

Satellitendaten zur Schätzung von Regionaleinkommen – Das Beispiel Deutschland

Christian Leßmann, André Seidel und Arne Steinkraus*

Einleitung

Für viele Regionen der Welt existieren keine validen statistischen Daten zu Einkommen und Wirtschaftskraft. Dabei sind zwei Faktoren von großer Bedeutung. Erstens spielt der Entwicklungsstand eine bedeutende Rolle. In Entwicklungsländern haben die Institutionen der amtlichen Statistik häufig nicht die notwendigen Kapazitäten zur Erhebung der notwendigen Daten [vgl. CHEN und NORDHAUS (2011, 2015)]. Häufig sind – wenn überhaupt – nur grobe Einkommensschätzungen auf Nationenebene möglich, welche von internationalen Organisationen – wie z. B. der Weltbank – bzw. mit deren Unterstützung vorgenommen werden. Die generierten Daten unterliegen dabei relativ großen Unsicherheiten, was durch die zahlreichen Datenrevisionen der Vergangenheit belegt wird. Zweitens ist es auch in höher entwickelten Staaten mit erheblichem Aufwand verbunden, valide Daten über kleinere Wirtschaftsräume zu erheben. Je kleiner der Raum ist, dessen wirtschaftliche Entwicklung untersucht werden soll, desto detailliertere Informationen sind notwendig und desto mehr vereinfachende Annahmen über die Zusammenhänge zwischen den betrachteten Regionen und übergeordneten räumlichen Einheiten müssen getroffen werden. Dies gilt natürlich nicht nur für die regionale Wirtschaft, sondern auch für andere wichtige Größen wie z. B. die Bevölkerungszahl. Die Ergebnisse des Zensus 2011 im Vergleich zu den Fortschreibungen der amtlichen Statistik zeigen deutlich, dass selbst in einem hochentwickelten Staat wie Deutschland erhebliche Messprobleme bei wirtschaftlich relevanten Daten bestehen.

Eine neue Möglichkeit zur Schätzung fehlender regionaler Einkommensdaten bieten Satellitenbilder der Erde bei Nacht. Die grundlegende Idee ist, dass die meisten wirtschaftlichen Aktivitäten – insbesondere der Konsum und die Produktion von Gütern –, die in den Abendstunden stattfinden, Licht benötigen bzw. emittieren. Aus der Lichtemission bei Nacht kann folglich ein Rückschluss auf wirtschaftliche Größen, wie z. B. das Einkommen, gezogen werden. Ziel dieses Beitrags ist, die in der Literatur verwendeten Daten vorzustellen sowie die Möglichkeiten und Grenzen der Nutzung von Satellitendaten zur Schätzung von Einkommen zu diskutieren. Dazu nehmen wir eine einfache ökonomische Auswertung der Daten Deutschlands vor und vergleichen diese mit anderen Ergebnissen der Literatur.

Satellitendaten und Einkommen

Die ersten Arbeiten, die den Zusammenhang zwischen der Lichtemission der Erde bei Nacht und sozioökonomischen Daten hergestellt haben, sind bereits in den 1960er Jahre entstanden. Jedoch zeigen erst ELVIDGE et al. (1997), dass die Lichtemission bei Nacht nahezu perfekt mit dem Bruttoinlandsprodukt auf Nationalstaatsebene korreliert ist ($R^2=0.97$). HENDERSON et al. (2012) untersuchen den Zusammenhang zwischen Änderungen der Lichtemissionen und realen Wachstumsraten des Einkommens. Dabei zeigt sich, dass immerhin etwa 70 % des Wachstums durch die Lichtdaten erklärt werden kann. Auf nationaler Ebene scheinen die Daten also sehr informativ zu sein. Fraglich ist jedoch, wie gut sie sich für regionalökonomische Untersuchungen eignen.

Zunächst wollen wir erklären, wie die Daten erhoben und aufbereitet werden. Mehr als 1.000 aktive Satelliten umkreisen die Erde in unterschiedlichen Abständen mit unterschiedlicher Geschwindigkeit. Sie liefern – je nach Zweck und Sensorausstattung – sehr unterschiedliche Daten. Für die hier diskutierten Untersuchungen werden die Satelliten des Defense Meteorological Satellite Program (DMSP) verwendet. Die von der US AIR FORCE betriebenen Satelliten umkreisen 14 Mal pro Tag die Erde und machen dabei zahlreiche Aufnahmen, die unter anderem für Wetterprognosen benötigt werden. Gemessen wird dabei neben anderen Informationen die Infrarotabstrahlung, welche nahe an dem für das menschliche Auge sichtbaren Licht ist. Die Daten können z. B. dazu genutzt werden, um die Wolkenabdeckung zu bestimmen, indem die gemessene Wärmestrahlung ins Verhältnis zu den Bodentemperaturen gesetzt wird. Bei dem Überflug eines einzelnen Satelliten werden die Daten für einen ca. 3.000 Kilometer breiten Streifen erfasst.

Ein Nebenprodukt dieser Messungen ist auch das von Menschen künstlich erzeugte Licht, welches z. B. von Siedlungen, Städten, Verkehrswegen und Industrieanlagen abgestrahlt wird. Die Aufbereitung der Daten erfolgt durch die Wetter- und Ozeanografiebehörde der

* Prof. Dr. Christian Leßmann leitet das Institut für Volkswirtschaftslehre an der Technischen Universität Carolo-Wilhelmina zu Braunschweig und ist Forschungsprofessor des ifo Instituts. Arne Steinkraus ist wissenschaftlicher Mitarbeiter am Institut für Volkswirtschaftslehre, und André Seidel ist wissenschaftlicher Mitarbeiter am Lehrstuhl für Volkswirtschaftslehre, insbesondere Finanzwissenschaft der Technischen Universität Dresden.

USA (NOAA). Berücksichtigt werden nur die Daten, die in den Abendstunden zwischen ca. 20:30 Uhr und 22:00 Uhr Ortszeit entstehen. Eine erhebliche Herausforderung ist die Isolation des menschengemachten, also künstlichen Lichts, von natürlichen Lichtquellen (z. B. Polarlichter, Waldbrände etc.). Zudem müssen die Daten um die Wolkenabdeckung, Staub in der Atmosphäre und andere Faktoren bereinigt werden. Am Ende werden Jahresmittelwerte für die verwendbaren und bereinigten Daten berechnet, welche dann zur weiteren Nutzung publiziert werden.

Die so entstandenen geokodierten Datensätze enthalten Helligkeitsinformationen für eine Fläche von etwa einem Quadratkilometer. Jedem Punkt ist dabei ein Helligkeitswert zwischen 0 und 63 zugewiesen, wobei höhere Werte eine höhere Lichtintensität repräsentieren. Die Daten sind an beiden Enden der Skala zensiert, woraus einige erhebliche Einschränkungen entstehen. Ein Wert von Null ist nicht zwangsläufig gleichbedeutend damit, dass in dem betreffenden Areal kein Mensch wohnt und gar kein Licht emittiert wird. Die Sensitivität der Sensoren ist jedoch relativ hoch, da das Licht einer modernen 250-Watt-Glühlampe unter freiem Himmel auf einer Fläche von 1 km² bereits erfasst wird. In armen Regionen der Erde kann dies aber dennoch zu Messfehlern führen, wenn in sehr dünn besiedelten Gebieten relativ wenig Licht emittiert wird. Die Zensierung der Daten bei hoher Lichtintensität in sehr dicht besiedelten und sehr reichen Regionen ist hingegen ein erhebliches Problem. Metropolregionen wie z. B. New York City, Frankfurt am Main oder Mexico City weisen in einigen Teilen des Stadtgebiets die höchsten Helligkeitswerte von 63 auf. Dennoch bestehen zwischen sowie innerhalb der genannten Regionen erhebliche Einkommensdifferenzen, die durch die Lichtdaten nicht erfasst werden können.

Eine weitere Besonderheit der Daten ist, dass die zu einem Pixel gehörende Fläche nur entlang des Äquators konstant ist. Am Äquator repräsentiert ein Bildpunkt eine Fläche von ca. 0,86 km², auf der Höhe von Berlin (52° Nord) ca. 0,52 km² und auf der Höhe von Reykjavík (64° Nord) nur noch ca. 0,38 km². Daher ist es üblich, Regionen jenseits der Polarkreise ($\approx 66^\circ$) von der Untersuchung auszuschließen. Hier sind zusätzlich die Polarlichter eine mögliche Fehlerquelle bei der Messung, und in den Sommermonaten können keine Bilder bei vollständiger Dunkelheit aufgenommen werden.

Zur Verfügung stehen die Daten für die Jahre 1992 bis 2013. Zu beachten ist, dass die Satelliten mehrfach ausgetauscht worden sind. Um dennoch eine Vergleichbarkeit zu gewährleisten, werden die Daten immer für einen einzelnen Satelliten veröffentlicht. Das bedeutet jedoch, dass es eine höhere Frequenz der Daten gibt, da sich die aktiven Zeiten einzelner Satelliten überlappen. Üblicherweise werden die Daten über verschiedene Sa-

telliten auf Jahresebene gemittelt. Auch dieses Vorgehen ist nicht unproblematisch, da es keinen Ausgleich für die Änderungen in der Sensortechnologie schafft. Jede Änderung der Satellitenkonstellation verursacht potenziell eine Sprungstelle in den Daten, die bei späteren Untersuchungen berücksichtigt werden muss.

Das Beispiel Deutschland

Im Folgenden wollen wir die Daten Deutschlands untersuchen. Dabei werden wir zunächst auf einfache graphische Analyseverfahren zurückgreifen und darauf aufbauend eine ökonometrische Untersuchung vornehmen. Unser Ziel ist, die Möglichkeiten und Grenzen der Anwendbarkeit dieser neuartigen Daten für die Berechnung und Prognose von Regionaleinkommen aufzuzeigen.

In einem ersten Schritt werden die geokodierten Satellitendaten mit einem geeigneten Softwarepaket wie beispielsweise QGIS ausgewertet. Benötigt werden neben den Lichtdaten auch Informationen über die Regionengrenzen, welche aus der Global Administrative Area (GADM) Datenbank entnommen werden. Hier betrachten wir NUTS-3-Regionen, die in Deutschland Kreisen und kreisfreien Städten entsprechen.

In Abbildung 1 sind die Daten von Deutschland für das Jahr 2000 exemplarisch dargestellt. Zur besseren Orientierung in der Karte haben wir auch die Grenzen der NUTS-3-Regionen mit eingezeichnet. Selbst kleinere Städte lassen sich mit bloßem Auge leicht erkennen. Große Agglomerationsräume erscheinen als helle Flecken. In den Metropolregionen lassen sich einzelne Städte nicht mehr exakt identifizieren; insbesondere das Rhein-Ruhr-Gebiet erscheint aus der Distanz als einziger heller Fleck. Augenscheinlich lässt sich mit der Satellitenhelligkeit die wirtschaftliche Aktivität als Ganzes erfassen.

Um etwas detailliertere Informationen über den Zusammenhang zwischen Licht und Einkommen zu erhalten, haben wir mittels QGIS die Summe der Helligkeitswerte aller Pixel einer Region berechnet und diese Daten dann mit Stata weiterverarbeitet. In der Literatur werden verschiedene Lichtindikatoren verwendet. In Abbildung 2 stellen wir drei unterschiedliche Vorgehensweisen vor.


In Abbildung 2a vergleichen wir das absolute Bruttoinlandsprodukt auf NUTS-3-Ebene mit der Summe der Helligkeitswerte der einzelnen Bildpunkte in einer Region. Betrachtet werden Durchschnittswerte für den Zeitraum 2000 bis 2011 und beide Variablen sind logarithmiert. Demnach scheint ein positiver Zusammenhang zwischen Helligkeit und Einkommen zu existieren. Bestätigt wird dies durch den Korrelationskoeffizienten, der für diese Variablen 0,53 beträgt. Im Vergleich zu früheren Untersuchungen, wie z. B. ELVIDGE et al. (1997), ist die Korrelation

zwischen Licht und Bruttoinlandsprodukt (BIP) jedoch vergleichsweise niedrig. Ein Grund dafür ist sicherlich, dass wir hier sehr kleinräumige Regionen betrachten, während die überwiegende Zahl früherer Studien auf Nationalstaaten oder zumindest größere Regionen abstellen. Dabei fällt das Problem der Topkodierung weniger stark ins Gewicht.

Eine wichtige Einschränkung der bisherigen Untersuchung ist, dass die unterschiedliche Größe der Regionen

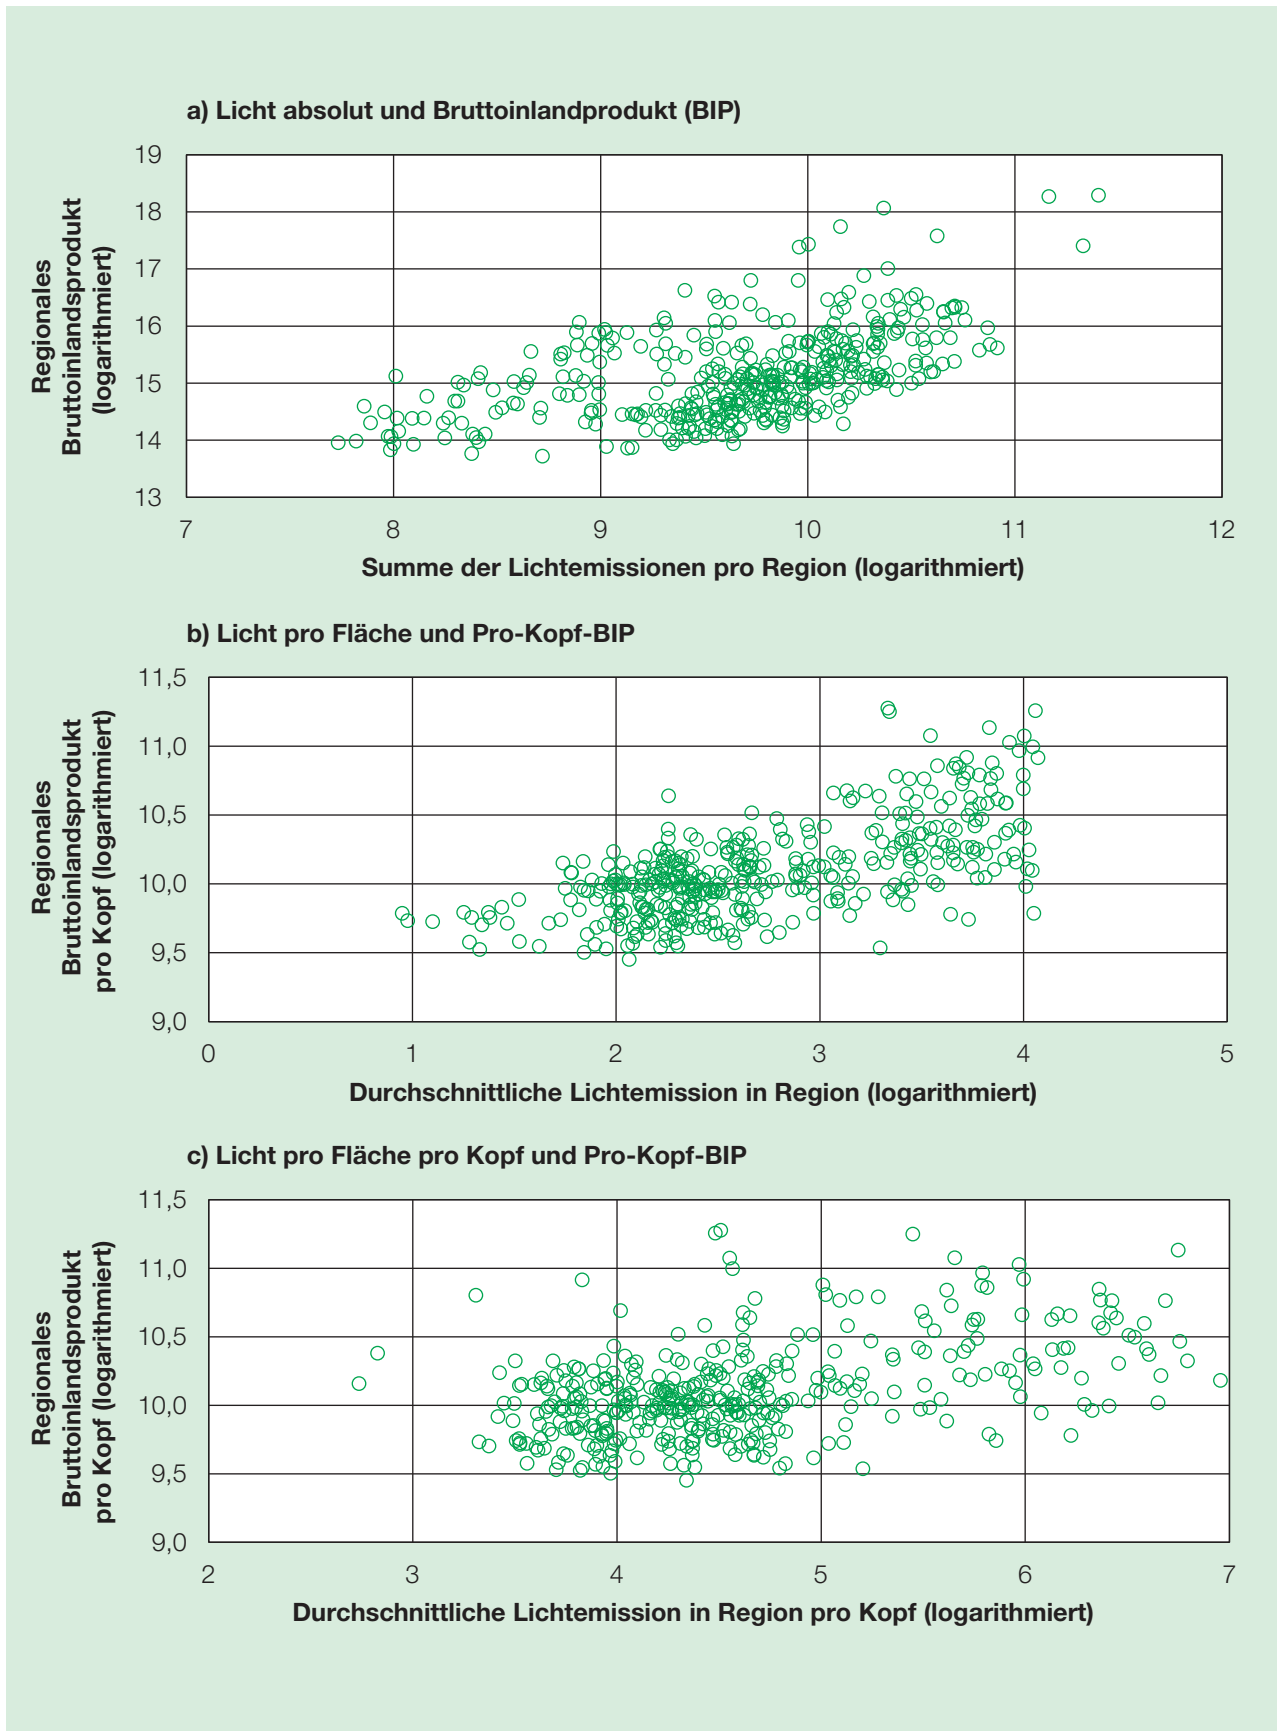
sowie die unterschiedliche Bevölkerungsdichte unberücksichtigt bleiben. Wenn das BIP als Indikator für die Produktivität oder die Lebensverhältnisse einer Region verwendet werden soll, dann bietet sich die Betrachtung von Pro-Kopf-Größen an. Bei den Lichtdaten muss zudem berücksichtigt werden, dass die Regionen unterschiedlich groß sind und daher eine stark unterschiedliche Anzahl an Pixeln aufweisen. Die Zahl der Pixel pro NUTS-3-Region variiert in unserem Datensatz zwischen

Abbildung 1: Nachtbeleuchtung in Deutschland im Jahr 2000



Quelle: NOAA (2015).

Abbildung 2: Licht und regionales Bruttoinlandsprodukt in Deutschland



Quelle: Eigene Berechnungen und Darstellung.

60 (Kreisfreie Stadt Rosenheim) und 5.954 (Uckermark). Um diesen Faktoren Rechnung zu tragen, berechnen wir die durchschnittliche Helligkeit der Pixel in einer Region (\overline{LICHT}) sowie die durchschnittliche Helligkeit der Pixel in einer Region pro Einwohner ($\overline{LICHT/KOPF}$). In den Abbildungen 2b und 2c stellen wir diese Größen dem BIP pro Kopf gegenüber. Auch hier zeigt sich ein positiver Zusammenhang. Die Korrelation zwischen Pro-Kopf-BIP und Licht pro Fläche ist mit einem Wert von 0,65 sogar noch etwas größer als die Korrelation zwischen den Absolutgrößen, während die Korrelation zwischen dem Pro-Kopf-BIP und der durchschnittlichen Helligkeit je Einwohner mit 0,47 etwas niedriger ausfällt.

Die drei Beispiele verdeutlichen einen zentralen Nachteil der Satellitendaten: Die gemessene Helligkeit steigt c. p. sowohl in der Bevölkerungsdichte als auch im Pro-Kopf-Einkommen. Von einer größeren Lichtemission kann daher nicht ohne Weiteres auf eine höhere Produktivität oder gar bessere Lebensverhältnisse in einer Region geschlossen werden. Zum Beispiel hat die Stadt München einen der höchsten Lichtemissionswerte pro Fläche in Deutschland. Wird hingegen die Lichtemission pro Fläche je Einwohner betrachtet, so hat München wegen der großen Bevölkerungszahl mit die geringsten Pro-Kopf-Lichtemissionen in unseren Daten. Es muss daher in einer multivariaten Regressionsanalyse für die hier nicht berücksichtigten Unterschiede zwischen den Regionen kontrolliert werden.

Regressionsanalyse

Die deskriptiven Auswertungen lassen vermuten, dass die Lichtdaten mit Einkommensgrößen statistisch zusammenhängen. Allerdings kann auf Basis der bislang verwendeten Methoden keine Aussage über die Größe und Stabilität des Effekts gemacht werden. Im Folgenden werden wir daher verschiedene Spezifikationen eines einfachen linearen Regressionsmodells schätzen. Die grundlegende Regressionsgleichung lautet

$$\log BIP/KOPF_{i,t} = \alpha_i + \beta \log \overline{LICHT}_{i,t} + \gamma_k X_{k,i,t} + \mu_t + \epsilon_{i,t}$$

wobei wir das Pro-Kopf-BIP ($BIP/KOPF_{i,t}$) auf die Lichtintensität pro Fläche ($\overline{LICHT}_{i,t}$) und k verschiedene Kontrollvariablen ($X_{k,i,t}$) regressieren. Als Kontrollvariablen verwenden wir die Bevölkerungsdichte, die Einwohnerzahl, die Fläche, den Urbanisierungsgrad sowie einen Ost-West-Dummy. Die Bevölkerungsdichte und der Urbanisierungsgrad sollen dabei die Messfehler aufgrund der Zensierung der Daten in sehr dichtbesiedelten Regionen verringern und darüber hinaus mögliche Verzerrungen durch unterschiedliche Siedlungsstrukturen abfangen. In

den Panelregressionen repräsentiert α_i regionenfixe Effekte, μ_t die Jahresdummy-Variablen und $\epsilon_{i,t}$ ist der Fehlerterm. In den Querschnittsregressionen verwenden wir Periodendurchschnittswerte aller Variablen für den gesamten Beobachtungszeitraum von 2000 bis 2011, sodass die Zeitindizes sowie die regionen- und zeitfixen Effekte obsolet werden. Da wir in unserem Modell bei abhängigen und unabhängigen Variablen logarithmierte Werte verwenden, können die Koeffizienten direkt als Elastizitäten interpretiert werden. Bezogen auf den uns am meisten interessierenden Koeffizienten des Maßes der Lichtintensität β , bedeutet dies, dass eine 1-prozentige Erhöhung der Lichtintensität mit einer β -prozentigen Erhöhung des Einkommens einhergeht.

Die Schätzergebnisse sind in Tabelle 1 zusammengefasst. Die Spezifikationen (1) bis (3) im oberen Bereich der Tabelle zeigen die Ergebnisse von Querschnittsregressionen; in den Spezifikationen (4) bis (6) im unteren Bereich nutzen wir Paneldaten. Der zentrale Unterschied zwischen Querschnitts- und Panelregressionen ist folgender: Querschnittsregressionen nutzen die Variation der Daten zwischen den Regionen, um die Regressionskoeffizienten zu bestimmen, während bei Paneldaten mit fixen Effekten die Regressionskoeffizienten aus der Variation der Daten innerhalb der Regionen über die Zeit bestimmt werden. Die Interpretation ist entsprechend unterschiedlich, da sich die Querschnittsregressionen auf Änderungen zwischen Beobachtungsträgern beziehen, während Panelregressionen auf zeitliche Änderungen innerhalb der Regionen abstellen.

Die Querschnittsregressionen zeigen einen positiven und zumeist statistisch signifikanten Zusammenhang zwischen dem Pro-Kopf-BIP und unserem Maß der Lichtintensität. Spezifikation (1) ist ohne Kontrollvariablen geschätzt und zeigt uns, dass die Lichtintensität allein etwa 40 % der Variation zwischen den Einkommen erklärt. In Spezifikation (2) und (3), fügen wir sequentiell die Kontrollvariablen hinzu, wobei der gesamte Erklärungsgehalt des Modells auf über 50 % steigt. In Spezifikation (3), welche alle Kontrollvariablen beinhaltet, ist der Koeffizient etwa 0,19, d. h. dass Regionen mit einer 10 % höheren Lichtemission ein etwa 2 % höheres Pro-Kopf-BIP haben. Im Vergleich zu den existierenden Länderquerschnittsuntersuchungen ist der Koeffizient etwas kleiner, was sicherlich auf die feinere regionalen Abgrenzung und die damit verbundenen Zensierungsprobleme der Daten zurückzuführen ist.

Die Koeffizienten der Kontrollvariablen zeigen, dass eine hohe Bevölkerungsdichte und eine hohe Einwohnerzahl mit höherem Pro-Kopf-BIP einhergehen, während überwiegend als städtisch klassifizierte Regionen ein niedrigeres Pro-Kopf-BIP aufweisen. Regionen in den alten Bundesländern haben ebenfalls ein höheres Pro-Kopf-

Tabelle 1: Querschnitts- und Panelregressionen auf Nuts-3-Ebene

Abhängige Variable: Bruttoinlandsprodukt pro Kopf ^a			
Variablen	Querschnittsregressionen		
	(1)	(2)	(3)
Lichtemission pro Fläche ^a	0,318*** (0,020)	0,029 (0,091)	0,194** (0,091)
Bevölkerungsdichte		0,015 (0,108)	0,196* (0,105)
Bevölkerungsgröße ^a		0,145** (0,070)	0,027 (0,072)
Fläche ^a		-0,189*** (0,069)	-0,045 (0,069)
Urbanisierungsgrad			-0,172*** (0,042)
Alte Bundesländer			0,254*** (0,023)
Konstante	9,231*** (0,051)	10,595*** (0,407)	9,527*** (0,403)
Beobachtungen (NUTS-3)	412	412	412
R ²	0,427	0,445	0,542
Panelregressionen			
	(4)	(5)	(6)
Lichtemission pro Fläche ^a	0,313*** (0,006)	0,144*** (0,022)	0,046*** (0,008)
Bevölkerungsdichte		0,180*** (0,030)	
Bevölkerungsgröße ^a		0,060*** (0,019)	-0,597*** (0,076)
Fläche ^a		-0,080*** (0,018)	
Urbanisierungsgrad		-0,169*** (0,012)	
Alte Bundesländer		0,252*** (0,007)	
Konstante	9,103*** (0,029)	9,629*** (0,102)	12,874*** (0,384)
Fixe Zeiteffekte	Ja	Ja	Ja
Fixe Regioneneffekte	Nein	Nein	Ja
R ²	0,446	0,557	0,794
Beobachtungen (NUTS-3)	4.944 (412)	4.944 (412)	4.944 (412)

Hinweise: Standardfehler in Klammern; Signifikanzniveaus sind wie folgt angegeben: Für *** ist die Irrtumswahrscheinlichkeit < 1%, für ** < 5% bzw. für * < 10%. – a) logarithmierte Werte.

Quelle: Eigene Berechnungen.

BIP, welches nicht durch die Lichtdaten erklärt werden kann. In diesem Zusammenhang ist es sinnvoll, sich vor Augen zu führen, was sich hinter den Lichtdaten und den damit gemessenen wirtschaftlichen Aktivitäten tatsächlich verbirgt. Zwar ist es durchaus plausibel anzunehmen, dass sowohl Produktion als auch Konsum mit höherer Lichtemission einhergehen. Allerdings können die Unterschiede zwischen alten und neuen Bundesländern bezogen auf die beiden Aspekte durchaus unterschiedlich groß sein.

In den Panelregressionen zeigt sich ein deutlich robuster jedoch schwächerer Zusammenhang. Die Spezifikationen (4) und (5) sind sogenannte Pooled Regressions, d.h. dass wir keine regionenfixen Effekte berücksichtigen.¹ Interessant ist der Unterschied zwischen den Spezifikationen (5) und (6). In der Pooled Regression mit Kontrollvariablen ist der Koeffizient mit 0,14 noch ähnlich groß wie bei den Querschnittsregressionen. In den Panelregressionen mit regionenfixen Effekten fällt er jedoch auf etwa 0,05. Obgleich der Effekt bei einem Konfidenzniveau von mehr als 99 % statistisch hochsignifikant ist, ist er doch ökonomisch sehr klein. Eine Erhöhung der Lichtemissionen um 10 % ist nur mit einer Zunahme des Pro-Kopf-BIP von 0,5 % innerhalb der Region verbunden. Für dieses im Vergleich zur Literatur relativ schwache Ergebnis kommt eine Reihe von Erklärungen infrage. Wenn etwa das Wirtschaftswachstum überwiegend auf die Agglomerationsräume konzentriert ist, bei denen die Lichtdaten in den Metropolregionen nach oben zensiert sind, dann mangelt es bei diesen hoch disaggregierten Daten an Variation in der Lichtintensität, um damit die Variation im Pro-Kopf-BIP erklären zu können.

Effekte nach Bundesländern

Abschließend wollen wir untersuchen, ob die Regressionsergebnisse zwischen den Bundesländern vergleichbar sind. Dazu führen wir Schätzungen durch, die analog zu den Ergebnissen der Spezifikation (6) in Tabelle 1 sind, d.h. klassische Panelregressionen mit fixen Effekten. Betrachtet werden dabei einzelne Subsamples der Länder in einzelnen Regressionen. In Tabelle 2 sind die Ergebnisse zusammengefasst. Aus Platzgründen beschränken wir uns auf den Koeffizienten β , der den Einfluss der Lichtintensität auf das Einkommen wiedergibt. Da die Stadtstaaten – abgesehen von der Trennung von Bremen in das Stadtgebiet und Bremerhaven – in den Regionalstatistiken nicht weiter untergliedert sind, können wir nur Ergebnisse für die Flächenländer berechnen.

In der Gesamtbetrachtung zeigen auch diese Regressionen, dass Lichtemissionen und Pro-Kopf-BIP po-

sitiv korreliert sind. In 12 von 13 Schätzungen ist der Koeffizient positiv. Statistisch signifikant ist er jedoch nur für die Länder Baden-Württemberg, Bayern, Hessen, Rheinland-Pfalz und Sachsen-Anhalt. Bemerkenswert ist darüber hinaus, dass die Größe des Koeffizienten mit Werten zwischen 0,05 und 0,12 – bezogen auf die signifikanten Ergebnisse – relativ stark variiert. Es bleibt daher festzuhalten, dass der Zusammenhang zwischen Lichtemissionen und regionalen Einkommen weit weniger robust ist, als die in der Literatur gefundenen Effekte auf nationalstaatlicher Ebene nahelegen [vgl. hierzu auch BIRKENBACH et al. (2013)]. Dies gilt zumindest für unser Beispiel Deutschland – ein Industrieland mit hohen Kapazitäten in den statistischen Institutionen. Allerdings muss auch berücksichtigt werden, dass die amtlichen Daten zum regionalen Bruttoinlandsprodukt, die wir hier als Vergleichsmaßstab herangezogen haben, wiederum auf Schätzungen beruhen, die selbst von Messungenauigkeiten beeinflusst werden.

Zusammenfassung und Fazit

Seit einigen Jahren werden Satellitendaten in volkswirtschaftlichen Untersuchungen verwendet. Insbesondere in Entwicklungsländern können diese helfen, Informationen über wirtschaftliche Aktivitäten zu erhalten, die aufgrund mangelnder Kapazitäten der statistischen Ämter gar nicht verfügbar oder wenig valide sind. Die neuen Daten erlauben prinzipiell sehr kleinräumige Analysen losgelöst von administrativen Einheiten, sodass sich eine Vielzahl an potenziellen Anwendungsfeldern ergibt. So berechnen z. B. ALESINA et al. (2015) Einkommensungleichheitsmaße zwischen verschiedenen ethnischen Gruppen und LEBMANN und SEIDEL (2015) analysieren regionale Ungleichheiten zwischen administrativen Regionen nahezu aller Staaten der Welt.

In unserem Beitrag haben wir die Satellitendaten vorgestellt sowie damit verbundene Messprobleme diskutiert. Anhand des Beispiels Deutschlands haben wir untersucht, inwieweit sich die Lichtemissionsdaten für regionalökonomische Analysen eignen. Wir finden keinen besonders großen und zudem wenig robusten Zusammenhang zwischen Lichtemissionen und regionalem Bruttoinlandsprodukt. Dieses Ergebnis bestätigt die Studie von CHEN und NORDHAUS (2015), die für Staaten mit großen Kapazitäten in den Statistikämtern keinen nennenswerten zusätzlichen Erklärungsgehalt von Lichtdaten bei der Berechnung des Inlandsprodukts finden. Für weniger entwickelte Staaten können die Daten jedoch ein wertvoller Indikator des nationalen oder regionalen Einkommens sein und damit helfen, die sehr lückenhaften Regionalstatistiken zu vervollständigen.

Tabelle 2: Regressionsergebnisse nach Bundesländern

Abhängige Variable: Bruttoinlandsprodukt pro Kopf ^a		
Bundesland	Lichtemission pro Pixel ^a	Standardfehler
Baden-Württemberg	0,123***	(0,030)
Bayern	0,064***	(0,019)
Brandenburg	-0,031	(0,047)
Hessen	0,073**	(0,028)
Mecklenburg-Vorpommern	0,008	(0,023)
Niedersachsen	0,021	(0,028)
Nordrhein-Westfalen	0,025	(0,027)
Rheinland-Pfalz	0,054*	(0,032)
Saarland	0,194	(0,108)
Sachsen	0,05	(0,036)
Sachsen-Anhalt	0,061*	(0,031)
Schleswig-Holstein	0,033	(0,041)
Thüringen	0,018	(0,059)

Hinweise: Alle Schätzungen beinhalten neben der Lichtemission pro Pixel, die Bevölkerungsgröße und zeit- und regionenfixe Effekte als weitere Erklärungsvariablen. – a) Variablen logarithmiert.

Quelle: Eigene Berechnungen.

Literatur

- ALESINA, A.; MICHALOPOULOS, S. und E. PAPAIOANNOU (2015): Ethnic Inequality, *Journal of Political Economy*, im Erscheinen.
- BIRKENBACH, F.; BODE, E.; LANGE, M. und P. NUNNENKAMP (2013): Night Lights and Regional GDP, ifw Kiel Working Paper Nr. 1888.
- CHEN, X. und W. D. NORDHAUS (2011): Using Luminosity Data as a Proxy for Economic Statistics, *Proceedings of the National Academy of Science of the USA*, 108(21), S. 8.589–8.594.
- CHEN, X. und W. D. NORDHAUS (2015): A Sharper Image? Estimates of the Precision of Nighttime Lights as a Proxy for Economic Statistics, *Journal of Economic Geography*, 15(1), S. 217–246.
- ELVIDGE, C. D.; BAUGH, K. E.; KIHN, E. A.; KROEHL, H. W.; DAVIS, E. R. und C. W. DAVIS (1997): Relation Between Satellite Observed Visible-Near Infrared Emissions, Population, Economic Activity and Electric Power Consumption, *International Journal of Remote Sensing*, 18(6), S. 1.373–1.379.
- GENNAIOLI, N.; LA PORTA, R.; LOPEZ DE SILVANES, F. und A. SHLEIFER (2013): Human Capital and Regional Development, *Quarterly Journal of Economics*, 128(1), S. 105–164.
- HENDERSON, J. V.; STOREYGARD, A. und D. N. WEIL (2012): Measuring Economic Growth from Outer Space, *American Economic Review*, 102(2), S. 994–1.028.
- LEBMANN, C. und A. SEIDEL (2015): Regional Inequality, Convergence, and its Determinants – A View from Outer Space, Center for Economic Studies & Ifo Institute Working Paper No. 5.322.

¹ Gleichzeitig unterstellen wir, dass alle Beobachtungen unabhängig voneinander sind. Das verstößt zwar gegen die grundlegenden Annahmen der Methode der kleinsten Quadrate, hilft uns allerdings zu untersuchen, wie groß der Erklärungsgehalt der zeitinvarianten Kontrollvariablen im Vergleich zum eher unspezifischen fixen Effekt ist.