

Satellitengestütztes Monitoring städtischer Lufttemperaturen

BENJAMIN BECHTEL¹, KLEMEN ZAKŠEK² & JÜRGEN BÖHNER³

Stadtklimatischen Fragen erfahren im Zuge der globalen Erwärmung zunehmendes Interesse auf Planungs- und Anwenderseite und erfordern robuste und handhabbare Modelle zur Vorhersage von städtischen Lufttemperaturen. Eine einfache Möglichkeit bilden dabei empirische Modelle, die den Nettoeffekt der gesamten Stadtstruktur in einer Transferfunktion parametrisieren. In dieser Studie wurde die Eignung von multitemporalen SEVIRI Oberflächentemperaturen für solche Modelle untersucht.

In einer Fallstudie für Hamburg, München und Köln konnte damit nicht nur der Jahresgang sondern für einzelne Episoden auch die Tagesgänge sehr gut nachvollzogen werden. Empirische Modelle für acht Stationen erreichten mit Aufnahmen zur Messzeit sowie von 1,2,4 und 8 Stunden zuvor RMSE von 1.5 bis 1.9 K und R^2 von bis zu 98 %. Weiterhin wurde das Modell in einem Prognose-Modus (also ohne aktuelle LST Informationen verwendet) und erreichte dabei RMSE von 1.9 bis 2.6 K und R^2 von 95 bis 97 % für eine zweistündige Vorhersage.

1 Einleitung

Informationen über städtische Lufttemperaturen auf lokaler Ebene sind von hoher praktischer Bedeutung für Stadtplanung und Gesundheitsversorgung. Vor allem der Klimawandel und Urbanisierung in großen Teilen der Welt haben das Interesse an den thermischen Eigenschaften von Stadtgebieten und dem Risiko von Hitzestress zusätzlich erhöht. Die Existenz von Temperaturunterschieden zwischen Stadt und Land, die als städtische Wärmeinsel (urban heat island, UHI) bezeichnet werden, ist dabei seit langem bekannt und gut untersucht (ARNFIELD, 2003; OKE, 1973; YOW, 2007). Zwar sind die der städtischen Wärmeinsel (UHI) zugrunde liegenden Prozesse in Gesamtheit gut verstanden, zur Modellierung in *urban canopy models* werden aber darüber hinaus zahlreiche geometrische und thermische Randbedingungen der Stadtstruktur benötigt. Diese sind oft nur eingeschränkt oder nicht standardisiert verfügbar. Eine Alternative bilden daher empirische Modelle, die den Nettoeffekt der gesamten Stadtstruktur in einer Transferfunktion parametrisieren. Die (weltraumgestützte) Fernerkundung im thermischen Infrarot Spektrum stellt eine wichtige Datengrundlage für solche Modelle dar (GALLO UND OWEN, 1998; WENG *et al.*, 2011).

Diese Ansätze haben bislang jedoch zwei wesentliche Beschränkungen. Erstens stellt die Überwachung der UHI und ihres Tagesgangs hohe Herausforderungen an die räumliche und zeitliche Auflösung der Daten, die bislang von keinem einzelnen Sensor befriedigt werden kann (TOMLINSON *et al.*, 2011, BECHTEL *et al.*, 2012). Daher sind zur Erhöhung der Auflösung oft Downscalingverfahren erforderlich (INAMDAR *et al.*, 2008; KOLIOS *et al.*, 2013; ZAKŠEK & OSTIR 2012, BECHTEL *et al.*, 2012, BECHTEL *et al.*, 2013). Zweitens ist für die UHI nicht die messbare Oberflächentemperatur (*land surface temperature*, LST) sondern die Lufttemperatur in der Stadthindernisschicht (Schicht bis zur mittleren Dachhöhe, *canopy layer air temperature*, CLAT) die entscheidende Größe. Einerseits ist die LST eine wichtige Randbedingung für die Energiebilanz und wurde vielfach verwendet, um die räumliche Verteilung der Lufttemperatur auf regionaler Skala zu schätzen (VOGT *et al.*, 1997; YAO UND ZHANG, 2013; ZAKŠEK &

SCHROEDTER - HOMSCHIEDT, 2009). In städtischen Gebieten ist die die Kopplung zwar besonders komplex und mit einer Reihe Schwierigkeiten verbunden (ROTH *et al.*, 1989, VOOGT & OKE, 2003) aber dennoch konnte eine Reihe von Studien relevante räumliche und zeitliche Korrelationen zwischen LST und der CLAT nachweisen (FABRIZI *et al.*, 2011; NICHOL *et al.*, 2009; NICHOL, 2005; PICHIERRI *et al.*, 2012). Da jedoch solche empirisch abgeleitete Funktionen zunächst jeweils nur für bestimmte Witterungsbedingungen gelten, verdient die Analyse von längeren Zeitreihen zusätzliche Aufmerksamkeit.

In dieser Studie schlagen wir empirische Modelle vor, die die LST Entwicklung über einen längeren Zeitraum nutzen, um die CLAT an einzelnen Stationen zu schätzen. Insbesondere untersuchen wir, ob multitemporale LST Daten in grober räumlichen Auflösung dafür geeignet sind und inwiefern das Modell den Tages- und Jahresgang wiedergeben kann. Die ursprüngliche Studie ist momentan im Review (BECHTEL *et al.*, 2014). In diesem Beitrag werden die Idee sowie ausgewählte Teilergebnisse präsentiert und der Ansatz auf die Städte Köln und München übertragen.

2 Daten und Methoden

Als Untersuchungsgebiete wurden die deutschen Großstädte Hamburg (53.5° O, 10° N), München (48.2 ° O, 11.5° N) sowie der Flughafen Köln-Bonn (50.9° N, 7.2 ° O) ausgewählt.

2.1 SEVIRI LST

SEVIRI ist das wichtigste Instrument an Bord der Meteosat Second Generation. Es scannt die Erdscheibe alle 15 min in 11 Bändern mit einer räumlichen Auflösung von ~3 km im Nadir. In Deutschland ist die Auflösung in Nord-Süd-Richtung jedoch geringer. Hier wurde das vorprozessierte LST Produkt der Land Surface Analysis Satellite Applications Facility (LSA SAF) verwendet, das aus den SEVIRI TIR- Kanäle bei 10,8 und 12,0 μm mit einem generalisierten split-window-Algorithmus erstellt wird. Die LST-Genauigkeit ist besser als 2 K.

2.2 Lufttemperatur

Die *in situ* Lufttemperatur wurde mit HMP45C Temperatursonden mit Strahlungsschutz von Vaisala in 2 m Höhe gemessen. Diese Sonden haben eine Genauigkeit von $\pm 0,2$ K (20 ° C). Die Meteostationen des HUSCO-Messnetzes (Hamburg Urban Soil Climate Observatory) befinden sich in unterschiedlichen Stadtstrukturen: Die Stationen #ih und #hc liegen in der Innenstadt innerhalb von Bereichen mit hoher Oberflächenversiegelung (> 90 %). Die restlichen vier Stationen sind innerhalb von zwei vorstädtischen Gebieten mit vorwiegend Einfamilienhausbebauung (#sw und #lw, ~50 % Oberflächenversiegelung) und Grünflächen (#sg und #lg, 0-5 % Oberflächenversiegelung). Die Stationen #sw und #lw liegen auf den Hinterhöfen von Einfamilienhäusern, bei #sw ist nachmittags Beschattung durch einen Baum möglich. Daneben wurden zu Vergleichszwecken an den Stationen auch die Oberflächentemperaturen mit einem Infrarot-Ferntemperatursensor IR120 von Campbell Scientific gemessen. Dieser erfasst die TIR-Strahlung in einem 8 -14 μm -Band und ist daher streng genommen ebenfalls ein Fernerkundungsverfahren. Die gemessene Temperatur ist ein räumlicher Mittelwert der

Strahldichte innerhalb des Sichtfeldes ($\sim 1\text{-}2 \text{ m}^2$) und hat ein typisches Rauschniveau von ca. 0.05 K sowie eine Genauigkeit von $\pm 0.2 \text{ K}$.

Für München und Köln wurden die DWD-Stationen München-Stadt (#ms) und Köln-Bonn (#kb) verwendet. Erstere liegt in einer dichten Stadtstruktur südlich des Olympiastadions, letztere an einem Flughafen südöstlich von Köln. Die DWD-Daten waren als Stundenwerte verfügbar.

Abb. 1 zeigt die Fernerkundungs- und *in situ* Daten für Hamburg das Jahr 2011. Die linke Spalte zeigt die SEVIRI LST, die mittlere *in situ* LST von HUSCO, und die rechte Spalte die CLAT von HUSCO. Die sechs Zeilen beziehen sich auf die Stationen #ih, #hc, #sg, #sw, #lg und #lw. Jedes der 18 Felder entspricht einem ganzen Jahr Messungen in 15-Minuten Zeitschritten mit je einem Tag pro Spalte. Daher werden jahreszeitliche Schwankungen von links (Januar) nach rechts (Dezember) und der Tagesgang von oben nach unten dargestellt. Bereits aus der visuellen Interpretation lassen sich wichtige Erkenntnisse gewinnen. Zunächst weist der SEVIRI - LST Datensatz größere Lücken durch Bewölkung auf. Im Allgemeinen sind die Stationen #ih und #hc im Stadtzentrum wärmer als die Stationen in den Vororten. In den suburbanen Gebieten sind die Stationen in der Einfamilienhausbebauung (#sw, #lw) etwas wärmer als die jeweiligen Parkstationen. Der Tagesgang der Sonneneinstrahlung ist am deutlichsten in der SEVIRI LST sichtbar, während besonders bei den städtischen Stationen eine verlangsamte nächtliche Auskühlung erkennbar ist, die die Speicherung und nächtliche Abgabe von Wärme belegt.

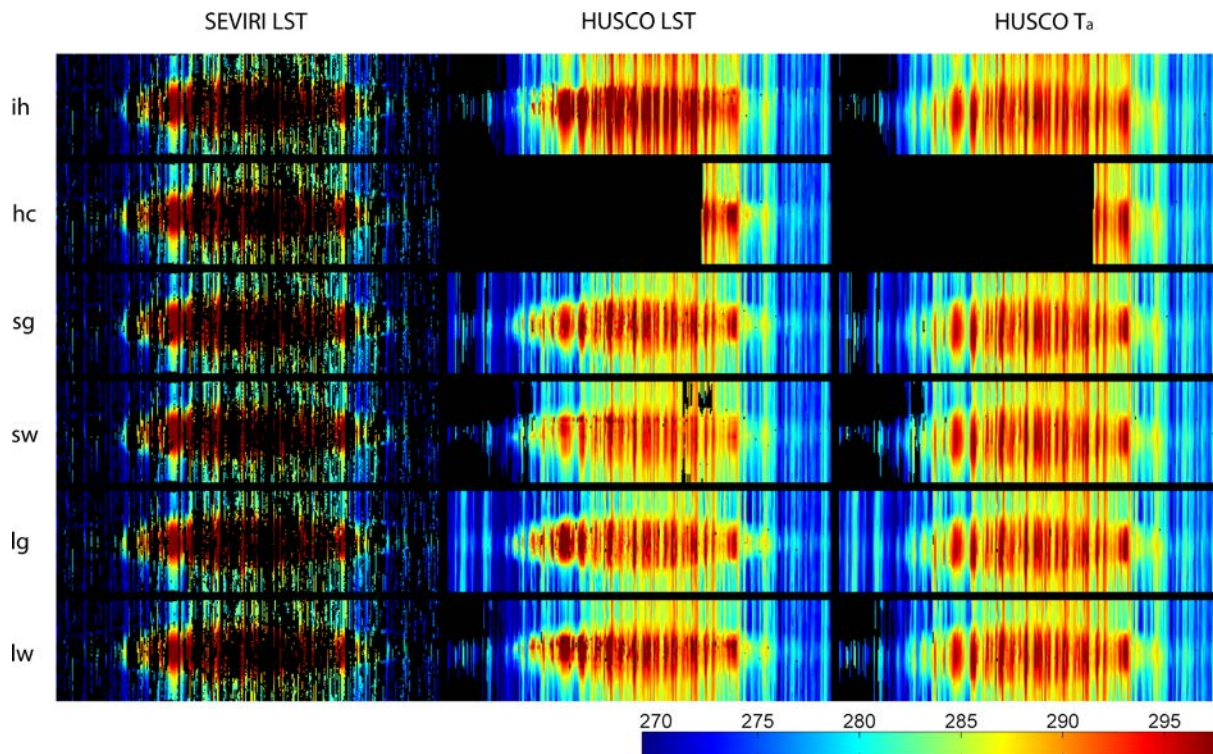


Abb. 1: SEVIRI LST (linke Spalte), *in situ* LST (Mitte) und Lufttemperatur (rechts) für die sechs Stationen (Zeilen) im Jahr 2011 in Kelvin. Innerhalb der Blöcke repräsentiert jede Spalte den Tagesgang von einem Tag und jede Zeile den Jahresgang zu einer bestimmten Tageszeit.

2.3 Empirische Analyse

Die empirische Analyse wurde mit Hilfe multipler linearer Regression zwischen SEVIRI LST als unabhängiger Variable (im folgenden Prädiktor) und der CLAT als abhängiger Variable durchgeführt. Diese Methode wurde anspruchsvolleren Modellen wie neuronalen Netzen vorgezogen, da sie robust und der Aufwand gering ist und der Einfluss der einzelnen Prädiktoren verständlich bleibt. Im ersten Schritt wurde nur die SEVIRI-LST zur gleichen Zeit als Prädiktor verwendet (Referenzmodell). Für die weitere Analyse wurden frühere Aufnahmen als zusätzliche Prädiktoren hinzugefügt. Die Sequenz **-[0 1 2]h** bedeutet beispielsweise, dass das multitemporale Prädiktorset aus der zeitgleichen Aufnahme sowie von einer und zwei Stunden vorher besteht.

Im hier vorgestellten Experiment, wurde jeweils das Jahr 2011 zur Kalibrierung und das Jahr 2012 zur Validierung verwendet. Diese Methode garantiert einem unabhängigen Testdatensatz (außer ein paar Stunden zwischen Silvester und Neujahr). Zur Bewertung wurden jeweils die erklärte Varianz R^2 sowie der *root mean square error* (RMSE) angegeben.

3 Ergebnisse und Diskussion

Die grundlegende Übereinstimmung des Jahresgangs zwischen SEVIRI LST und CLAT ist bereits visuell in Abb. 1 zu erkennen und lässt vermuten, dass ein relevanter Teil der jährlichen Variation aus den Prädiktoren zu erklären ist. Im Referenzmodell (nur SEVIRI LST zum gleichen Zeitpunkt) galt dies für 89 bis 92 % der jährlichen Varianz der CLAT bei quadratischen Fehlern von 2.5 bis 3.4 K. Nun wurden sukzessive weitere Zeitschritte als Prädiktoren hinzugefügt (siehe Tabelle 1) und bereits die Ergänzung um eine einzelne Aufnahme von zwei Stunden vorher **-[0 2]h** verbesserte die Modelperformance merklich, senkte den RMSE auf 1.9 bis 2.5 K und die steigerte die erklärte Varianz auf 94 - 96 %.

Tab. 1: Ergebnisse des empirischen Modells für Hamburg (6 Stationen), Köln-Bonn und München mit verschiedenen multitemporalen Prädiktorsets.

Prädiktorset	N	RMSE								R^2 (validation)							
		ih	hc	sg	sw	lg	lw	kb	ms	ih	hc	sg	sw	lg	lw	kb	ms
Referenz: [0]h	1	3.01	3.06	2.68	2.89	2.59	2.49	3.04	3.35	0.89	0.88	0.91	0.90	0.91	0.92	0.90	0.91
LST-[0 2]h	2	2.41	2.38	2.15	2.30	1.90	1.85	2.19	2.49	0.94	0.94	0.95	0.95	0.96	0.96	0.96	0.95
LST-[0 4]h	2	2.08	2.09	2.10	2.12	1.82	1.81	1.94	2.17	0.95	0.96	0.95	0.95	0.97	0.96	0.97	0.96
LST-[0 8]h	2	1.98	2.02	2.23	2.11	2.04	2.11	2.15	2.33	0.96	0.96	0.95	0.96	0.96	0.96	0.96	0.96
LST-[0 10]h	2	2.21	2.22	2.36	2.26	2.24	2.24	2.47	2.73	0.95	0.96	0.95	0.96	0.95	0.95	0.95	0.94
LST-[2 4]h	2	2.52	2.67	2.60	2.68	2.50	2.50	2.65	2.85	0.93	0.92	0.93	0.93	0.93	0.93	0.94	0.94
LST-[0 2 8]h	3	1.73	1.81	1.96	1.84	1.61	1.70	1.80	2.03	0.97	0.97	0.97	0.97	0.97	0.97	0.98	0.97
LST-[0 1 2]h	3	2.42	2.35	2.12	2.29	1.83	1.71	2.11	2.45	0.94	0.94	0.95	0.95	0.96	0.97	0.96	0.95
LST-[0 2 4]h	3	1.99	1.98	2.00	2.04	1.68	1.63	1.88	2.14	0.96	0.96	0.96	0.96	0.97	0.97	0.97	0.96
LST-[0 4 8]h	3	1.75	1.80	2.02	1.92	1.65	1.72	1.79	1.94	0.97	0.98	0.96	0.97	0.97	0.97	0.98	0.97
LST-[0 2 10]h	3	1.75	1.82	1.98	1.85	1.70	1.76	1.86	2.09	0.97	0.98	0.97	0.97	0.97	0.97	0.98	0.97
LST-[0 4 12]h	3	1.77	1.90	2.05	1.95	1.79	1.86	1.81	2.02	0.97	0.98	0.97	0.97	0.97	0.97	0.98	0.97
LST-[0 4 8 12]h	4	1.67	1.89	2.00	1.89	1.70	1.77	1.75	1.94	0.98	0.98	0.97	0.97	0.97	0.97	0.98	0.97
LST-[0 1 2 4 8]h	5	1.64	1.74	1.82	1.73	1.47	1.54	1.69	1.95	0.98	0.98	0.97	0.98	0.98	0.98	0.98	0.97
LST-[0 1 4 8 12]h	5	1.62	1.84	1.89	1.78	1.52	1.63	1.72	1.94	0.98	0.98	0.97	0.98	0.98	0.98	0.98	0.97
Vorhersagemodus																	
LST-[2 8]h	2	2.34	2.51	2.63	2.57	2.63	2.59	2.56	2.77	0.94	0.94	0.93	0.94	0.93	0.93	0.95	0.94
LST-[2 12]h	2	2.18	2.39	2.60	2.44	2.63	2.63	2.54	2.68	0.95	0.95	0.94	0.95	0.93	0.93	0.95	0.94
LST-[4 12]h	2	3.26	3.62	4.04	3.98	4.31	4.22	4.21	4.53	0.90	0.89	0.85	0.87	0.82	0.82	0.87	0.84
LST-[2 3 4 8 10]h	5	1.99	2.25	2.36	2.25	2.26	2.35	2.36	2.57	0.96	0.96	0.95	0.96	0.95	0.95	0.96	0.95
LST-[2 3 4 8 12]h	5	1.95	2.25	2.39	2.26	2.28	2.38	2.34	2.55	0.97	0.96	0.95	0.96	0.95	0.95	0.96	0.95

Im Modell **-[0 1 2 4 8]h** sanken die Fehler sogar auf 1.5 bis 1.9 Kelvin und die erklärten Varianzen betragen durchweg über 97 %. Es ist allerdings anzumerken, dass letzterer Wert leicht überschätzt sein könnte, da die multitemporalen Prädiktoren durch die Autokorrelation nicht unabhängig sind und damit eine Annahme der Regression nicht erfüllen.

In den letzten vier Experimenten wurde die zeitgleiche Aufnahme nicht verwendet und somit die Möglichkeit einer Kurzzeitvorhersage getestet. Während die 2-Stunden-Prognose immerhin noch eine Genauigkeit von etwa 2.5 K RMSE erreichte, führte die 4-Stunden-Prognose zu Fehlern von etwa 4 K. Interessanterweise waren die innerstädtischen Stationen #ih und #hc, die im Referenzmodell am schlechtesten abschnitten und sich mit zusätzlichen Prädiktoren stärker verbesserten, im Prognose-Modus besonders gut. Die Stationen #kb und #ms waren insgesamt vergleichbar mit den Hamburgern, wobei München meist etwas schlechter abschnitt.

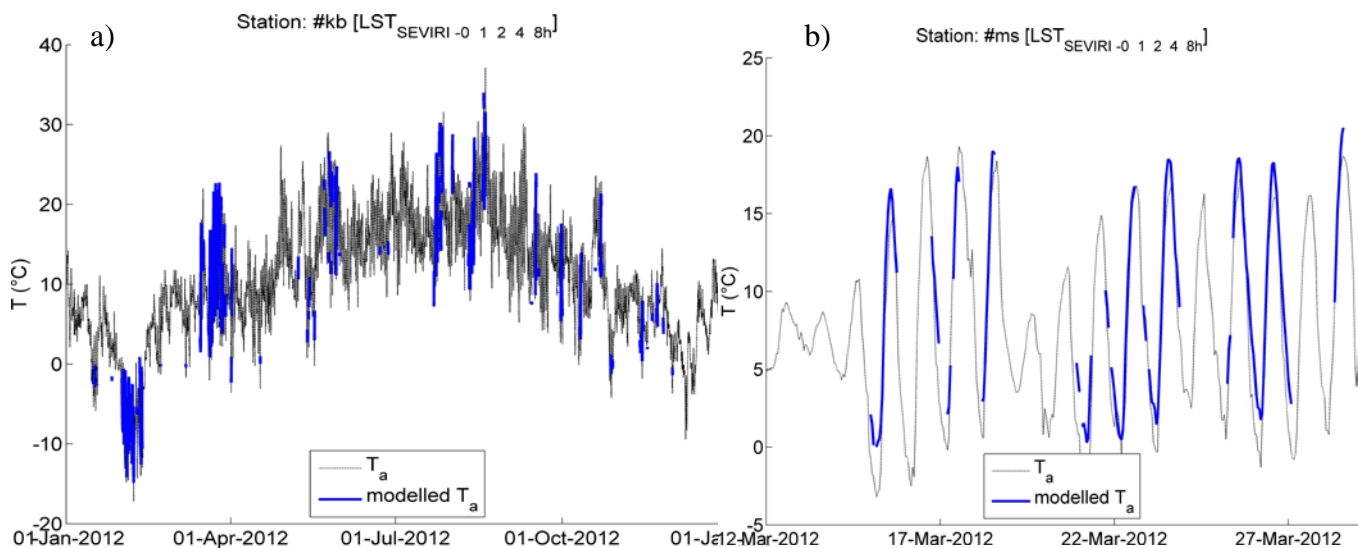


Abb 2. Gemessene und modellierte Lufttemperatur in Grad Celsius. a) Jahrgang für 2012 an der Station Köln-Bonn. b) Ausgewählter Zeitraum im März 2012 für die Station München-Stadt.

Da die hohe erklärte Varianz hauptsächlich auf den Jahresgang zurückzuführen ist, verdient der Tagesgang weitere Aufmerksamkeit. Abbildung 2 zeigt die Modellergebnisse (blaue Linie) und die *in situ* Messungen (schwarze Linie) für ausgewählte Zeiträume für die Stationen #kb und #ms. Die linke Abbildung zeigt den Jahresgang 2012 für #kb und bestätigt eine hohe Übereinstimmung. Die mehrwöchige Periode im März für #ms in der rechten Abbildung zeigt, dass die modellierten Tagesgänge gut wiedergegeben werden, wobei das Modell jedoch einen kleinen Warm-Bias aufweist. Es wird jedoch auch deutlich, dass die Ergebnisse aufgrund der Bewölkung größere Lücken aufweisen.

Dieser Zielkonflikt zwischen Abdeckung und Genauigkeit des Modells lässt sich auch an der Stichprobengröße erkennen (nicht dargestellt). Generell erhöhte sich die Genauigkeit mit der Anzahl der Prädiktoren aber die Anzahl der verfügbaren Datensätze nahm ab. Während für das Referenzmodell an den Hamburger Stationen im Jahr 2012 durchschnittlich 7858 wolkenfreie Akquisitionen verfügbar waren (entsprechend 22% des Jahres) reduzierte sich diese Zahl für das

beste Modell **-[0 1 2 4 8]h** auf 1492 (bzw. 4%). Diese Reduktion war umso größer, je größer der betrachtete Zeitraum war, da wolkenfreien Bedingungen über längere Zeiträume in Hamburg selten sind (z.B. 4842 verfügbare für **-[0 2]h** und nur 2916 für **-[0 10]h**). Von den getesteten Sets von ihrer jeweiligen Größe schnitten **-[0 4]h**, **-[0 2 8]h** und **-[0 1 2 4 8]h** am besten ab.

Teilweise resultiert der geringere Fehler aus der Reduktion der Stichprobengröße und damit Beschränkung des Modells auf bestimmte Witterungsbedingungen (Wolkenfreiheit für mehrere Stunden). Zum Test wurde das Referenzmodell ebenfalls auf diese Stichprobe beschränkt, wobei die Ergebnisse jedoch meist nur wenig besser wurden.

Generell kann die Performance der multitemporalen Modelle als sehr gut bewertet werden, auch wenn der Vergleich mit früheren Studien schwierig ist. Die meisten von ihnen befassen sich mit Bestimmung von Temperaturminima oder Tagesmitteln und rangieren von einfachen und erweiterten statistischen Ansätze bis hin zu Energiebilanzmodellen. Beispielsweise schätzen CRESWELL *et al.* (1999) in Afrika 2 m Lufttemperatur aus METEOSAT LST und erreichten für 72 % der Fälle Abweichungen unter 3 K. JANG *et al.* (2004) verwendeten neuronale Netze und neben den 5 Bänder von AVHRR, Höhe, Sonnenzenitwinkel und den julianischen Tag als Prädiktoren und erreichten eine Korrelation von 0.93 ($R^2 = 0.86$) und einem RMSE von 1.8 K. ZAKŠEK & SCHROEDTER-HOMSCHEIDT (2009) erreichten mit einer Parametrisierung für Mitteleuropa auf der Basis von SEVIRI LST und einiger weiterer Parameter wie Albedo, NDVI und Topographie R von 0.95 ($R^2 = 0.90$) und einem RMSE von 2.0 K. PICHIERRI *et al.* (2012) verwendet einen *split-window* Ansatz, um CLAT von Mai bis September direkt aus MODIS Strahlungstemperaturen (Bänder 31 und 32) und Emissivitäten zu schätzen und erreichten tagsüber mit unseren Ergebnissen vergleichbare Genauigkeiten von etwa 1.8 K RMSE und 0.7 R^2 und sogar bessere Werte für nachts (RMSE = 1.2 K, $R^2 = 0.9$).

Obwohl die gute Reproduktion des Jahresgangs im Einklang mit früheren Studien ist, lagen die Ergebnisse über unseren Erwartungen. Im Vergleich zum Referenzmodell verbesserte die Verwendung multitemporaler Daten das Ergebnis erheblich, was als vielversprechende Erweiterung der satellitengestützten Überwachung der Lufttemperatur gesehen wird. Offensichtlich enthält die multitemporale LST zusätzliche Informationen über die Wechselwirkung zwischen Atmosphäre und Oberfläche im Quellgebiet, wodurch das komplexe Zusammenspiel effektiv in einer einzigen empirischen Funktion parametrisiert werden kann. Allerdings ist darauf hinzuweisen, dass diese zunächst nur für den jeweiligen Standort gilt und keinesfalls für weitere (ähnliche) Standorte repräsentativ ist, da sie neben den Oberflächeneigenschaften in der unmittelbaren Nachbarschaft auch von denen im gesamten betrachteten Pixel abhängt. Auch wenn die Performance im Prognosemodus deutlich geringer ist, könnte ein Fehler von etwa 2-2.5 K für bestimmte Anwendungen akzeptabel sein und bietet daher einen interessanten Ansatz zur Kurzfristvorhersage städtischer Lufttemperaturen und Wärmebelastung. Der größte Nachteil der Methode liegt bislang in der begrenzten Verfügbarkeit der Daten, die es zum "Schönwettermodell" macht.

4 FAZIT

Empirische Modelle auf Basis multitemporaler geostationärer LST Daten haben ein hohes Potenzial Zeitreihen städtischer Lufttemperaturen auf lokaler Skala zu erklären und eignen sich deutlich besser als eine einfache Korrelation zu einem Zeitpunkt. Vor allem der zweite und dritte Zeitschritt verbessern das Ergebnis dabei deutlich. Die besten Modelle erreichen einen RMSE von ~ 1,5 K und ein R^2 von 98 %. Einer Kurzfristvorhersage hatte zwar etwas größere Fehler, ist aber für 2 Stunden zumindest vielversprechend, was angesichts der schnellen Verfügbarkeit der Daten und Prozessierung möglicherweise noch interessant ist. Die größte Einschränkung ist die Verfügbarkeit von wolkenfreien Messungen.

5 Literaturverzeichnis

- ARNFIELD, A.J. 2003. Two decades of urban climate research: a review of turbulence, exchanges of energy and water, and the urban heat island. *International Journal of Climatology*, **23**, 1–26.
- BECHTEL, B., BÖHNER, J., ZAKŠEK, K. & WIESNER, S. 2013. Downscaling of diurnal land surface temperature cycles for urban heat island monitoring. *In Urban Remote Sensing Event (JURSE), 2013 Joint – Urban Remote Sensing Event (JURSE), 2013 Joint*. IEEE.
- BECHTEL, B., ZAKŠEK, K. & HOSHYARIPOUR, G. 2012. Downscaling Land Surface Temperature in an Urban Area: A Case Study for Hamburg, Germany. *Remote Sensing*, **4**, 3184–3200, 10.3390/rs4103184.
- BECHTEL, B., WIESNER, S. & ZAKŠEK, K. 2014. Estimation of dense time series of urban air temperatures from multitemporal geostationary satellite data. Submitted to *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*
- CRESSWELL, M.P., MORSE, A.P., THOMSON, M.C. & CONNOR, S.J. 1999. Estimating surface air temperatures, from Meteosat land surface temperatures, using an empirical solar zenith angle model. *International Journal of Remote Sensing*, **20**, 1125–1132.
- FABRIZI, R., BONAFONI, S. & BIONDI, R. 2010. Satellite and Ground-Based Sensors for the Urban Heat Island Analysis in the City of Rome. 1400–1415.
- FABRIZI, R., DE SANTIS, A. & GOMEZ, A. 2011. Satellite and ground-based sensors for the Urban Heat Island analysis in the city of Madrid. *In Urban Remote Sensing Event (JURSE), 2011 Joint – Urban Remote Sensing Event (JURSE), 2011 Joint*. IEEE, 349–352.
- GALLO, K.P. & OWEN, T.W. 1998. Assessment of urban heat Islands: A multi-sensor perspective for the Dallas-Ft. worth, USA region. *Geocarto International*, **13**, 35–41.
- INAMDAR, A.K., FRENCH, A., HOOK, S., VAUGHAN, G. & LUCKETT, W. 2008. Land surface temperature retrieval at high spatial and temporal resolutions over the southwestern United States. D07107.
- JANG, J.-D., VIAU, A.A. & ANCTIL, F. 2004. Neural network estimation of air temperatures from AVHRR data. *International Journal of Remote Sensing*, **25**, 4541–4554.
- NICHOL, E.J., FUNG, W.Y., LAM, K.S. & WONG, M.S. 2009. Urban heat island diagnosis using ASTER satellite images and “in situ” air temperature. *Atmospheric Research*, **94**, 276–284.
- NICHOL, J. 2005. Remote sensing of urban heat islands by day and night. *Photogrammetric engineering and remote sensing*, **71**, 613–622.

- PICHIERRI, M., BONAFONI, S. & BIONDI, R. 2012. Satellite air temperature estimation for monitoring the canopy layer heat island of Milan. *Remote Sensing of Environment*, **127**, 130–138, 10.1016/j.rse.2012.08.025.
- ROTH, M., OKE, T.R. & EMERY, W.J. 1989. Satellite-derived urban heat islands from three coastal cities and the utilization of such data in urban climatology. *International Journal of Remote Sensing*, **10**, 1699–1720.
- SUN, Y.-J., WANG, J.-F., ZHANG, R.-H., GILLIES, R.R., XUE, Y. & BO, Y.-C. 2005. Air temperature retrieval from remote sensing data based on thermodynamics. *Theoretical and Applied Climatology*, **80**, 37–48, 10.1007/s00704-004-0079-y.
- TOMLINSON, C.J., CHAPMAN, L., THORNES, J.E. & BAKER, C. 2011. Remote sensing land surface temperature for meteorology and climatology: a review. *Meteorological Applications*, **18**, 296–306, 10.1002/met.287.
- VOGT, J.V., VIAU, A.A. & PAQUET, F. 1997. Mapping regional air temperature fields using satellite-derived surface skin temperatures. *International Journal of Climatology*, **17**, 1559–1579.
- VOOGT, J.A. & OKE, T.R. 2003. Thermal remote sensing of urban climates. *Remote Sensing of Environment*, **86**, 370–384.
- WENG, Q., RAJASEKAR, U. & HU, X. 2011. Modeling Urban Heat Islands and Their Relationship With Impervious Surface and Vegetation Abundance by Using ASTER Images. *IEEE Transactions on Geoscience and Remote Sensing*, **49**
- YAO, Y. & ZHANG, B. 2013. MODIS-based estimation of air temperature of the Tibetan Plateau. *Journal of Geographical Sciences*, **23**, 627–640, 10.1007/s11442-013-1033-7.
- YOW, D.M. 2007. Urban heat islands: observations, impacts, and adaptation. *Geography Compass*, **1**, 1227–1251.
- ZAKŠEK, K. & OŠTIR, K. 2012. Downscaling land surface temperature for urban heat island diurnal cycle analysis. *Remote Sensing of Environment*, **117**, 114–124, 10.1016/j.rse.2011.05.027.
- ZAKŠEK, K. & SCHROEDTER-HOMSCHEIDT, M. 2009. Parameterization of air temperature in high temporal and spatial resolution from a combination of the SEVIRI and MODIS instruments. *ISPRS Journal of Photogrammetry and Remote Sensing*, **64**, 414–421.

¹ Benjamin Bechtel, KlimaCampus, Uni Hamburg, benjamin.bechtel@uni-hamburg.de

² Klemen Zakšek, Institut für Geophysik, Uni Hamburg, klemen.zaksek@zmaw.de

³ Jürgen Böhner, KlimaCampus, Uni Hamburg, boehner@geowiss.uni-hamburg.de