

»» Kommunaler Investitionsrückstand: Es kommt nicht nur auf die Höhe an!

Nr. 284, 22. April 2020

Autoren: Dr. Stephan Brand, Telefon 069 7431-6257, stephan.brand@kfw.de

Dr. Johannes Steinbrecher, Telefon 069 7431-2306, johannes.steinbrecher@kfw.de

Elisabeth Krone (Deutsches Institut für Urbanistik), krone@difu.de

Dr. Martin Rößler (Lehrstuhl für Wirtschaftspolitik und Wirtschaftsforschung, TU Dresden) martin.roessler@tu-dresden.de

Patrick Zwerschke (Lehrstuhl für Wirtschaftspolitik und Wirtschaftsforschung, TU Dresden) patrick.zwerschke@tu-dresden.de

Kommunale Investitionsrückstände können verschiedene Ursachen haben. Die Regionalpolitik steht vor der Herausforderung, diese Ursachen zu erkennen und adäquat zu adressieren. Kommunale Investitionshemmnisse sind aufgrund von methodischen Herausforderungen aber schwer zu analysieren. Da die zu Grunde liegenden Zusammenhänge komplex sein können, bedarf es einerseits einer umfangreichen Datenbasis, die viele verschiedene regionale Facetten abbilden kann und andererseits empirischer Methoden, die in der Lage ist, mit dieser Vielzahl an Indikatoren umzugehen.

In unserer Analyse kombinieren wir deshalb erstmalig Daten der amtlichen Statistik mit den Ergebnissen des KfW-Kommunalpanels, um besonders detaillierte Einblicke in die kommunale Investitionstätigkeit zu erhalten. Diese Vielzahl an Indikatoren untersuchen wir mit Methoden des maschinellen Lernens, die in der Lage sind, komplexe Zusammenhänge selbstständig zu „erlernen“ und dabei nur die Indikatoren auszuwählen, die für die Analyse einen Mehrwert bieten. Es zeigt sich, dass dieses Vorgehen für die vorliegende Problemstellung eine höhere Prognosegüte als klassische empirische Verfahren verspricht.

Die ersten Ergebnisse zeigen auf, dass es hohe Rückstände sowohl in finanzstarken als auch finanzschwachen Regionen gibt, für die aber unterschiedliche Probleme ursächlich scheinen. Aus der reinen Höhe der Rückstände lässt sich somit noch keine politisch sinnvolle Maßnahme ableiten. Für einen Abbau des Rückstands müssen deshalb nicht nur finanzielle Hürden sondern auch kapazitativen Engpässe abgebaut werden.

Die öffentliche Infrastruktur ist eine zentrale Voraussetzung für die Wettbewerbsfähigkeit und die Lebensqualität vor Ort. Die deutsche Infrastruktur scheint jedoch seit Jahren an Wettbewerbsfähigkeit zu verlieren. Umso zahlreicher wurden in den vergangenen Jahren darum die Forderungen nach höheren öffentlichen Investitionen.¹

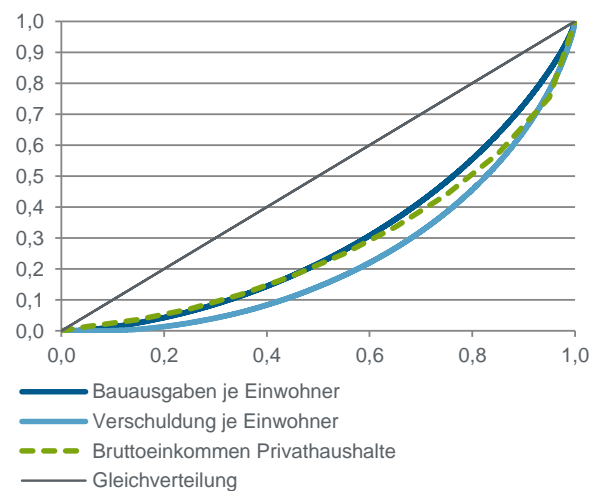
Infrastruktur ist Kernbestandteil der kommunalen Daseinsvorsorge

Ein wesentlicher Teil der öffentlichen Infrastruktur wird von der kommunalen Ebene bereitgestellt. Der Anteil der Kommunen an den gesamten öffentlichen Investitionen nimmt allerdings seit Jahrzehnten stetig ab. Zudem weisen die Kom-

munen trotz gestiegener Investitionsausgaben des Gesamtstaates weiterhin negative Nettoinvestitionen auf.

Dabei fallen insbesondere die regionalen Unterschiede bei der Investitionstätigkeit auf. Die Bauausgaben der Kommunen sind in etwa genauso (un)gleich verteilt wie die Bruttoeinkommen der Privathaushalte in Deutschland (Grafik 1). Dies bedeutet beispielsweise, dass die 30 % der Kommunen mit den niedrigsten Bauausgaben nicht mal 10 % Anteil an den gesamten Bauausgaben haben, während die Top 10 % der Kommunen 30 % aller Bauausgaben auf sich vereinen.

Grafik 1: Regionale Ungleichheit in Deutschland



Lesehilfe: Abgebildet sind Lorenzkurven für die durchschnittlichen Bauausgaben und die Gesamtverschuldung der Kommunen in den Jahren 2015 bis 2017 (in Pro-Kopf-Werten). Je „dicker der Bauch“ der Kurve ist, desto größer ist die Ungleichheit der Verteilung. Zum Vergleich ist die Verteilung der Bruttoeinkommen der Privathaushalte abgetragen. Datengrundlage für die Bruttolöhne ist der Monatsbericht der Deutschen Bundesbank April 2019, S. 13–44.

Quelle: Deutsche Bundesbank und Statistisches Bundesamt, eigene Berechnungen.

Für diese Unterschiede kann es gute Gründe geben. So unterscheidet sich die kommunale Ebene sehr stark in ihrer Struktur und dem Organisationsgrad ihrer Aufgaben.² Unterschiedliche Investitionsniveaus können somit (zum Teil) einfach nur ein Spiegelbild unterschiedlicher Aufgabenzuschnitte sein. Auch verbergen sich hinter den Zahlen qualitative Unterschiede; hohe Schulden, denen z. B. eine intakte Infrastruktur gegenübersteht sind sicherlich anders zu bewerten als Kassenkredite in gleicher Höhe, die nur die Haushaltlöcher vergangener Jahre gestopft haben.

Die ausgeprägten regionalen Unterschiede dürften aber in Kombination mit den negativen Nettoinvestitionen darauf hinweisen, dass zumindest ein Teil der kommunalen Ebene erhebliche Investitionsprobleme bzw. -hindernisse hat. Für eine gute Regionalpolitik ist nun entscheidend, dass die Gründe für Investitionsrückstände erkannt und betroffene Regionen zielgenau adressiert werden können.

Da trotz der hohen politischen Relevanz des Themas bislang immer noch relativ wenig über die Investitionshemmnisse auf kommunaler Ebene bekannt ist, hat KfW Research in Zusammenarbeit mit der TU Dresden in einem gemeinsamen Forschungsprojekt einen innovativen Untersuchungsansatz gewählt, um sich den Gründen des kommunalen Investitionsrückstands analytisch anzunähern. Im Folgenden werden die wesentlichen Ergebnisse dargestellt.

Befragungsdaten unterstützen bei dem Verständnis der amtlichen Statistik

Eine Analyse der kommunalen Investitionsrückstände wird durch zwei zentrale Herausforderungen erschwert. Zum Ersten sind die offiziellen Statistiken häufig nicht detailliert genug, um den Investitionsbedarf und die Hemmnisse einzelner Kommunen eingehend analysieren zu können.³ Zum Zweiten können die zu Grunde liegenden Beziehungen äußerst komplex sein.⁴ Die möglichen Einflussfaktoren und Wechselwirkungen sind so vielfältig, dass traditionelle empirische Verfahren an ihre Grenzen stoßen.

Zum KfW-Kommunalpanel

Im Rahmen des KfW-Kommunalpanels befragt das Deutsche Institut für Urbanistik im Auftrag der KfW seit 2009 die deutschen Städte, Kreise und Gemeinden hinsichtlich ihrer Finanzlage, den Investitionen sowie den Finanzierungsmöglichkeiten.⁵ Dabei konzentriert sich die Befragung auf Kommunen mit mehr als 2.000 Einwohnern, die rd. 95 % der kommunalen Investitionen tätigen. Im Themenkomplex der Investitionstätigkeit erfährt vor allem die Frage nach den durch die Kämmereien wahrgenommenen Investitionsrückständen eine besondere Beachtung. Der Investitionsrückstand wird als das Investitionsvolumen definiert, das benötigt wird, um die Infrastruktur auf den notwendigen Stand zu bringen.⁶ Im KfW-Kommunalpanel 2019 betrug der wahrgenommene Investitionsrückstand insgesamt rd. 138 Mrd. EUR, wobei die größten Anteile auf Schulen, Straßen und Verwaltungsgebäude entfielen.

Um sich der Frage nach den Ursachen der regionalen Unterschiede beim Investitionsrückstand dennoch annähern zu können, werden in der Analyse die Daten der amtlichen Statistik durch die Ergebnisse aus dem KfW-Kommunalpanel ergänzt (siehe Box). Das KfW-Kommunalpanel enthält sowohl konkrete numerische Schätzungen der Kämmerer zum Investitionsrückstand in zentralen Investitionsbereichen, als auch qualitative Einschätzungen zu Finanzlage, Investitionsbedarfen und zukünftiger Entwicklung des Investitionsrückstands. Die Einschätzung der Kämmerer gibt damit detaillierte Einblicke in die Investitions- bzw. Infrastrukturbedarfe von Kommunen, die in der amtlichen Statistik nicht doku-

mentiert sind.⁷ Dadurch bietet das KfW-Kommunalpanel wertvolle Kontextvariablen, die ein Verständnis des Investitionsrückstands erheblich erleichtern.

Durch die Kombination von amtlicher Statistik und dem KfW-Kommunalpanel lassen sich theoretisch über 1.000 verschiedene Indikatoren für die Gemeindeebene ableiten, mit denen die Determinanten kommunaler Investitionsrückstände untersucht werden können. Nicht alle dieser Indikatoren sind jedoch sinnvoll und viele messen auch ähnliche Einflussfaktoren. Deshalb werden für die vorliegende Analyse ca. 200 theoretisch fundierten Prädiktoren ausgewählt (siehe Grafik 2). Diese spiegeln unterschiedliche Facetten der kommunalen Investitionstätigkeit wider, wie z. B. die Finanzkraft oder die demografischen Rahmenbedingungen.⁸

Grafik 2: Untersuchte Einflussfaktoren für den kommunalen Investitionsrückstand im Basismodell

Finanzen und Wirtschaft	1) Finanzkraft 2) Verschuldung 3) Haushaltsstruktur 4) Finanzierung 5) Industriestruktur 6) Immobilienmarkt	118 Indikatoren
Demografie und Soziales	7) Bevölkerung 8) Altersstruktur 9) (Binnen)Wanderung 10) Sozialstruktur 11) Arbeitsmarkt und Arbeitslosigkeit	68 Indikatoren
Räumliche und andere Faktoren	12) Räumliche Faktoren 13) Zeitliche Faktoren 14) Sonstige	23 Indikatoren

Quelle: eigene Darstellung.

So werden beispielsweise Indikatoren wie Gesamteinnahmen der Kommunen oder die Hebesätze der Grund- und Gewerbesteuer als Indikatoren für die Finanzkraft integriert. Bei der Haushaltsstruktur werden unter anderem zentrale Ausgabenkategorien wie Personal-, Bauausgaben und Ausgaben für die Kosten der Unterkunft und Heizung berücksichtigt. Darüber hinaus werden Einschätzungsfragen aus dem KfW-Kommunalpanel zur Finanzlage und zum Finanzierungsumfeld integriert. Die demografischen Rahmenbedingungen werden durch zahlreiche Indikatoren zur Bevölkerungsentwicklung, Altersstruktur und Binnenwanderung abgebildet. Die sozialen Rahmenbedingungen werden vorrangig über verschiedene Arbeitslosenstatistiken skizziert. Darüber hinaus werden Indikatoren zur Wirtschaftsstruktur und zum Immobilienmarkt berücksichtigt, um die wirtschaftliche Prosperität von Regionen abbilden zu können. Letztendlich werden auch Dummy-Variablen eingefügt, um auf spezifische kommunale bzw. regionale Besonderheiten kontrollieren zu können, beispielsweise die strukturellen Unterschiede zwischen kreisfreien und kreisangehörigen Gemeinden.

Auf diese Weise wird die Anzahl der berücksichtigten Variablen weit über den Umfang klassischer empirischer Analysen hinaus erweitert, was eine deutlich bessere Abdeckung möglicher Einflusskanäle gewährleistet. Andererseits kann jeder der Indikatoren immer noch sinnvoll interpretiert werden, was das Risiko einer Fehlidentifikation von (Schein-)Korrelationen reduziert.

Verfahren maschinellen Lernens können dabei helfen, unbekannte Zusammenhänge zu entdecken

Die Vielzahl der untersuchten Indikatoren und möglichen Wirkungskanäle erfordert allerdings auch bei der Methodik innovative Ansätze. Sind wie im vorliegenden Fall weder die funktionale Form noch die relevanten Einflussgrößen des untersuchten Zusammenhangs bekannt, können traditionelle Verfahren die fraglichen Zusammenhänge wahrscheinlich nicht zufriedenstellend erklären.⁹

Aus diesem Grund wird für die hier untersuchte Frage eine Methode gewählt, die relevante Wirkzusammenhänge automatisch erkennt und irrelevante Faktoren von der Analyse ausschließt. Wir nutzen dafür Klassifikationsbäume (CART) und deren Weiterentwicklung Random Forest (RF). Dabei handelt es sich um nicht-parametrische Methoden aus dem Bereich des maschinellen Lernens. Diese Verfahren machen keine spezifischen Annahmen über die funktionale Form der untersuchten Zusammenhänge, sondern "lernen" diese aus den Daten. Dabei selektieren sie nur solche Indikatoren, die auch eine gewisse Vorhersagekraft für die Zielvariable (also in unserem Fall den Investitionsrückstand) haben.¹⁰

Aus diesem Grund wird zur Analyse des kommunalen Investitionsrückstands auf regressionsbaumbasierte Verfahren zurückgegriffen. Die Funktionsweise dieser Verfahren ist stilisiert in Grafik 3 dargestellt. Angenommen der Investitionsrückstand von Gemeinden kann zwei Zustände annehmen, hoch (grün) oder niedrig (blau), und durch die Verschuldung und die Größe der Bevölkerung vorhergesagt werden. Die linke Grafik zeigt zunächst die "Rohdaten" als Punktwolke. In dem Beispiel konzentrieren sich blaue Punkte in der linken unteren Ecke, einige befinden sich außerdem auf der rechten Seite der Grafik. Ein Entscheidungsbaum wird nun versuchen, die Beobachtungen durch die Einführung von Trennungsregeln bestmöglich zu separieren.¹¹ Zunächst würde dafür bei den Beispieldaten bei einem geeigneten Schwellenwert der Bevölkerung eine horizontale Linie gezogen. In weiteren Schritten würden die dadurch entstandenen Segmente weiter unterteilt, bis eine optimale Zuordnung der Daten erreicht wurde. Im diskutierten Beispiel besteht die end-

gültige Partitionierung aus fünf Regionen (R1 bis R5). Die dafür eingeführten Aufteilungsregeln lassen sich in Form eines Entscheidungsbaums darstellen (rechte Abbildung in Grafik 3). Um die Prognosegüte der Modelle zu verbessern, wird das Verfahren in der Regel mehrere hundert Mal wiederholt und die daraus entstandenen Ergebnisse gemittelt.¹²

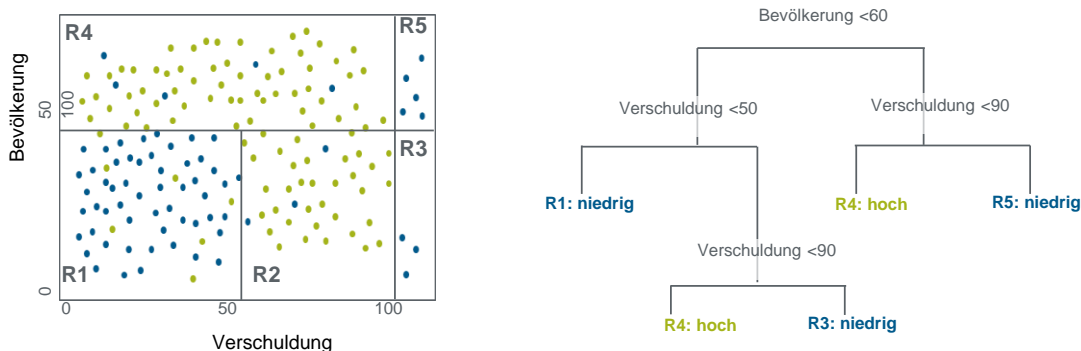
Ein zentraler Vorteil ist somit einerseits, dass komplexe Zusammenhänge und Interaktionen in der Analyse berücksichtigt werden können, ohne dass diese vorher explizit festgelegt werden müssen. Die Mittelung vieler hundert Modelle sorgt darüber hinaus dafür, dass nur solche Indikatoren für die Prognose genutzt werden, die sich auch in einer Vielzahl von Modellen als hilfreich erwiesen haben.

In unserer Analyse gehen wir insbesondere der Frage nach, welche der oben diskutierten Indikatoren eine Identifikation von Kommunen mit hohen Rückständen ermöglichen. Wir teilen dafür die Gruppe der Kommunen zunächst in solche mit einem hohen Investitionsrückstand und solche mit einem niedrigen Rückstand ein.¹³ Im Anschluss werden auf Grundlage der Jahre 2014–2017 die Kommunen mit einem hohen Investitionsrückstand im Jahr 2018 prognostiziert.¹⁴ Da für die vorliegende Fragestellung weder die maßgeblichen Indikatoren noch der konkrete Zusammenhang bekannt sind, ermöglichen die spezifischen Stärken der Verfahren maschinellen Lernens in unserer Analyse eine höhere Prognosegüte als klassische empirische Ansätze.

Hohe Investitionsrückstände sind kein Phänomen finanzschwacher Regionen

Für die Interpretation der Ergebnisse können die Indikatoren anhand ihrer relativen Wichtigkeit geordnet werden.¹⁵ Die Wirkungsrichtung der Zusammenhänge zwischen Investitionsrückstand und den ausgewählten Indikatoren lässt sich darüber hinaus grafisch nachvollziehen.¹⁶ In Grafik 4 sind die zwanzig wichtigsten Indikatoren für die Prognose hoher Investitionsrückstände abgebildet. Dabei sind sowohl die Oberkategorie (farblich) als auch die Richtung der Wirkungszusammenhänge (anhand von Pfeilen) dargestellt.

Grafik 3: Stilisierte Funktionsweise eines Entscheidungsbaumes



Quelle: eigene Darstellung.

Grafik 4: Wichtigste Prädiktoren eines hohen Investitionsrückstands sind Strukturschwäche

Rang	Indikator	Kategorie und Zusammenhang mit Investitionsrückstand	
1	Fläche	Räumliche und andere Faktoren	↘
2	Süddeutschland	Räumliche und andere Faktoren	↗
3	NRW	Räumliche und andere Faktoren	↘
4	Unterhalt Straßen nicht gewährleistet	Finanzen und Wirtschaft	↗
5	Doppische Buchführung (Doppik)	Räumliche und andere Faktoren	↘
6	Gesamtbevölkerung	Demografie und Soziales	↘ ↗
7	Landkreis	Räumliche und andere Faktoren	↗
8	Anteil Bevölkerung zw. 30–60 Jahren	Demografie und Soziales	↘
9	Finanzlage ist gut	Finanzen und Wirtschaft	↘
10	Bevölkerungsdichte	Demografie und Soziales	↘ ↗
11	Tourismusbetriebe	Finanzen und Wirtschaft	↗
12	Unterhalt insgesamt nicht gewährleistet	Finanzen und Wirtschaft	↗
13	Verschuldung je Einwohner	Finanzen und Wirtschaft	↗
14	Anteil Bevölkerung über 60 Jahre	Demografie und Soziales	↗
15	Betriebe des Verarbeitenden Gewerbes	Finanzen und Wirtschaft	↗
16	Veränderung der Arbeitslosenzahl	Demografie und Soziales	↘ ↗
17	Personalausgaben je Einwohner	Finanzen und Wirtschaft	↘ ↗
18	Anteil Bevölkerung zw. 6–18 Jahren	Demografie und Soziales	↘
19	Anteil Bevölkerung zw. 3–6 Jahren	Demografie und Soziales	↘ ↗
20	Anteil Bevölkerung unter 3 Jahren	Demografie und Soziales	↘ ↗

Lesehilfe: Abgebildet sind die über alle Modelle hinweg als am wichtigsten identifizierenden Indikatoren in absteigender Reihenfolge. Die Pfeile in der rechten Spalte verdeutlichen den Einfluss des Indikators auf das Prognoseergebnis. Ein aufsteigender Pfeil bedeutet, dass mit höheren Werten der Variable (z. B. Verschuldung) auch die Wahrscheinlichkeit steigt, in die Gruppe mit hohen Rückständen eingeordnet zu werden. Einfacher gesagt: höher verschuldete Kommunen haben häufiger auch einen hohen Investitionsrückstand. Bei den absinkenden Pfeilen gilt der umgekehrte Fall. Die grauen Doppelpfeile deuten auf ein u-förmiges Muster hin. Hier sinkt zunächst die Wahrscheinlichkeit hoher Rückstände, steigt ab einem bestimmten Wert aber anschließend wieder an.

Quelle: eigene Darstellung.

Betrachtet man zunächst die drei thematischen Oberkategorien wird deutlich, dass ein hoher Investitionsrückstand keinesfalls nur eine Frage der Finanz- und Wirtschaftskraft zu sein scheint. Zwar haben sieben der 20 wichtigsten Prädiktoren einen Bezug zur Finanzkraft bzw. Wirtschaftsstruktur der Kommune, allerdings sind die demografischen und sozialen Rahmenbedingungen mit acht Indikatoren sogar noch etwas häufiger vertreten (Grafik 4). Auch räumliche Faktoren spielen eine wichtige Rolle bei der Prognose hoher Investitionsrückstände.¹⁷

Wirft man nun einen Blick auf die ausgewählten Prädiktoren und die durch die Pfeile dargestellten Wirkzusammenhänge fällt auf, dass sich sowohl Indikatoren, die Finanz- oder Strukturschwäche andeuten auf der Liste wiederfinden, als auch solche, die eher auf wirtschaftlich starke Kommunen hinweisen. So steigt die Wahrscheinlichkeit, dass für eine Kommune ein hoher Rückstand prognostiziert wird beispielsweise an, wenn in dieser Kommune der Unterhalt der Infrastruktur nicht vollumfänglich gewährleistet ist. Dies ist sicher häufiger in finanzschwachen Kommunen der Fall.

Gleichzeitig werden Kommunen aus Bayern und Baden-Württemberg eher in die Kategorie mit hohen Rückständen eingeordnet, beides Länder mit vielen eher finanz- und investitionsstarken Kommunen. Eine Ambivalenz beim Investitionsrückstand zeigt sich auch an wechselnden Vorzeichen mehrerer Indikatoren (graue Pfeile in beide Richtungen). Hier hängt der Effekt von dem Niveau des jeweiligen Indikators ab. So werden beispielsweise Kommunen mit einer geringen Bevölkerung mit einer höheren Wahrscheinlichkeit der Gruppe mit hohem Rückstand zugeordnet. Mit zunehmender Bevölkerungsgröße sinkt dann zunächst die Wahrscheinlichkeit, steigt ab einer bestimmten Bevölkerungsgröße aber wieder an. Sehr bevölkerungsreiche Kommunen haben dann eben-

falls wieder eine hohe Wahrscheinlichkeit für hohe Investitionsrückstände. An beiden Enden des Wertebereichs gibt es somit häufiger hohe Rückstände. Diese dürften aber häufig unterschiedliche Ursachen haben.¹⁸

Unterschiedliche Ursachen von Investitionsrückständen zwischen finanzstarken und -schwächeren Kommunen

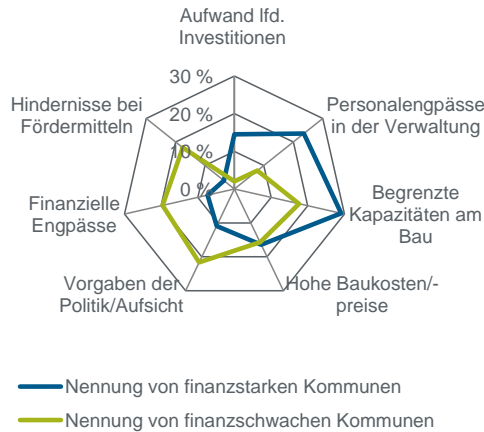
Diese Gegensätze finden sich auch im Gesamtbild. Die Selektion der verschiedenen Stärke- und Schwächeindikatoren legt nahe, dass sich zwar ein hoher Rückstand sowohl in strukturstarken als auch -schwachen Kommunen beobachten lässt. Dieser ist aber vermutlich jeweils auf eine Kombination unterschiedlicher Ursachen zurückzuführen. Ein Phänomen, das sich auch bei zentralen Investitionsbereichen wie dem Schulbau zeigt (Grafik 5).¹⁹

So gaben bei den offenen Fragen im KfW-Kommunalpanel 2019 von den Kommunen, die im Schulbau besondere Herausforderungen sahen, die finanzstarken Kommunen in erster Linie Kapazitätsengpässe als zentrale Hindernisse an. Bei den finanzschwachen Kommunen waren es hingegen nach wie vor eher finanzielle oder politische Einschränkungen, die einen Abbau des Rückstands bei Schulen erschweren.

Die Ergebnisse der vorliegenden Analyse verdeutlichen, dass diese Komplexität in den Ursachen auch dann beobachten lässt, wenn in der Analyse eine Vielzahl an Einflussfaktoren und Informationen mehrerer Jahre berücksichtigt werden. Beide Ergebnisse deuten darauf hin, dass die Problemlage im Zusammenhang mit den Investitionsrückstand stark von den vorherrschenden Rahmenbedingungen abhängt. In starken Regionen spiegelt der Investitionsrückstand scheinbar eher „Wachstumsschmerzen“ wider, die aus dem Umstand resultieren, dass die Infrastruktur nicht so schnell oder in dem Umfang aus- und aufgebaut werden

kann, wie es die Kommune eigentlich wünscht.²⁰ In diesen Regionen ist das Geld in der Regel vorhanden, es fehlt aber an ausreichend Personal- und Baukapazitäten.

Grafik 5: Beim Schulbau zeigen sich ebenfalls hohe Rückstände mit unterschiedlichen Ursachen



Quelle: Brand et al. (2019): Fokus Volkswirtschaft, Nr. 266, KfW Research.

Bei den finanzschwachen Kommunen fehlt es hingegen häufig nach wie vor an der ausreichenden Finanzausstattung, was sich auch daran zeigt, dass in diesen Kommunen häufig selbst der Unterhalt der Infrastruktur nicht vollumfänglich gesichert ist. Problematisch ist für diese Kommunen insbesondere, dass sie, sobald einmal Finanzmittel vorhanden sind, wahrscheinlich ebenfalls Kapazitätsengpässen ausgesetzt sein werden. Diesen Kommunen ist also wahrscheinlich mit „einfach mehr Geld“ auch nicht geholfen.

Fazit

Der kommunale Investitionsrückstand ist eine regionalpolitische Herausforderung. Um den Investitionsrückstand besser zu verstehen bedarf es sowohl einer umfangreichen Datenbasis als auch Methoden, die diese Daten sinnvoll verwerten können. Die ersten Ergebnisse unserer Analyse zeigen, dass der von uns gewählte innovative Ansatz – Daten der amtlichen Statistik mit Befragungsdaten des KfW-Kommunalpanels zu kombinieren und durch Verfahren maschinellen Lernens auszuwerten – viel versprechend ist.

Aus der vorliegenden Analyse folgt, dass es hohe Rückstände sowohl in finanzstarken als auch finanzschwachen Regionen gibt, für die aber unterschiedliche Rahmenbedingungen und Restriktionen ursächlich scheinen. Finanzstarke Kommunen sind vor allem Kapazitätsengpässen ausgesetzt, finanzschwachen Kommunen fehlt es hingegen häufig zunächst am Geld und dann ebenfalls an Kapazitäten. Aus der reinen Höhe der Rückstände lässt sich somit noch keine politisch sinnvolle Maßnahme ableiten.

Das bedeutet im Umkehrschluss, dass der kommunale Investitionsrückstand nur bedingt durch „einfach mehr Geld“ zu beheben sein wird.²¹ Die strukturellen Hemmnisse finanzschwacher Kommunen erfordern strukturelle Anpassungen in der Aufgaben- und Finanzmittelverteilung. Die gegenwärtigen Kapazitätsengpässe bei finanzstarken Kommunen erfordern hingegen Geduld und Planungssicherheit für Bauwirtschaft und Kommunen, damit Investitionen langfristig sinnvoll geplant und Kapazitäten weiter aufgebaut werden können.

¹ Vgl. Gornig, M., Michelsen, C. and K. v. Deuverden (2015): Local public infrastructure showing signs of wear and tear, DIW Economic Bulletin, 42+43 (2015), S. 561-567; IMF (2019): Article IV Consultation Germany, Juli 2019, OECD (2018): OECD Economic Surveys Germany, June 2018. Die sinkende Wettbewerbsfähigkeit der deutschen Infrastruktur wird beispielsweise durch verschiedene Ausgaben des World Economic Global Competitiveness Reports; EIB (2017): EIB Investment Survey – Municipal Infrastructure European Union Overview. Und Gornig et al. (2015): a.a.O. konstatiert.

² Vgl. Brand und Steinbrecher (2019c): **Kommunale Auslagerungen: ein Spiegelbild regionaler Vielfalt in Deutschland**, Fokus Volkswirtschaft Nr. 268, KfW Research.

³ Zwar gibt die Kassenstatistik Einblick in einige investitionsnahe Ausgabenbereiche, z. B. Baumaßnahmen, aber eine ganzheitliche Betrachtung der Investitionen ist momentan nur schwer, Rückschlüsse auf individuelle Bedarfe oder Investitionsrückstände überhaupt nicht abzuleiten.

⁴ So unterscheiden sich beispielsweise die rechtlichen, wirtschaftlichen und sozialen Rahmenbedingungen zwischen Bundesländern und den föderalen Ebenen teilweise deutlich.

⁵ Das aktuelle KfW-Kommunalpanel sowie frühere Ausgaben und Zusatzinformationen sind auf der Internetseite verfügbar: www.kfw.de/kommunalpanel.

⁶ Die Definition ist der Frage 5 im Fragebogen 2018 zu entnehmen. Der Investitionsrückstand besagt demnach nicht, dass die Infrastruktur per se und überall in schlechtem Zustand ist, sondern dass es entsprechend großer (finanzieller) Anstrengungen bedarf, die Infrastruktur (insbesondere in investitionsschwachen Kommunen) auf ein angemessenes und zukunftsfähiges Niveau zu bringen.

⁷ So werden z. B. Einschätzungen zur Qualität der Infrastruktur oder zur Dringlichkeit von bestimmten Investitionsbedarfen abgefragt, die wichtige Zusatzinformationen für ein Verständnis der kommunalen Investitionsbedarfe sind. Dadurch können Befragungen eine sinnvolle und wertvolle Ergänzung der amtlichen Statistik sein. Vgl. Brand und Steinbrecher (2019a): **Doppelt hält besser: Umfragen als sinnvolle Ergänzung der amtlichen Statistik**, Fokus Volkswirtschaft Nr. 253, KfW Research.

⁸ Für eine Diskussion der aktuellen wissenschaftlichen Literatur und eine vollständige Liste aller untersuchten Indikatoren siehe Rößler, M. & P-Zwerschke (2019): Dokumentation zum Forschungsvorhaben: „Vertiefende Analyseansätze zur Höhe und Entwicklung des kommunalen Investitionsrückstandes im KfW-Kommunalpanel“.

⁹ Berücksichtigt man allein die mögliche Vielfalt der kommunaler Rahmenbedingungen – wie 13 Flächenländer, unterschiedlichen Kommunaltypen (z. B. kreisfrei vs. -angehörig) und unterschiedlichen regionalen Faktoren (z. B. schrumpfend vs. wachsend) – zeigt sich, dass einfache lineare Zusammenhänge höchstwahrscheinlich einer solchen Komplexität nicht gerecht werden können. Klassische Analyseverfahren stoßen dabei an Grenzen, da sie häufig eine explizite Auswahl an Prädiktoren bzw. erwarteten Wirkzusammenhänge erfordern.

¹⁰ Die Darstellung von Einzelbäumen folgt weit gehend James et al. (2013): An Introduction to Statistical Learning, Springer Texts in Statistics sowie Kapelner und Bleich (2016): bartMachine: Machine Learning with Bayesian Additive Regression Trees, Journal of Statistical Software 70 (4), S. 1–40. Die folgenden Erläuterungen beziehen sich nur auf grundlegende Beschreibungen der Idee hinter Baummethoden. Eine intuitive Einführung in die Baummethoden bieten Strobl, C., Malley, J. and G. Tutz (2009): An Introduction to Recursive Partitioning: Rationale, Application, and Characteristics of Classification and Regression Trees, Bagging, and Random Forests, Psychological Method, 14(4), S. 323–348.

¹¹ Es wird dazu in jedem Arbeitsschritt jeweils nur eine Variable zur Einführung einer Regel verwendet – die jeweils prädiktivste Variable im Datensatz.

¹² Ein großer Nachteil einfacher Baummodelle ist ihre Instabilität gegenüber kleinen Änderungen in den Trainingsdaten. Um die Vorhersagekraft und Stabilität zu verbessern, können statt einem viele Bäume – also ein Wald von Bäumen – berechnet und schließlich aggregiert werden. Die bekannteste Variante solcher Baumensembles ist Random Forest (RF). Vgl. Strobl et al. (2009): a. a. O.

¹³ Die Analyse wird also als Klassifikationsproblem gestaltet, das heißt es wird nicht die genaue Höhe des Rückstandes prognostiziert, sondern nur, ob eine Kommune zur Gruppe mit hohem Rückstand gehört oder nicht. Dies hat mehrere Vorteile. So lassen sich beispielsweise die Ergebnisse besser mit Blick auf die Prognosegüte bewerten: es gibt nur richtige oder falsche Prognosen. Eine Kommune wird dabei in die Gruppe mit dem hohen Rückstand eingeordnet, wenn ihr Gesamt-Pro-Kopf-Investitionsrückstand im betreffenden Jahr unter den 33,3 % höchsten Rückständen lag (also im höchsten Terzil der Pro-Kopfrückstände). Da diese Einteilung relativ arbiträr ist, wurden auch andere Schwellenwerte geprüft (z. B. 10 % oder 20 %). Insgesamt ändern sich die Ergebnisse qualitativ dadurch nicht, allerdings bietet die Terzil-Einteilung insgesamt die beste Modellperformance.

¹⁴ Die Jahre 2014 bis 2017 sind der sog. Trainingsdatensatz, die Beobachtungen des Jahres 2018 sind der Testdatensatz. Die Prognose für 2018 klassifiziert die Kommunen binär in hohe und niedrige Rückstände. Auf diese Weise kann eine Situation abgebildet werden, in der auf Basis der Daten eines bestimmten Zeitraumes Prognosen über Investitionsrückstände und deren Entwicklungen im Folgejahr getroffen werden sollen. Im Fokus der Analyse steht der Einsatz von Conditional Random Forests. Diese Variante von Random Forest ist besonders geeignet um Variablen unterschiedlicher Skalenniveaus in der Analyse zu berücksichtigen. Das Tuning dieses Algorithmus auf Basis der Trainingsdaten erfolgt mittels 5-fold Cross Validation. Als Tuning-Parameter dient die Anzahl der pro Split zufällig gezogenen Kandidaten-Variablen. Als Kriterium zur Durchführung eines Splits wird die Unterschreitung des Signifikanzniveaus von 10 % verwendet. Zum Benchmarking wird zunächst ein einzelner Regressionsbaum (Conditional Inference Tree) herangezogen. Sowohl beim Training des Random Forest als auch bei der Auswertung der Testdaten werden Fehlwerte über sogenannte „surrogate splits“ berücksichtigt. Insgesamt stehen im Trainingsdatensatz rd. 2.930 Beobachtungen zur Verfügung. Der Testdatensatz beinhaltet je nach Spezifikation zwischen 240 und 700 Beobachtungen.

¹⁵ Um zu bestimmen welche Variablen für das jeweilige Modell am wichtigsten waren, wird ein Permutationstest durchgeführt. Dazu wird zunächst ein Random Forest geschätzt. Da hierbei für die Berechnung jedes einzelnen Regressionsbaums nur eine Teilmenge der Daten verwendet wird, ein so genannter Bootstrap, kann die Prognosegüte jedes einzelnen Baumes anhand der jeweils gerade nicht verwendeten Daten evaluiert werden. Daraus lässt sich über alle Bäume hinweg der so genannte Out-of-Bag Error (OOB Error) berechnen. Um zu bestimmen wie wichtig eine Variable für die Güte des Gesamtmodells ist, muss zunächst bestimmt werden welcher OOB Error zu erwarten wäre, wenn die Variable nicht zur Verfügung gestanden hätte. An dieser Stelle kommt die Permutation der Daten ins Spiel: Die Variablen werden für den Vergleich des OOB Errors nicht einfach ausgelassen, sondern zufällig zwischen den Beobachtungen umsortiert. Beispielsweise wird die Einwohnerzahl der Stadt Köln der Stadt Bottrop zugeteilt. Dadurch bleibt das Modell insgesamt unverändert (z. B. mit Blick auf die Anzahl integrierter Variablen), der Zusammenhang zwischen der betreffenden Variable und der zu erklärenden Variable wird durch die Permutation aber gestört. Mit diesen veränderten Werten wird der OOB Error für jeden Baum neu berechnet. Falls eine Variable wesentlich zum Modell beiträgt, so sollte der OOB Error signifikant ansteigen, da die Beziehung zwischen der zu erklärenden Variable und der Prognosevariable durch die Permutation zerstört wurde. Die durchschnittliche Diskrepanz der OOB Errors über alle Bäume hinweg bemisst die Relevanz der Variable. Um die relative Bedeutung zu messen werden die Werte am Ende normiert, sodass die Variable mit der größten Relevanz den Wert 100 erhält. Die weiteren Variablen werden relativ dazu angegeben. Eine Variable Importance von 50 bzw. 0,5 bedeutet folglich, dass die durchschnittliche OOB Error Diskrepanz der betreffende Variable über alle gebildeten Bäume im Random-Forest nur halb so hoch war, wie bei der wichtigsten Variablen. Da der vorliegende Datensatz Fehlwerte enthält, wird eine leicht modifizierte Variante des skizzierten Permutationstests nach Hapfelmeier et al. (2014) verwendet. Vgl. Hapfelmeier, A., Hothorn, T., Ulm, K., & Strobl, C. (2014). A new variable importance measure for random forests with missing data. *Statistics and Computing*, 24(1), S. 21–34.

¹⁶ Dafür werden so genannte Partial Dependence Plots analysiert. Es handelt sich dabei um eine Abbildung des zu erwarteten Werts der zu erklärenden Variable für unterschiedliche Ausprägungen eines bestimmten Prädiktors – unter Kontrolle aller anderen Einflussgrößen.

¹⁷ Im konkreten Fall kann das Modell 76,4 % aller Beobachtungen korrekt klassifizieren, die Präzision eines Zufallsschätzers läge nur bei 56,5 %. Dies bedeutet, dass unser Modell eine immerhin knapp 20 %-Punkte höhere Accuracy hat als eine Zufallsprognose. Das Modell bietet somit durchaus einen Mehrwert bei der Prognose des Rückstandes. Allerdings ist eine Gesamt-Accuracy von 0,76 immer noch vollständig zufriedenstellend und soll durch aufbauende Analysen und zusätzliche Daten weiter erhöht werden. Dennoch zeigt sich im Vergleich mit anderen Verfahren bereits eine deutlich bessere Performance der Verfahren maschinellen Lernens im Vergleich zu traditionellen Klassifikationsansätze wie der logistischen Regression.

¹⁸ Hohe Rückstände bei kleinen Kommunen dürften eher der relativ geringen Bevölkerungsgröße geschuldet sein: so haben kleine Kommunen zwar einen geringeren Aufgaben- und Investitionsumfang als größere Städte und Gemeinden. Allerdings beinhaltet dieser zentrale Infrastruktur wie beispielsweise die Wasserver- und -entsorgung. Fallen hier Investitionen an, müssen hohe Beträge durch vergleichsweise wenige Einwohner gestemmt werden. Entsprechend hohe Pro-Kopf-Werte sind die Folge. Bei größeren Städten dürfte der Rückstand dagegen eher aus der Vielzahl der kommunalen Aufgaben in Verbindung mit eingeengten haushaltspolitischen Handlungsspielräumen resultieren. Größere Städte müssen eine Vielzahl unterschiedlicher Infrastrukturleistungen anbieten, sind dabei aber überdurchschnittlich oft von Haushaltsengpässen betroffen, die sich beispielsweise in hohen Kassenkreditschulden oder Haushaltssicherungskonzepten zeigen. Fehlen die Investitionsmittel, können sich aufgrund der Vielzahl der Aufgaben auch kleine Rückstände in Einzelbereichen zu einem substantiellen Gesamtrückstand aufsummieren. Zur Thematik der Auslagerungen vgl. Brand, S. und J. Steinbrecher (2019): Kommunale Auslagerungen: ein Spiegelbild regionaler Vielfalt in Deutschland, online verfügbar.

¹⁹ Vgl. Brand, S., Krone, E. und J. Steinbrecher (2019): **Kommunaler Investitionsrückstand bei Schulen: Was steckt genau dahinter?** Fokus Volkswirtschaft Nr. 266, KfW Research.

²⁰ Siehe dazu insbesondere auch Krone et al. (2018): **KfW-Kommunalpanel 2018**, KfW Research.

²¹ Vgl. Brand, S. und J. Steinbrecher (2016): **Erst mehr Geld und jetzt mehr Personal – was benötigen Kommunen für Investitionen?** Fokus Volkswirtschaft Nr. 151, KfW Research.