

Yadegar, Edesa; Lange, Kerstin; Levagin, Bogdan; Oruc, Bayram

Article

t+20 – ein Projekt zur Schnellschätzung von Konjunkturindikatoren

WISTA - Wirtschaft und Statistik

Provided in Cooperation with:

Statistisches Bundesamt (Destatis), Wiesbaden

Suggested Citation: Yadegar, Edesa; Lange, Kerstin; Levagin, Bogdan; Oruc, Bayram (2025) : t+20 – ein Projekt zur Schnellschätzung von Konjunkturindikatoren, WISTA - Wirtschaft und Statistik, ISSN 1619-2907, Statistisches Bundesamt (Destatis), Wiesbaden, Vol. 77, Iss. 3, pp. 57-73

This Version is available at:

<https://hdl.handle.net/10419/320361>

Standard-Nutzungsbedingungen:

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

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

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

Terms of use:

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

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

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

$t+20$ – EIN PROJEKT ZUR SCHNELL- SCHÄTZUNG VON KONJUNKTUR- INDIKATOREN

Edesa Yadegar, Kerstin Lange, Bogdan Levagin, Bayram Oruc

↳ **Schlüsselwörter:** Verarbeitendes Gewerbe – Nowcasting – Aktualität –
Maschinelles Lernen – Imputation

ZUSAMMENFASSUNG

Im Projekt $t+20$ des Statistischen Bundesamtes wurden Methoden untersucht, um Konjunkturindikatoren für das Verarbeitende Gewerbe beschleunigt bereitzustellen. Der Einsatz mikrodatenbasierter Modelle, darunter Imputationsmethoden und Maschinelles Lernen, sowie eines makrodatenbasierten Dynamischen Faktormodells soll präzise und verlässliche Schätzungen bereits 15 bis 20 Tage nach Monatsende ermöglichen. Die Analyse zeigt, dass diese Verfahren eine zuverlässige und frühzeitige Einschätzung konjunktureller Entwicklungen zulassen und somit eine wertvolle Grundlage für politische und unternehmerische Entscheidungen bieten.

↳ **Keywords:** *manufacturing – nowcasting – timeliness – machine learning – imputation*

ABSTRACT

The $t+20$ project implemented by the Federal Statistical Office investigated methods to speed up the provision of economic indicators for the manufacturing sector. Using microdata-based models, including imputation methods and machine learning, and a macrodata-based dynamic factor model, the project's aim was to produce precise and reliable estimates as early as 15 to 20 days after the end of the preceding month. The analysis shows that these methods enable the early and reliable assessment of economic developments and therefore offer a valuable basis for political and business decisions.

Edesa Yadegar

hat International Economics and Economic Policy mit dem Schwerpunkt Statistik und Ökonometrie studiert und ist Wissenschaftliche Mitarbeiterin im Referat „Konjunktur der Industrie, Produktionsstatistik“ des Statistischen Bundesamtes. Sie befasst sich im $t+20$ -Projekt mit der beschleunigten Bereitstellung von Konjunkturindikatoren.

Kerstin Lange

hat Statistik studiert und ist Referentin im Referat „Künstliche Intelligenz, Big Data“ des Statistischen Bundesamtes. Sie entwickelt Verfahren zur Imputation und automatisierten Plausibilisierung, unter anderem aus dem Bereich des Maschinellen Lernens. Zudem berät sie bei deren Implementierung in die Statistikproduktion.

Bogdan Levagin

ist Data Scientist und Referent im Referat „Künstliche Intelligenz, Big Data“ des Statistischen Bundesamtes. Er befasst sich unter anderem mit dem Einsatz von Maschinellern Lernen, Big Data und Machine Learning Operations in der amtlichen Statistik.

Bayram Oruc

hat Volkswirtschaftslehre mit den Schwerpunkten Statistik, Ökonometrie und Makroökonomik studiert. In seiner Funktion als Referent im Referat „Konjunktur der Industrie, Produktionsstatistik“ des Statistischen Bundesamtes beschäftigt er sich unter anderem mit methodischen Fragestellungen zur Erhebung und Auswertung von Konjunkturstatistiken.

1

Einleitung

Zuverlässige Daten zur konjunkturellen Entwicklung in Deutschland sind essenziell, insbesondere in Krisenzeiten, wenn sich wirtschaftliche Rahmenbedingungen rasch und unvorhersehbar ändern. Unternehmen und politische Entscheidungsträger sind besonders dann auf aktuelle Informationen angewiesen, um schnell und gezielt reagieren, Risiken bewerten und wirtschaftliche Stabilität fördern zu können. Auch innerhalb der amtlichen Statistik – insbesondere in den Volkswirtschaftlichen Gesamtrechnungen (VGR) – besteht ein hoher Bedarf an zeitnahen Indikatoren, beispielsweise um für die erste Lageeinschätzung des Bruttoinlandsprodukts fundierte Schätzungen für noch nicht verfügbare Monatsdaten nutzen zu können. Die fortschreitende Digitalisierung eröffnet dabei neue Möglichkeiten, statistische Prozesse zu optimieren und methodische Ansätze weiterzuentwickeln, um sowohl die Verfügbarkeit als auch die Qualität aktueller Wirtschaftsdaten weiter zu steigern.

Im Projekt $t+20$ des Statistischen Bundesamtes wurde untersucht, inwiefern Konjunkturindikatoren beschleunigt bereitgestellt werden können.¹ Je nach Wirtschaftssektor unterscheiden sich die Veröffentlichungszeitpunkte. So wird der Umsatz im Einzelhandel 30 Tage nach Ende des Monats ($t+30$) veröffentlicht, während die Ergebnisse der Monatserhebung im Bauhauptgewerbe nach 55 Tagen ($t+55$) bereitstehen. Der Fokus des $t+20$ -Projektes lag auf dem Verarbeitenden Gewerbe, für das zum Zeitpunkt $t+45$ das vorläufige Umsatzaggregat² vorliegt, während der vorläufige Umsatzindex bereits zum Zeitpunkt $t+38$ verfügbar ist. Das Projekt $t+20$ hatte zum Ziel, das Umsatzaggregat im Verarbeitenden Gewerbe bereits 15 bis 20 Tage nach Abschluss des Berichtszeitraums bereitzustellen. Das Projekt identifizierte Beschleunigungspotenziale sowohl bei der Datenerhebung als auch bei den statistischen Methoden. Auf methodischer Ebene wurden

1 Ähnliche Untersuchungen wurden bereits mit spanischen Daten durchgeführt und sind in Salgado und andere (2023) sowie Barragán und andere (2022) veröffentlicht.
2 Das Umsatzaggregat bezeichnet in diesem Aufsatz den absoluten Umsatz im Gegensatz zum Umsatzindex. Dieses setzt sich aus den Umsätzen der Wirtschaftszweige (basierend auf Betriebsmeldungen) im Verarbeitenden Gewerbe zusammen.

verschiedene Hochrechnungs-, Imputations- und ökonomische Schätzverfahren – darunter ARIMA-Modelle sowie Dynamische Faktormodelle – ausgewertet. Dieser Beitrag präsentiert die relevantesten und vielversprechendsten Ansätze.

Kapitel 2 stellt zunächst die Datenstruktur und -grundlage der mikrodatenbasierten Modelle vor, die auf den von den Statistischen Ämtern der Länder erhobenen Daten der meldepflichtigen Betriebe beruhen und das Umsatzaggregat als Zielvariable haben. Dazu gehören die Darstellung der Ergebnisse maschineller Lernverfahren sowie weitere Optimierungsansätze verschiedener Imputationsverfahren. Der Einsatz dieser Modelle ist unerlässlich, da zum Zeitpunkt der frühzeitigen Schätzung bei $t+15$ etwa 50% und bei $t+20$ rund 35% der Meldungen noch nicht vorliegen; entsprechend müssen die fehlenden Werte modellgestützt imputiert werden. Anschließend werden in Kapitel 3 das aktuell eingesetzte Imputationsmodell erläutert und die Ergebnisse für den Prognosehorizont $t+20$ präsentiert³. Ergänzend dazu wird das makrodatenbasierte dynamische Faktormodell untersucht, das sowohl amtliche Statistiken als auch öffentlich verfügbare Zeitreihen anderer Datenanbieter verwendet, um Indizes als Zielgröße zu schätzen. Es dient als Benchmark und ermöglicht eine alternative, beschleunigte Bereitstellung von Konjunkturindikatoren am aktuellen Rand. Ein kurzes Fazit beschließt den Beitrag.

2

Mikrodatenbasierte Modelle

2.1 Datengrundlage

Die dem mikrodatenbasierten Ansatz zugrunde liegenden Daten fußen auf dem Monatsbericht für Betriebe des Verarbeitenden Gewerbes sowie des Bergbaus und der Gewinnung von Steinen und Erden (Statistisches Bundesamt, 2025a). An dieser monatlichen Erhebung, einer sogenannten Totalerhebung mit Abschneidegrenze, nehmen alle produzierenden Betriebe mit 50 und mehr

3 Zwischen $t+15$ und $t+20$ steigt die Verfügbarkeit amtlicher Meldungen stark an. Dies hebt die Datenqualität deutlich, was sich in einer signifikant verbesserten und robusteren Schätzung niederschlägt. Daher wird $t+15$ im aktuellen Verfahren nicht mehr verwendet.

tätigen Personen teil. Im Jahr 2024 waren dies rund 23 000 Betriebe. Die Erhebung umfasst unter anderem Angaben zu Umsätzen (untergliedert nach Inlands- und Auslandsumsatz sowie industriellen Hauptgruppen), zur Produktart und zum Absatz, zu den tätigen Personen sowie zu geleisteten Arbeitsstunden. Aus diesen Angaben werden monatlich unter anderem der absolute Umsatz sowie die Umsatzvolumenindizes und die Wertindizes berechnet. Diese Daten liefern wichtige Hinweise zur wirtschaftlichen Entwicklung in Deutschland, die unter anderem die Volkswirtschaftlichen Gesamtrechnungen, der Finanzsektor sowie Ministerien und Wirtschaftsverbände nutzen. Die Betriebe teilen sich in der tiefsten Aufbereitungseinheit auf in insgesamt etwa 32 000 fachliche Betriebsteile. Ein fachlicher Betriebsteil umfasst sämtliche Aktivitäten innerhalb eines Betriebes, die derselben Gruppe der Wirtschaftszweigklassifikation⁴ zugeordnet werden können. Diese Ebene bildet für die mikrodatenbasierten Modelle die Grundlage der Schätzung.

Bei dieser dezentralen Statistik melden die Betriebe ihre Daten zunächst an die Statistischen Ämter der Länder. Diese prüfen die Meldungen, plausibilisieren die Daten und übermitteln diese nach Abschluss eines Berichtsmonats an das Statistische Bundesamt. Die fehlenden Angaben von Betrieben ohne Meldung bis zu diesem Zeitpunkt werden durch die Statistischen Ämter der Länder mit dem Vormonatswert imputiert.

Die Datenbasis der Regressoren und der Zielvariable „Umsatz im Verarbeitenden Gewerbe“ des zu berechnenden Modells reicht zurück bis ins Jahr 2014. Bis einschließlich Juni 2022 lagen ausschließlich vollständig verfügbare Daten rückwirkend vor, keine Echtzeitinformationen. Seit Juli 2022 stehen Daten in Echtzeit zur Verfügung: Erstmals liegen Betriebsmeldungen für den jeweils aktuellen Berichtsmonat bereits während des Monats vor und bevor die regulären qualitätssichernden Prozesse der Statistischen Ämter der Länder – wie Plausibilisierungen, Rücksprachen mit den Betrieben und Imputationen fehlender Werte – (vollständig) durchgeführt wurden. Zum Zeitpunkt t+20 fehlen einerseits Meldungen der Betriebe, andererseits sind bereits gemel-

dete Werte noch nicht vollständig plausibilisiert. Der tagesaktuelle Zugriff auf Mikrodaten vor Abschluss eines Berichtsmonats ermöglichte eine methodische Weiterentwicklung, sodass im Zuge des Projektes schließlich ein erfolgreiches Imputationsverfahren auf Basis dieser Daten entwickelt werden konnte. Datenauszüge werden zu den Zeitpunkten t+15 (bis Juni 2024) und t+20 (fortlaufend) erstellt. Die Daten gliedern sich auf in

- › gemeldete und bereits plausibilisierte Werte,
- › gemeldete und nicht plausibilisierte Werte und
- › fehlende Werte.

➤ **Grafik 1** zeigt die Anteile der plausibilisiert vorliegenden Daten zu den Zeitpunkten t+15 beziehungsweise t+20, von denen die zu schätzenden Anteile abhängen: Je geringer der Anteil der plausibilisiert vorliegenden Meldungen, desto höher der Anteil der zu imputierenden Ergebnisse von fachlichen Betriebsteilen. Durch die Anpassung des Berichtskreises einmal jährlich bleiben die fachlichen Betriebsteile über das Jahr hinweg konstant. Allerdings können einzelne Betriebsteile in einem Monat bereits zu t+15 oder t+20 plausibilisiert vorliegen, während sie im nächsten Monat noch fehlen, und umgekehrt.

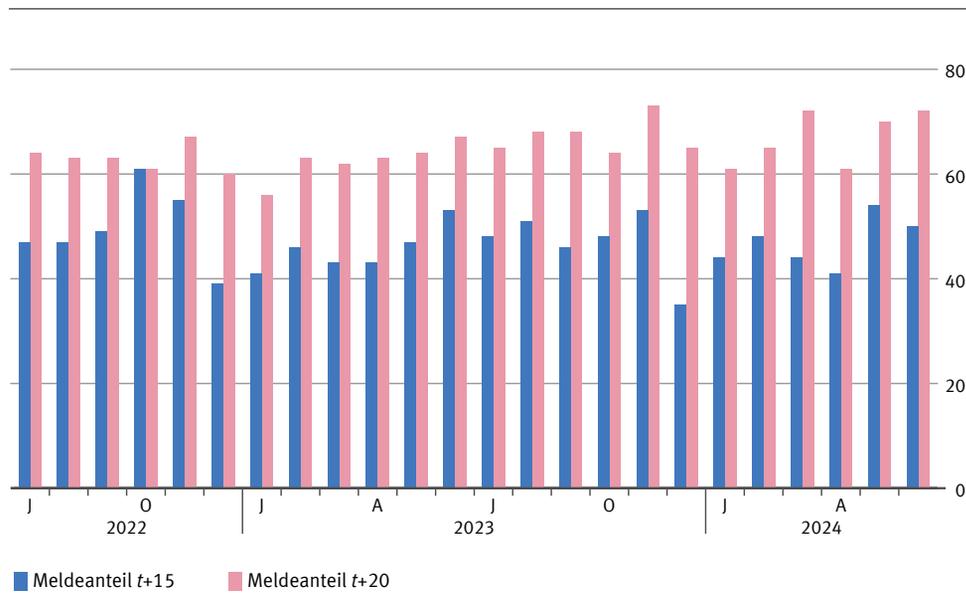
Bei den Schätzungen zum Zeitpunkt t+15 war der Anteil der plausibilisiert vorliegenden Daten so gering, dass eine Ausreißererkennung entwickelt und auf die noch nicht plausibilisierten Werte angewandt wurde. Deren Ziel war zu entscheiden, ob die noch nicht plausibilisierten Werte imputiert werden müssen oder ob sie, analog zu den bereits plausibilisierten Werten, bestehen bleiben können. Hierfür wurde die Vormonatsveränderungsrate des Umsatzes eines fachlichen Betriebsteils in Relation zu dessen Branchenergebnis (Wirtschaftszweig-4-Steller nach der WZ 2008) gesetzt, wodurch ein Korridor entstand. Werte, die innerhalb dieses Korridors lagen und demzufolge nicht als Ausreißer erkannt wurden, wurden wie bereits plausibilisierte Werte behandelt und nicht imputiert. Im anderen Fall wurden sie als fehlend betrachtet und entsprechend imputiert.

Herausfordernd bei der Datenlage ist, dass die bereits gemeldeten Werte im aktuellen Berichtsmonat systematisch verzerrt sein können. Insbesondere melden größere und heterogene Betriebe tendenziell spät, weshalb die vorhandenen Meldungen des jeweils aktuellen Berichtsmonats nicht ohne Zusatzinformationen aus

4 Der Erhebungsbereich des Monatsberichts umfasst die Abschnitte B und C der Klassifikation der Wirtschaftszweige, Ausgabe 2008 (WZ 2008; Statistisches Bundesamt, 2008), die rechtsverbindlich auf der europäischen Wirtschaftszweigklassifikation NACE Rev. 2 (Eurostat, 2008) aufbaut.

Grafik 1

Anteile plausibilisiert vorliegender Meldungen im Zeitverlauf
in %



t+15: 15 Tage nach Monatsende; t+20: 20 Tage nach Monatsende

vergangenen Berichtsmonaten zur Schätzung der fehlenden Werte geeignet sind. Vor diesem Hintergrund sind eine hohe Meldequote sowie die Verfügbarkeit von Daten aus allen Bundesländern für gute Schätzungen entscheidend.

Die Mikrodaten wurden über einen Zeitraum von mehr als zwei Jahren jeweils zu den Zeitpunkten $t+15$ und $t+20$ extrahiert, imputiert und in verschiedenen Modellansätzen evaluiert. Die Ergebnisse zeigen, dass zum Zeitpunkt $t+20$ im Durchschnitt rund 20 Prozentpunkte mehr plausibilisierte Betriebsmeldungen vorliegen als zu $t+15$ – ein Zuwachs, der sich unmittelbar in einer deutlich verbesserten Modellgüte und einer robusteren Schätzgenauigkeit niederschlägt. Durch die höhere Qualität der plausibilisiert vorliegenden Meldungen kann auf zusätzliche Korrekturmaßnahmen wie eine interne Ausreißererkennung verzichtet werden, ohne die Prognosegüte zu beeinträchtigen. Die Wahl von $t+20$ als Referenzzeitpunkt basiert daher primär auf methodischen Qualitätsgewinnen. Ergänzend wird dieser Zeitpunkt auch von den Volkswirtschaftlichen Gesamtrechnungen als hinreichend früh und qualitativ tragfähig eingeschätzt, um bei der Berechnung des Bruttoinlandsprodukts (BIP) Berücksichtigung zu finden – wobei die höhere Schätzqualität gegenüber einer

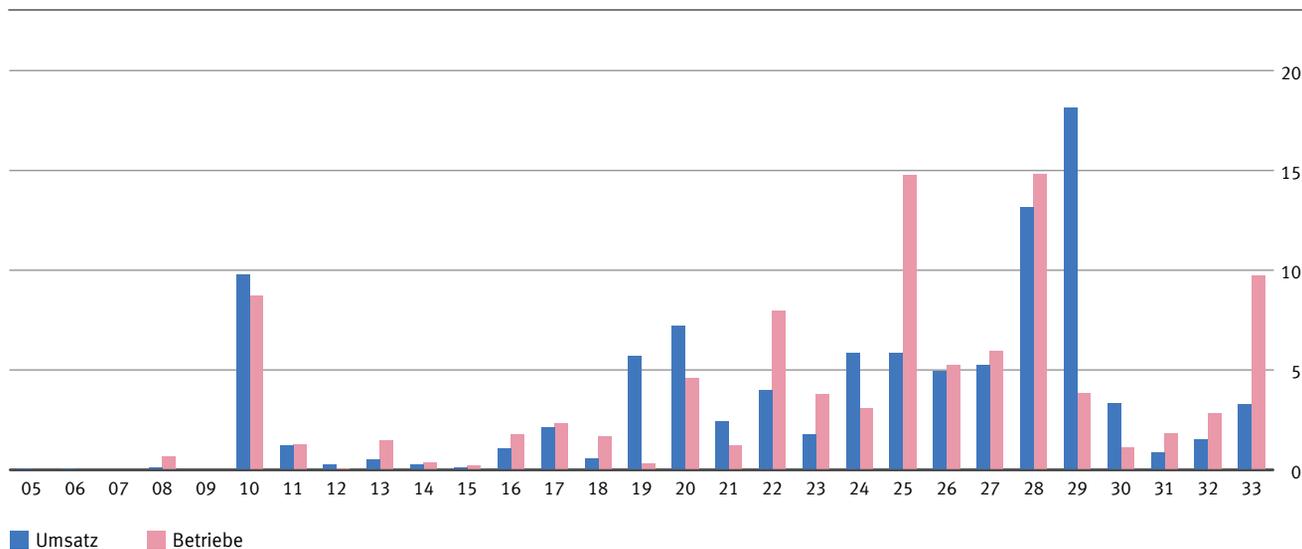
lediglich fünf Tage früheren Verfügbarkeit ($t+15$) klar überwiegt.

Aus diesem Grund fokussierten sich die Arbeiten darauf, das unbereinigte Umsatzaggregat des Verarbeitenden Gewerbes zu $t+20$ – und damit 25 Tage vor der bisherigen Veröffentlichung – zu berechnen und bereitzustellen.

Die Wirtschaftszweige unterscheiden sich erheblich in Bezug auf Umsatzhöhe, Unternehmensstruktur, Volatilität und ihren jeweiligen Anteil am Verarbeitenden Gewerbe. Aufgrund dieser Heterogenität wurde die Imputation wirtschaftszweigspezifisch auf der Ebene der 2-Steller durchgeführt, um branchenspezifische Muster adäquat zu berücksichtigen. Die ausgeprägte Heterogenität hinsichtlich der wirtschaftlichen Bedeutung und Größe der einzelnen Wirtschaftszweige lässt sich sowohl an den Umsatzanteilen der einzelnen 2-Steller am Gesamtumsatz dieser Abschnitte als auch am Anteil der Betriebe je Wirtschaftszweig erkennen. [↪ Grafik 2](#)

Grafik 2

Relevanz der Wirtschaftszweige
in %



2-Steller der Wirtschaftszweige B und C der Klassifikation der Wirtschaftszweige, Ausgabe 2008 (WZ 2008).
Untersuchter Zeitraum: Juli 2022 bis Juni 2024.

2.2 Methodische Tests

Ausgehend von den oben genannten deskriptiven Analysen wurde untersucht, welches Vorgehen und welche Methode die besten Schätzungen für das Umsatzaggregat erzielen könnten. Zudem wurde evaluiert, inwiefern sich die Schätzungen zu den Zeitpunkten $t+15$ und $t+20$ qualitativ unterscheiden und wie die Zielgröße möglichst genau geschätzt werden kann, um Ergebnisse zu veröffentlichen. Um die Verfahren zu bewerten wurden die Qualitätsdimensionen maschinellen Lernens in der amtlichen Statistik herangezogen: Genauigkeit, Robustheit, Erklärbarkeit, Reproduzierbarkeit, Aktualität und Pünktlichkeit sowie Wirtschaftlichkeit (Saidani und andere, 2023).

Die Evaluation der Genauigkeit der verschiedenen Verfahren erfolgt anhand zurückliegender Zeiträume. Dabei ist zu beachten, dass erstens Concept Drift⁵ auftreten kann und zweitens das Training der Modelle mit der Zeit rechenintensiver wird, weil jeden Monat neue Daten

⁵ Concept Drift beschreibt die Veränderung der zugrunde liegenden Verteilung der Daten über die Zeit, wodurch die trainierten Modelle an Genauigkeit verlieren. Dies kann sich auf die erklärenden Variablen (Feature Drift), die zu erklärende Variable (Target Drift) oder den Zusammenhang zwischen beiden Variablen (Posterior Drift) beziehen (Saidani und andere, 2023).

hinzukommen. Die Evaluation anhand zurückliegender Zeiträume ist dennoch sinnvoll, weil für diese Zeiträume zum Testzeitpunkt sowohl die plausibilisierten als auch die veröffentlichten Ergebnisse zur Verfügung stehen und somit für einen Vergleich nutzbar sind. Für den mit dem Schätzverfahren vervollständigten Datensatz wird dann die Summe aus dem Inlands- und Auslandsumsatz als Zielgröße berechnet. Dabei erfolgt zur Messung der Genauigkeit ein Vergleich mit den Ergebnissen, die das Statistische Bundesamt zum Zeitpunkt $t+45$ veröffentlicht. In diese $t+45$ -Ergebnisse flossen dementsprechend Meldungen ein, die nach den Zeitpunkten $t+15$ beziehungsweise $t+20$ eingegangen sind. Für den Vergleich werden die prozentuale Abweichung $\frac{A-P}{A}$ sowie die absolute prozentuale Abweichung $\frac{|A-P|}{|A|}$ (Botchkarev, 2019) je Monat berechnet. Dabei bezeichnet A den aktuell zum Zeitpunkt $t+45$ veröffentlichten Gesamtumsatz und P den durch das Schätzverfahren nach $t+15$ beziehungsweise $t+20$ berechneten Gesamtumsatz. Während die prozentuale Abweichung dazu dient festzustellen, ob über- oder unterschätzt wird, misst die absolute prozentuale Abweichung den Betrag der Schätzfehler.

Es wurden verschiedene Ansätze, Methoden und Kombinationen von Regressoren getestet und anhand der genannten Gütemaße evaluiert.

Zunächst wurden unterschiedliche Ansätze miteinander verglichen, um zu bewerten, welche Trainingsdaten für die Modellbildung genutzt werden und wie sich das unterschiedliche Trainingsmaterial auf die Genauigkeit der Schätzungen auswirkt. Dafür wurde ein Random-Forest-Modell verwendet, beginnend mit einem Modell, das einmalig trainiert auf alle Monate im Testzeitraum angewendet wurde. Ohne die gemeldeten Daten zu den Zeitpunkten $t+15$ beziehungsweise $t+20$ einzubeziehen, wurden alle Umsätze vom Modell geschätzt. Davon ausgehend wurde das Trainieren des Modells monatlich wiederholt und das Training für alle Daten bis zum vergangenen Monat durchgeführt, um dann den aktuellen Monatsmonat zu schätzen. Da dieses Vorgehen die bisher gemeldeten Daten zu den Zeitpunkten $t+15$ beziehungsweise $t+20$ noch nicht berücksichtigt, wurde die Datengrundlage zur Modellbildung um diese Daten erweitert, sodass nur die fehlenden Angaben geschätzt wurden. Die deskriptiven Analysen haben ergeben, dass sich die Umsätze und die erklärenden Merkmale stark nach Wirtschaftszweigen unterscheiden; daher wurden die genannten Ansätze zusätzlich so durchgeführt, dass Modelle je 2-Steller des Wirtschaftszweigs trainiert wurden. Die geringste mittlere absolute prozentuale Abweichung über alle Monate im Testzeitraum erzielt der Ansatz, bei dem für jeden Wirtschaftszweig ein Modell mit den vorliegenden Daten zu den Zeitpunkten $t+15$ beziehungsweise $t+20$ monatlich neu trainiert wurde.¹⁶

Mit diesem ausgewählten Ansatz wurden verschiedene Schätzmethoden auf ihre Eignung und ihre Leistung im vorliegenden Fall geprüft, davon werden vier Methoden näher vorgestellt:

1) Ein-Schritt-Verfahren:

- a) **Random Forest:** Die Zielvariable wird in einem iterativen Verfahren gemeinsam mit den Regressoren durch ein Random-Forest-Modell (Breiman, 2001) aus dem R-Paket „missRanger“ (Mayer, 2023) imputiert.

⁶ Einzelne Modelle nicht nach Wirtschaftszweigen zu trennen, sondern getrennt nach Unternehmensgrößenklassen zu schätzen, lieferte deutlich schlechtere Ergebnisse.

- b) **Lineare Regression:** Die Zielvariable wird in einem iterativen Verfahren gemeinsam mit den Regressoren durch ein Lineares Regressionsmodell aus dem R-Paket „mice“ (Multivariate Imputation by Chained Equations; van Buuren, 2023) imputiert (siehe Abschnitt 2.3).

2) Zwei-Schritt-Verfahren:

- a) **Random Forest mit imputierten Regressoren:** Imputation der Regressoren durch das R-Paket „mice“ mittels Linearer Regression und anschließende Anwendung des Random-Forest-Modells aus dem R-Paket „ranger“ (Wright, 2023), um die Zielvariable zu schätzen.
- b) **Lineare Regression mit imputierten Regressoren:** Imputation der Regressoren mittels Linearer Regression durch das R-Paket „mice“ und anschließende Anwendung des Linearen Regressionsmodells aus dem R-Paket „caret“ (Kuhn, 2024), um die Zielvariable zu schätzen.

Bei der Anwendung des Ein-Schritt-Verfahrens werden alle fehlenden Werte in den Daten (Regressoren sowie zu schätzende Umsätze) in einem iterativen Verfahren simultan geschätzt (siehe Abschnitt 2.3).

Die Implementierungen, die bei den beiden Zwei-Schritt-Verfahren genutzt werden (2a und 2b), sind so ausgerichtet, dass sie lediglich eine Zielgröße schätzen können; das ist im hier dargestellten Fall die Summe aus Inlands- und Auslandsumsatz.¹⁷ Die zu einer guten Schätzung dieser Zielgröße benötigten Regressoren (siehe Abschnitt 2.3) weisen ebenfalls Lücken in den Daten auf. Diese Situation können die Funktionen aus den R-Paketen „ranger“ und „caret“ nicht meistern, deshalb ist eine vorherige Imputation der Regressoren nötig. Die Regressoren wurden aus diesem Grund zuvor mit der Linearen Regression aus dem R-Paket „mice“ geschätzt, um eine anschließende Imputation der Umsätze mit den jeweiligen Verfahren zu ermöglichen. Dieses Vorgehen hat den Nachteil, dass fehlende Werte bei der Zielgröße und bei den Regressoren nicht im gleichen Schritt imputiert werden können und verschiedene Methoden aufeinander aufbauen. So werden imputierte Werte bei den Regressoren bei der Imputation der Zielgröße wie

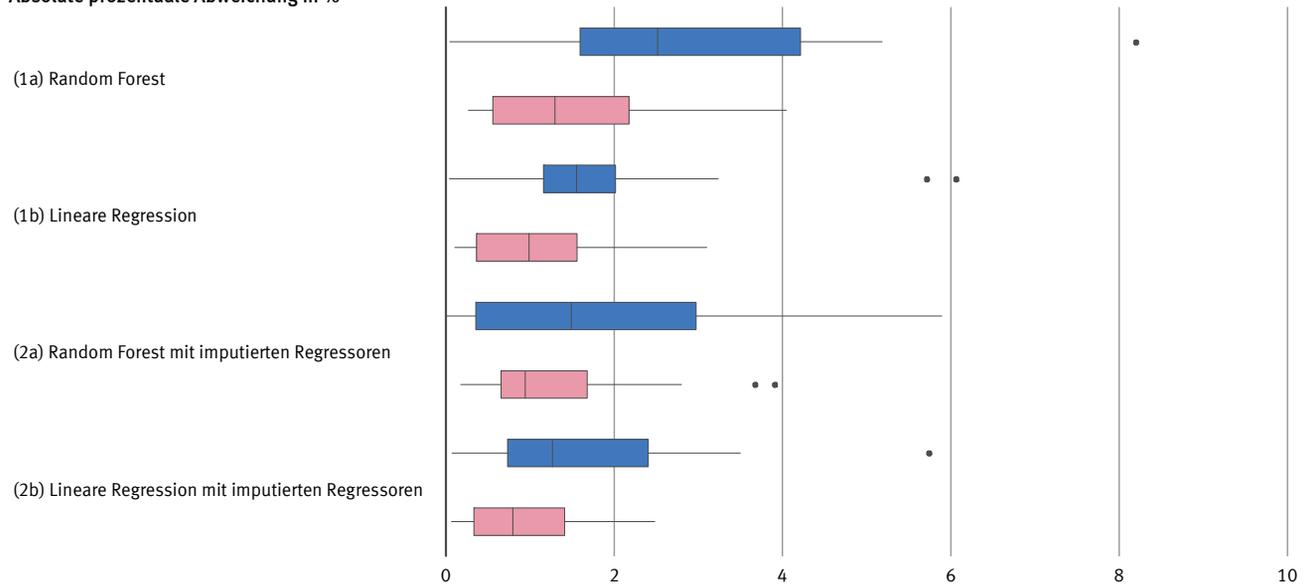
⁷ Inlands- und Auslandsumsatz einzeln zu schätzen und nachfolgend zu summieren hat die Evaluationskennzahl nicht verbessert. Auch das Vorgehen, Inlands- und Auslandsumsatz jeweils in mehreren Teilschritten zu imputieren, lieferte keine guten Ergebnisse.

t+20 – ein Projekt zur Schnellschätzung von Konjunkturindikatoren

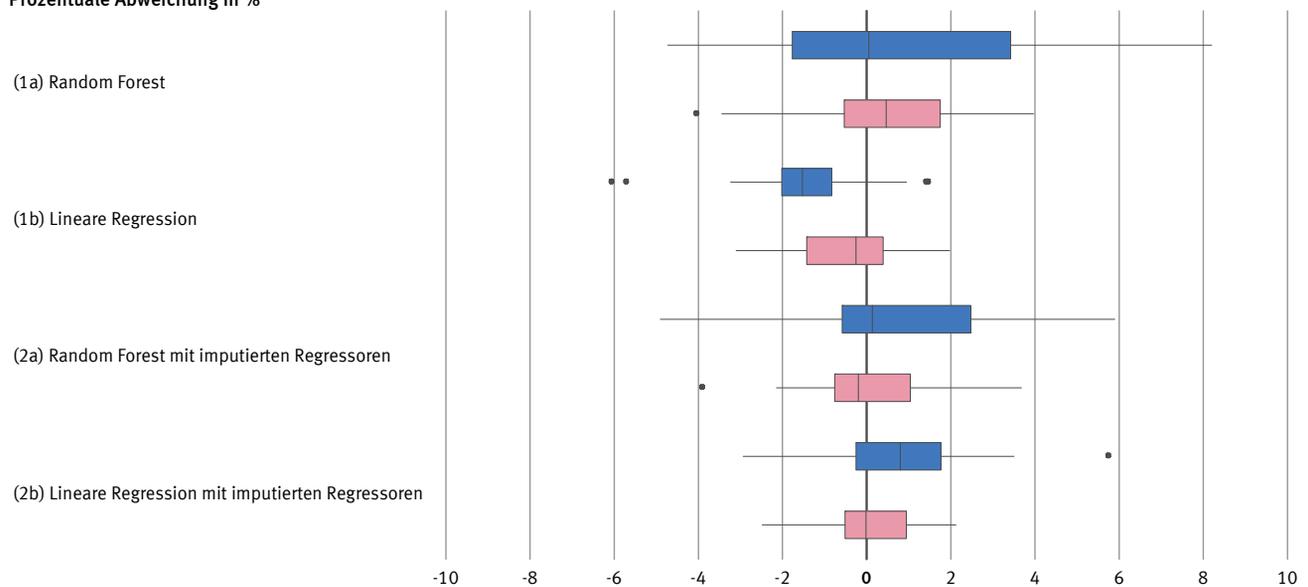
Grafik 3

Abweichungen der Schätzungen zu den Zeitpunkten t+15 und t+20 im Vergleich zu den veröffentlichten Ergebnissen zum Zeitpunkt t+45

Absolute prozentuale Abweichung in %



Prozentuale Abweichung in %



■ t+15 ■ t+20

t+15: 15 Tage nach Monatsende; t+20: 20 Tage nach Monatsende; t+45: 45 Tage nach Monatsende.

beobachtete Werte bei der Modellbildung behandelt und die Unsicherheiten, die mit der Imputation einhergehen, unterschätzt.

Die Auswertungen zur absoluten prozentualen Abweichung und zur prozentualen Abweichung wurden im Vergleich der vier Methoden für die Zeitpunkte $t+15$ sowie $t+20$ durchgeführt. [↘ Grafik 3](#)

Die in diesem Abschnitt in den Boxplots und Tabellen dargestellten Ergebnisse wurden mit der Auswahl an Regressoren, die in Abschnitt 2.3 vorgestellt werden, durchgeführt. Alle Berechnungen wurden in der Programmiersprache R durchgeführt.

Im Vergleich der beiden Zeitpunkte ist deutlich zu erkennen, dass die Abweichungen zwischen den Schätzungen und dem jeweils veröffentlichten Ergebnis für die $t+20$ -Schätzung über alle Methoden geringer ausfallen. Dies ist erwartbar, da zum Zeitpunkt $t+20$ durchschnittlich etwa 20 Prozentpunkte mehr plausibilisierte Daten vorliegen und somit zum einen der Anteil der zu schätzenden Betriebe deutlich geringer ist (siehe Grafik 1) und zum anderen mehr aktuelles Trainingsmaterial für den aktuell zu schätzenden Monat zur Verfügung steht. Die Genauigkeit der Schätzung fünf Tage später ist erheblich besser – je nach Methode um durchschnittlich 0,71 bis 1,12 Prozentpunkte. Dieser Qualitätsunterschied gibt den Ausschlag für die Entscheidung, die aktuellen Schätzungen zum Zeitpunkt $t+20$ auszuführen.

Bei der absoluten prozentualen Abweichung ist sehr gut zu erkennen, dass die linearen Modelle besser als die nicht linearen Modelle abschneiden. Der Hauptgrund hierfür sind die genutzten erklärenden Variablen, die einen starken linearen Zusammenhang zur Zielvariable aufzeigen. Außerdem kann der Random Forest nur Werte innerhalb des beobachteten Wertebereichs der Zielvariablen vorhersagen, wohingegen die Lineare Regression außerhalb des Wertebereichs extrapolieren kann. Die besten Methoden sind deshalb das Zwei-Schritt-Verfahren mit der Linearen Regression und den imputierten Regressoren (2b) und das Ein-Schritt-Verfahren mit der Linearen Regression (1b), unter anderem auch wegen der niedrigeren Standardabweichung. [↘ Tabelle 1](#) Zudem ist gut zu sehen, dass die maximale absolute prozentuale Abweichung bei (1b) und (2b) niedriger ist als bei den anderen Verfahren. Das spricht für die Robustheit des Verfahrens. Die prozentuale Abweichung zeigt auf, ob die Verfahren tendenziell unter- oder überschätzen.

Bei den Schätzungen zum Zeitpunkt $t+20$ liegt die durchschnittliche prozentuale Abweichung bei allen Verfahren nahe Null. Daher gibt es keine Anzeichen für eine systematische Verzerrung in Richtung einer Unter- oder Überschätzung.

Die finale Auswahl des Verfahrens erfolgte unter Berücksichtigung des Fachaufsatzes zu Qualitätsdimensionen (Saidani und andere, 2023). Bezüglich Reproduzierbarkeit, Aktualität und Pünktlichkeit erfüllen die beiden Verfahren (1b) und (2b) die Anforderungen gleichermaßen. Beide Verfahren sind in der Lage, immer wieder gleiche Ergebnisse innerhalb der geforderten Zeit zu generieren. Anhand der Ergebnisse der absoluten prozentualen Abweichungen schneidet (2b) etwas besser ab als (1b), jedoch weist die gemeinsame Imputation aller Merkmale in einem Schritt (1b) durch das R-Paket „mice“ in den Bereichen Erklärbarkeit und Wartung mehr Stärken auf. Da die Implementierung der Linearen Regression von „mice“ die komplette Schätzung in einem Schritt durchführt, ist dieses Verfahren besser nachzuvollziehen und zeitlich effizienter. Das bringt auch eine einfachere Wartung mit sich, wohingegen (2b) weitere Datenvorverarbeitungsschritte benötigt und somit komplexer aufgebaut ist. Weiterhin konnte in hier nicht dargestellten Untersuchungen beobachtet werden, dass (1b) robuster ist, vor allem wenn die Datengrundlage aufgrund fehlender Betriebsmeldungen zum Zeitpunkt $t+20$ verstärkt Datenlücken aufzeigt. Aus diesen Gründen wird das Ein-Schritt-Verfahren mit der Linearen Regression (1b) ausgewählt.

Während des Entwicklungsprozesses wurden verschiedene Kombinationen von Regressoren getestet und dabei auch Regressoren aus anderen Datenquellen angespielt. Auf die Regressoren, die zu den besten Evaluationskennzahlen und zur Verwendung der oben genannten Ergebnisse geführt haben, geht der folgende Abschnitt näher ein.

t+20 – ein Projekt zur Schnellschätzung von Konjunkturindikatoren

Tabelle 1

Verteilungskennzahlen der Schätzungen zu den Zeitpunkten t+15 und t+20 im Vergleich zu den veröffentlichten Ergebnissen zum Zeitpunkt t+45

Zeitpunkt der Schätzung	Methode zur Schätzung der Umsätze	Minimum	1. Quartil	Median	Mittelwert	3. Quartil	Maximum	Standardabweichung
absolute prozentuale Abweichung								
t+15	(1a) Random Forest	0,05	1,59	2,52	2,68	4,22	8,20	1,97
	(1b) Lineare Regression	0,04	1,16	1,55	1,90	2,02	6,06	1,44
	(2a) Random Forest mit imputierten Regressoren	0,01	0,36	1,49	2,09	2,97	5,89	1,89
	(2b) Lineare Regression mit imputierten Regressoren	0,07	0,73	1,27	1,66	2,40	5,74	1,34
t+20	(1a) Random Forest	0,27	0,56	1,30	1,56	2,18	4,05	1,25
	(1b) Lineare Regression	0,11	0,37	0,99	1,07	1,56	3,10	0,84
	(2a) Random Forest mit imputierten Regressoren	0,18	0,66	0,94	1,29	1,68	3,91	1,03
	(2b) Lineare Regression mit imputierten Regressoren	0,07	0,33	0,79	0,95	1,41	2,48	0,73
prozentuale Abweichung								
t+15	(1a) Random Forest	- 4,73	- 1,77	0,06	0,75	3,42	8,20	3,28
	(1b) Lineare Regression	- 6,06	- 2,02	- 1,53	- 1,55	- 0,83	1,46	1,82
	(2a) Random Forest mit imputierten Regressoren	- 4,91	- 0,58	0,14	0,89	2,48	5,89	2,70
	(2b) Lineare Regression mit imputierten Regressoren	- 2,93	- 0,25	0,80	0,83	1,76	5,74	1,99
t+20	(1a) Random Forest	- 4,05	- 0,53	0,46	0,41	1,75	3,97	1,98
	(1b) Lineare Regression	- 3,10	- 1,42	- 0,25	- 0,50	0,39	1,97	1,28
	(2a) Random Forest mit imputierten Regressoren	- 3,91	- 0,76	- 0,20	0,09	1,04	3,68	1,67
	(2b) Lineare Regression mit imputierten Regressoren	- 2,48	- 0,51	- 0,01	0,04	0,95	2,12	1,21

2.3 Aktuelle Methodik

Zur Imputation fehlender Daten wurden verschiedene Verfahren getestet. Dabei hat sich die regressionsbasierte Methode aus dem R-Paket „mice“ (van Buuren, 2018, 2023) aufgrund der aufgelisteten Qualitätsdimensionen in Abschnitt 2.2 als ideale Lösung erwiesen.

Konkret kommt die Funktion `norm.predict` des Pakets „mice“ (Version 3.16.0) zum Einsatz – eine deterministische Methode zur Imputation metrischer Variablen, die auf einem linearen Regressionsmodell beruht. Dabei wird angenommen, dass zwischen den zu imputierenden Merkmalen und ihren jeweiligen Regressoren ein linearer Zusammenhang besteht. Die Regressionskoeffizienten werden mittels der Methode der kleinsten Quadrate auf Basis der beobachteten Werte und relevanter Regressoren geschätzt. Fehlende Werte werden anschließend durch die exakten Vorhersagen aus dem Modell ersetzt, ohne zufällige Variation oder Berücksichtigung von Schätzunsicherheiten.

Die regressionsbasierte Imputation (1b) erfolgt auf Ebene der fachlichen Betriebsteile und nutzt separate Modelle für jeden 2-Steller des Wirtschaftszweigs. Das Ergebnis dieser Imputation ist ein vollständiger Mikrodatensatz. Für diesen werden im Anschluss die Gesamtumsätze (bestehend aus Inlands- und Auslandsumsätzen) addiert, sodass am Ende ein aggregiertes Ergebnis über alle Wirtschaftszweige (2-Steller) hinweg vorliegt, das den absoluten Umsatz für das gesamte Bundesgebiet ausweist.

➤ **Übersicht 1** gibt einen Überblick über die im Modell verwendeten Regressoren. Diese wurden auf Basis theoretischer Überlegungen sowie empirischer Befunde ausgewählt, um die zugrunde liegenden Zusammenhänge möglichst präzise zu erfassen. Jeder Regressor repräsentiert einen spezifischen Einflussfaktor, dessen Wirkung auf die abhängige Variable quantifiziert wird.

Die Regressoren des Imputationsmodells berücksichtigen sowohl zeitliche als auch strukturelle Einflussfaktoren, um die Dynamik der Zielvariablen adäquat abzubilden. Wesentliche Bestandteile des Modells sind zeitliche Komponenten, welche die Entwicklung des Umsatzes über verschiedene Perioden hinweg erfassen. Der Vormonatwert und der Vorjahreswert der Zielvariablen dienen hierbei als zentrale Regressoren, da sie sowohl kurzfristige als auch längerfristige Trends und saisonale Muster abbilden. Ergänzend werden gleitende Durchschnitte⁸ des Umsatzes über Zeiträume von drei und zwölf Monaten herangezogen, um zufällige Schwankungen zu glätten und verlässliche Muster in der Umsatzentwicklung zu identifizieren. Neben der Umsatzhistorie spielen weitere wirtschaftliche Einflussgrößen eine bedeutende Rolle. So wird der gleitende Durchschnitt des Auftragseingangs über eine sechsmonatige Periode herangezogen, um saisonale Muster in der Auftragseingangsentwicklung zu identifizieren.

⁸ Berechnung des Durchschnitts über einen festgelegten Zeitraum, der kontinuierlich aktualisiert wird. Gleitende Durchschnitte dienen dazu, kurzfristige Schwankungen zu glätten und langfristige Trends besser erkennbar zu machen. In diesem Zusammenhang werden gleitende Durchschnitte über drei und zwölf Monate verwendet, um saisonale und zufällige Umsatzschwankungen zu reduzieren und verlässliche Muster in der Umsatzentwicklung abzuleiten.

Übersicht 1

Regressoren des ausgewählten Imputationsmodells

Regressor	Erläuterungen
Quantile des Umsatzes	Gleitende 12-Monatsdurchschnitte des Umsatzes werden für jeden fachlichen Betriebsteil (FBT) berechnet und innerhalb des Wirtschaftszweiges (WZ) 2-Steller in Umsatzgruppen eingeteilt.
Vormonatwert der Zielvariablen	auf Basis FBT
Vorjahreswert der Zielvariablen	auf Basis FBT
Gleitende Durchschnitte Auftragseingang	sechsmonatige Periode, skaliert zwischen 0 und 1 auf Basis FBT, ausgerichtet auf Zielvariable (Inland/Ausland)
Gleitende Durchschnitte Umsatz	dreimonatige Periode, skaliert zwischen 0 und 1 auf Basis FBT, ausgerichtet auf Zielvariable (Inland/Ausland)
Vormonatwert Preise	auf Basis WZ 4-Steller (FBT), ausgerichtet auf Zielvariable (Inland/Ausland)
Kalenderfaktoren	monatlich auf Basis des schwerpunktmäßigen WZ 4-Stellers, ausgerichtet auf Zielvariable (Inland-/Ausland)
Art der Einheit	Einbetriebs-/Mehrbetriebsunternehmen
Bundesland	Kategoriale Variable
Vormonatwert der tätigen Personen	Skaliert zwischen 0 und 1
Zeitfixierte Effekte	Berichtsjahr und Berichtsmont fließen als separate Regressoren ins Modell ein.

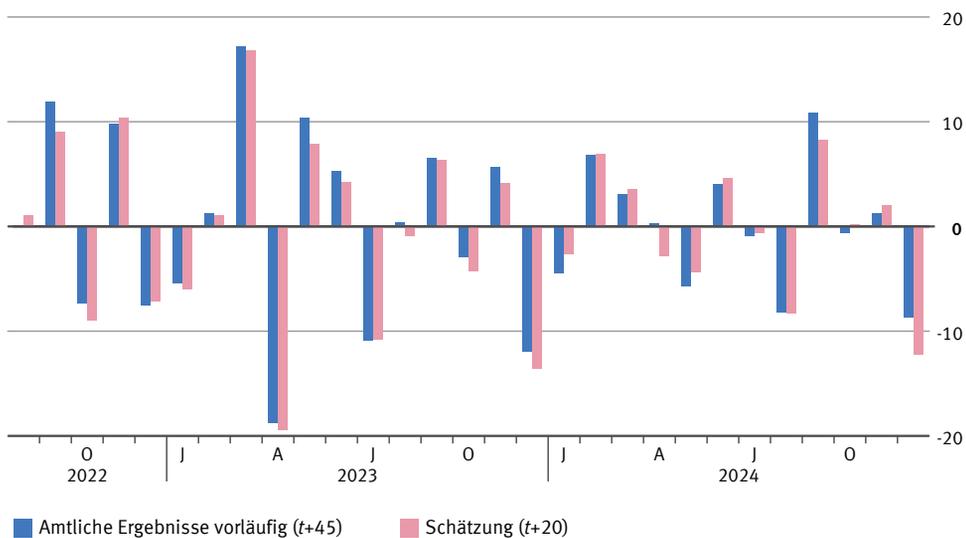
natige Periode als Frühindikator für künftige Umsätze berücksichtigt. Ebenso werden Preisentwicklungen in die Modellierung einbezogen, indem der Vormonatswert der Inlandspreise auf Basis des Wirtschaftszweigs auf vierstelliger Ebene berücksichtigt wird. Diese Variable trägt dazu bei, die Effekte von Preisveränderungen auf die Umsatzentwicklung zu quantifizieren. Um strukturelle Unterschiede zwischen Betrieben zu erfassen, werden zudem kategoriale Variablen wie die Art der Einheit (Einbetriebs- oder Mehrbetriebsunternehmen) sowie das Bundesland einbezogen.

Diese Variablen erlauben es, die Betriebe nach Unternehmensstruktur und regionalen wirtschaftlichen Rahmenbedingungen zu differenzieren. Darüber hinaus werden kalenderbedingte Effekte berücksichtigt, die sich aus unterschiedlichen Monatskonstellationen, Feiertagen oder saisonalen Besonderheiten ergeben. Schließlich wird durch die Einbeziehung der Zahl der tätigen Personen als skaliertes Vormonatswert ein weiterer betrieblicher Indikator herangezogen, der die Produktionskapazität und damit potenzielle Umsatzveränderungen widerspiegelt. Um systematische, zeitliche Effekte zu erfassen und das Modell an langfristige Entwicklungen anzupassen, werden zudem zeitfixierte

Effekte für Berichtsjahr und Berichtsmontat integriert. Diese umfassende Auswahl an Regressoren ermöglicht eine Imputation der fehlenden Werte, die die Struktur der Wirtschaftszweige und Bundesländer berücksichtigt, indem sowohl ökonomische Zusammenhänge als auch betriebliche Strukturen adäquat abgebildet werden. Die Kombination dieser erklärenden Variablen erlaubt es, die Umsatzentwicklung der fachlichen Betriebsteile mit hoher Präzision zu schätzen und so eine verlässliche Datengrundlage für weiterführende Analysen zu schaffen. Herausfordernd bleibt jedoch weiterhin, dass die bereits gemeldeten Werte im aktuellen Berichtsmontat keine adäquate Stichprobe der Grundgesamtheit darstellen. Da größere und heterogene Betriebe dazu tendieren, ihre Meldungen später abzugeben, sind die bereits gemeldeten Umsätze im aktuellen Monat nicht repräsentativ und eignen sich daher nicht als Regressoren, um die fehlenden Werte des jeweiligen Monats optimal zu schätzen.

➤ Grafik 4 bildet die Vormonatsveränderungsraten der t+20-Schätzungen im Vergleich zu den vorläufig veröffentlichten amtlichen Ergebnissen zum Zeitpunkt t+45 über den gesamten Betrachtungszeitraum ab. Diese Gegenüberstellung ermöglicht eine detaillierte Analyse

Grafik 4
Ergebnisse des Imputationsverfahrens (1b) zum Zeitpunkt t+20 im Vergleich zu den vorläufigen amtlichen Ergebnissen zum Zeitpunkt t+45
Veränderungsraten des Umsatzes in %



t+20: 20 Tage nach Monatsende; t+45: 45 Tage nach Monatsende.

der Schätzgenauigkeit und zeigt die Abweichungen zwischen den frühzeitigen Schätzungen und den vorläufigen Ergebnissen. Monate, in denen die Meldequote bedeutend niedriger als üblich war oder in denen Meldungen aus einzelnen Bundesländern vollständig fehlten, führten zu größeren Abweichungen. Zudem werden die starken Schwankungen des Umsatzes deutlich, die von einem Monat zum anderen auftreten können und eine Herausforderung für die Schätzungen darstellen. Nach einer Auswertung von insgesamt 30 Monaten liegt der Mittelwert der absoluten prozentualen Abweichung bei 1,1% und der Mittelwert der prozentualen Abweichung bei -0,54%.

3

Dynamische Faktormodelle: methodische Tests auf Makroebene

Dieses Kapitel zielt auf die Nutzung von eng mit der Umsatzentwicklung verknüpften Konjunkturindikatoren ab und verfolgt dabei einen ökonometrischen Ansatz. Die mikrodatenbasierten Schätzungen des Umsatzaggregats im Verarbeitenden Gewerbe (siehe Kapitel 2) ergänzend umfasst das Projekt $t+20$ hierbei eine Schätzung konjunktureller Indikatoren auf der Makroebene: Geschätzt wurden die Veränderungsraten des kalender- und saisonbereinigten Umsatzvolumenindex des Verarbeitenden Gewerbes und Bergbaus sowie des Produktionsindex des Verarbeitenden Gewerbes, Bergbaus und der Gewinnung von Steinen und Erden gegenüber dem Wert des vorangegangenen Monats mithilfe eines Dynamischen Faktormodells (DFM). Erste vorläufige amtliche Veröffentlichungen dieser Konjunkturindikatoren erfolgen in der Regel erst 38 Tage (Konjunkturindizes werden vor dem Monatsbericht veröffentlicht) nach Abschluss des Berichtsmonats. Dagegen ermöglicht es das Dynamische Faktormodell, bereits 15 Tage nach Monatsende erste belastbare Schätzungen auf Basis großer Datenmengen bereitzustellen. Dabei ist zu beachten, dass die amtlichen Veröffentlichungen der Konjunkturindizes zu $t+38$ als vorläufige Werte dienen und nochmals revidiert werden.

Dynamische Faktormodelle stellen den Standard in der Literatur zu zeitreihenökonometrischen Prognosen dar (zum Beispiel Bańbura und andere, 2013). Sie zielen darauf ab, aus einer Vielzahl von beobachtbaren Zeit-

reihen sogenannte co-movements, also gemeinsame Bewegungsmuster oder Trends, die in mehreren Variablen gleichzeitig erkennbar sind, zu extrahieren und in einer kleineren Anzahl latenter, nicht direkt beobachtbarer Faktoren zusammenzufassen.

Die Schätzung der Faktoren und ihrer Dynamik erfolgt mittels des Kalman-Filters. Diese rekursive Methode ermöglicht es, auch bei unvollständigen Daten optimale Schätzungen (im Sinne der Minimierung der mittleren quadratischen Abweichung zwischen beobachteten und geschätzten Werten) zu liefern und somit mit der zeitlichen Asynchronie umzugehen. Dabei werden drei Faktoren zugrunde gelegt, die einem autoregressiven Pro-

Übersicht 2

Liste der Modelltreiber für das Dynamische Faktormodell

Produktionsindex (preis-, kalender- und saisonbereinigt), Industrie

Umsatzindex (preis-, kalender- und saisonbereinigt), Wirtschaftsabschnitte B + C

AuftragseingangsindeX, Wirtschaftsabschnitt C

Lkw-Maut-Fahrleistungsindex

Pkw-Neuzulassungen (kalender- und saisonbereinigt)

Pkw-Exporte (kalender- und saisonbereinigt)

Exporte

Importe

Verbraucherpreise, ohne Energie

Erzeugerpreise, ohne Energie

WTI Öl Preis

EUR/USD Wechselkurs (Monatsdurchschnitt)

Geleistete Arbeitsstunden, Industrie

BA-X Job Index Unbesetzter Stellen

Arbeitslosenrate

Ifo-Geschäftsklima (Total)

Ifo-Geschäftsklima (Verarbeitendes Gewerbe)

Ifo-Exporterwartungen (3 Monate)

Ifo-Produktionserwartungen (3 Monate)

Ifo-Erwartungen über Anzahl der Mitarbeiter

S&P Einkaufsmanagerindex (Aufträge)

S&P Einkaufsmanagerindex (Produktion)

Eurostat Geschäftsklima Indikator

Eurostat Konsumentenzufriedenheit Dienstleistungen

DG ECFIN Beschäftigungserwartungsindikator

OECD MEI Nachfrageerwartungen

ZEW Wirtschaftserwartung

GfK Konsumklima

GfK Wirtschaftserwartungen

zess zweiter Ordnung folgen. Verschiedene alternative Setups bezüglich der Anzahl an Faktoren oder die *lag order* des autoregressiven Prozesses wurden getestet, konnten jedoch die Prognosegüte dieses Modells nicht übertreffen.

Bei der Auswahl geeigneter Zeitreihen für die Modellierung werden insgesamt 29 Modelltreiber⁹, die starke gemeinsame Bewegungsmuster mit den Zielvariablen aufweisen, zugrunde gelegt. Die Modelltreiber stammen aus verschiedenen Bereichen, darunter amtliche Statistiken, externe quantitative Umfragedaten und externe qualitative Umfragedaten, und spiegeln so die unterschiedlichen Dimensionen wirtschaftlicher Aktivität wider. [↪ Übersicht 2](#) Ein zentrales Merkmal des hier beschriebenen Ansatzes ist, dass die verwendeten Modelltreiber am aktuellen Rand oft früher verfügbar sind als die Zielvariablen – ein Phänomen, das als „ragged edge“ bekannt ist.

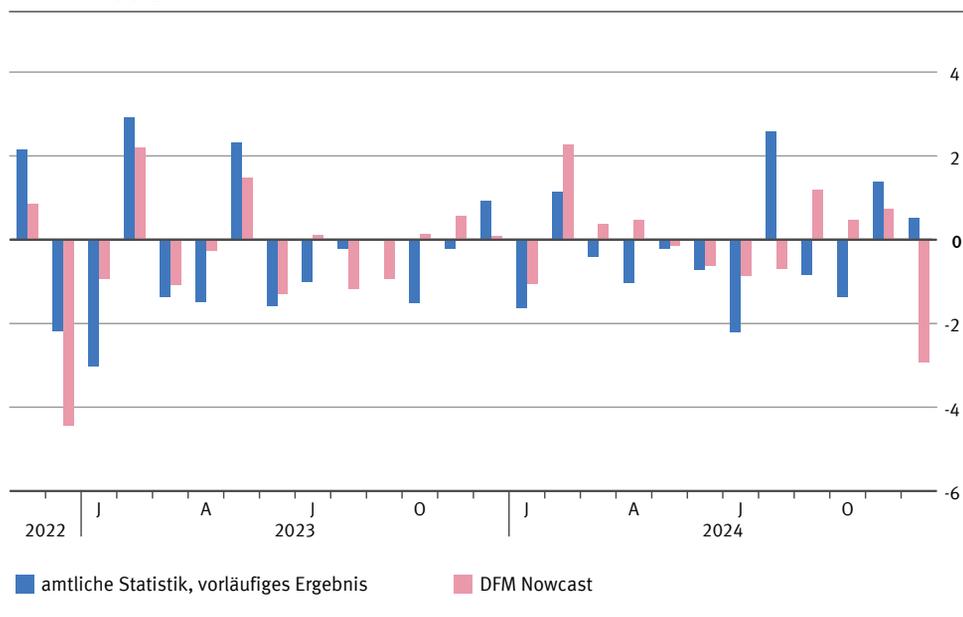
Für die Evaluierung der Prognosegüte des Dynamischen Faktormodells wurde ein Schätzzeitraum von 26 Mona-

⁹ Die Auswahl der Modelltreiber basiert auf einer Analyse der ökonomischen Wechselwirkungen zwischen den einzelnen Variablen sowie einer statistischen Auswertung von Zusammenhangsmaßen.

ten zugrunde gelegt. Die erste Schätzung erfolgte für den Berichtsmonat November 2022. Die in [↪ Grafik 5](#) (Umsatzvolumenindex) und [↪ Grafik 6](#) (Produktionsindex) dargestellten Vormonatsveränderungsraten zeigen die mit dem Dynamischen Faktormodell geschätzten Werte im Vergleich zu den vorläufigen amtlichen Ergebnissen. Nach Auswertung der 26 Monate ergibt sich ein MAE (Mean Absolute Error) von 1,23 beim Umsatzvolumenindex und 1,26 beim Produktionsindex. Ergänzend dazu liegt der RMSE (Root Mean Square Error) beim Umsatzvolumenindex bei 1,49 und beim Produktionsindex bei 1,59. Es ist dabei zu beachten, dass insbesondere in der zweiten Hälfte des Berichtsjahres 2024 die Vorzeichen der Veränderungsraten gegenüber dem Vormonat nicht immer korrekt vorhergesagt werden. Das Einbeziehen von Indikatoren mit vorlaufenden Eigenschaften – wie etwa dem Auftragseingang oder dem Lkw-Maut-Fahrleistungsindex (Cox und andere, 2020) –, die als Frühindikatoren wichtige Impulse liefern, verbesserte die Prognosegüte.

Das Dynamische Faktormodell stellt hier keine methodische Alternative zu den zuvor diskutierten mikrodatenbasierten Ansätzen dar. Vielmehr dient es – auf Basis allgemein verfügbarer Makrodaten – als Bench-

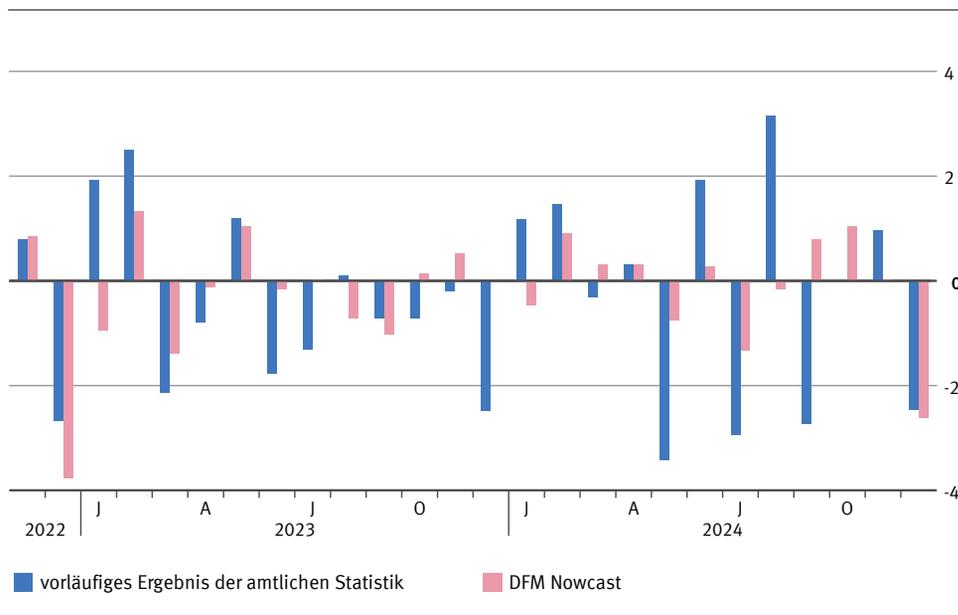
Grafik 5
Umsatzvolumenindex
Veränderung gegenüber dem Vormonat in %



Schätzergebnisse des Dynamischen Faktormodells (DFM) für den kalender- und saisonbereinigten Umsatzvolumenindex im Vergleich zum vorläufigen Wert der amtlichen Statistik.

Grafik 6

Produktionsindex
Veränderung gegenüber dem Vormonat in %



Schätzergebnisse des Dynamischen Faktormodells (DFM) für den kalender- und saisonbereinigten Produktionsindex im Vergleich zum vorläufigen Wert der amtlichen Statistik.

mark, um das Potenzial einer beschleunigten Indikatorbereitstellung unter veränderten Datenvoraussetzungen exemplarisch aufzuzeigen. Dabei ist zu berücksichtigen, dass die hier genannten Kennzahlen aufgrund der abweichenden Daten- und Zielgrößenbasis nur begrenzt mit jenen der mikrodatenbasierten Modelle vergleichbar sind.

4

Fazit

Das Projekt $t+20$ hat gezeigt, dass es möglich ist, die Konjunkturindikatoren Umsatz und Produktion im Verarbeitenden Gewerbe mithilfe von mikro- und makrodatenbasierten Modellen zuverlässig und zu einem frühen Zeitpunkt zu schätzen. Dabei wurden regressionsbasierte Imputationsverfahren, Verfahren des Maschinellen Lernens sowie Dynamische Faktormodelle untersucht. Als beste Methode hat sich aufgrund der besseren Erklärbarkeit und einfacheren Wartung das mikrodatenbasierte Modell erwiesen, bei dem die Werte mittels Linearer Regression in einem Schritt geschätzt

wurden. Dennoch bestehen weiterhin Optimierungspotenziale.

Die Schätzqualität der mikrodatenbasierten Verfahren hängt maßgeblich von der Verfügbarkeit plausibilisierter Meldungen ab. Während $t+20$ gegenüber $t+15$ bereits Verbesserungen aufweist, bleiben wirtschaftliche Schocks, größere Datenlücken und die Prognose hochvolatiler und heterogener Betriebe als Herausforderungen. Die genutzten zeitabhängigen Regressoren sind in zu erwartenden Konjunkturzyklen ein hilfreiches Instrument, schwächeln jedoch bei plötzlich auftretenden Schocks. In den Testzeiträumen hat sich gezeigt, dass diese Regressoren Hinweise auf sich anbahnende Krisen ermöglichen, jedoch können diese erst nach einigen Monaten präzise genug schätzen. Zudem fallen die Schätzungen anhand der verschiedenen Methoden unterschiedlich gut in den Wirtschaftszweigen aus, sodass eine branchenspezifische Optimierung die Schätzqualität verbessern könnte. Beispielsweise wäre der Einsatz branchenspezifischer Regressoren denkbar.

Insgesamt liefert das Projekt belastbare Ergebnisse für eine beschleunigte Bereitstellung von Konjunkturindikatoren. Die kontinuierliche methodische Weiterentwick-

lung bleibt jedoch essenziell und bietet Potenziale, die Prognosegüte weiter zu verbessern. Insbesondere sind in Krisenzeiten weiterhin belastbare Schätzungen am aktuellen Rand zu gewährleisten und die Relevanz und Aktualität statistischer Produkte zu erhöhen. Seit dem Berichtsmonat Januar 2025 ist das Projekt in der Rubrik EXSTAT – Experimentelle Daten (Statistisches Bundesamt, 2025b) veröffentlicht. Dort werden künftig auch Informationen zu Methodik und Hintergrund bereitgestellt. Die Schätzungen des absoluten Umsatzes selbst werden im [Dashboard Deutschland](#) im Bereich Dashboard-Konjunktur öffentlich zugänglich gemacht. 

LITERATURVERZEICHNIS

Bañbura, Marta/Giannone, Domenico/Modugno, Michele/Reichlin, Lucrezia. *Now-casting and the real-time data flow*. In: Handbook of Economic Forecasting. Jahrgang 2. Ausgabe 4/2013, Seite 195 ff. DOI: [10.1016/B978-0-444-53683-9.00004-9](https://doi.org/10.1016/B978-0-444-53683-9.00004-9)

Barragán, Sandra/Barreñada, Lasai/Calatrava, Jorge Fernández/Gálvez Sainz de Cueto, Juan Carlos/Martín del Moral, José Manuel/Rosa-Pérez, Elena/Salgado, David. *Early Estimates of the Industrial Turnover Index using Statistical Learning Algorithms*. [Zugriff am 14. April 2025]. Verfügbar unter: www.ine.es

Botchkarev, Alexei. *A new typology design of performance metrics to measure errors in machine learning regression algorithms*. In: Interdisciplinary Journal of Information, Knowledge and Management. Ausgabe 14/2019, Seite 45 ff. [Zugriff am 29. April 2025]. Verfügbar unter: www.ijikm.org

Breiman, Leo. *Random forests*. In: Machine Learning. Band 45. Ausgabe 1/2001, Seite 5 ff.

Cox, Michael/Triebel, Jürgen/Linz, Stefan/Fries, Claudia/Flores, Luis Federico/Lorenz, Andreas/Ollech, Daniel/Dietrich, Andreas/LeCrone, Julian/Webel, Karsten. *Täglicher Lkw-Maut-Fahrleistungsindex aus digitalen Prozessdaten der Lkw-Mauterhebung*. In: WISTA Wirtschaft und Statistik. Ausgabe 4/2020, Seite 63 ff.

Eurostat (Statistisches Amt der Europäischen Union). *NACE Rev. 2. Statistische Systematik der Wirtschaftszweige in der Europäischen Gemeinschaft*. 2008. [Zugriff am 29. April 2025]. Verfügbar unter: ec.europa.eu

Kuhn, Max. *caret: Classification and Regression Training*. R package version 6.0-94. 2024. [Zugriff am 29. April 2025]. Verfügbar unter: [CRAN.Rproject.org](https://CRAN.R-project.org)

Mayer, Michael. *missRanger: Fast Imputation of Missing Values*. R package version 2.2.1. 2023. [Zugriff am 29. April 2025]. Verfügbar unter: [CRAN.Rproject.org](https://CRAN.R-project.org)

Saidani, Younes/Dumpert, Florian/Borgs, Christian/Brand, Alexander/ Nickl, Andreas/Rittmann, Alexandra/Rohde, Johannes/Salwiczek, Christian/Storfinger, Nina/Straub, Selina. *Qualitätsdimensionen maschinellen Lernens in der amtlichen Statistik*. In: AStA Wirtschafts- und Sozialstatistisches Archiv. Jahrgang 17. Ausgabe 3-4/2023, Seite 253 ff. DOI: [10.1007/s11943-023-00329-7](https://doi.org/10.1007/s11943-023-00329-7)

Salgado, David/Barragán, Sandra/Rosa-Pérez, Elena. *Timeliness and accuracy with machine learning algorithms: Early estimates of the industrial turnover index*. 2023. [Zugriff am 29. April 2025]. Verfügbar unter: <https://unece.org>

Statistisches Bundesamt. *Klassifikation der Wirtschaftszweige 2008 (WZ 2008)*. Wiesbaden 2008. [Zugriff am 30. April 2025]. Verfügbar unter: www.destatis.de

Statistisches Bundesamt. *Qualitätsbericht – Monatsbericht für Betriebe des Verarbeitenden Gewerbes sowie des Bergbaus und der Gewinnung von Steinen und Erden*. 2025a. [Zugriff am 29. April 2025]. Verfügbar unter: www.destatis.de

LITERATURVERZEICHNIS

Statistisches Bundesamt. *Eine frühe Schätzung des Umsatzaggregats im Verarbeitenden Gewerbe auf Basis von Mikrodaten*. 2025b. [Zugriff am 29. April 2025]. Verfügbar unter: www.destatis.de

van Buuren, Stef. *Flexible Imputation of Missing Data*. 2. Auflage. 2018.

van Buuren, Stef. *mice: Multivariate Imputation by Chained Equations*. R package version 3.16.0. 2023. [Zugriff am 29. April 2025]. Verfügbar unter: CRAN.Rproject.org

Wright, Marvin N. *ranger: A Fast Implementation of Random Forests*. R package version 0.15.1. 2023. [Zugriff am 29. April 2025]. Verfügbar unter: CRAN.Rproject.org

Herausgeber
Statistisches Bundesamt (Destatis), Wiesbaden

Schriftleitung
Dr. Daniel Vorgrimler
Redaktion: Ellen Römer

Ihr Kontakt zu uns
www.destatis.de/kontakt

Erscheinungsfolge
zweimonatlich, erschienen im Juni 2025
Ältere Ausgaben finden Sie unter www.destatis.de sowie in der [Statistischen Bibliothek](#).

Artikelnummer: 1010200-25003-4, ISSN 1619-2907

© Statistisches Bundesamt (Destatis), 2025
Vervielfältigung und Verbreitung, auch auszugsweise, mit Quellenangabe gestattet.