermittlungsmethode	text	2	0.355	0.000
Unterer Heizwert.Datenquelle	text	3	0.160	0.001
Unterer Heizwert.AB man. Methode	float	1	0.984	0.000
Unterer Heizwert.Meth. genehmigt	text	2	0.383	0.000
Unterer Heizwert.Ebene ÜP	text	13	0.924	0.003
Material Unterer Heizwert	float	54	0.642	0.011
Unterer Heizwert.Material Minimum zulässig	float	9	0.982	0.002
Unterer Heizwert.Material Maximum zulässig	float	10	0.982	0.002
Unterer Heizwert zulässig	text	2	0.930	0.000
Faktor (OxF, UmF).KEY Parameter	text	2	0.965	0.000
Faktor (OxF, UmF).Parameter	text	2	0.965	0.000
Faktor	float	16	0.965	0.003
Faktor (OxF, UmF).Einheit	text	1	0.965	0.000
Faktor (OxF, UmF).AB man. Parameter	float	1	0.965	0.000
Faktor (OxF, UmF).Meth. genehmigt	text	2	0.042	0.000
Faktor (OxF, UmF).Ebene ÜP	text	4	0.256	0.001
Biogener Anteil.KEY Parameter	text	1	0.999	0.000
Biogener Anteil.Parameter	text	1	0.999	0.000
Biogener Anteil	float	153	0.999	0.032
Biogener Anteil.Einheit	text	2	0.999	0.000
Biogener Anteil.AB man. Parameter	float	1	0.999	0.000
Biogener Anteil.Ermittlungsmethode	float	0	0.000	0.000
Biogener Anteil.Datenquelle	float	0	0.000	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Biogener Anteil.AB man. Methode	float	1	0.999	0.000
Biogener Anteil.Meth. genehmigt	text	2	0.243	0.000
Biogener Anteil.Ebene ÜP	text	4	0.113	0.001
Biogener Anteil plausibel	text	2	0.999	0.000
Kons An.Key Parameter	text	1	0.020	0.000
Kons. Anpassung Parameter	text	1	0.020	0.000
Kons. Anpassung Wert	float	1	0.020	0.000
Kons. Anpassung Einheit	text	2	0.020	0.000
Kons An Manuell Parameter	float	1	0.020	0.000
Kons. Anpassung Ermittlungsmethode	float	0	0.000	0.000
Kons. Anpassung Datenquelle	float	0	0.000	0.000
Kons An Ab man Methode	float	1	0.020	0.000
Kons An.Meth. Genehmigt	float	0	0.000	0.000
Kons An.Ebene Üp	float	0	0.000	0.000
Kons An Biogen Plausibel	float	0	0.000	0.000
Nachh. Biom..KEY Parameter	text	1	0.483	0.000
Nachh. Biom..Parameter	text	1	0.483	0.000
Nachh. Biom..Nachh. Biom.	text	8	0.483	0.002
Nachh. Biom..Einheit	text	1	0.482	0.000
Nachh. Biom..AB man. Parameter	float	1	0.483	0.000
Nachh. Biom..Ermittlungsmethode	float	0	0.000	0.000
Nachh. Biom..Datenquelle	float	0	0.000	0.000
Nachh. Biom..AB man. Methode	float	1	0.483	0.000
Nachh. Biom..Meth. genehmigt	float	0	0.000	0.000
Nachh. Biom..Ebene ÜP	float	0	0.000	0.000
Biomasse nachhaltig.KEY Parameter	text	1	0.483	0.000
Biomasse nachhaltig.Parameter	text	1	0.483	0.000
Biomasse nachhaltig.Nachh. Biom.	float	2	0.483	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Biomasse nachhaltig.Einheit	text	1	0.482	0.000
Lager.Wie wird die Verbrauchsmenge bestimmt?	text	2	0.046	0.000
Lager.Flag Manuell	float	1	0.733	0.000
Lager.Liefer- oder Berichtsmenge / Verkaufsmenge	text	34	0.733	0.007
Lager.Einheit_Liefer- oder Berichtsmenge / Verkaufsmenge	float	3	0.733	0.001
Lager.Menge Abgang/ Zugang	text	5	0.733	0.001
Lager.Einheit_Menge Abgang/ Zugang	float	3	0.733	0.001
Lager.Sind Lagerbestandsänderungen zu berücksichtigen?	text	2	0.049	0.000
Lager Anfangsbestand	text	24	0.733	0.005
Lager.Einheit_Lager Anfangsbestand	float	2	0.733	0.000
Lager Endbestand	text	23	0.733	0.005
Lager.Einheit_Lager Endbestand	float	2	0.733	0.000
Datum von	datetime	23	0.999	0.005
Datum bis	datetime	26	0.999	0.005
CO2	float	2500	0.999	0.522
CO2.Einheit	text	1	0.997	0.000
CO2 (FMS).CO2 (FMS)	float	2240	0.999	0.468
Expr1151	text	1	0.999	0.000
CO2 (FMS).Einheit	text	1	0.999	0.000
CO2 Biogen	float	347	0.999	0.072
CO2 Biogen.Einheit	text	1	0.997	0.000
Energie	float	2122	0.984	0.443
Energie.Einheit	text	1	0.981	0.000
Energie Biogen	float	302	0.984	0.063
Energie Biogen.Einheit	text	1	0.983	0.000

B.3 Prüfmeldungen

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Jahr Ereignis	integer	18	1.000	0.000
Szenario-ID	integer	847	1.000	0.010
KEY Version	text	2	1.000	0.000
KEY Status	text	5	1.000	0.000
KEY Ursache	text	10	0.491	0.000
Prüfmodul Status Nr	integer	3	1.000	0.000
PM Nummer	text	26	1.000	0.000
FM Nummer	text	69	1.000	0.001
Prüfstatus Nr	integer	3	1.000	0.000
Referenz auf Objekt	text	18540	1.000	0.223
Prüfung überstimmt	text	2	1.000	0.000
Ursprünglicher Prüfstatus Nr	integer	3	1.000	0.000
Hat Kindermeldungen	integer	1	1.000	0.000
Lfd Nr	integer	13	1.000	0.000
Szenarien_Übersicht Prüfvermerke_Prüfung	integer	3	1.000	0.000
Berichtsdeckblatt_ Prüfvermerke_Prüfung	text	3	0.874	0.000
Emissionsbericht_ Übersicht Prüfvermerke_Prüfung	integer	3	1.000	0.000

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Stammdaten Anlage_Prüfvermerke_Prüfung	text	2	0.874	0.000
Stammdaten Klassifizierung_Prüfvermerke_Prüfung	float	0	0.000	0.000
Stammdaten Berichtsanlagenteil_Prüfvermerke_Prüfung	text	2	0.321	0.000
Stoffströme_Prüfvermerke_Prüfung	text	3	0.321	0.000
Weiterleitungen_Prüfvermerke_Prüfung	text	1	0.873	0.000

B.4 Produktmengen

column_name	dtype	n_distinct_vals	fill_ratio	distinct_ratio
Jahr Ereignis	integer	11	1.000	0.001
Szenario-ID	integer	793	1.000	0.052
KEY Version	text	2	1.000	0.000
AR	float	8789	1.000	0.574
AR Einheit	text	5	1.000	0.000

C Detaillierte Ergebnistabellen AP3

C.1 Gesamte Beobachtungen, Ausreißer und Ausreißerquote pro Land

Tabelle 9: Gesamte Beobachtungen, Ausreißer und Ausreißerquote pro Land

Land	Abkürzung	Gesamte Beobachtungen	Ausreißer	Ausreißerquote
Vereinigte Arabische Emirate	AE	45	4	9%
Albanien	AL	9	0	0%
Armenien	AM	2	0	0%
Argentinien	AR	7	0	0%
Österreich	AT	6998	321	5%
Australien	AU	1.160	183	16%
Aruba	AW	14	0	0%
Aserbaidtschan	AZ	23	0	0%
Barbados	BB	3	0	0%
Belgien	BE	10438	268	3%
Bulgarien	BG	6028	312	5%
Bermuda	BM	348	53	15%
Brunei Darussalam	BN	12	1	8%
Brasilien	BR	148	9	6%
Bahamas	BS	53	0	0%
Belarus (Weißrussland)	BY	20	2	10%
Belize	BZ	5	0	0%
Kanada	CA	598	4	1%
Schweiz	CH	7646	798	10%
Chile	CL	47	2	4%
China, Volksrepublik	CN	113	7	6%
Kolumbien	CO	1	0	0%
Kap Verde	CV	20	3	15%
Zypern	CY	990	19	2%

Land	Abkürzung	Gesamte Beobachtungen	Ausreißer	Ausreißerquote
Tschechische Republik	CZ	12.049	205	2%
Deutschland	DE	74378	2396	3%
Dänemark	DK	10043	343	3%
Algerien	DZ	26	1	4%
Estland	EE	1.551	12	1%
Ägypten	EG	52	3	6%
Spanien	ES	42083	1252	3%
Äthiopien	ET	52	3	6%
Finnland	FI	10622	601	6%
Färöer	FO	33	0	0%
Frankreich	FR	29228	2242	8%
Vereinigtes Königreich Großbritannien und Nordirland	GB	66290	3247	5%
Georgien	GE	7	0	0%
Gibraltar	GI	8	0	0%
Grönland	GL	26	1	4%
Griechenland	GR	6060	347	6%
Guatemala	GT	2	0	0%
Hongkong	HK	26	1	4%
Kroatien	HR	1.486	22	1%
Ungarn	HU	11071	630	6%
Indonesien	ID	6	1	17%
Republik Irland	IE	4798	479	10%
Israel	IL	161	16	10%
Indien	IN	21	0	0%
Iran, Islamische Republik	IR	29	2	7%
Island	IS	429	28	7%
Italien	IT	41.638	1.050	3%

Land	Abkürzung	Gesamte Beobachtungen	Ausreißer	Ausreißerquote
Japan	JP	124	3	2%
St. Kitts und Nevis	KN	4	0	0%
Korea, Republik (Südkorea)	KR	133	7	5%
Kuwait	KW	8	0	0%
Kaimaninseln	KY	276	3	1%
Kasachstan	KZ	53	1	2%
Libanon	LB	21	1	5%
Liechtenstein	LI	80	2	2%
Sri Lanka	LK	17	2	12%
Litauen	LT	2708	138	5%
Luxemburg	LU	1556	66	4%
Lettland	LV	1.945	257	13%
Libysch-Arabische Dschamahirija (Libyen)	LY	8	0	0%
Marokko	MA	49	4	8%
Monaco	MC	5	0	0%
Moldawien (Republik Moldau)	MD	24	2	8%
Madagaskar	MG	22	1	5%
Malta	MT	329	7	2%
Mauritius	MU	37	5	14%
Mexiko	MX	36	0	0%
Malaysia	MY	34	0	0%
Nigeria	NG	10	0	0%
Niederlande	NL	24.705	530	2%
Norwegen	NO	6.055	1.987	33%
Neuseeland	NZ	19	0	0%
Panama	PA	4	0	0%
Peru	PE	4	0	0%

Land	Abkürzung	Gesamte Beobachtungen	Ausreißer	Ausreißerquote
Philippinen	PH	199	3	2%
Polen	PL	27189	1126	4%
Portugal	PT	7539	236	3%
Katar	QA	33	1	3%
Réunion	RE	24	2	8%
Rumänien	RO	8237	716	9%
Russland	RU	253	17	7%
Saudi Arabien	SA	126	12	10%
Seychellen	SC	18	0	0%
Schweden	SE	11499	294	3%
Singapur	SG	843	20	2%
Slowenien	SI	7218	370	5%
Slowakei	SK	5589	347	6%
Thailand	TH	23	1	4%
Turkmenistan	TM	7	0	0%
Tunesien	TN	46	3	7%
Türkei	TR	409	18	4%
Taiwan	TW	20	3	15%
Ukraine	UA	82	2	2%
Uganda	UG	13	1	8%
Vereinigte Staaten von Amerika	US	7.691	2.059	27%
Uruguay	UY	24	3	12%
Venezuela	VE	2	1	50%
Britische Jungferninseln	VG	79	0	0%
Amerikanische Jungferninseln	VI	1	0	0%
Vietnam	VN	16	0	0%
Südafrika	ZA	13	0	0%

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

C.2 Gesamte Beobachtungen, Beobachtungen Luftfahrt, Aureißerquote gesamt und Luftfahrt

Tabelle 10: Gesamte Beobachtungen, Beobachtungen Luftfahrt, Aureißerquote gesamt und Luftfahrt

Land		Gesamte Beobachtungen	Beobachtungen Luftfahrt	Anteil Luftfahrt	Ausreißer gesamt	Ausreißer Luftfahrt	Anteil Ausreißer Luftfahrt an allen Ausreißern
Vereinigte Arabische Emirate	AE	45	44	98%	4	4	100%
Albanien	AL	9	9	100%	/	/	/
Armenien	AM	2	2	100%	/	/	/
Argentinien	AR	7	7	100%	/	/	/
Österreich	AT	6.998	398	6%	321	138	43%
Australien	AU	1.160	43	4%	183	8	4%
Aruba	AW	14	14	100%	/	/	/
Aserbaidshan	AZ	23	23	100%	/	/	/
Barbados	BB	3	3	100%	/	/	/
Belgien	BE	10.438	370	4%	268	67	25%
Bulgarien	BG	6.028	180	3%	312	69	22%
Bermuda	BM	348	276	79%	53	51	96%
Brunei Darussalam	BN	12	12	100%	1	1	100%
Brasilien	BR	148	100	68%	9	9	100%
Bahamas	BS	53	12	23%	/	/	/
Weißrussland	BY	20	20	100%	2	2	100%
Belize	BZ	5	5	100%	/	/	/
Kanada	CA	598	85	14%	4	3	75%
Schweiz	CH	7.646	489	6%	798	163	20%
Chile	CL	47	33	70%	2	2	100%

Land		Gesamte Beobachtungen	Beobachtungen Luftfahrt	Anteil Luftfahrt	Ausreißer gesamt	Ausreißer Luftfahrt	Anteil Ausreißer Luftfahrt an allen Ausreißern
China, Volksrepublik	CN	113	107	95%	7	7	100%
Kolumbien	CO	1	1	100%	/	/	/
Kap Verde	CV	20	20	100%	3	3	100%
Zypern	CY	990	131	13%	19	13	68%
Tschechische Republik	CZ	12.049	201	2%	205	39	19%
Deutschland	DE	74.378	792	1%	2.396	58	2%
Dänemark	DK	10.043	387	4%	343	74	22%
Algerien	DZ	26	26	100%	1	1	100%
Estland	EE	1.551	44	3%	12	4	33%
Ägypten	EG	52	52	100%	3	3	100%
Spanien	ES	42.083	960	2%	1.252	130	10%
Äthiopien	ET	52	52	100%	3	3	100%
Finnland	FI	10.622	56	1%	601	16	3%
Färöer	FO	33	33	100%	/	/	/
Frankreich	FR	29.228	704	2%	2.242	216	10%
Vereinigtes Königreich Großbritannien und Nordirland	GB	66.290	679	1%	3.247	62	2%
Georgien	GE	7	7	100%	/	/	/
Gibraltar	GI	8	0	0%	/	/	/
Grönland	GL	26	26	100%	1	1	100%
Griechenland	GR	6.060	248	4%	347	73	21%
Guatemala	GT	2	2	100%	/	/	/
Hongkong	HK	26	22	85%	1	1	100%
Kroatien	HR	1.486	0	0%	22	0	0%
Ungarn	HU	11.071	133	1%	630	47	7%

Land		Gesamte Beobachtungen	Beobachtungen Luftfahrt	Anteil Luftfahrt	Ausreißer gesamt	Ausreißer Luftfahrt	Anteil Ausreißer Luftfahrt an allen Ausreißern
Indonesien	ID	6	6	100%	1	1	100%
Irland	IE	4.798	432	9%	479	154	3%
Israel	IL	161	156	97%	16	16	100%
Indien	IN	21	19	90%	/	/	/
Iran	IR	29	29	100%	2	2	100%
Island	IS	429	217	51%	28	28	100%
Italien	IT	41.638	425	1%	1.050	72	7%
Japan	JP	124	41	33%	3	3	100%
St. Kitts und Nevis	KN	4	0	0%	/	/	/
Korea, Republik (Südkorea)	KR	133	79	59%	7	7	100%
Kuwait	KW	8	8	100%	/	/	/
Kaimaninseln	KY	276	74	27%	3	2	67%
Kasachstan	KZ	53	53	100%	1	1	100%
Libanon	LB	21	21	100%	1	1	100%
Liechtenstein	LI	80	40	50%	2	2	100%
Sri Lanka	LK	17	17	100%	2	2	100%
Litauen	LT	2.708	71	3%	138	22	16%
Luxemburg	LU	1.556	160	10%	66	30	45%
Lettland	LV	1.945	103	5%	257	54	21%
Libyen	LY	8	8	100%	/	/	/
Marokko	MA	49	49	100%	4	4	100%
Monaco	MC	5	5	100%	/	/	/
Moldau	MD	24	24	100%	2	2	100%
Madagaskar	MG	22	22	100%	1	1	100%
Malta	MT	329	158	48%	7	7	100%

Land		Gesamte Beobachtungen	Beobachtungen Luftfahrt	Anteil Luftfahrt	Ausreißer gesamt	Ausreißer Luftfahrt	Anteil Ausreißer Luftfahrt an allen Ausreißern
Mauritius	MU	37	37	100%	5	5	100%
Mexiko	MX	36	9	25%	/	/	/
Malaysia	MY	34	13	38%	/	/	/
Nigeria	NG	10	10	100%	/	/	/
Niederlande	NL	24.705	196	1%	530	26	5%
Norwegen	NO	6.055	260	4%	1987	143	7%
Neuseeland	NZ	19	8	42%	/	/	/
Panama	PA	4	4	100%	/	/	/
Peru	PE	4	0	0%	/	/	/
Philippinen	PH	199	0	0%	3	0	0%
Polen	PL	27.189	329	1%	1.126	75	7%
Portugal	PT	7.539	196	3%	236	37	16%
Katar	QA	33	33	100%	1	1	100%
Réunion	RE	24	24	100%	2	2	100%
Rumänien	RO	8.237	493	6%	716	117	16%
Russland	RU	253	253	100%	17	17	100%
Saudi-Arabien	SA	126	126	100%	12	12	100%
Seyschellen	SC	18	11	61%	/	/	/
Schweden	SE	11.499	429	4%	294	113	38%
Singapur	SG	843	21	2%	20	2	10%
Slowenien	SI	7.218	68	1%	370	20	5%
Slowakei	SK	5.589	40	1%	347	23	7%
Thailand	TH	23	23	100%	1	1	100%
Turkmenistan	TM	7	7	100%	/	/	/
Tunesien	TN	46	46	100%	3	3	100%
Türkei	TR	409	242	59%	18	15	83%

Land		Gesamte Beobachtungen	Beobachtungen Luftfahrt	Anteil Luftfahrt	Ausreißer gesamt	Ausreißer Luftfahrt	Anteil Ausreißer Luftfahrt an allen Ausreißern
Taiwan	TW	20	19	95%	3	3	100%
Ukraine	UA	82	82	100%	2	2	100%
Uganda	UG	13	0	0%	1	0	0%
Vereinigte Staaten von Amerika	US	7.691	2790	36%	2059	1400	68%
Uruguay	UY	24	24	100%	3	3	100%
Venezuela	VE	2	2	100%	1	1	100%
Britische Jungferninseln	VG	79	60	76%	/	/	/
Amerikanische Jungferninseln	VI	1	1	100%	/	/	/
Vietnam	VN	16	16	100%	/	/	/
Südafrika	ZA	13	13	100%	/	/	/

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)

C.3 Ausreißerquote in unterschiedlichen Zeiträumen

Tabelle 11: Ausreißerquote in unterschiedlichen Zeiträumen

Land		Ausreißerquote 2011-2020	Ausreißerquote 2014-2020	Ausreißerquote 2016-2020
Vereinigte Arabische Emirate	AE	9%	0%	0%
Albanien	AL	0%	0%	0%
Armenien	AM	0%	/	/
Argentinien	AR	0%	/	/
Österreich	AT	5%	12%	10%
Australien	AU	16%	9%	25%
Aruba	AW	0%	0%	0%
Aserbaidshan	AZ	0%	0%	6%
Barbados	BB	0%	0%	0%
Belgien	BE	3%	5%	2%

Land		Ausreißerquote 2011-2020	Ausreißerquote 2014-2020	Ausreißerquote 2016-2020
Bulgarien	BG	5%	3%	4%
Bermuda	BM	15%	1%	1%
Brunei Darussalam	BN	8%	0%	0%
Brasilien	BR	6%	0%	0%
Bahamas	BS	0%	0%	0%
Weißrussland	BY	0%	0%	0%
Belize	BZ	0%	/	/
Kanada	CA	1%	0%	4%
Schweiz	CH	10%	6%	7%
Chile	CL	4%	0%	0%
China, Volksrepublik	CN	6%	0%	2%
Kolumbien	CO	0%	/	/
Kap Verde	CV	15%	0%	6%
Zypern	CY	2%	0%	0%
Tschechische Republik	CZ	2%	3%	2%
Deutschland	DE	3%	3%	5%
Dänemark	DK	3%	1%	18%
Algerien	DZ	4%	0%	0%
Estland	EE	1%	1%	3%
Ägypten	EG	6%	0%	0%
Spanien	ES	3%	1%	2%
Äthiopien	ET	6%	2%	0%
Finnland	FI	6%	18%	4%
Färöer	FO	0%	0%	0%
Frankreich	FR	8%	8%	4%
Vereinigtes Königreich Großbritannien und Nordirland	GB	5%	10%	8%
Georgien	GE	0%	0%	0%

Land		Ausreißerquote 2011-2020	Ausreißerquote 2014-2020	Ausreißerquote 2016-2020
Gibraltar	GI	0%	0%	/
Grönland	GL	4%	0%	0%
Griechenland	GR	6%	7%	5%
Guatemala	GT	0%	0%	0%
Hongkong	HK	4%	0%	0%
Kroatien	HR	1%	1%	6%
Ungarn	HU	6%	10%	21%
Indonesien	ID	17%	0%	0%
Irland	IE	10%	4%	3%
Israel	IL	10%	1%	2%
Indien	IN	0%	0%	0%
Iran	IR	7%	0%	12%
Island	IS	7%	1%	0%
Italien	IT	3%	1%	1%
Japan	JP	2%	0%	0%
St. Kitts und Nevis	KN	0%	/	/
Korea, Republik (Südkorea)	KR	5%	1%	4%
Kuwait	KW	0%	0%	0%
Kaimaninseln	KY	1%	0%	0%
Kasachstan	KZ	2%	0%	0%
Libanon	LB	5%	0%	0%
Liechtenstein	LI	3%	0%	0%
Sri Lanka	LK	12%	0%	0%
Litauen	LT	5%	1%	1%
Luxemburg	LU	4%	2%	1%
Lettland	LV	13%	5%	1%
Libyen	LY	0%	0%	0%
Marokko	MA	8%	0%	0%

Land		Ausreißerquote 2011-2020	Ausreißerquote 2014-2020	Ausreißerquote 2016-2020
Monaco	MC	0%	/	/
Moldau	MD	8%	0%	6%
Madagaskar	MG	5%	0%	0%
Malta	MT	2%	3%	2%
Mauritius	MU	14%	0%	0%
Mexiko	MX	0%	0%	0%
Malaysia	MY	0%	0%	0%
Nigeria	NG	0%	0%	0%
Niederlande	NL	2%	8%	3%
Norwegen	NO	33%	8%	4%
Neuseeland	NZ	0%	0%	0%
Panama	PA	0%	/	/
Peru	PE	0%	0%	/
Philippinen	PH	2%	7%	1%
Polen	PL	4%	1%	1%
Portugal	PT	3%	1%	2%
Katar	QA	3%	0%	0%
Réunion	RE	8%	0%	0%
Rumänien	RO	9%	8%	1%
Russland	RU	7%	0%	4%
Saudi-Arabien	SA	10%	2%	1%
Seyschellen	SC	0%	0%	0%
Schweden	SE	3%	7%	3%
Singapur	SG	2%	13%	14%
Slowenien	SI	5%	7%	28%
Slowakei	SK	6%	2%	0%
Thailand	TH	4%	0%	6%
Turkmenistan	TM	0%	0%	0%

Land		Ausreißerquote 2011-2020	Ausreißerquote 2014-2020	Ausreißerquote 2016-2020
Tunesien	TN	7%	0%	4%
Türkei	TR	4%	1%	3%
Taiwan	TW	15%	0%	0%
Ukraine	UA	2%	0%	2%
Uganda	UG	8%	0%	0%
Vereinigte Staaten von Amerika	US	27%	4%	6%
Uruguay	UY	13%	0%	0%
Venezuela	VE	50%	0%	/
Britische Jungferninseln	VG	0%	0%	0%
Amerikanische Jungferninseln	VI	0%	/	/
Vietnam	VN	0%	0%	0%
Südafrika	ZA	0%	0%	0%

Quelle: Eigene Berechnung auf Basis EUTL bereitgestellt durch Abrell (2024)