

שיטות היברידיות מבוססי לוויין להערכת חשיפה לזיהום אוויר

מקורות מידע וגיוס משאבים לקידום תחבורה בת-קיימא
ברשויות המקומיות 2021

פרופ' איתי קלוג
המחלקה לגאוגרפיה ופיתוח סביבתי





Environmental Exposure Assessment (EEA) laboratory at Ben Gurion University



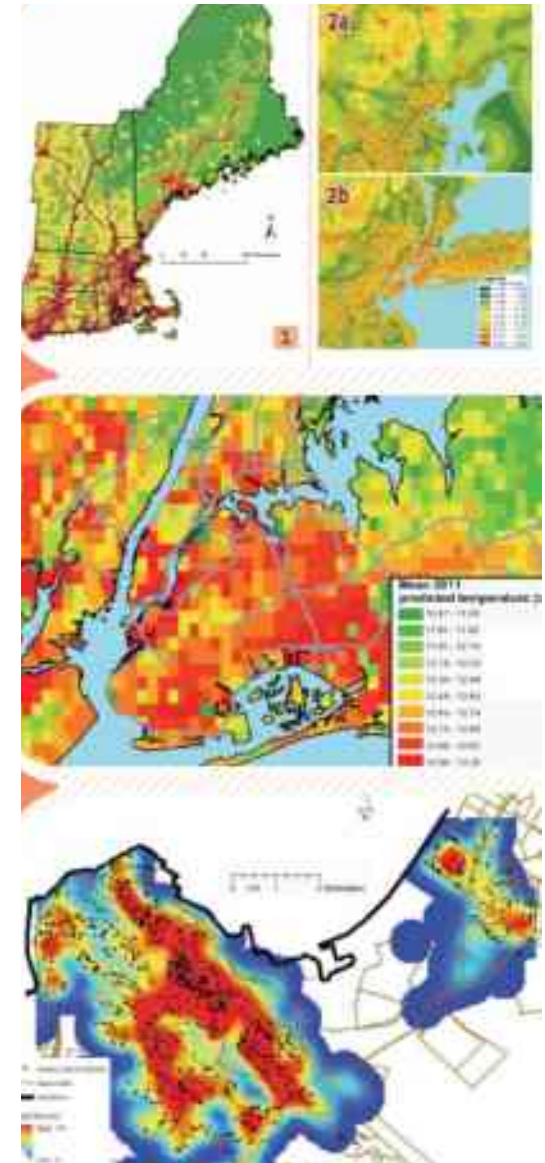
<http://in.bgu.ac.il/humsos/eeal/>

Focus on the challenges of developing robust high-resolution environmental exposure assessment models and studying unbiased exposure-health outcome associations in environmental health studies

We apply advanced geo-statistical methods and novel GIS/remote sensing based technologies to address these scientific challenges

We research among other :

1. $PM_{2.5/10}$ hybrid satellite based models
2. Air Temperature exposure assessment models
3. Noise pollution LUR based models
4. Light-at-Night Satellite based exposure assessment
5. Built environment: Walkability indexes, SES “exposures”, NDVI analysis
6. Environmental Epidemiology studies



זיהום אוויר

ארגון הבריאות העולמי העריך לאחרונה שחשיפה לחלקיקים עדינים (PM2.5) תורמת לתמותה מוקדמת של כשני מיליון אנשים בשנה, דבר המדרג אותו כגורם התמותה ה-13 בעולם (Lozano et al., 2013; WHO, 2012)

בעולם

זיהום האוויר הורג 7 מיליון בני אדם כל שנה

ליו רוק פליטות מהמוסדות המפעלים אחראית לכך. ארגון הבריאות העולמי העריך שרוב הקרובות נכנסים מאוירי מזהמים בתוך בתים שלהם. נשים יולדים בסיכון גבוה



זיהום אוויר גורם למחש של כשנתיים מיליון בני אדם בשנה. זיהום המסוידות מהקוויבנות מזהם כחומרה חממה ושולטת בחורף. במקומות סגורים, כגון בבתים, כך נעלה חוליה שפרסם במשוע ארסן הכריאות העלתי

- מיד חדשות המסלום :**
- **מכרס על לכונו ערסן דולמיים אושרו בינים**
 - **"החול חשק ב" SMS מעיל זימן גאני חק**
 - **חשדו און האלטרנטי "השכסילי חלומות חשק"**
 - **האמר פינגים ועוללת בעתבות שפסכה שחובה**

לשי הארגון, זיהום האוויר הוא הגורם לאחד מכל שבעה מקרי מוות, עליון לטבון הבגיאטי המביבות היצודים העול בוחר. "ללא ברירה למעט, זה רופך את המורך לרשות מזהם האוויר לקשר מאסר לחישה". אומר פרוק קר, מנהל ארגון החקיקה המביבות בקונס קולו בלודון שלא היה חלק מהדו"ח של ארגון הבריאות.



חומר חלקיקי

חלקיקי חומר-
(Particulate Matter - PM)
הם שברים קטנים של חומר נוזלי או מוצק
הנמצאים בגז או נוזל.

מקורות חומר חלקיקי עשויים להיות
טבעיים או מעשה ידי אדם (מקור
אנתרופוגני).

מקורות נפוצים הם פרחים (התורמים
אבקנים), שריפות (בעיקר ממנועי
דיזל), כרייה, בנייה (חול ומתכות)
וסופות חול טבעיות.

PM מסווג לפי מתאר הקוטר
האירודינמי שלו **במיקרונים**




image courtesy of the U.S. EPA

המרכיב הספציפי של PM2.5 בזיהום אויר הוא קריטי במיוחד משום שגודל החלקיקים הקטן מאפשר להם לחדור לריאה ולתוך מחזור הדם.

ככל שהחלקיק גדול יותר, כך סכנתו פוחתת כיוון שהוא בעל סיכוי גדול יותר להיתפס על ידי האף או הגרון ולהיפלט בנשימה על ידי שיעול או להיבלע.

התקן הישראלי לחומר חלקיקי נשים ((RSP - Respirable Particles 200)) מיקרוגרם למטר מעוקב ליממה ו- 75 מיקרוגרם למטר מעוקב לשנה. זאת לעומת התקן האמריקאי של 150 מיקרוגרם למטר מעוקב ל-24 שעות ו- 50 מיקרוגרם למטר מעוקב לשנה

PM2.5: Invisible Killer



מחקרים רבים מצאו קשר בין PM2.5 ועליה בשיעורי תחלואה ובאופן ספציפי עם:

Hospital Admissions (**kloog 2012**; Schwartz 1997)

Mortality (**kloog 2013**; Zanobetti 2008; Basu 2005)

Reduced birth weights (Bell 2007; **Kloog et al 2012**; Zeka 2006)

Cardiovascular disease (De Hartog 2009; Dominici 2006; **Kloog 2012**; Mann 2002; Pope 2011; Schwartz, 1997)

Respiratory disease (Dominici et al., 2006; **Kloog 2012**; Schwartz, 1996).

myocardial infarction (heart attack) (D'Ippoliti 2003; Hodas 2013; **Madrigano 2012**; Rich 2013; Zanobetti and Schwartz, 2005)



- לאקלים תפקיד מרכזי בהתפתחות, הסעה ופיזור של מזהמים באוויר.
- אירועי זיהום אוויר קיצוניים קשורים ברוב המקרים עם ימים שבהם עוצמת הרוח חלשה מאוד או לחלופין תקופות עם רוחות קיצוניות שיכולות להסיע זיהום אוויר למרחקים ארוכים.

זיהום אוויר ובמיוחד זיהום חלקיקי משתנים כתגובה לשינוי אקלים:

- שריפות מלאכותיות וטבעיות מעלות את כמות החלקיקים באוויר, כולל חלקיקים רעלניים.
- דפוסי מזג אוויר יכולים לחזק אפקטים של "איי חום" עירוניים אשר מובילים לרמות זיהום גבוהות.



כמו שבעשור הקודם המחקרים האפידמיולוגיים התמקדו בקשר שבין חשיפה ל PM2.5 לתחלואה, בשנים האחרונות החלו להתייחס להשפעות הבריאותיות של חשיפה למקרי מזג אוויר קיצוניים כתוצאה משינויי האקלים.

שינויי האקלים יובילו לטמפרטורות חמות יותר והתרבות של מקרי מזג אוויר קיצוני. אלה מקושרים לעלייה בתחלואה ותמותה באוכלוסיות רגישות (Le Tertre et al. 2006; Ostro et al. 2009)

עליה זו בתמותה ותחלואה לא מתרחשת רק בתקופות גלי חום, אלא גם בתקופות פחות קיצוניות (Kloog et al. 2011 ; Basu et al. 2005; Kinney 2008; Le Tertre et al. 2006; Ostro et al. 2009; Zanobetti and Schwartz 2008)



הערכת חשיפה

באופן אידיאלי הערכת חשיפה למזהמים סביבתיים תתבצע ברמה האישית. אך באופן מעשי הדבר בלתי אפשרי ממספר סיבות:

- א. הערכה כזו יקרה מאוד.
- ב. יש בבדיקות משום פגיעה בפרטיות.
- ג. אלה לא בדיקות מעשיות לאורך פרקי זמן ארוכים.
- ד. הבדיקות האלה לא מאפשרות לבדוק אוכלוסיות גדולות.

הפתרון להערכת חשיפה, אם כן, מגיע מתחנות ניטור ומודלים בקנה מידה גדול.


מחקרים אפידמיולוגיים רבים בשנים האחרונות משתמשים בשיטות אנליטיות מתוחכמות יותר כדי לשפר את ההבנה לגבי ההשפעות של PM2.5 על בריאות האדם.

מחקרים אלה משתמשים באזורים גאוגרפיים גדולים מאוד (מדינות וכו') כיחידת המחקר.

כתוצאה מכך יש פוטנציאל להטיה של השפעות הבריאות עקב "הטיית חשיפה":

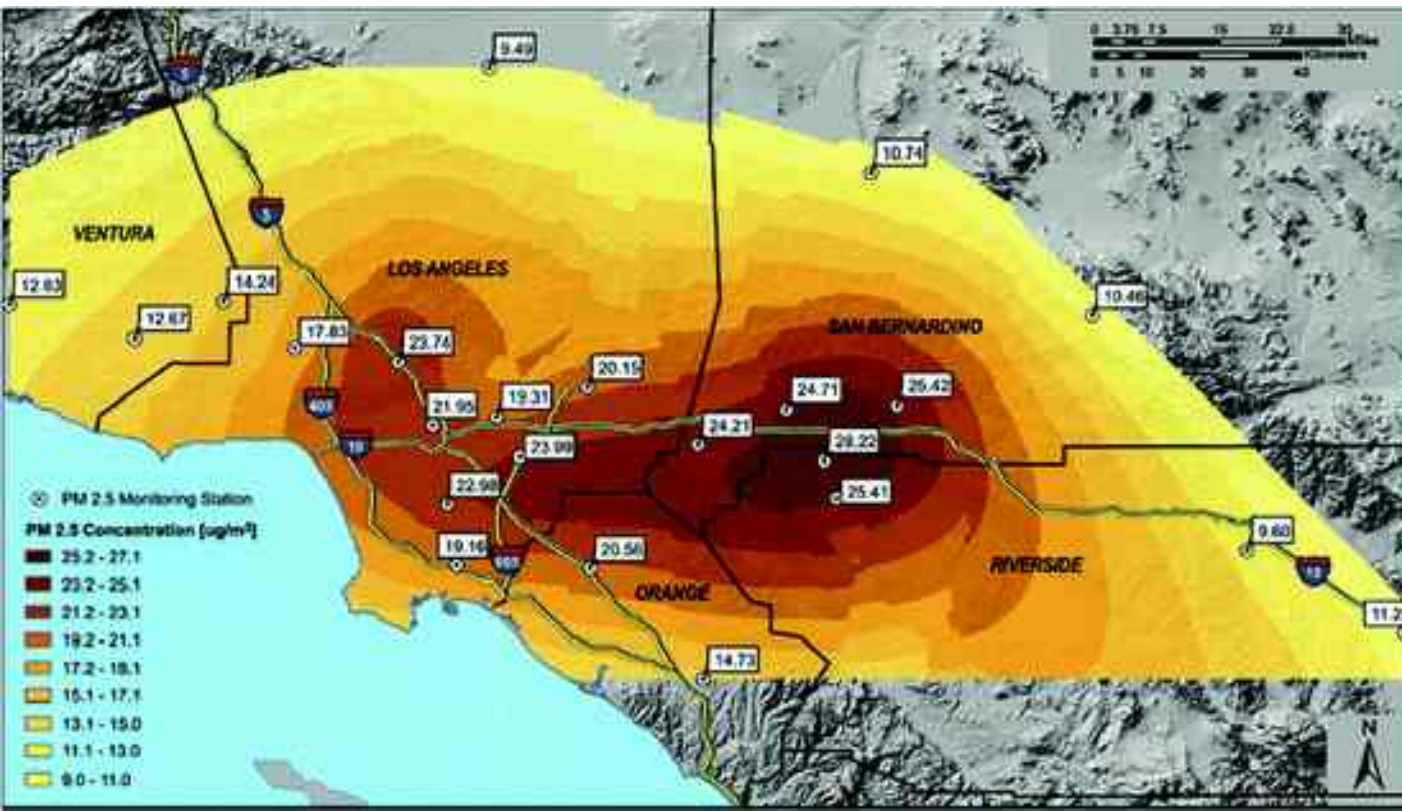
Exposure measurement error

הערכת חשיפה בלתי מדויקת לכל משתתף במחקר בשל נתוני חשיפה מוגבלים/שגויים.



- בנוסף, כל המחקרים האפידמיולוגים ממוקדים תמיד באזורים עירוניים בלבד כיוון ש:
1. תחנות ניטור נמצאות בעיקר באזורים עירוניים.
 2. רוב האוכלוסייה נמצאת גם היא באזורים עירוניים.

מגבלות אלה מצביעות על הצורך לפתח שיטות סטטיסטיות ומודלים טובים יותר להערכת חשיפה במחקרים אפידמיולוגיים.



המודל המוביל בשנים האחרונות בהערכת חשיפה ל $PM_{2.5}$ באירופה הוא ה ESCAPE

A multi-group European collaboration - the ESCAPE Project (European Study of Cohorts for Air Pollution Effects)




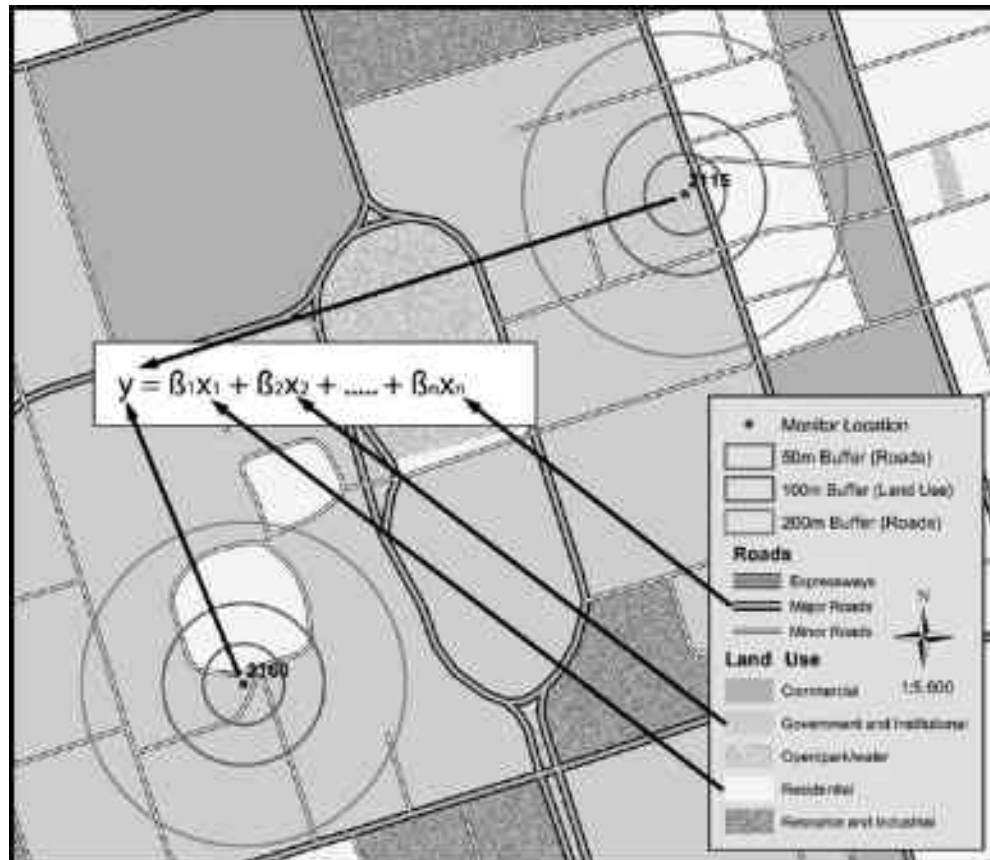
זהו כיום המודל הגדול והטוב ביותר המספק הערכות חשיפה ל $PM_{2.5}$ לעשרות מחקרים באירופה.

שם המחקר	מספר המחקר
1990	
1991	
1992	
1993	
1994	
1995	
1996	
1997	
1998	
1999	
2000	
2001	
2002	
2003	
2004	
2005	
2006	
2007	
2008	
2009	
2010	
2011	
2012	
2013	
2014	
2015	
2016	
2017	
2018	
2019	
2020	
2021	
2022	
2023	
2024	
2025	
2026	
2027	
2028	
2029	
2030	
2031	
2032	
2033	
2034	
2035	
2036	
2037	
2038	
2039	
2040	

A LUR model is one of the most widely used exposure assessment tools in air pollution epidemiological


Allows researches to estimate the concentration at unmonitored locations.

The LUR model evaluates the relationship between observed air pollution concentrations and predictor variables such as land use and traffic condition around the monitoring sites in the multivariate regression model.



תוצאות פרויקט ה ESCAPE פורסמו לאחרונה (ומשתמשים בתוצאות המודל מספר גדול של מחקרים אפידמיולוגיים כיום באירופה.
(Eeftens et al. 2012b; Raaschou-Nielsen et al. 2013)

מודל ה- LUR שפותח במסגרת ESCAPE הראה יכולת ניבוי סבירה (maximum $R^2 = 0.71$) אך סובל מהרבה מגבלות שמודלים של LUR סובלים ממנה:
-מחסור בניבוי יומי (No daily time variations)
-מחסור בתחנות ניטור באזורים לא עירוניים גורם לכך שהמודל לא יכול לנבא באזורים אלה.




כדי להתמודד עם חלק מהמגבלות של המודלים הקודמים התחלנו לפתח מודלים מורכבים יותר שהובילו להתפתחויות חשובות בתחום המחקר של הערכת החשיפה.

הכיסוי המרחבי הגבוה שלוויינים מאפשרים נותן לנו את היכולת להרחיב את הערכת החשיפה במרחב מעבר למה שתחנות ניטור על הקרקע מאפשרות. כך אנו מגיעים לאזורים כפריים ואזורים מרוחקים מתחנות ניטור ומשפרים משמעותית את הערכת החשיפה באזורים אלו

בעקבות המחקרים מבוססי הלווין שלנו (2010-2011) החלו בשנים האחרונות להופיע מחקרים המשתמשים בנתוני לוויין בכדי לנבא $PM_{2.5}$ (Cordero et al. 2013; A. Chudnovsky, Lyapustin, et al. 2013; Chang, Hu, and Liu) (2013; Gupta et al. 2013; Kim et al. 2013)

מחקרים אלה אומנם מראים יכולת ניבוי גבוהה יותר ממודלים LUR קודמים, אך הם עדיין סובלים מהמגבלה לנבא בצורה מדויקת וברזולוציה גבוהה בזמן ובמרחב (במיוחד באזורים לא עירוניים) דבר שהוא קריטי במחקרים אפידמיולוגיים שעוסקים בחשיפה אקוטית (קצרת מועד).



MODIS (Moderate Resolution Imaging Spectroradiometer)

מערכת ה-MODIS כוללת שני לוויינים השייכים לסוכנות החלל האמריקאית NASA (לוויני TERA ו-AQUA). במערכת ישנם 36 ערוצים בתחומים שונים של הספקטרום האלקטרו-מגנטי

הלווינים מספקים מידע יומי של AOD


הרזולוציה הבסיסית של AOD היא 10X10 ק"מ.



Aerosol optical Depth: Definition


עובי אופטי אטמוספרי -

"Aerosol Optical Depth" (AOD) or "Aerosol Optical Thickness"
האור הנבלע על ידי פיזור ארוסולים וספיגתם בעמודה אטמוספרית.




What MODIS observes

May 4, 2001; 13:25 UTC
Level 1 "reflectance"



Attributed to aerosol (AOD)

May 4, 2001; 13:25 UTC
Level 2 "product"



There are many different "algorithms" to retrieve aerosol from MODIS

1. **Dark Target ("DT" ocean and land; Levy, Mattoo, Munchak, Remer, Tanré, Kaufman)**
2. **Deep Blue ("DB" desert and beyond; Hsu, Bettenhausen, Sayer, ..)**
3. **MAIAC (coupled with land surface everywhere; Lyapustin, Wang, Korkin, ...)**
4. Ocean color/atmospheric correction (McClain, Ahmad, ...)
5. Etc (neural net, model assimilation, statistical, ...)

AOD is a **unitless** value.

Sample AOD values:

0.02 - very clean isolated area

0.08 – background over ocean

0.2 – fairly clean

0.6 –polluted

1.5 – heavy smoke/dust even

>3.0 – Sun's disk obscured!

0.4 over India



>2.0 in Brazil





Assessing temporally and spatially resolved PM_{2.5} exposures for epidemiological studies using satellite aerosol optical depth measurements

Itai Kloog^a, Petros Koutrakis^b, Brent A. Coull^c, Heung-Jin Lee^d, and Joel Schwartz^e

<http://dx.doi.org/10.1016/j.atmosenv.2010.08.031>



Article

pubs.rsc.org/en

Incorporating Local Land Use Regression And Satellite Aerosol Optical Depth In A Hybrid Model Of Spatiotemporal PM_{2.5} Exposures In The Mid-Atlantic States

Itai Kloog,^{1,*} Francesco Nordin,¹ Brent A. Coull,² and Joel Schwartz³

¹Department of Environmental Health—Exposure, Epidemiology and Risk Program, Harvard School of Public Health, Landmark Center 401 Park Drive West, Boston, Massachusetts 02115, United States

²Department of Biostatistics, Harvard School of Pub



Estimating spatio-temporal resolved PM₁₀ aerosol mass concentrations using MODIS satellite data and land use regression over Lombardy, Italy

Francesco Nordin^a, Itai Kloog^b, Brent A. Coull^c, Alexandra Chudnovsky^d, Paolo Girli^e, Pier Alberto Bertozzi^f, Andrea A. Ilicakovic^g, Joel Schwartz^h

Fine particulate matter predictions using high resolution Aerosol Optical Depth (AOD) retrievals

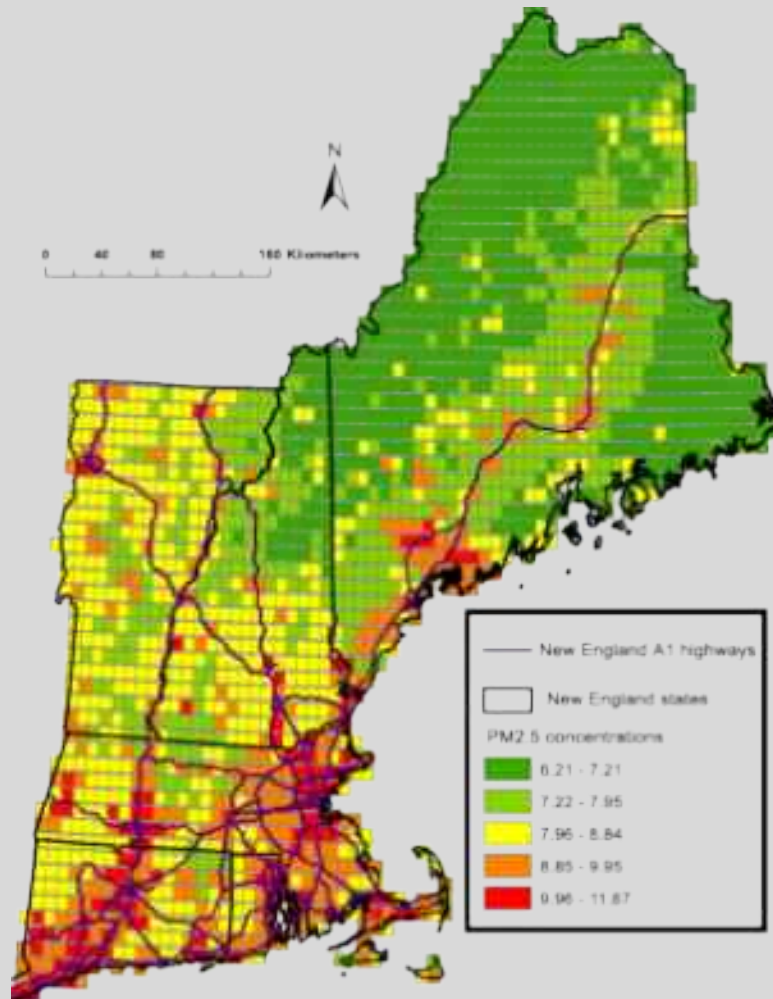
Alexandra A. Chudnovsky^{a,b,c}, Petros Koutrakis^d, Itai Kloog^b, Steven Melly^e, Francesco Nordin^a, Alexei Lyapustin^f, Yujie Wang^g, Joel Schwartz^h

^aDepartment of Environmental Health, Harvard School of Public Health, Boston MA, USA
^bDepartment of Geography and Public Health Research, Harvard University, Boston, MA, USA
^cDepartment of Geographic and Environmental Engineering, Boston University, Boston, MA, USA
^dDepartment of Environmental Health, Harvard School of Public Health, Boston MA, USA
^eUniversity of Maryland Eastern Shore, Pocomoke, MD, USA



מודלים MODIS (2010-2012)

**Mean $PM_{2.5}$ concentrations in each
10x10 km grid during the entire
modeling period (2000-2008)
predicted by the AOD models.**




תוצאות שלב 1

Stage 1 prediction accuracy- out of sample CV R^2 for yearly $PM_{2.5}$ prediction models (2000-2008).

Year	First model CV-NE
2000	0.680
2001	0.811
2002	0.815
2003	0.850
2004	0.800
2005	0.842
2006	0.840
2007	0.873
2008	0.817
Overall Mean	0.811

Predicted $PM_{2.5}$ concentrations averaged over the entire study period-Mid Atlantic

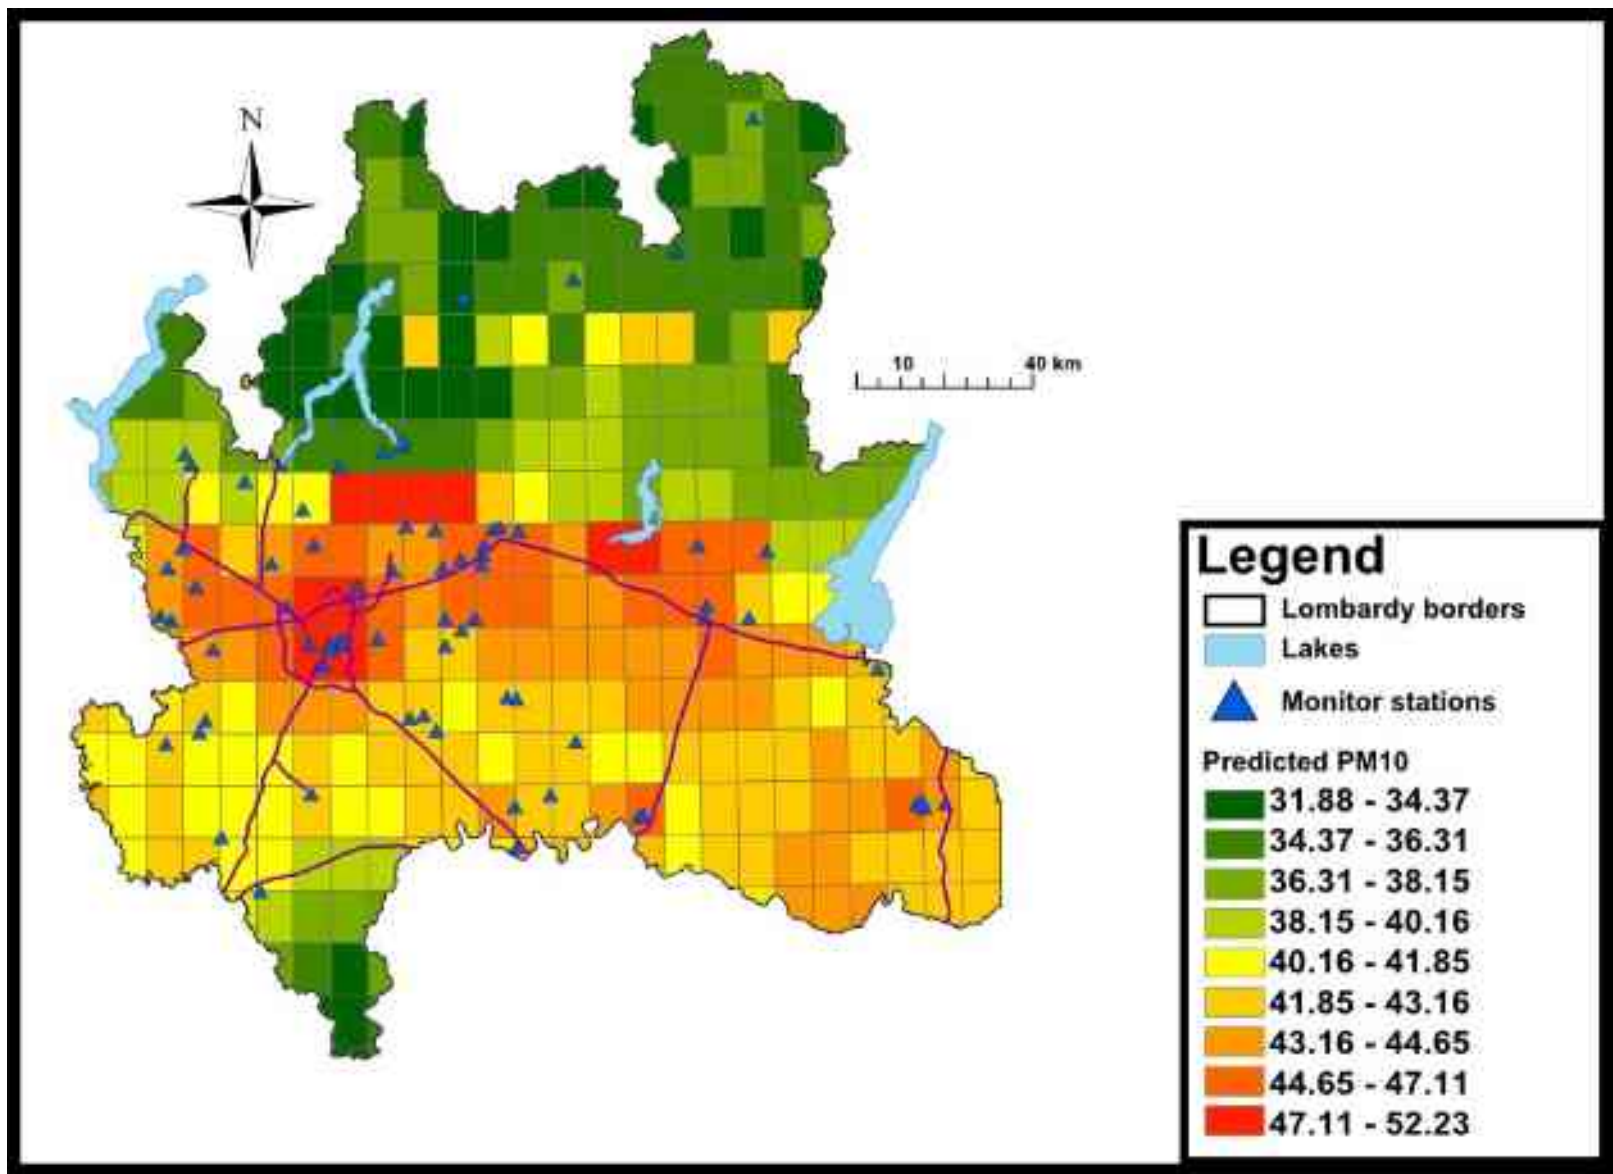


Mean $PM_{2.5}$ concentrations in each 10x10 km grid during the entire modeling period (2000-2008) predicted by the AOD models.

תוצאות שלב 1

Stage 1 prediction accuracy- out of sample CV R² for yearly PM_{2.5} prediction models (2000-2008).

Year	New model CV-NE	New model CV-MIA
2000	0.759	0.852
2001	0.844	0.840
2002	0.831	0.829
2003	0.848	0.875
2004	0.875	0.853
2005	0.816	0.831
2006	0.885	0.861
2007	0.916	0.847
2008	0.847	0.802
Overall Mean	0.847	0.843



Mean PM₁₀ concentration in each 10x10 km grid during the entire modeling period (2000-2009) predicted by the AOD models.

מגבלות המחקרים הקודמים

- רזולוציה גסה יחסית של 10X10 ק"מ וכתוצאה מכך עדיין יש BIAS
- עדיין יש מקום לשפר את יכולת הניבוי של המודל

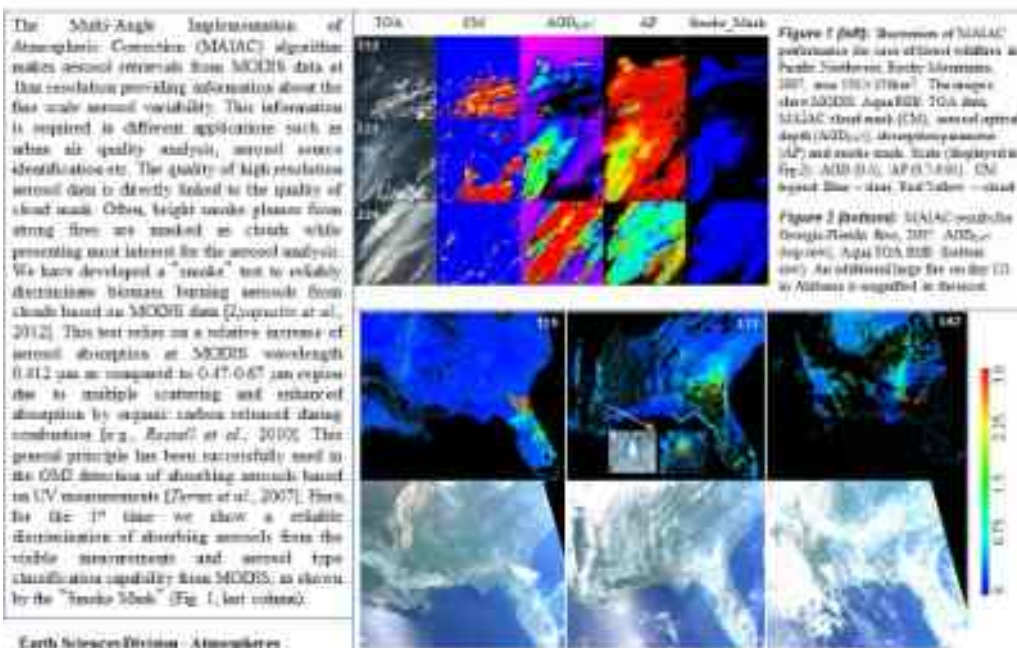
- לאחרונה צוות מדענים ב NASA פיתח אלגוריתם חדש לעיבוד נתונים של MODIS אשר מספק נתוני AOD ברזולוציה של 1X1 ק"מ (Lyapustin et al., 2011; Lyapustin et al., 2011)

התחלנו בשיתוף פעולה ושימוש ב- MAIAC



Discrimination of Biomass Burning Smoke and Clouds in MAIAC Algorithm

A. Lyapustin, S. Korkin, Y. Wang, B. Quayle, I. Leszto, Code 613, NASA GSFC



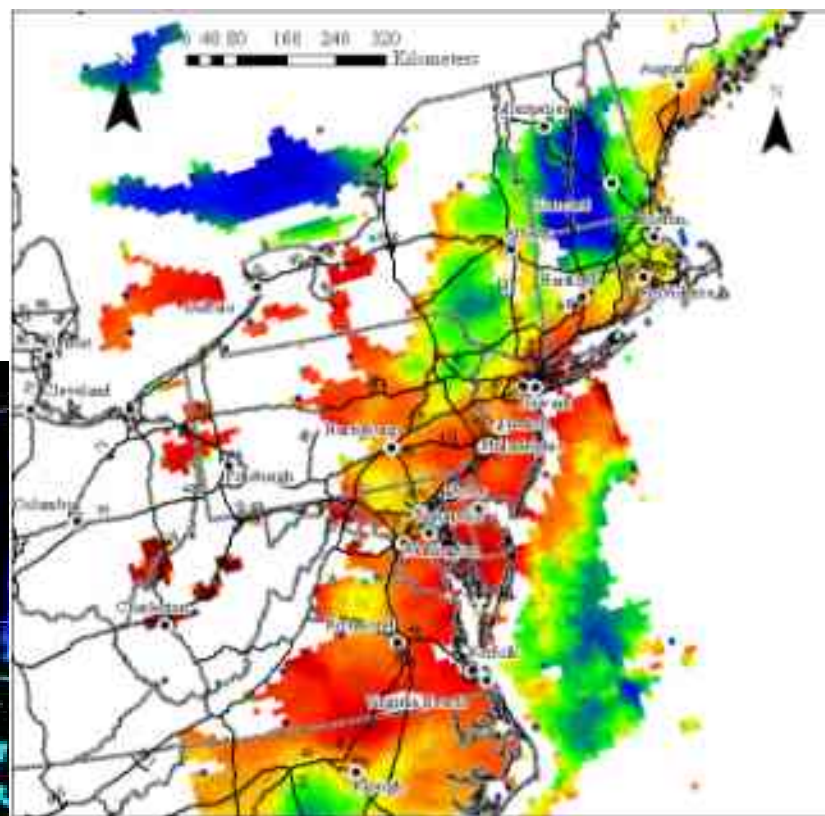

A New Hybrid Spatio-Temporal Model For Assessing Daily Multi-Year PM2.5 Concentrations Across Northeastern USA Using High Resolution Aerosol Optical Depth (AOD) Data

Itai Kloog¹, Alexandra A. Chudnovsky², Allan Just³, Francesco Nordio³, Petros Koutrakis³, Brent A. Coull³, Alexei Lyapustin⁵, Yujie Wang⁶ and Joel Schwartz³

- אנו משתמשים ב MODIS satellite images algorithms (MAIAC) שמספק נתונים באיכות גבוהה ברזולוציה מרחבית גבוהה 1X1 ק"מ
- אנו פיתחנו ואימתנו מודלים (cross validated) לניבוי יומי של 25PM ברזולוציה מרחבית גבוהה של 1X1 ק"מ לאורך צפון מזרח ארה"ב, בשנים 2003-2011 שמאפשר לנו להעריך בצורה מדויקת יותר לטווח הקצר והארוך את רמות הזיהום גם באזורים עירוניים וגם באזורים כפריים.
- בנוסף פיתחנו שלב חדש במודל, שאפשר לנו לנבא 25PM ברזולוציה מרחבית גבוהה של 200X200 מטר שמשלימים את הניבוי הלוויני

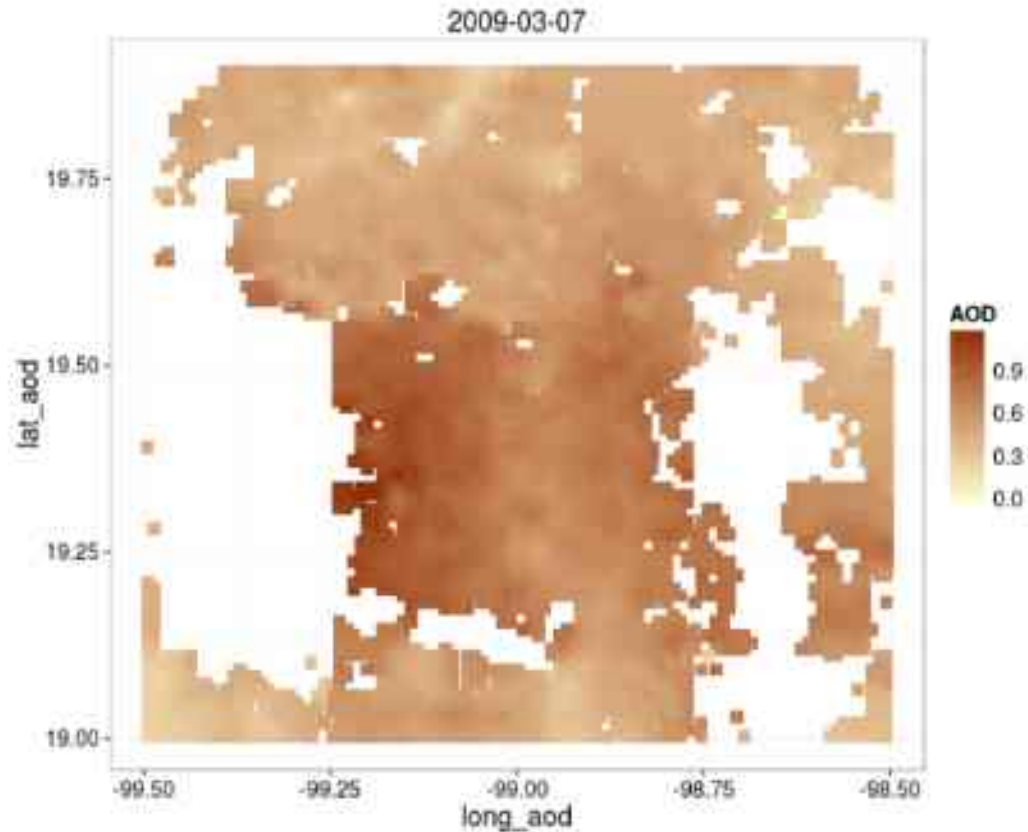
בניית בסיס הנתונים

הדמיות רסטוריות יומיות (קבצי HDF) של נתוני AOD מ MODIS-MAIAC (לתקופה 2003-2013)
עובדו על ידי ArcGIS ותוכנת SAS וMATLAB R (מעל 60,000 הדמיות....)



Sample day with available AOD data (Mexico)

Sample day with available AOD data



This date has 41% coverage (59% clouds)

נתוני PM2.5

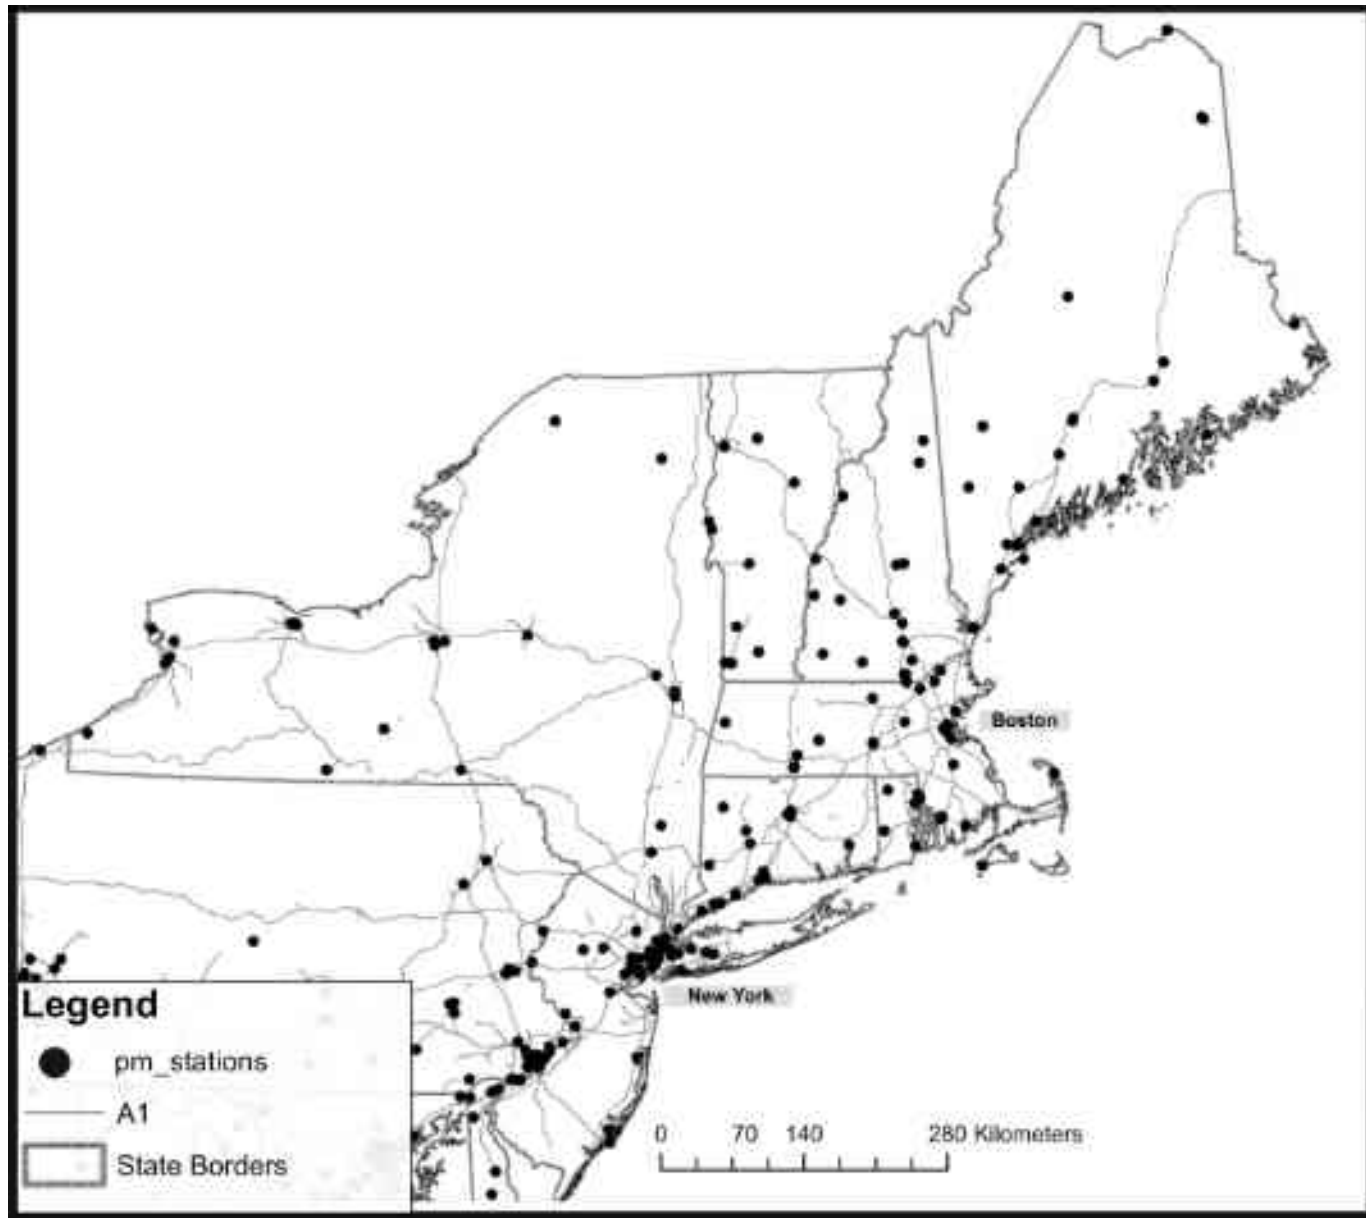
נתונים יומיים של רמות PM2.5 נאספו משני מקורות
עיקריים:

US Environmental Protection Agency (EPA) Air (1
Quality System (AQS)

IMPROVE (Interagency Monitoring of Protected (2
Visual Environments) network

שטח המחקר כלל 161 תחנות עם ממוצע יומי לכלל
ניו-אינגלנד בתקופת המחקר של $11.7 \mu\text{g}/\text{m}^3$ וסטיית
תקן של $7.8 \mu\text{g}/\text{m}^3$.






The spatial domain of our region included the Northeastern part of the USA, and includes the states of Connecticut, Maine, Massachusetts, New Hampshire, Rhode Island, Vermont, New York and New Jersey.

נתוני AOD יומיים קושרו באופן מרחבי ועיתי לנתוני ה- $PM_{2.5}$ באמצעות קוד python או ArcGIS .R.

תוצאת תהליך זה היא בסיס נתונים עם כל רמות ה- $PM_{2.5}$ היומיות שנמדדו בתחנות הניטור ונקודות ה- AOD ברדיוס של קילומטר מהן.



```
#
# mapr.es
# Created on: Thu May 21 2020 11:41:44 AM
# Generated by ArcGIS/ModelBuilder

# Import system modules
import sys, os, arcpy

# Create the Workspace object
ws = arcpy.workspace.Create()

# Load required toolboxes...
AddToolbox("%ProgramFiles%\ArcGIS\toolbox\Toolboxes\MapToolbox.tbx")

#####

#####

# Local Variables---
ZI_AOI_AOD_2000_mpg = "C:\Users\user\AppData\Local\Temp\MapToolbox\ZI_AOI_AOD_2000_mpg"
PM_AOI_AOD_2000_mpg = "C:\Users\user\AppData\Local\Temp\MapToolbox\PM_AOI_AOD_2000_mpg"
AOD_AOI_AOD_2000_mpg = "C:\Users\user\AppData\Local\Temp\MapToolbox\AOD_AOI_AOD_2000_mpg"

# Process: Spatial Join...
[MapToolbox] Spatial Join (PM_AOI_AOD_2000_mpg, AOD_AOI_AOD_2000_mpg, ZI_AOI_AOD_2000_mpg, YESNO YES NO YES)
```

לבסוף, כל המשתנים של **המרחב**:

population density, elevation, traffic density, percentages of land use according to 12 land use categories based on the national land cover data (NLCD), point emissions and total area-source emissions (tons per year) for $PM_{2.5}$, PM_{10} , SO_2 and NO_x .

והזמן:

Temperature, Wind speed, Visibility, Relative Humidity, PBL, NDVI

הוספו לבסיס הנתונים ב ArcGIS על ידי `spatial join`, פונקציות רסטוריות וכלים נוספים) `..extract values to points, etc`



מתודות סטאטיסטיות

על מנת לנבא ריכוזי $PM_{2.5}$ בכל תא בכל יום



התחלנו בכיול היחס בין $PM_{2.5}$ - AOD לכל יום
(שלב 1)

$PM_{2.5} \sim AOD + \text{other predictors}$
(fit with mixed effects model)

השתמשנו במודל משלב 1 כדי לנבא ריכוזי $PM_{2.5}$ בתאים
ללא תחנות ניטור אך עם מדדי AOD זמינים
(שלב 2)

הערכנו את ריכוזי $PM_{2.5}$ בתאים ללא כל מידע
על ידי שימוש במודל שלב 2 (תוך שימוש בקשר של ערכי
תאים עם AOD עם $PM_{2.5}$ שנמדד בתחנות ניטור אחרות
והקשר לערכי AOD זמינים בתאים שכנים.
(שלב 3)

using gam spatial smoothing of nearby AOD and
daily regional patterns




Global (1x1km) scale

Stage 1
Fit daily calibration using data from pixels with co-located PM and AOD:
 $PM_{2.5} \sim AOD + \text{other spatio-temporal predictors}$ (fit with fixed effects model)


Stage 2
Use the fits from calibration models to predict $PM_{2.5}$ in grid cells with AOD but without monitors

Stage 3
Estimate $PM_{2.5}$ in cells with no available AOD data using spatial smoothing of nearby AOD and daily regional patterns



Local (100x100m) scale

Stage 4
Take residuals between stage 1 1x1km predicted $PM_{2.5}$ and measured $PM_{2.5}$ and regress against local spatial and temporal predictor variables using Support Vector Machine learning algorithms and to estimate $PM_{2.5}$ residuals.



- PM2.5 monitoring site
- AOD
- No AOD
- Predicted PM2.5
- Residuals PM2.5

Final $PM_{2.5}$ predictions at 100x100m scale by summing 'global' $PM_{2.5}$ predictions from Stage 1 and 'local' $PM_{2.5}$ predictions from Stage 4.

Local PM stage (LPM):

לבסוף לקחנו את ה residuals של המודל בכל תא שבו ישנו אתר ניטור וביצענו רגרסיה עם משתני ה LU והמשתנים העטיים המקומיים (באזור חיץ של ~ 50) בכל תחנת ניטור בכדי לקבל הערכה על התוספת המצטברת של הזיהום (בעיקר מתנועה) המקומי בכל אתר ניטור.

$$\begin{aligned} \text{ResidPM}_{ij} &= f_1(\text{Traffic Density}_i, \text{Population Density}_i) + f_2(\text{Elevation}_i) \\ &+ f_3(\text{Percent Urban}_i) + f_4(\text{Distance to A1 roads}_i) \\ &+ f_5(\text{Distance to Point emissions}_i) + f_6(\text{PBL}_i) \\ &+ f_7(\text{Traffic Density}_i, \text{PBL}) + f_1(\text{Traffic Density}_i, \text{Visibility}) + \varepsilon_{ij} \end{aligned}$$


כדי לאמת את המודל שלנו (לערוך ולידציה), בסיס הנתונים חולק שוב ושוב באופן אקראי ((ten folds ל 90% ו -10%. ניבוי עבור 10% מהנתונים שהושארו בחוץ נעשה מהמודל הסופי של 90% הנתונים של הנתונים. (out of sample CV).

```
splitdf <- function(dataframe, seed=NULL) {  
  if (is.null(seed)) set.seed(seed)  
  index <- 1:nrow(dataframe)  
  trainindex <- sample(index, trunc(length(index)/10))  
  trainset <- dataframe[trainindex, ]  
  testset <- dataframe[-trainindex, ]  
  list(trainset=trainset, testset=testset)  
}  
  
#s1  
splits_s1 <- splitdf(F_2001_all_st_table)  
  
mod1_T2001_10_s1 <- splits_s1$trainset  
mod1_T2001_90_s1 <- splits_s1$testset
```

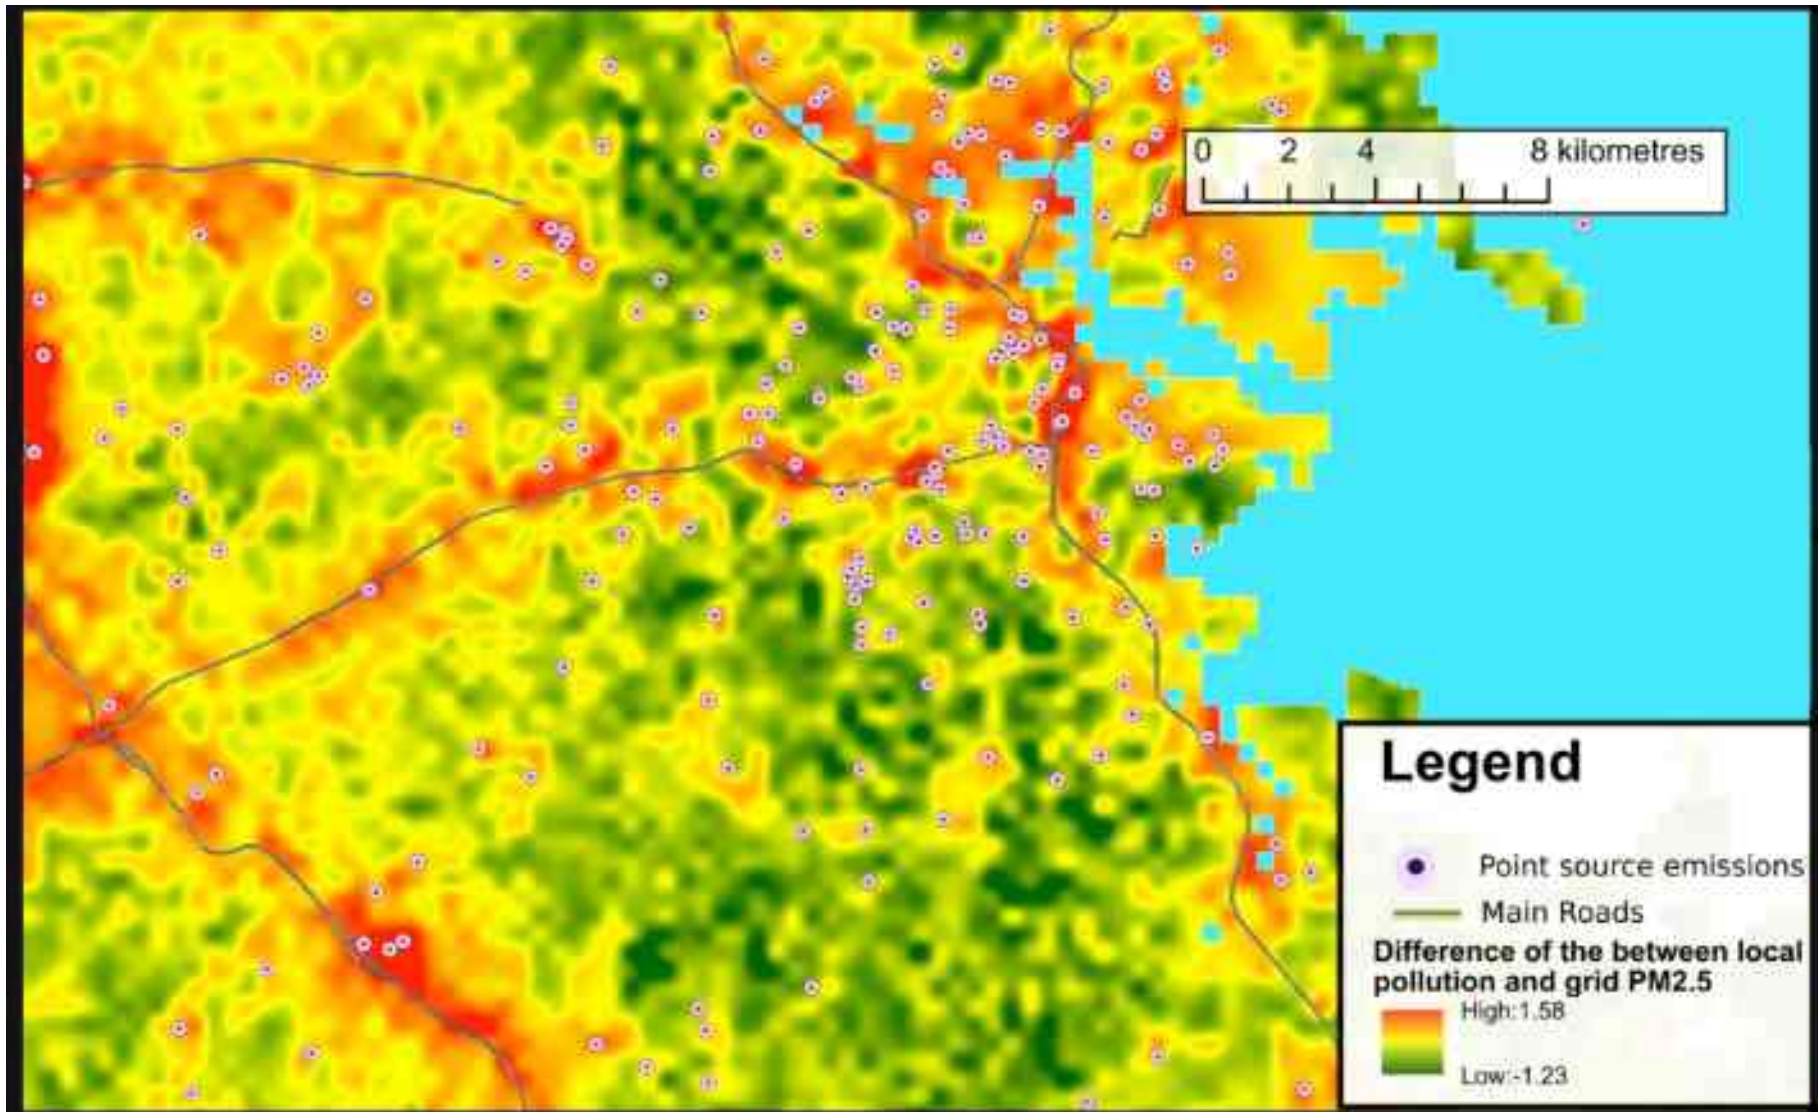
Prediction accuracy: R² for Stage3 PM_{2.5} predictions

(Final prediction model including locations without AOD for 2000-2008).

year	R2	Slope	spatial	temporal	Rmspe (µg/m3)	spatial rmspe (µg/m3)	Slope_leave 5 out
2003	0.91	1.02	0.88	0.91	2.69	0.65	1.09
2004	0.89	1.01	0.93	0.88	2.47	0.60	1.09
2005	0.88	1.01	0.93	0.88	2.79	0.63	1.10
2006	0.89	1.02	0.93	0.89	2.37	0.53	1.08
2007	0.91	1.01	0.96	0.91	2.26	0.47	1.04
2008	0.87	0.99	0.96	0.86	2.30	0.42	1.03
2009	0.87	1.01	0.94	0.86	1.95	0.37	1.06
2010	0.89	1.00	0.96	0.88	1.91	0.29	1.04
2011	0.84	1.01	0.92	0.83	2.09	0.39	1.05
Overall Mean	0.88	1.01	0.93	0.88	2.32	0.48	1.07



Mean PM_{2.5} concentrations in each 1x10 km grid in the Boston area during 2003 predicted by the AOD models



The difference of the estimated local pollution from the average PM_{2.5} concentrations at a very fine resolution (200x200m) aggregated over a year (2003) in Boston

לווינים הם גלובליים - וגם המתודולוגיה היא כזו

הרחבת המודלים לאזורים אחרים

- לצערנו במודלים אלו אין "one size fits all"
- לכל אזור יש **מקסימום** גיאוגרפים שונים לחלוטין (שלג, סופות אבק, הרים, אקלים) **שמתעשרים** שינוי של המודל בכל אזור
 - שכבת גבול PBL(mixing height) נמוכה,
 - מכתש בצורת קערה
 - משטרי רוח חזקים

ישראל:

בעיות באלגוריתם-surface brightness
סופות חול (חלקיקים לא אנתרופוגניים)

זיהום אויר במקסיקו סיטי

- Megacity >22 million
- Much higher exposures
- No reliable spatio-temporally resolved exposure assesment

Local data sources

Vigilamos la calidad del aire que respiras

SIMAT




- Hourly $PM_{2.5}$ since mid 2003 on 9-15 monitors from the RAMA network of real-time sensors (TEOM); averaged to day
- Planetary boundary layer (mixing height) measurement
- Road density data from municipality and from OpenStreetmap
- Precipitation data from the Water System of Mexico City
- Elevation from global digital elevation model

Methodologic challenges

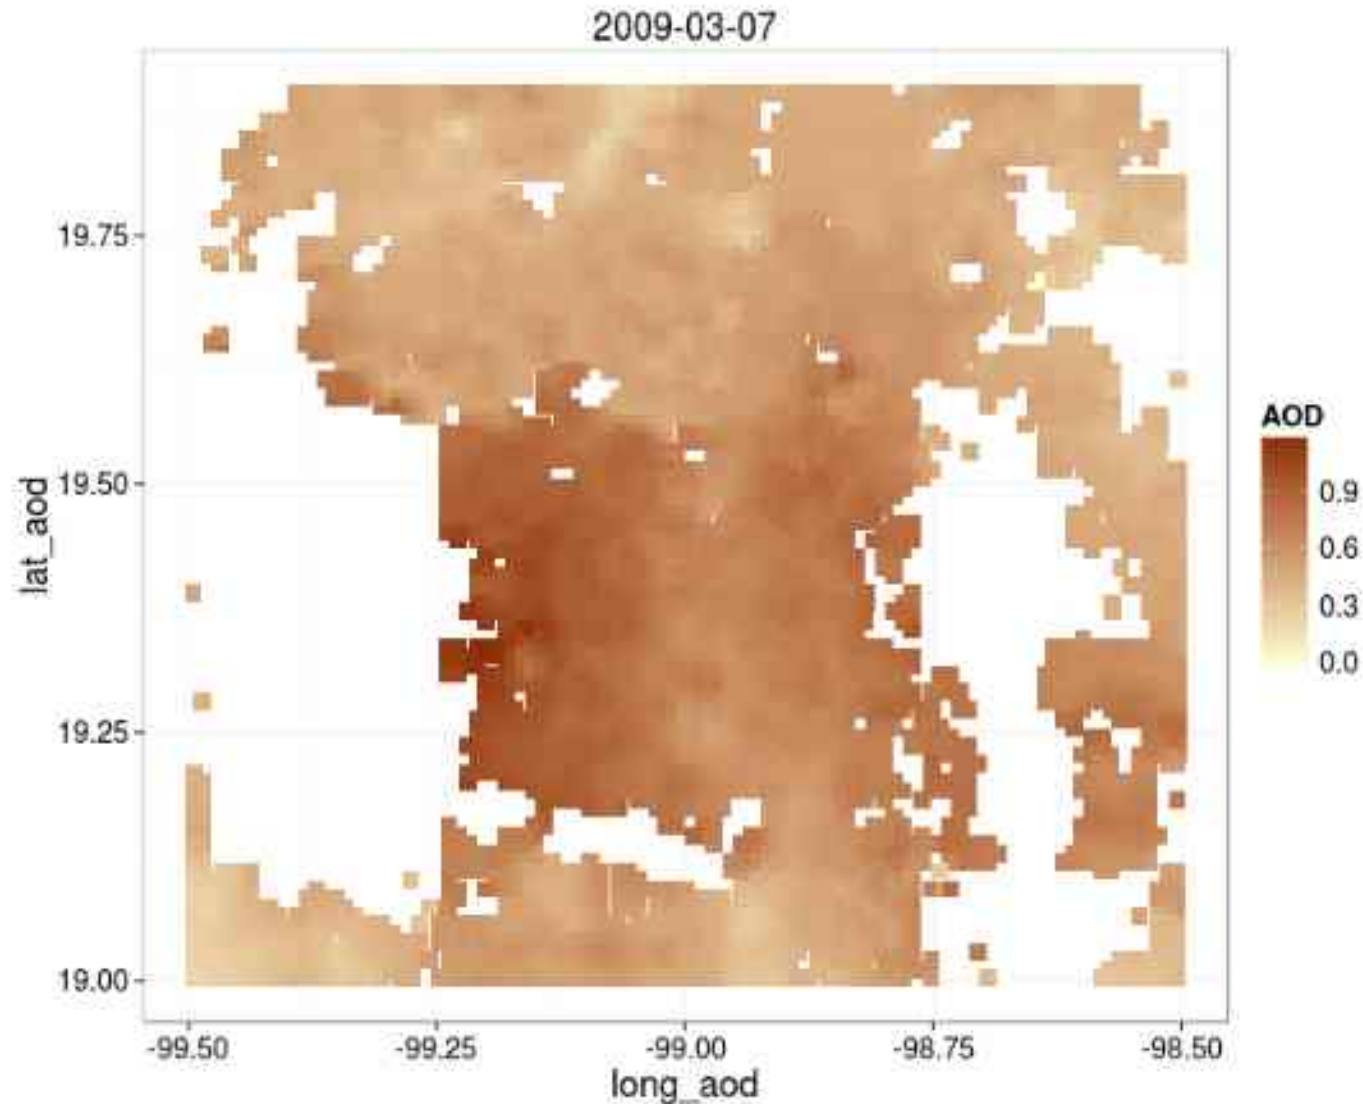
- Surface materials required different AOD pre-processing at NASA (lighter background)
- Mixing height and basin circulation
- Distinctive climatological cycle / seasonality
- Availability of spatial datasets

Mexico City AOD data

תמונות רסטר יומיות של MODIS AOD (באמצעות אלגוריתם MAIAC) עובדו ב R עבור 2004-2014.
אזור המחקר היה 75X75 ק"מ; 5925 תאים ביום < 20 מיליון שילובי יום-תא.

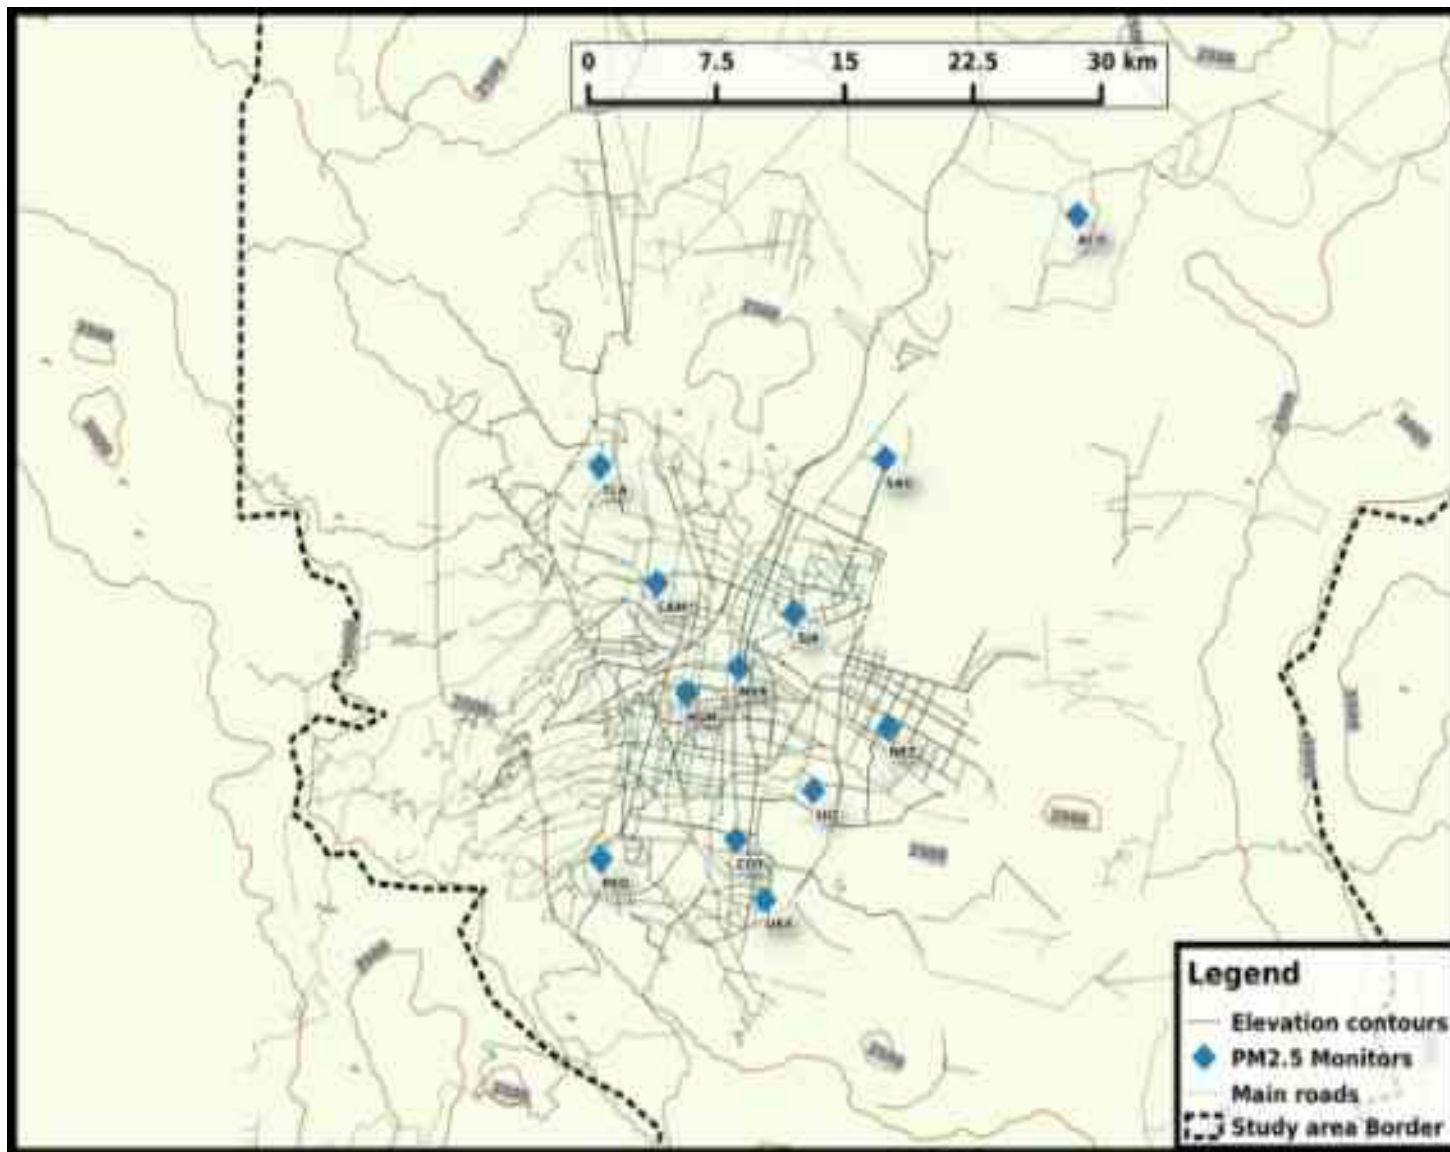


Sample day with available AOD data



This date has 41% coverage (59% clouds)

Study Area



Stage 1: calibration for Mexico City

$$\text{PM}_{ij} = (\alpha + u_j) + (\beta_1 + v_j) \text{AOD}_{ij} + \beta_2 \text{Temperature}_{ij} + \beta_3$$

Mean AM PBL_j + **β4 Precipitation_j** + β5

log(Elevation)_i + β6 Roadway density_i + ε_{ij}

$$(u_j \ v_j) \sim [(0 \ 0), \Sigma]$$

Stage 2: prediction with satellite data

This is used to make predictions for site-days without monitors

- מודל הכיול (calibration model) הראה ביצועים טוב מאוד


CV R² of 0.730

- גם מודל הכיסוי המלא (full coverage model) הראה ביצועים טוב מאוד:


CV R² of 0.724

הביצועים בשלב זה הם גבוהים יחסית בהתחשב בכך שמודל זה מורץ בימים שאין כלל AOD מהלווין


Enrollment Locations (green)
Schools with PM monitoring
from Albino Barraza are squares



Mean PM_{2.5} predictions



The overall mean PM_{2.5} predictions for all years (2004-2014) across the entire study area



PM_{2.5} measurements and cross-validated predictions from the full coverage model for the CAM monitor in 2010. Connected blue points are the daily PM_{2.5} measurements while red points are the full coverage predictions. Smoothed curves are loess regression lines for measurements (solid) and predictions (dashed).

Israel


Temporal Predictors	Spatial Predictors
Temperature	population density
Relative humidity	elevation
Rainfall	traffic density
Dust Classification	distance from major roads
	distance from the shoreline
	percent of open space

$$PM_{ij} = (\alpha + u_j + g_{j(m)}) + (\beta_1 + v_j + h_{j(m)}) AOD_{ij} + \sum_{m=1}^9 \gamma_{1m} X_{1(m)} + \sum_{m=1}^9 \gamma_{2m} X_{2(m)} + \epsilon_{ij}$$

$$(u_j, v_j) \sim N(0, 0, \Sigma)$$

$$(g_{j(m)}, h_{j(m)}) \sim N(0, 0, \Sigma_{m,m})$$



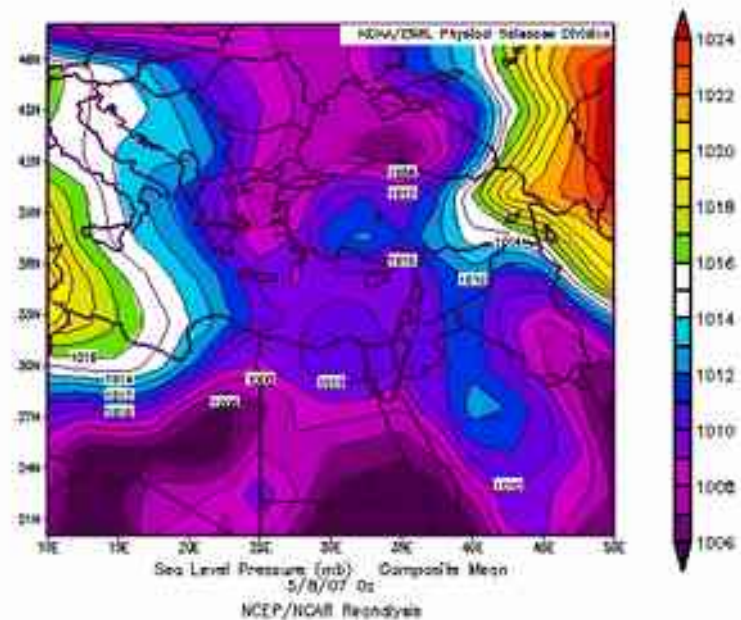



Classification of Dust Events

- Dust events were determined based on ground PM10 conc. following validated algorithm (Sorek-Hamer, 2010)

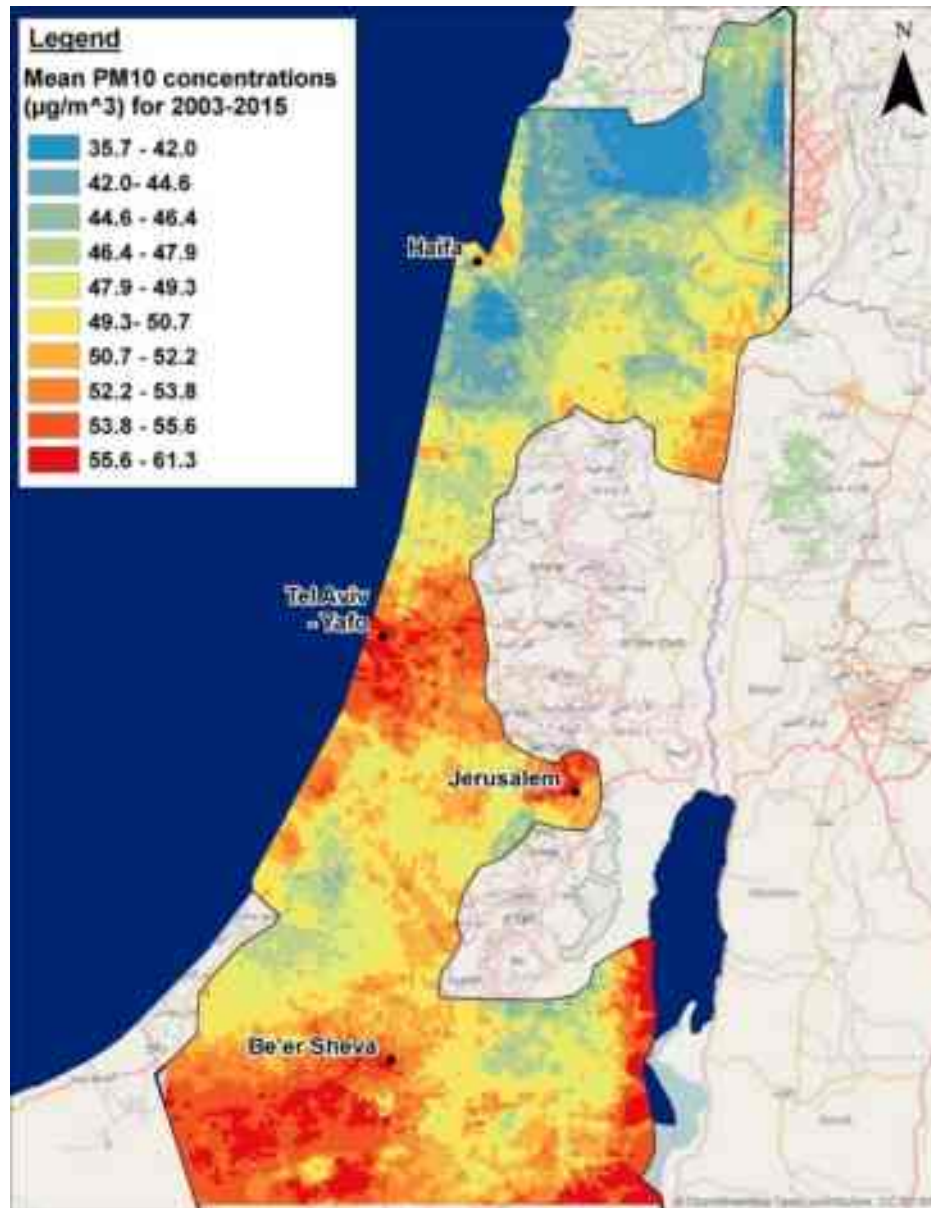
Dust Event = a day with at least 3 hours of (half hourly) PM10 conc. above 100 $\mu\text{g}/\text{m}^3$ with a max. above 180 $\mu\text{g}/\text{m}^3$, in at least 3 adjacent stations simultaneously.

- The 67 dust events list was evaluated by a day-by-day analysis of back-trajectories and by synoptic maps.



Preliminary results

Daily PM_{10} prediction (using MAIAC AOD data from AQUA platform)



Stage 1 – CV Calibration, Local stage

Cross validated (cv) measures

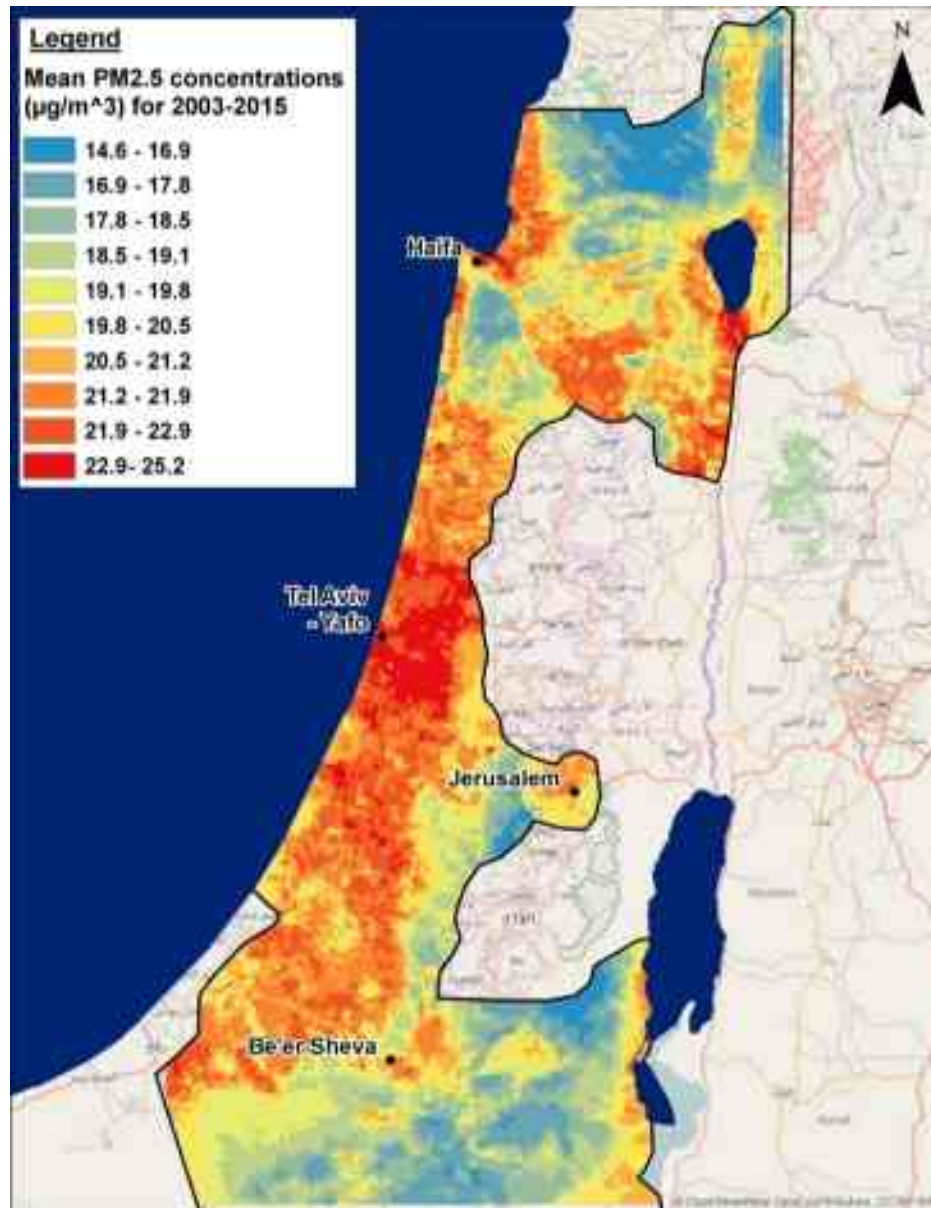
$m1.cv.loc.R^2$	0.9
-----------------	-----

$m1.cv.loc.slope$	1.0
-------------------	-----

$m1.cv.loc.rmspe$	16.7
-------------------	------

Preliminary results

Daily $PM_{2.5}$ prediction (using MAIAC AOD data from AQUA platform)



Stage 1 – CV Calibration, Local improvement

Cross validated (cv) measures

m1.cv.loc. R^2	0.85
------------------	------

m1.cv.loc.slope	1.02
-----------------	------

m1.cv.loc.rmspe	6.50
-----------------	------

Intra-daily PM modeling in Israel (Shetin, 2018)

Estimating PM₁₀ and PM_{2.5} concentrations in Israel on daily (24-hours mean PM) and intra-daily (mean PM around the Aqua and Terra overpasses) temporal resolutions.



This was achieved using a hybrid three stage modeling approach which applies a mixed modeling framework in each stage.



Estimating daily and intra-daily PM₁₀ and PM_{2.5} in Israel using a spatio-temporal hybrid modeling approach

Alexandra Shtein^{a,*}, Arnon Karnieli^b, Itzhak Katra^c, Raanan Raz^d, Ilan Levy^e, Alexei Lyapustin^f, Michael Dorman^g, David M. Broday^h, Itai Kloog^g



Main findings

- During the overpass times of Terra (morning) and Aqua (afternoon) we saw significant differences in PM concentrations relative to the mean daily concentrations and between morning and afternoon.
- We also observed different spatial patterns of the mean PM for non-dust period (days not affected by dust storms).
- Allows to use anthropogenic and background PM in health studies as two different exposures

Results

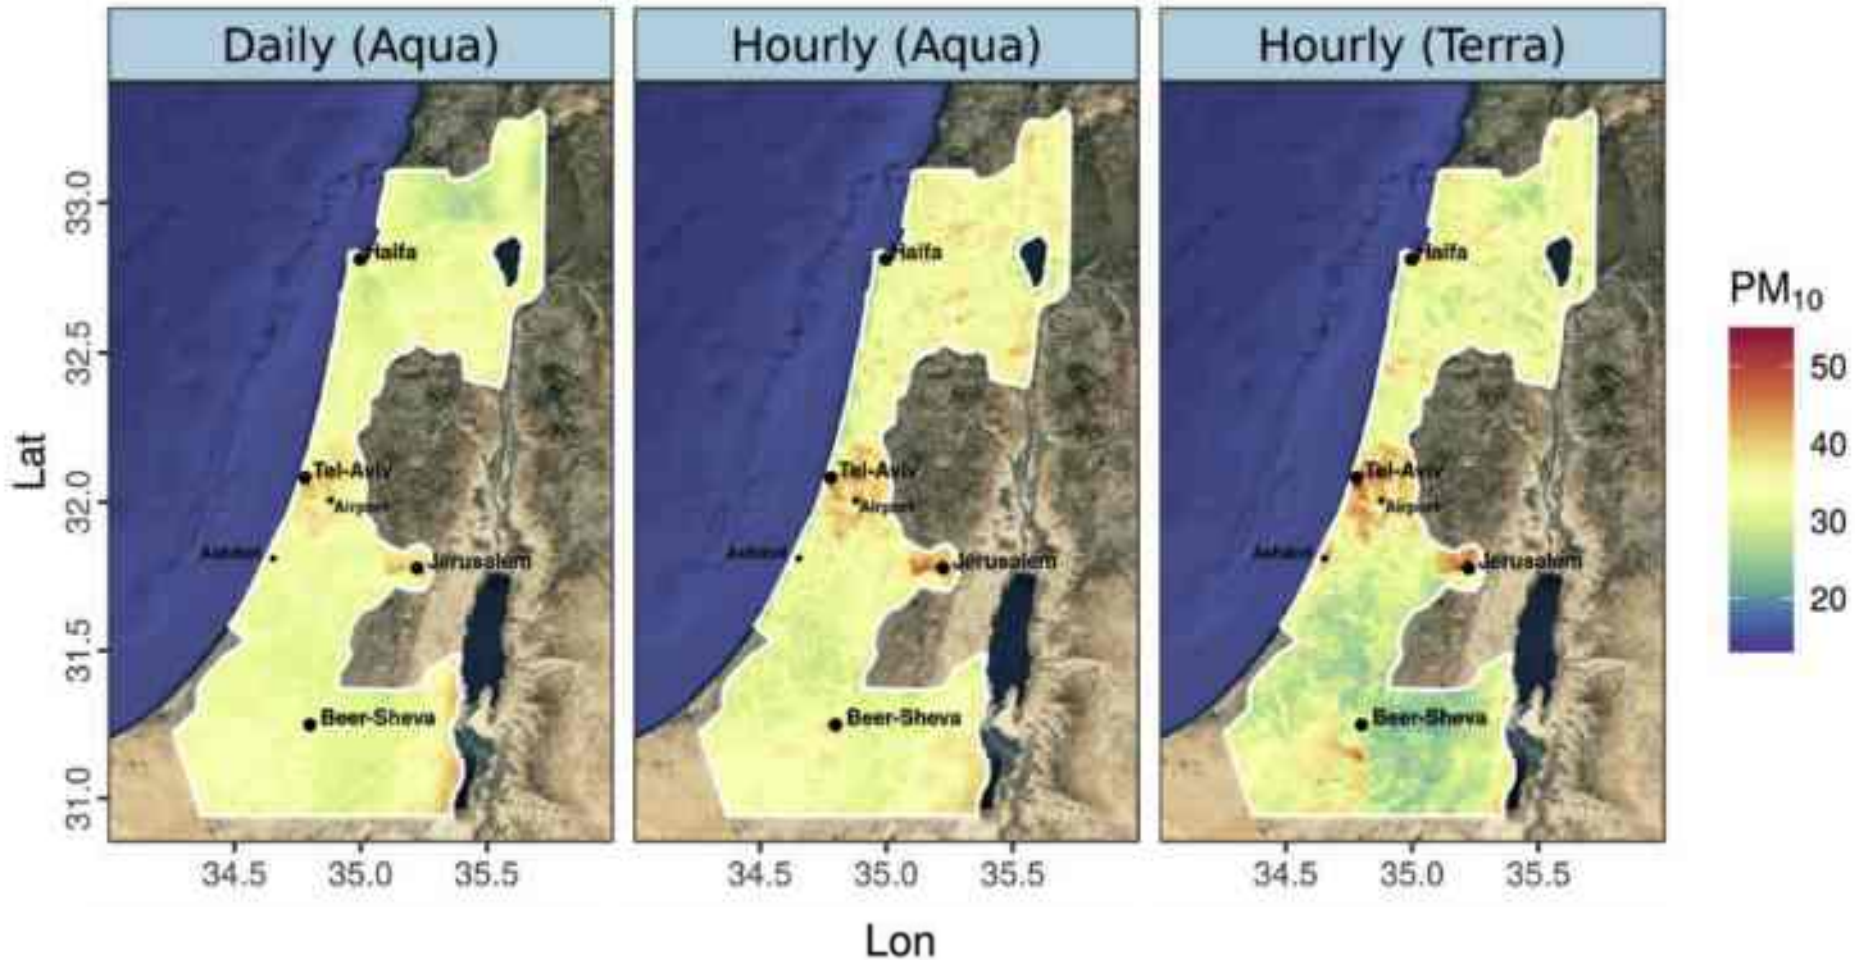
Model performance estimation for PM_{2.5} and PM₁₀ models

Cross validated model performance for the calibration stage for daily and intra-daily (Hourly) PM₁₀ and PM_{2.5} models. Hourly models estimate the PM concentration around the overpass time of the satellite (Terra\Aqua).

	PM ₁₀			PM _{2.5}		
	Daily (Aqua)	Hourly (Aqua)	Hourly (Terra)	Daily (Aqua)	Hourly (Aqua)	Hourly (Terra)
Overall R ²	0.92	0.90	0.91	0.87	0.82	0.84
Overall RMSE	19.94	30.75	24.77	6.16	8.88	9.51
Slope	1.09	1.07	1.00	1.05	1.02	1.01
Spatial R ²	0.95	0.84	0.97	0.95	0.94	0.79
Spatial RMSE	2.99	12.02	1.72	0.85	0.74	1.65
Temporal R ²	0.89	0.86	0.91	0.87	0.82	0.84
Temporal RMSE	19.88	35.29	24.72	6.14	8.86	9.46

Results

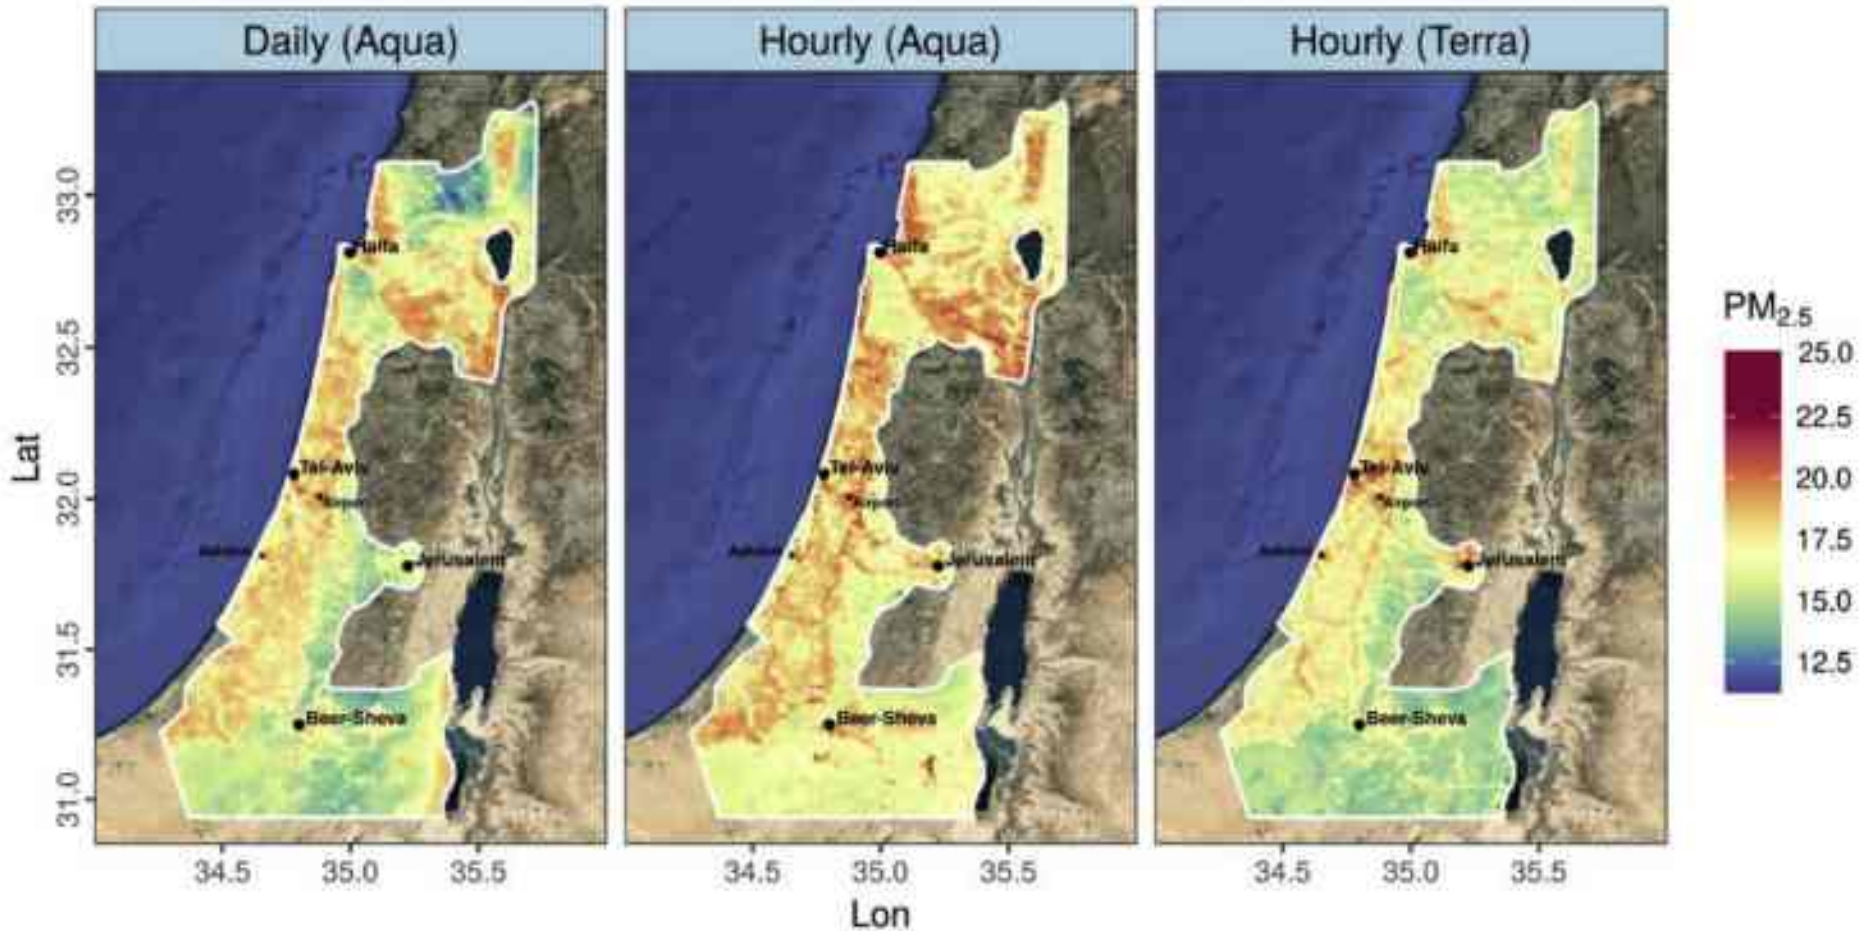
Daily and inter-daily maps of mean PM_{10} concentration for 2005-2015



Maps of the mean 2005–2015 non-dust PM_{10} model results for the three time windows: Terra overpass, Aqua overpass, and daily average (24 h mean).


Results

Daily and inter-daily maps of mean $PM_{2.5}$ concentration for 2005-2015



Maps of the mean 2005–2015 non-dust $PM_{2.5}$ model results for the three time windows: Terra overpass, Aqua overpass, and daily average (24 h mean).

שימוש באפידמיולוגיה



Short Term Effects of Particle Exposure on Hospital Admissions in the Mid-Atlantic States: A population Estimate (2014)

OPEN ACCESS Freely available online

PLOS ONE

Short Term Effects of Particle Exposure on Hospital Admissions in the Mid-Atlantic States: A Population Estimate

Itai Kloog^{1,2*}, Francesco Nordio², Antonella Zanobetti², Brent A. Coull³, Petros Koutrakis², Joel D. Schwartz²

1 Department of Geography and Environmental Development, Ben-Gurion University of the Negev, Beer Sheva, Israel, **2** Department of Environmental Health - Exposure, Epidemiology and Risk Program, Harvard School of Public Health, Boston, Massachusetts, United States of America, **3** Department of Biostatistics, Harvard School of Public Health, Boston, Massachusetts, United States of America

Abstract

Background: Many studies report significant associations between PM_{2.5} (particulate matter <2.5 micrometers) and hospital admissions. These studies mostly rely on a limited number of monitors which introduces exposure error, and excludes rural and suburban populations from locations where monitors are not available, reducing generalizability and potentially creating selection bias.

Methods: Using prediction models developed by our group, daily PM_{2.5} exposure was estimated across the Mid-Atlantic (Washington D.C., and the states of Delaware, Maryland, New Jersey, Pennsylvania, Virginia, New York and West Virginia). We then investigated the short-term effects of PM_{2.5} exposures on emergency hospital admissions of the elderly in the Mid-Atlantic region. We performed case-crossover analysis for each admission type, matching on day of the week, month and year and defined the hazard period as lag01 (a moving average of day of admission exposure and previous day exposure).

Results: We observed associations between short-term exposure to PM_{2.5} and hospitalization for all outcomes examined. For example, for every 10- $\mu\text{g}/\text{m}^3$ increase in short-term PM_{2.5} there was a 2.2% increase in respiratory diseases admissions (95% CI = 1.9 to 2.6), and a 0.78% increase in cardiovascular disease (CVD) admission rate (95% CI = 0.5 to 1.0). We found differences in risk for CVD admissions between people living in rural and urban areas. For every 10- $\mu\text{g}/\text{m}^3$ increase in PM_{2.5} exposure in the 'rural' group there was a 1.0% increase (95% CI = 0.6 to 1.5), while for the 'urban' group the increase was 0.7% (95% CI = 0.4 to 1.0).

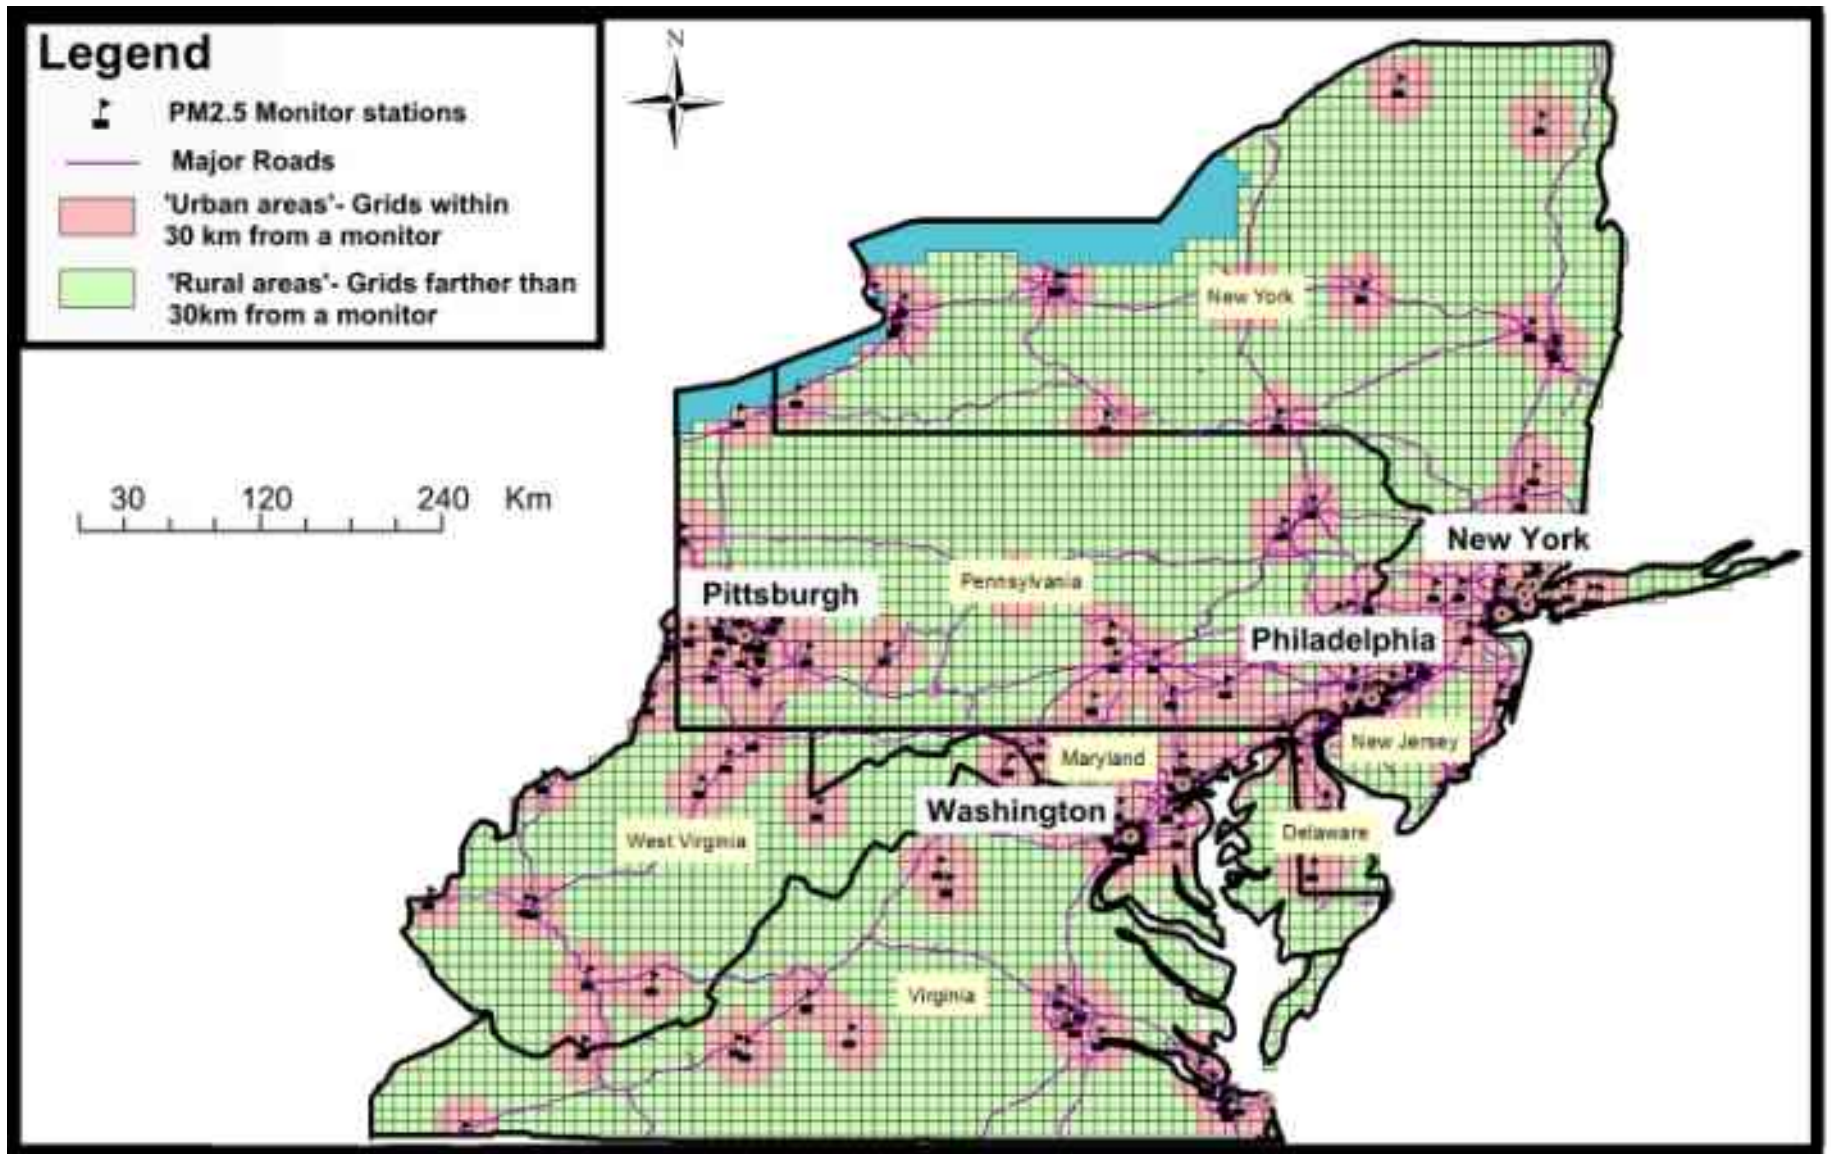
Conclusions: Our findings showed that PM_{2.5} exposure was associated with hospital admissions for all respiratory, cardiac vascular disease, stroke, ischemic heart disease and chronic obstructive pulmonary disease admissions. In addition, we demonstrate that our AOD (Aerosol Optical Depth) based exposure models can be successfully applied to epidemiological studies investigating the health effects of short-term exposures to PM_{2.5}.

מחקרים רבים מצאו קשר מובהק בין החשיפה ואשפוזים בבתי חולים.
(Brunekreef and Holgate 2002; Fusco et al. 2001; Kloog et al. 2012a;
Peacock et al. 2011; Wellenius et al. 2005; Zanobetti and Schwartz
2005).

מחקרים אלו לרוב נשענים על מספר מוגבל של תחנות ניטור שמוביל
להטיית חשיפה, ומשאיר את האזורים הכפריים והרחוקים מערים מחוץ
למחקר שיוצר הטיית בחירה (selection Bias)

על ידי שימוש במודלים שלנו, אנו חקרנו את ההשפעה של חשיפה קצרת
טווח (short-term) ל PM2.5 על אשפוזים בבתי חולים בצפון מזרח
ארה"ב - Mid-Atlantic region



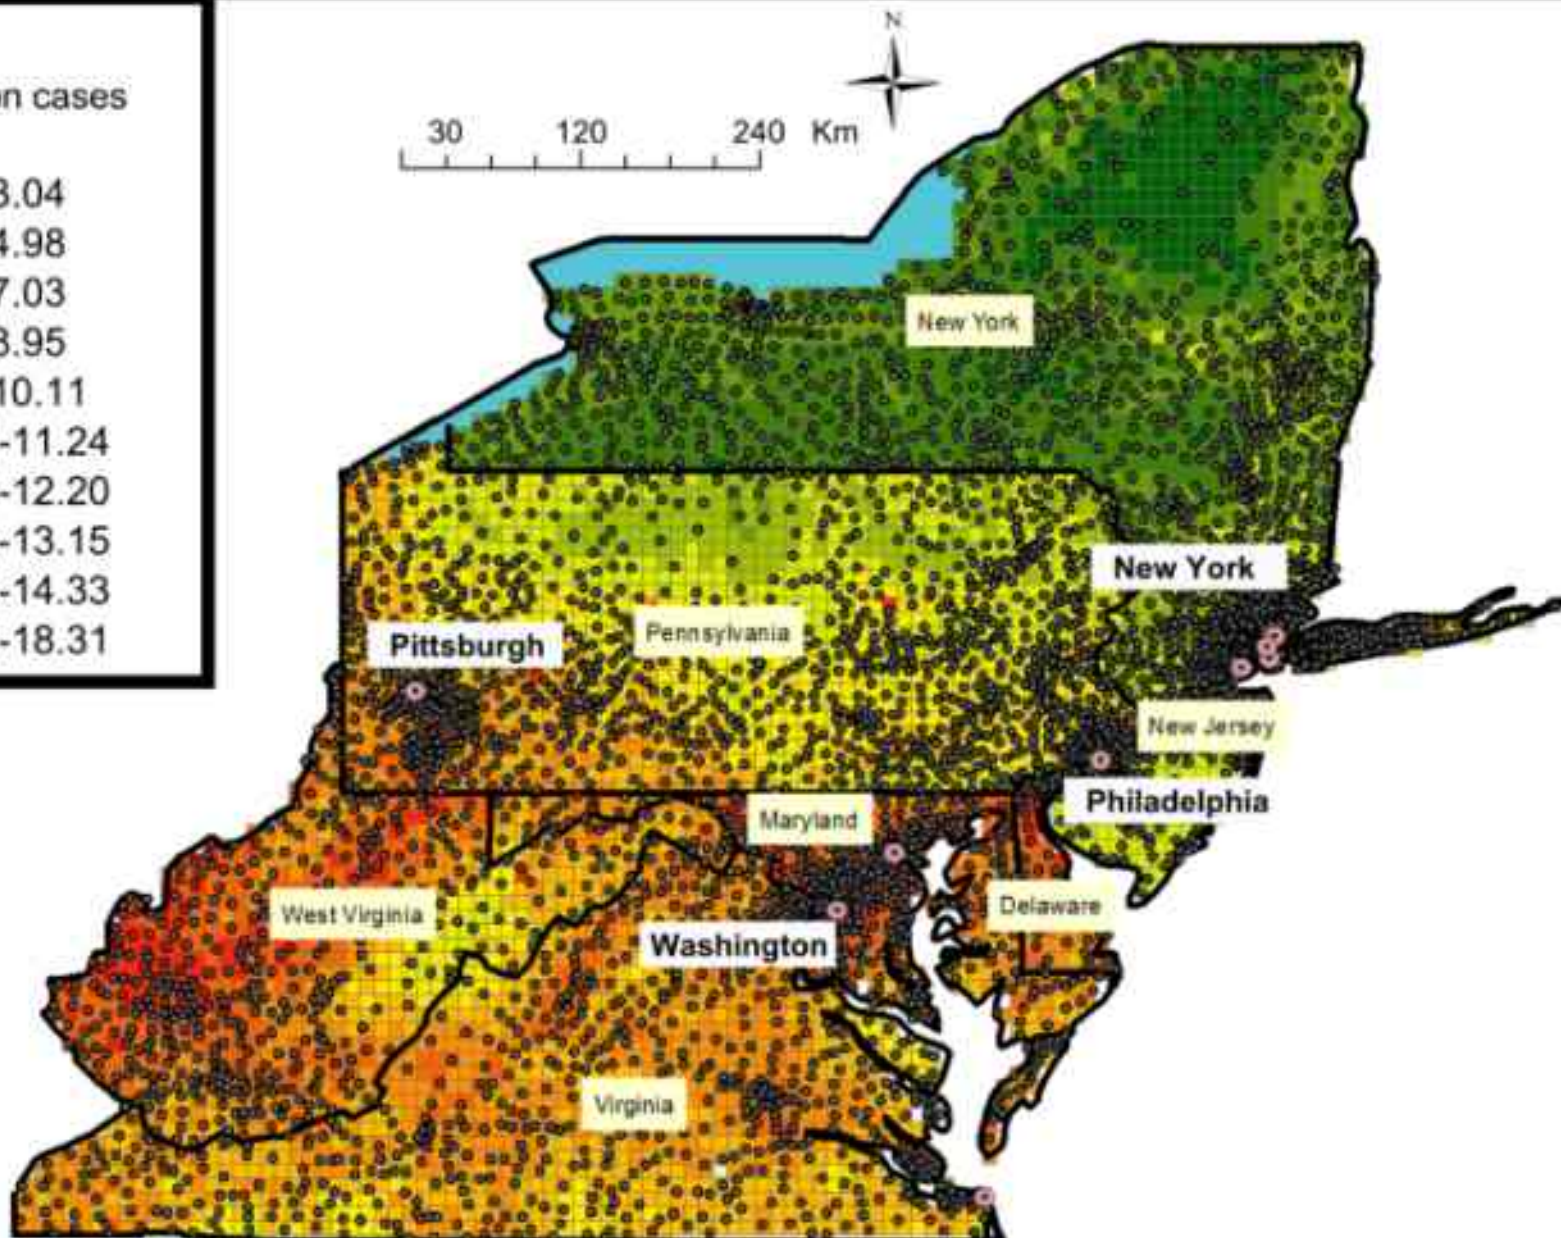



Map of the study area showing the MEDICARE population within and outside 30km of a PM_{2.5} monitor.

Legend

- Admission cases

$Pm_{2.5}$




Map of the study area showing the residential location of admission cases juxtaposed over a sample PM_{2.5} 10x10km pollution grid for 01/06/2001.

השתמשנו בשיטה סטטיסטית נפוצה של case-crossover analysis
לכל מקרה אשפוז
בשיטה זו כל מקרה- case הוא הבקרה של עצמו - control-
(the study is self-matched)

עבור כל אדם יש "חלון מקרה" בו האדם הא "מקרה" וחלון בקרה בו
האדם הוא "בקרה"

אנו משווים את סיכון החשיפה בין החלונות האלו



Estimated percent increase in hospital admissions for a 10 µg/m³ increase in short-term PM_{2.5} by cause of admission

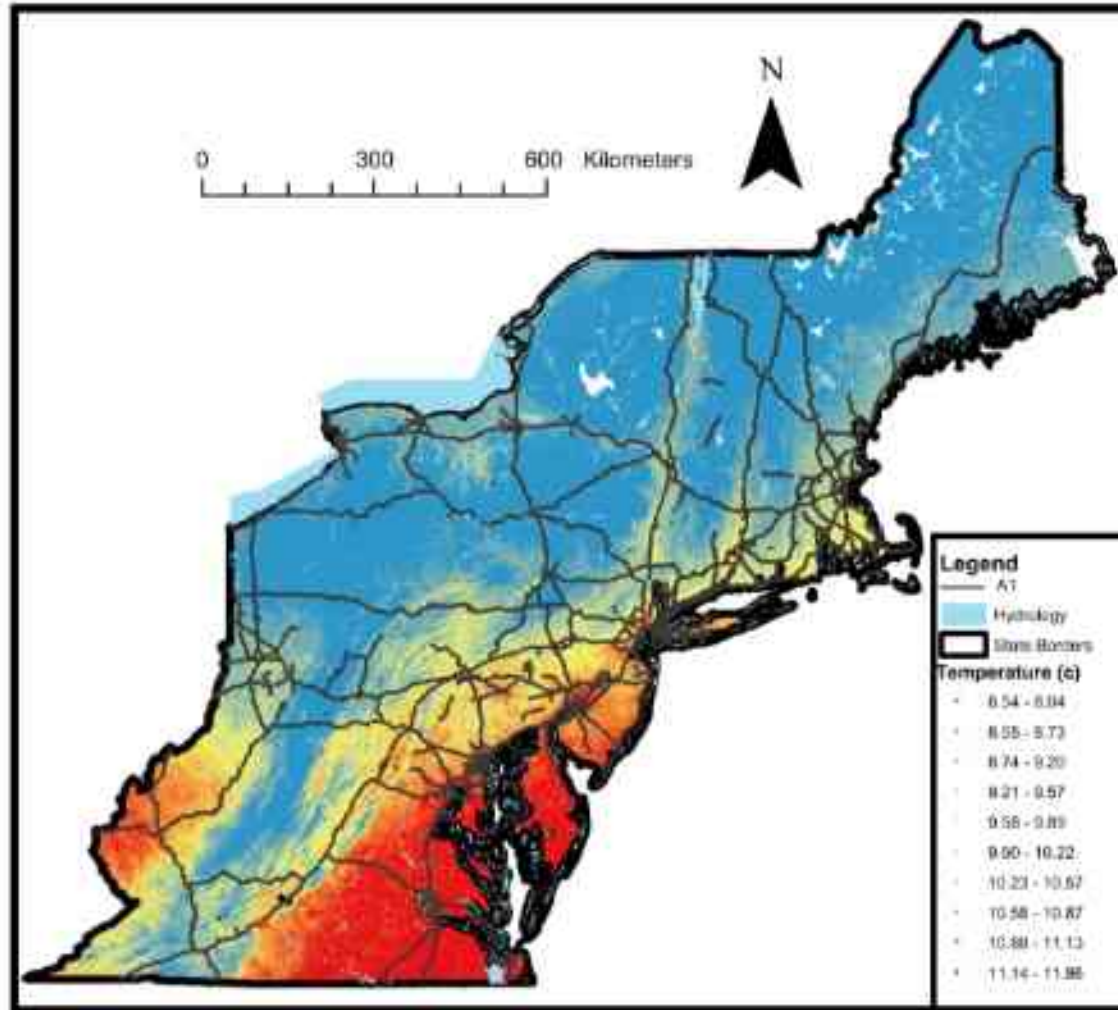
All Respiratory	CVD	Stroke	COPD	IHD
% increase	% increase	% increase	% increase	% increase
2.23 (1.91-2.56)	0.78 (0.54-1.01)	0.11 (0.36-0.59)	1.83(1.18- 2.48)	0.99(0.62- 1.37)
CVD Interactions	% increase			
'rural' group	1.04 (0.56 to 1.51)			
'urban' group	0.7 (0.44 to 0.96)			

לראשונה במחקר אפידמיולוגי סביבתי כלשהו נכללה כל האוכלוסייה של האזור ה Mid- Atlantic במחקר ולא רק אוכלוסיות קרובות לתחנות ניטור.

הממצאים מצביעים על קשר מובהק וחיובי בין חשיפה ל 25PM ועליה ב CVD, IHD, COPD and stroke



Predicting Spatiotemporal Mean Air Temperature Using MODIS Satellite Surface Temperature Measurements Across the North Eastern USA



הקדמה

- למרות שתחנות מטאורולוגיות מספקות תצפיות טמפרטורה מדויקות הכיסוי המרחבי והעיטי שלהם מוגבלת.
- מכיוון שלטמפרטורה יש שונות מרחבית לא מעטה בערים תחנת ניטור בודדת בערים גדולות אינם אידאלית עבור מחקרים אפידמיולוגיים.
- נתוני לווין מרחיבים את הכיסוי המרחבי, ומשפרים את יכולתנו להעריך את הטמפרטורה (Ta)



מטרה:


מחקרים עם שינויי אקלים ובריאות הם HOT TOPIC
מטרת המחקר הייתה לשלב את רגרסית שימוש קרקע (LU), משתנים
מטאורולוגיים ו spatial smoothing על מנת לחזות T_a בימים בהם נתוני T_s
אינם זמינים
באופן ספציפי, פיתחנו ואימתנו מודלים להערכת T_a יומי ברזולוציה 1×1
ק"מ בצפון מזרח ארה"ב לשנים 2000-2013 המבוססים על נתונים T_s
מלוויין MODIS

נתוני מזג אוויר

נתוני Ta יומיים ומהירות הרוח לשנת 2003 התקבלו משלושה מקורות שונים:

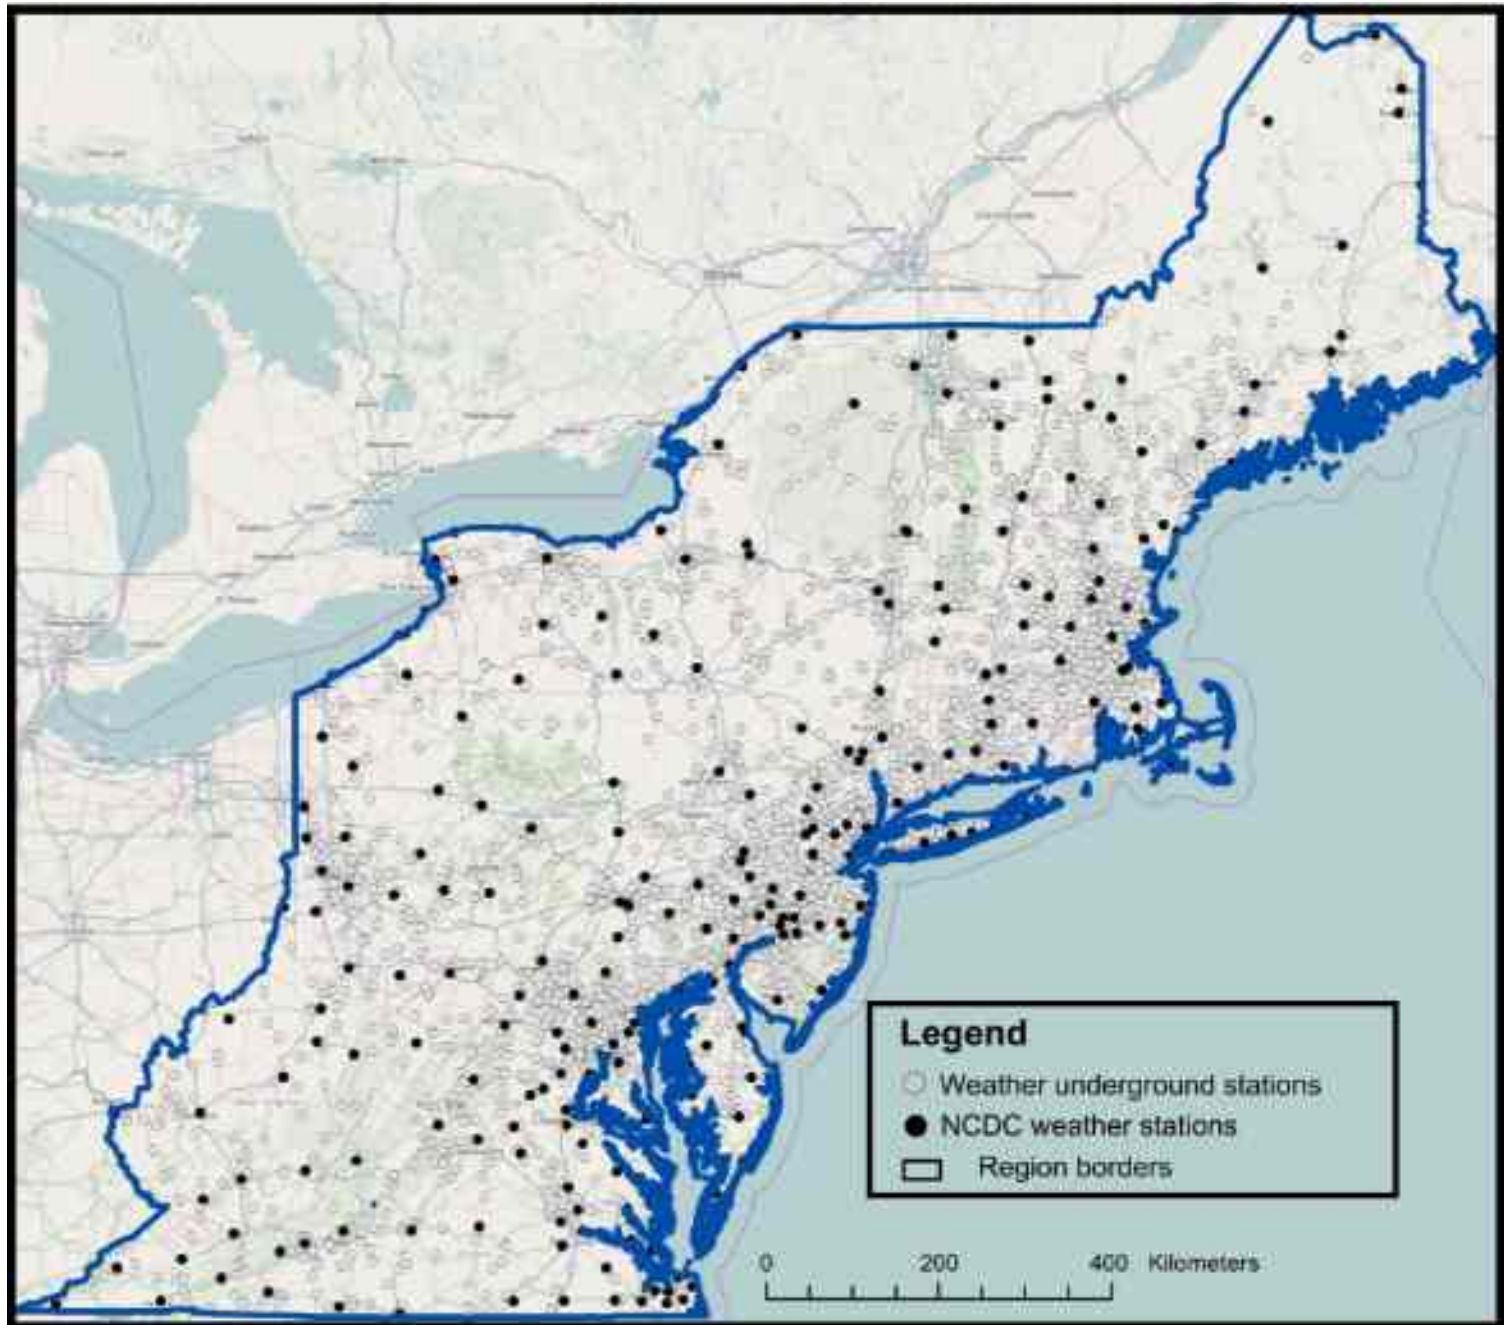
,The National Climatic Data Center (NCDC)
,US Environmental Protection Agency (EPA)
.Weather underground Inc. (WU)

-
-



השגנו את נתוני הטמפרטורות היומית הממוצעת, המינימום, ומקסימום וסיננו את הערכים החריגים (outliers).
במהלך תקופת המחקר פעלו בין 530-2000 תחנות ניטור בצפון מזרח ארה"ב


אזור המחקר




מתודות סטטיסטיות

על מנת להעריך Ta בכל תא בכל יום

התחלנו בכיול היחס בין Ts - Ta לכל יום
(שלב 1)



השתמשנו במודל משלב 1 כדי לנבא Ta בתאים ללא תחנות
מטרולוגיות אך עם מדדי Ts זמינים
(שלב 2)




הערכנו את Ta בתאים ללא כל מידע
על ידי שימוש במודל שלב 2 (תוך שימוש בקשר של ערכי
תאים עם Ts עם Ta שנמדד בתחנות מטרולוגיות אחרות
והקשר לערכי Ts זמינים בתאים שכנים.
(שלב 3)

Prediction accuracy: Ten-fold cross validated (CV) results for model 1 predictions (Calibration stage using MODIS Night Surface Temperature for 2000-2011).

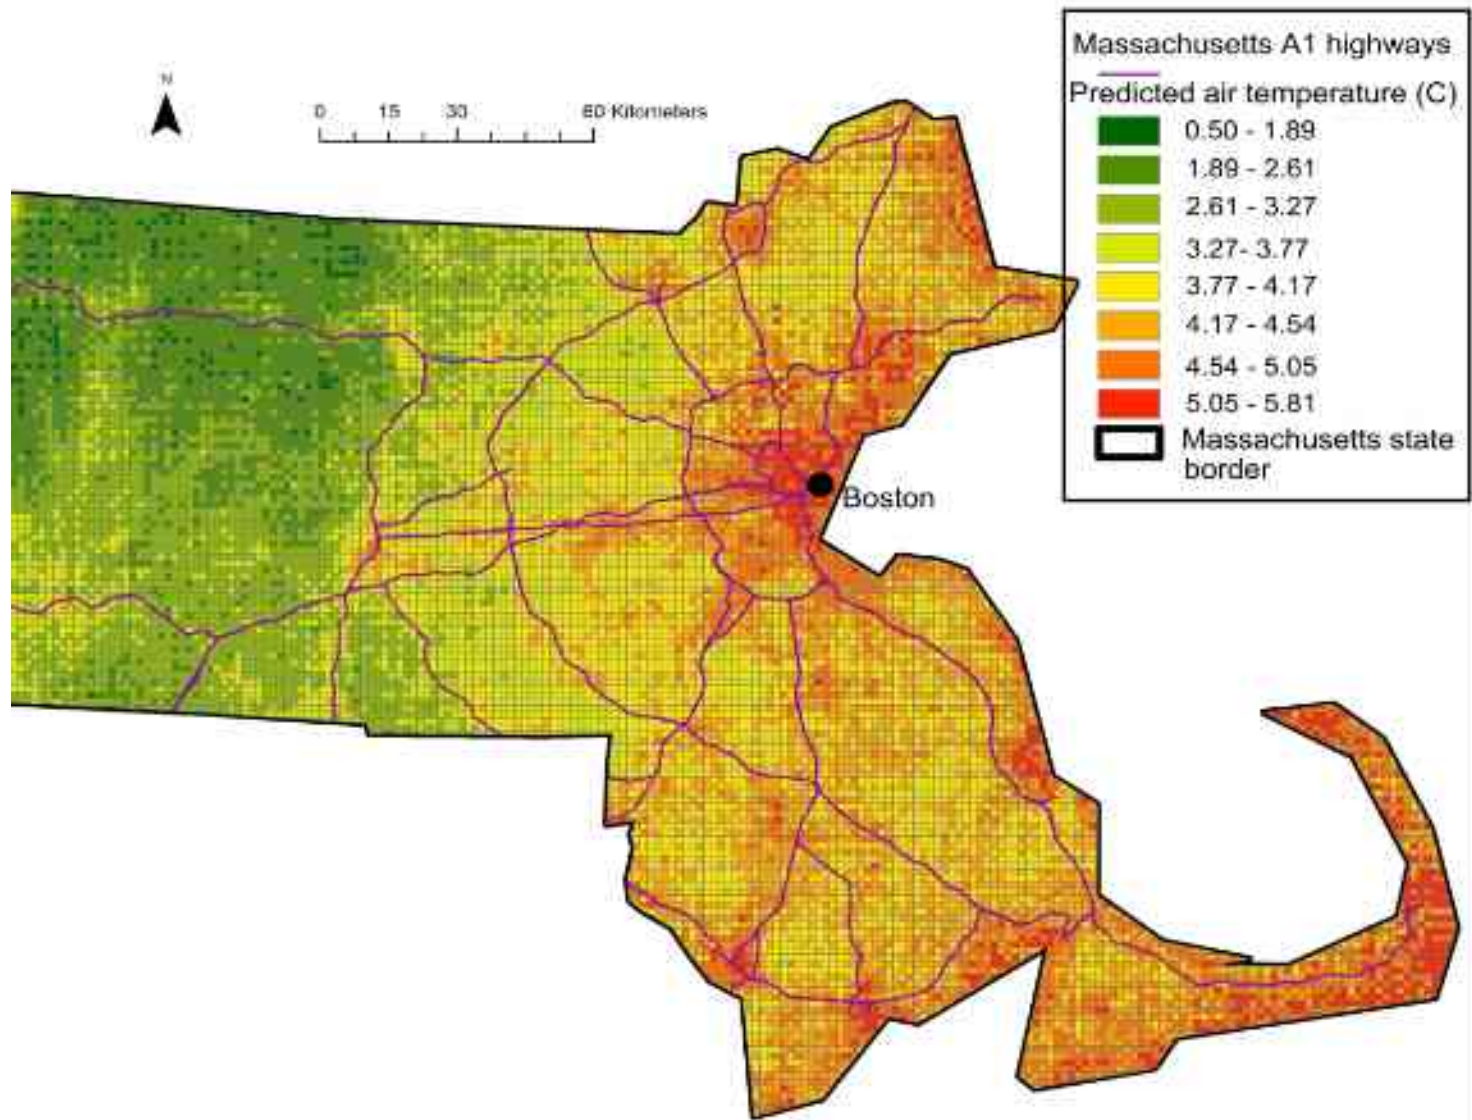
Yearly Dataset	CV R ²	Intercept ^a	Slope ^a	RMSPE ^b (Spatial)
2000	0.933	-0.019 ± 0.022	1.001 ± 0.001	1.246
2001	0.943	0.000 ± 0.015	1.000 ± 0.001	1.183
2002	0.953	0.021 ± 0.018	0.999 ± 0.001	1.195
2003	0.958	0.022 ± 0.017	0.999 ± 0.001	1.107
2004	0.951	0.001 ± 0.014	1.000 ± 0.001	1.161
2005	0.946	0.021 ± 0.016	0.999 ± 0.001	1.225
2006	0.945	0.025 ± 0.013	0.999 ± 0.001	1.167
2007	0.945	0.020 ± 0.013	0.999 ± 0.001	1.290
2008	0.947	-0.006 ± 0.011	1.000 ± 0.001	1.238
2009	0.943	0.005 ± 0.009	1.000 ± 0.001	1.209
2010	0.949	0.013 ± 0.009	1.000 ± 0.001	1.253
2011	0.955	-0.005 ± 0.009	1.000 ± 0.001	1.303

Prediction accuracy: Ten-fold cross validated (CV) results for model 1 predictions for all states, sample cities, urban vs. rural and season analysis for a sample year (2005).

type	CV R ²	Slope	RMSPE ^a
WV	0.945	0.960	1.738
VA	0.957	0.988	1.745
PA	0.952	0.987	1.798
MD	0.959	1.003	1.769
NY	0.945	1.002	2.159
RI	0.966	0.999	1.605
NJ	0.955	1.013	1.914
DE	0.957	0.994	1.426
CT	0.892	0.988	2.908
MA	0.943	0.998	1.687
VT	0.960	0.985	1.821
NH	0.944	1.001	2.238
ME	0.940	0.987	1.791
Boston	0.960	1.004	1.700
NYC	0.913	1.002	2.664
rural	0.949	1.001	2.010
urban	0.951	1.002	2.010
winter	0.944	1.001	1.937



The spatial pattern of predicted air temperature values from the surface temperature models, averaged over the 2011 for the metropolitan New-York area.



Mean Air temperature levels in each 10x10 km grid during 2003 predicted by the Surface temperature models.

המודל שלנו הראה יכולת ניבוי גבוהה במיוחד אפילו בימים ללא נתוני לוויין!

mean out-of-sample $R^2=0.947$ and $R^2=0.940$ respectively


השימוש ב - כיולים יומים של Ts-Ta מאפשר הערכה טובה יותר של אינטראקציות הזמן-מרחב מאשר מודלים שכוללים רק משתנים מרחביים או טמפורלים.

אנו הראנו כיצד ניתן לנבא Ta בצורה אמינה לי ידי שימוש במודל שלנו

מחקרים אפידמיולוגיים יכולים להשתמש בתוצאות המודל להערכת חשיפה מדויקת יותר.

Using Satellite Based Spatio-Temporal Resolved Air Temperature Exposure to Study the Association between Ambient Air Temperature, Birth Weight and gestational age in Massachusetts (EHP 2015)


Itai Kloog^{1,2*}, *Steven J. Melly*², *Brent A Coull*³, *Francesco Nordio*² and *Joel Schwartz*²



- הקשר בין חשיפה בזמן הריון לטמפרטורה והשפעות שליליות על ילודה כמעט ולא נחקר
- רוב המחקרים שפורסמו עד כה שהתמקדו ביחסים שבין ילודה מוקדמת וטמפרטורה גבוהה הניבו תוצאות מעורבות:
- מחקר אחד דיווח על עלייה בסיכוי ללידת תינוקות במשקל נמוך (birth weight < 1500 grams) וטמפרטורות קרות (Hartig and Catalano 2013).
- מחקר אחר לא מצא קשר בין לידה מוקדמת (birth at < 37 weeks completed gestation) ובין מספר השפעות סביבתיות כגון טמפרטורה ולחות (Lee et al. 2008)
- להבדיל מספר מחקרים נוספים דיווחו על עלייה בסיכוי ללידה מוקדמת עם עלייה בטמפרטורה ובלחות (Basu et al. 2010; Lajinian et al. 1997)

לתחנות ניטור של טמפרטורה יש פריסה מרחבית מוגבלת, במיוחד באזורים שאינם עירוניים ובנוסף הן לא קולטות אפקטים של אי חום עירוני

לכן השימוש בתחנות ניטור אלו יכולים להביא להטיית חשיפה במחקרים אפידמיולוגים שבוחנים את ההשפעה של טמפרטורה קיצונית ושינויי אקלים על בריאות האדם

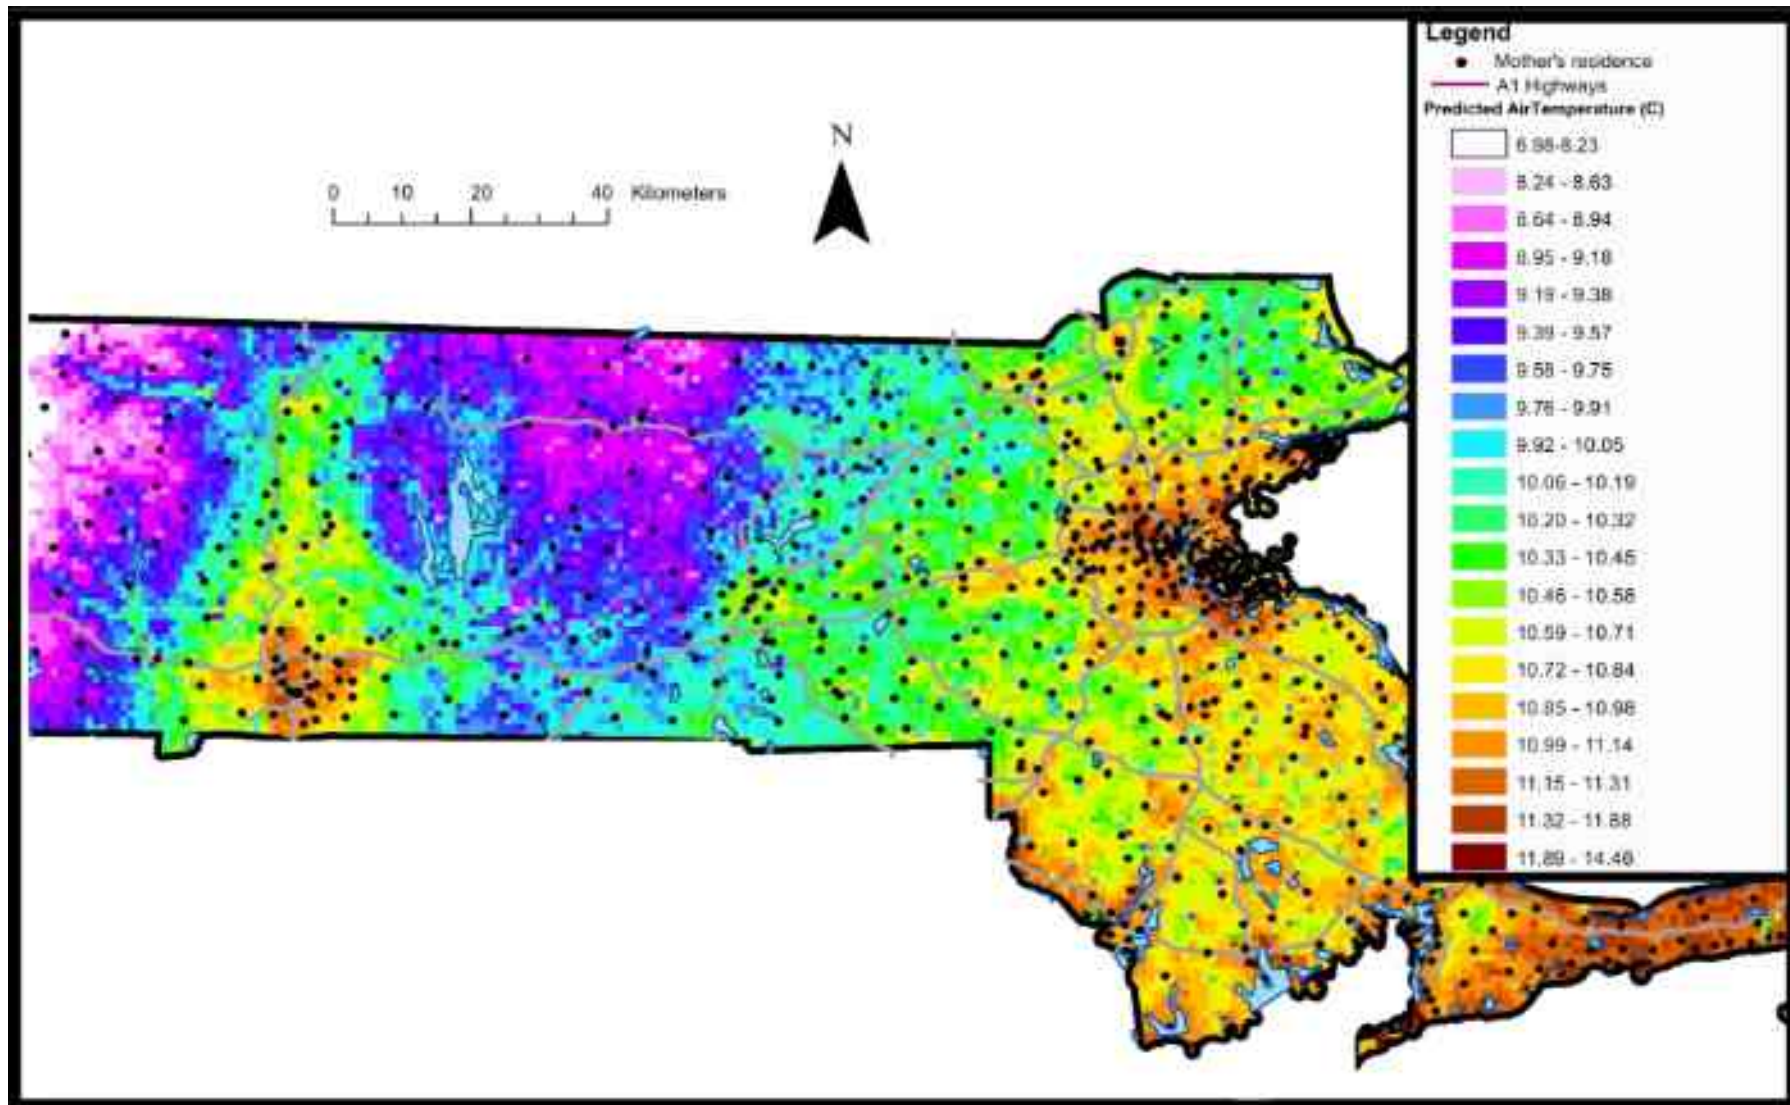


Map of the study area showing the location of a subset of mothers, the location of the ground air monitoring stations and the areas within and outside 30km of an air temperature station.

בחנו את הקשר שבין משקל לידה נמוך ורמת הטמפרטורה במהלך ההריון במסצ'וסטס במשך 9 שנים (2000-2008) תוך שימוש בתחנות ניטור של טמפרטורה וגם במודל המרחבי-עיטי שלנו כדי להעריך חשיפה במשך ההריון

בעזרת המודל הערכנו חשיפה יומית במשך כל תקופת ההריון מיום ההפרייה ועד הלידה לכל אמא בנפרד.

באנליזה של משקל הלידה החסרנו לידות מרובות עוברים ולידות מוקדמות משבוע 37 דבר זה השאיר 466,533 לידות.



Map of the study area showing the residential location of a subset of mothers over a sample air temperature (C°) 1x1 grid across a sample year (2005).

We used linear mixed models to estimate the association between Ta exposure and birth weight (among full term births)

We adjusted for infant sex, maternal age, maternal race, mean income, maternal education level, prenatal care, gestational age, maternal smoking, average traffic density, a random intercept for census tract and mothers health (diabetes, lung disease, renal disease etc.)

$$BW_{ij} = (\alpha + u_j) + \beta_1 Ta_i + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + e_{ij}$$

Effects of one interquartile range increase in Air temperature (C°) on birth weight for full term births at various exposure periods.

Exposure period	Predicted Air temperature (C°)		Closest monitor temperature (C°)	
	Birth weight change (in grams)	95% CI	Birth weight change (in grams)	95% CI
Day of birth	-3.29	(-7.91 to 1.33)	-0.23	(-5.59 to 5.13)
One day prior to birth	-3.82*	(-8.46 to 0.83)	1.26	(-4.08 to 6.6)
Moving average of 2 days prior to birth	-4.60**	(-9.8 to 0.61)	0.57	(-4.95 to 6.09)
Moving average of 3 days prior to birth	-4.97**	(-10.67 to 0.74)	1.11	(-4.59 to 6.81)
Last week (7 days prior to birth)	-10.68***	(-18.07 to -3.28)	-0.21	(-6.44 to 6.03)
Last 2 weeks (14 days prior to birth)	-15.99***	(-24.76 to -7.23)	-1.93	(-9 to 5.15)
Last month (30 days prior to birth)	-15.69***	(-26.73 to -4.66)	-2.58	(-11.12 to 5.95)
Last 90 days prior to birth	-19.24***	(-32.58 to -5.90)	-9.77	(-22.47 to 2.93)
Entire pregnancy	-6.32***	(-9.24 to -3.41)	-7.89	(-28.14 to 12.36)

סיכום:


- בעזרת השימוש במודל הטמפרטורה שלנו הצלחנו להעריך חשיפה מדויקת לכל האימהות ללא הטיה מרחבית או עיטית וללא קשר של מרחק המגורים של אותן אימהות מחנות הניטור
- מצאנו אפקט עקבי של עליה בטמפרטורה מול עלייה במשקל היילודים לאחר נטרול גורמים מתערבים שידועים כגורמי סיכון למשקל נמוך כגון נתונים סוציו-אקונומיים, המצב הבריאותי של האם לפני ובמהלך ההריון, הסביבה הפיזית וכו'
- המודל גם הצביע על כך שהאפקט היה גדול יותר באזורים אורבנים


זיהום אור מוגדר על ידי IDA כ:

מזהם סביבתי שמורכב מאור מזיק או מפריע שמקורו

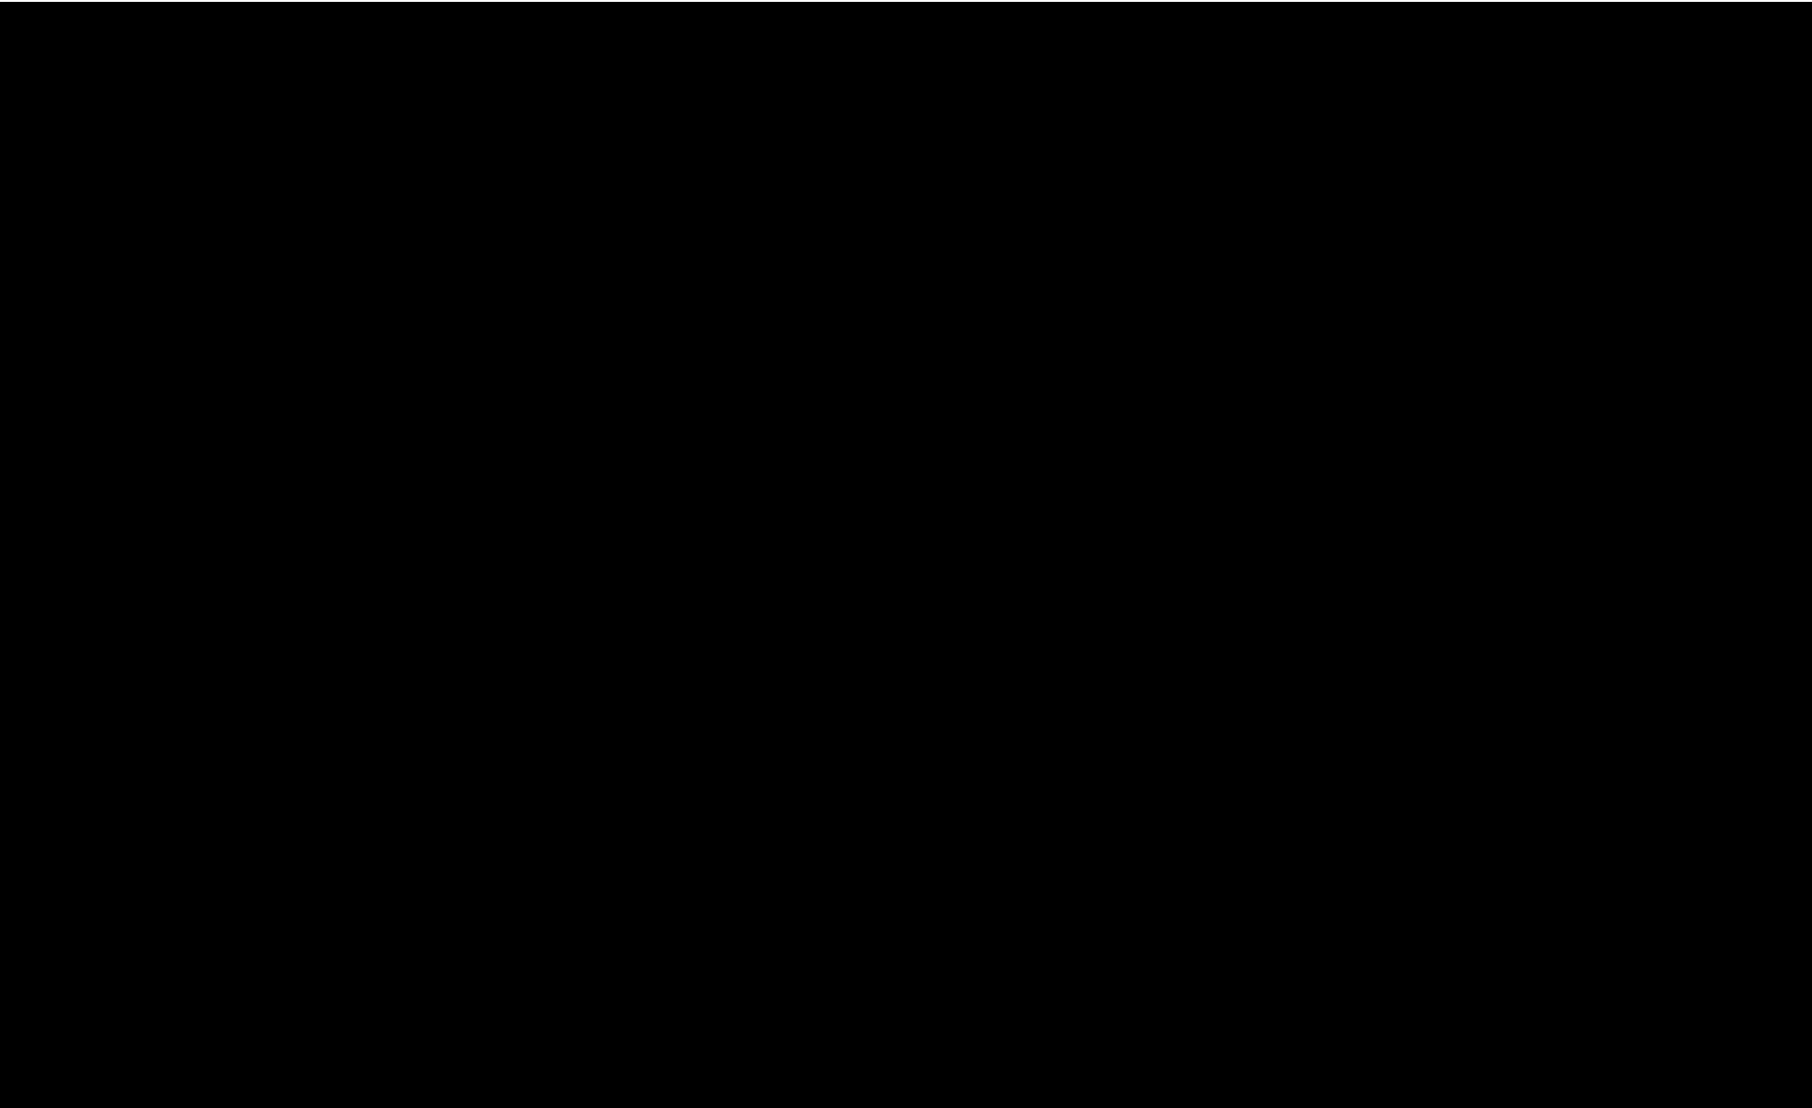
מערים, תחבורה ותאורה חיצונית.

(<http://www.darksky.org>).





LAN map of earth, 1997



LAN map of earth, 3 billion years ago

Variable	DMSP-OLS	SNPP-VIIRS
Builder/Operator	U.S. Air Force	NASA – NOAA Joint Polar Satellite System (JPSS)
Orbit	Polar – 850km altitude, 98.8 degree inclination, 102 minutes	Polar – 827km altitude, 98.7 degree inclination, 102 minutes
Swath	3000km	3000km
Nighttime overpass	~ 19:30	~ 01:30
Low light imaging bandpass	Panchromatic 0.5 to 0.9 um	Panchromatic 0.5 to 0.9 um
Ground footprint	5km X 5km at nadir	742m X 742m
Quantization	6 bit	14 bit
Saturation	Common in urban cores	No saturation
Low light imaging detection limit	~ 5E-10 Watts/cm2/sr	~ 2E-11 Watts/cm2/sr

nano-Watts/cm²/sr

- < 1
- 1 - 6.8
- 6.8 - 12.7
- 12.7 - 18.6
- 18.6 - 24.3
- 24.3 - 30.2
- 30.2 - 36.1
- 36.1 - 41.9
- 41.9 - 47.7
- 47.7 - 53.6
- 53.6 - 59.4
- 59.4 - 65.3
- 65.3 - 71.1
- 71.1 - 76.9
- 76.9 - 82.8
- 82.8 - 88.6
- 88.6 - 94.5
- 94.5 - 100.3
- 100.3 - 106.2
- 106.2 - 112
- > 112



LAN intensity levels (nano-watts/cm²/sr) in Israel according to nighttime satellite image from SNPP-VIIRS on January, 2017.

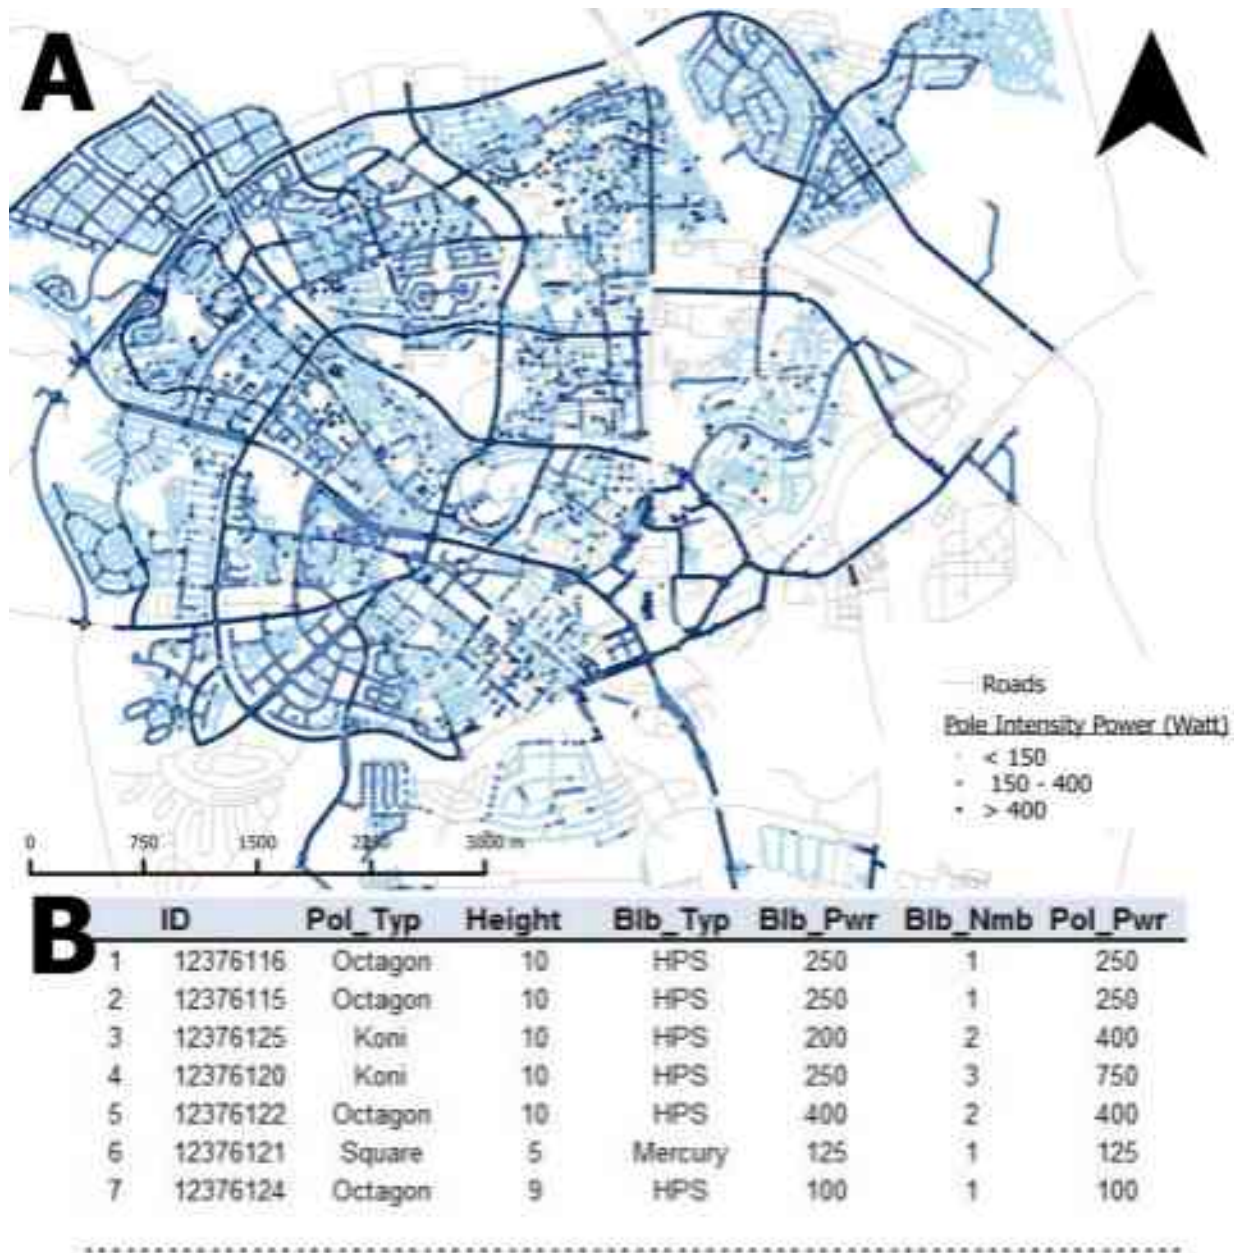


Figure 2. Streetlight poles distribution within the city of Beer-Sheva (A), showing the poles estimated intensity power (in watt), and an example of the extracted data from the streetlight GIS layer that was obtained from Beer-Sheva municipal (B).

Socioeconomic state (Income/Expenditure)

Sky View Factor

Air Pollution (PM)

NDVI

Population Density

Trees

Roads

Streetlight Poles

Traffic Volumes

Land Use

Satellite Data(VIIRS)

Street Density

Building Fraction

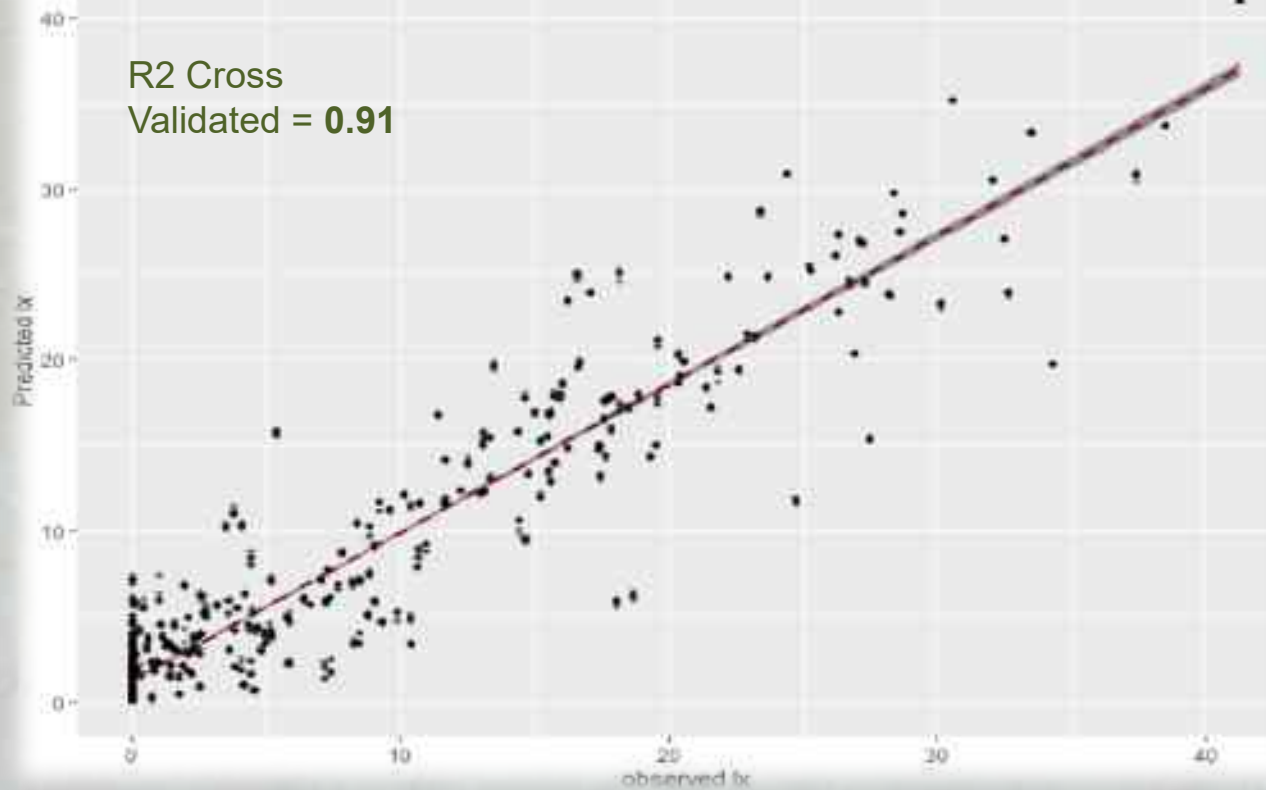
Albedo



Estimation Model Mixed Effect Modeling

$$Y_{ij} = (\alpha + \beta_j) + \beta_1 * X_{1ij} + \beta_2 * X_{2ij} + \beta_4 * X_{4ij} + \beta_5 * X_{5ij} + \beta_6 * X_{6ij} + \beta_7 * X_{7ij} + \epsilon_{ij} \quad (Y_{ij} \sim N(\mu, \sigma^2))$$

CV Model Results



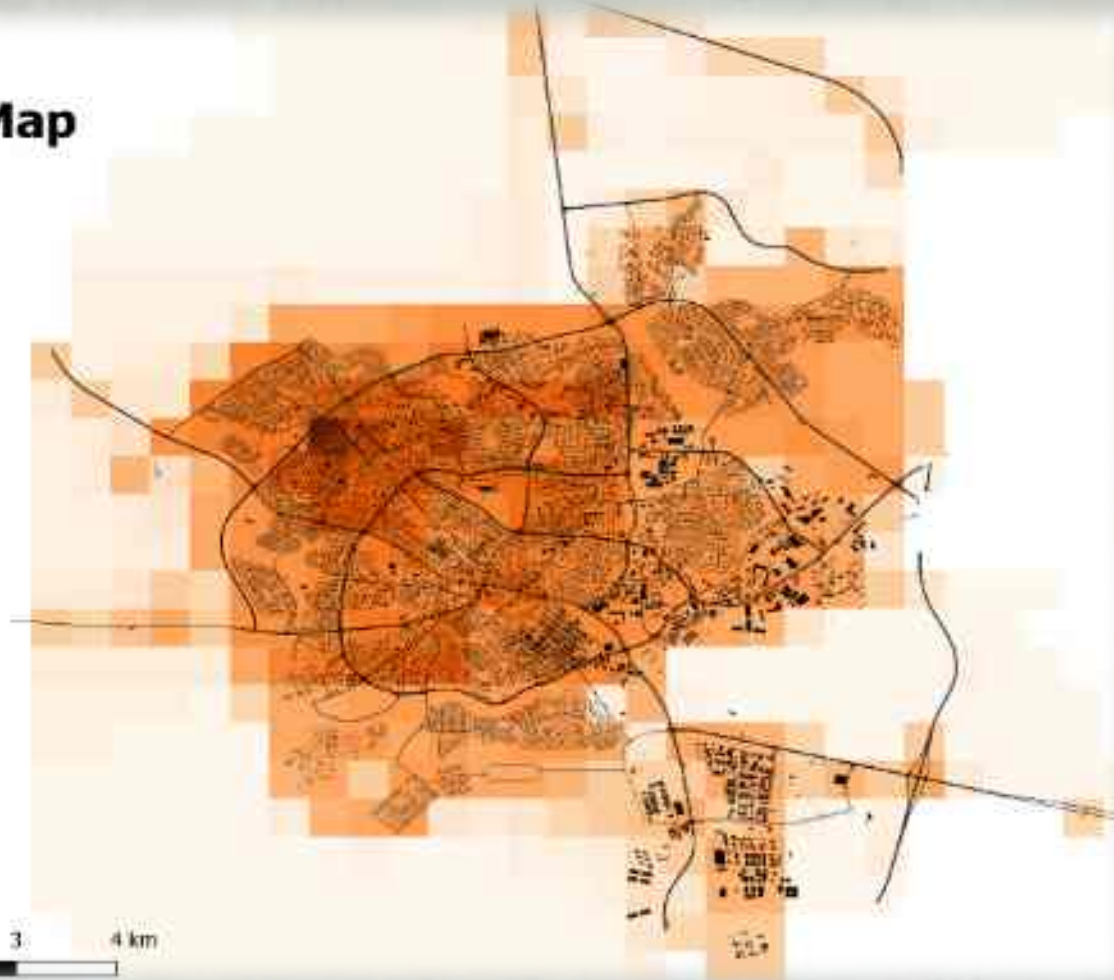
Beer-Sheva Prediction Map

- Buildings
- Roads

Predicted Light Intensity (bc)

- 0 - 0
- 0 - 0.2
- 0.2 - 0.5
- 0.5 - 0.8
- 0.8 - 0.9
- 0.9 - 1.2
- 1.2 - 1.8
- 1.8 - 2
- 2 - 2.5
- 2.5 - 4
- 4 - 6
- 6 - 14
- 14 - 18
- 18 - 22
- 22 - 25
- 25 - 29.8
- 29.8 - 31.7
- 31.7 - 33.5
- 33.5 - 35.4
- 39.1 - 41

0 1 2 3 4 km



Exposure to “green, natural areas” around each participant’s home address estimated using a satellite-image based vegetation index (NDVI)-30m resolution

