

深層学習を用いた都市活動空間分布の推計手法

紀伊雅敦*, 宮崎浩之**, 杉田暁***

*香川大学, **東京大学, 中部大学***

1. はじめに

都市形状は人間活動の空間的形跡であり、その計測、推定方法は環境政策や気候変動政策など様々な政策分野で応用されている。しかし、既往研究では、都市形状の推計パラメータの設定方法は経験的なものにとどまっており、精度検証も十分ではない。また、多くの分析では、都市形状は都市的土地被覆の推計にとどまり、都市内部の活動密度の空間分布についての研究はほとんどなされていない。さらに、将来都市形状推計における Shared Socioeconomic Pathway (SSP) 等の将来の社会経済シナリオの反映方法についても十分ではない。

本研究は、都市活動の空間分布の遷移を解析し、都市変化パターンの類型化と将来予測のための深層学習を用いた方法論の構築を目的とする。本研究により、各都市の諸条件に制約され個別性の強かった都市空間分析に統合的な視点を与えるとともに、データ駆動とシナリオ駆動を融合した将来推計手法を構築することで、革新的な都市形態学の理論構築を目指す。

社会経済シナリオと地理条件等を融合した都市形状の解析と予測への応用は十分研究が進んでおらず、デジタルアース研究のこれまでの知見を活用することで飛躍的な研究の進展が期待される。またデジタルアース研究に、本研究で構築する革新的な都市の自律的構造形成モデルを導入することは、デジタルアースの将来予測と問題複合体対応のツールとしての側面を一層強化することにつながると考えられる。

2. 方法

本研究では全世界の多様な都市活動の将来空間分布を統一的な方法により推計することを試みる。このため、使用データは全世界を対象に整備されている必要がある。本研究では、Colorado School of Mines が公開する Monthly Cloud-free DNB Composite 夜間光データ¹を都市活動の空間分布を捉える指標とし、道路インフラ等を含む地理情報と社会経済シナリオに基づき、その将来値を推計する方法論を探索する。既往研究により、夜間光は交通量等の都市活動と相関することが示されている¹⁾。なお、当然、都市活動の空間的変化には様々なパターンが想定される。

そのような多様な変化パターンを統一的に推計する手法として、本研究ではニューラルネットワーク等の回帰モデルを用いる。その際、空間情報と社会経済情報等を合わせて入力する点に特徴がある。これにより、既往研究に見られるデータ駆動のみで将来を推計するのではなく、関連する社会経済シナリオの検討結果を推計に反映させることができる。これは政策科学のためのツールとして不可欠な機能である。

具体的には、2012 年のデータで 2016 年の 30 秒グリッドの夜間光強度を推計する回帰モデルを作成する。説明変数は 2012 年の夜間光、交通条件、気象条件、地形条件、植生、水面、保護区、都市圏人口、GDP を用いる。ここで、人口、GDP 以外は 30 秒グリッドデータを用い、人口と GDP は都市圏の値を用いる。また、上記グリッドデータのうち、2012 年夜間光、NPP、地形、保護区については、当該グリッドと周辺 8 グリッドのベクトルを説明変数として用いる。これより、用意した説明変数は 84 である。これらのデータを世界 100 都



図 1 対象都市の位置

¹ <https://eogdata.mines.edu/products/vnl/>

市を対象に整理し、2016年の夜間光強度を100都市共通のモデルで推計することとした。対象エリアでデータが整備されたグリッド数は165万である。モデルは、ニューラルネットワークと線形回帰を用いた。対象とする100都市は、世界の主要都市の中から、地理分布や発展段階が異なるものを選択した。対象都市の位置を図1に示す。

3. 結果

まず、ニューラルネットワーク (NN) の適用結果を示す。ここでは、3層のNNとし活性化関数をlogisticとしている。165万サンプルのうち、70%を学習データ、30%を検証用データとして用いた。中間ユニットが1つの場合 (NN1) と2つの場合 (NN2) を学習させたところ検証データのRMSEは、NN1では4.65、NN2では5.35となり、中間層ユニットを1つから2つにするだけで過学習が生じていることが分かった。このことは、単調性の制約を設ける方が、汎化性能が高いことを示唆している。一方、線形回帰モデルでは、ステップワイズ法により、84変数のうち34変数が選択された。そのRMSEは6.14であった。推計されたパラメータの値を表1、ステップワイズで選択された変数名を表2に示す。

表1 線形回帰モデルパラメータの推計値

term	estimate	std.error	statistic	p.value
(Intercept)	0.2026129	0.0159523	12.7011466	0.0000000
X3	-0.1100101	0.0021237	-51.8021158	0.0000000
X5	0.0426503	0.0052990	8.0487536	0.0000000
X6	-0.0471849	0.0051787	-9.1113487	0.0000000
X7	0.0146078	0.0009023	16.1886068	0.0000000
X8	-0.0002261	0.0000132	-17.1037815	0.0000000
X9	0.0000143	0.0000085	1.6855669	0.0918794
X10	0.0030999	0.0001770	17.5129952	0.0000000
X11	-0.0430212	0.0010915	-39.4136842	0.0000000
X12	0.0702498	0.0013714	51.2261542	0.0000000
X13	-0.0312409	0.0011333	-27.5669844	0.0000000
X14	0.0727258	0.0012290	59.1771410	0.0000000
X15	1.0406372	0.0015927	653.3813928	0.0000000
X16	-0.0178694	0.0015549	-11.4925286	0.0000000
X17	-0.0125753	0.0009455	-13.3004240	0.0000000
X18	0.0319248	0.0012135	26.3069954	0.0000000
X19	-0.0147260	0.0011294	-13.0384402	0.0000000
X23	0.0169248	0.0079782	2.1213939	0.0338888
X29	-0.0000840	0.0000411	-2.0450861	0.0408465
X34	-0.0000836	0.0000585	-1.4282619	0.1532167
X36	-0.0000977	0.0000567	-1.7240473	0.0846995
X42	-0.0039799	0.0009363	-4.2504870	0.0000213
X44	0.0018105	0.0008414	2.1518486	0.0314094
X46	0.0035815	0.0008203	4.3660945	0.0000126
X47	-0.0943092	0.0242281	-3.8925448	0.0000992
X48	0.0527019	0.0268179	1.9651789	0.0493937
X55	-0.0217808	0.0140696	-1.5480762	0.1216041
X65	0.0668661	0.0305027	2.1921334	0.0283700
X66	0.0546097	0.0304974	1.7906376	0.0733517
X74	-0.1078739	0.0329210	-3.2767512	0.0010501
X75	-0.0676499	0.0365965	-1.8485365	0.0645250
X76	-0.0402912	0.0270707	-1.4883719	0.1366530
X81	-0.0387302	0.0235253	-1.6463203	0.0996980
X83	0.0000000	0.0000000	-13.8585434	0.0000000
X84	0.0000057	0.0000003	20.4351621	0.0000000

例えば、X3の中心部からの道路時間距離のパラメータは負であり、都心に近いほど夜間光強度が高いことを表している。また、X84は一人あたりGDPが高いほど夜間光も明るいことを示しているが、X83の人口については、t-値 (Statisticと表記) が負であり、パラメータは負である。これは経験的な理解とは異なる結果だが、全世界の都市を同一のモデルで推計していることに起因していると考えられる。その解釈については考察の節で検討する。

表2 ステップワイズで選択された変数

Variables	Descriptions
X3	Road time distance (hour)
X5	Time distance from the nearest station
X6	Time distance from city center using railway
X7	Annual mean temperature
X8	Temperature Seasonality (standard deviation*100)
X9	Annual precipitation
X10	Precipitation Seasonality (Coefficient of Variation)
X11-19	Nighttime light intensity at previous period (2012)
X23	Net primary product of previous period (2012)
X29, X34, X36	Terrain Elevation Data
X42, X44, X46	standard deviation of elevation
X47, X48, X55	Water surface
X65, X66	Protected areas (2) Marine Protected Areas
X74, X75, X76, X81	Protected areas (3) Other effective area-based conservation measures
X83	Total population
X84	GDP per capita: PPP in 2011 USD

次に、このモデルに2016年のデータを入力し、2020年の夜間光を推計した。その結果、全100都市の対象グリッドの線形回帰モデルの推計値と観測値の重相関係数は0.871となった。参考として、東京とトロントの推計結果を図2、3に示す。

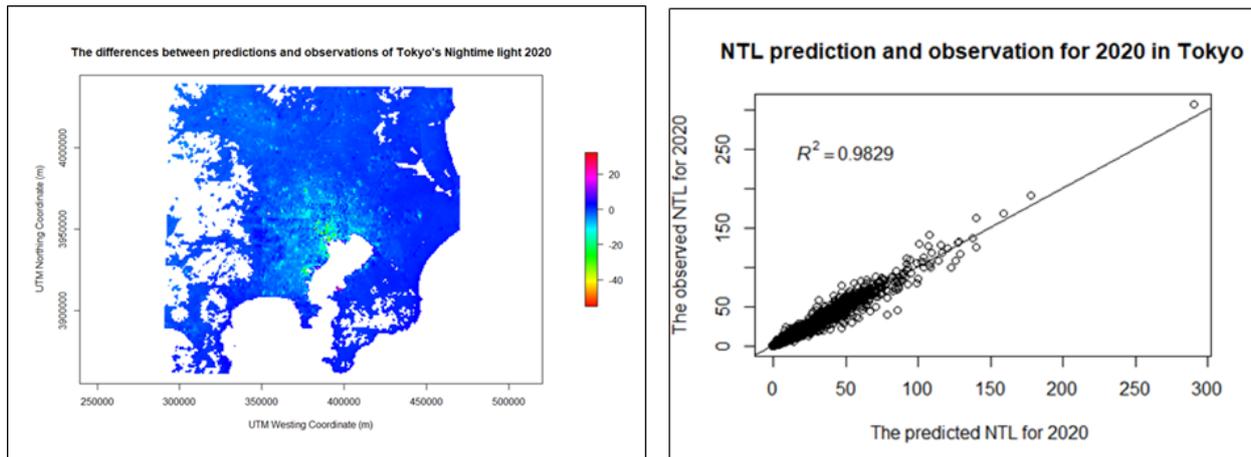


図2 東京の夜間光の予測値（左）と観測値と予測値のプロット

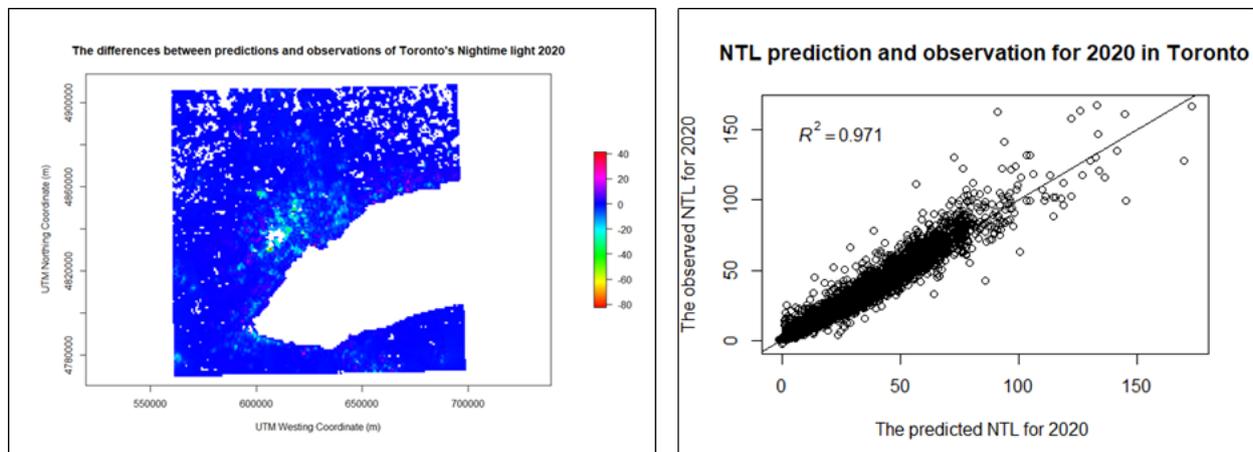


図3 トロントの夜間光の予測値（左）と観測値と予測値のプロット

4. 考察

本研究ではニューラルネットワークを非線形回帰モデルとして夜間光推計に適用したが、中間ユニット 2 で過学習が生じている。この結果は、夜間光で代理される都市活動量に対する、説明変数の非単調な影響関係が把握できていないことを意味している。例えば、経験的には、気温や降水量などは適正な範囲が存在し、極端な値をとる場合には活動量は少なくなると考えられることから、非単調な影響関係が見られると想定したが、今回対象とした 100 都市は国連の都市データベースに掲載されている主要な都市であり、そもそも極端な気候を含んでいないと考えられる。このため、対象とする領域に応じて、そもそも、都市活動に対する日単調な影響要因が存在するかについて検証することが必要と考えられる。

一方、線形モデルより、中間ユニット数 1 の NN の RMSE が高い結果となっている。このことは、要因の影響に非線形性が見られることを示唆している。このため、線形回帰モデルであっても、Box-Cox 変換や Box-Tidwell 変換により、推計精度が向上する可能性があると考えられる。

また、説明変数として、当該グリッドのみならず、周辺グリッドも入力変数として用いた。これは、局所条件がもたらす影響を想定したためである。例えば、前期において当該グリッドの夜間光が暗いとしても、周辺グリッドが明るければ、当期において開発が進み明るくなるケースなども考えられる。線形回帰モデルにおいてステップワイズ法でそれら周辺グリッドの変数も採択されているが、隣接グリッドの同一の変量は相関が高いとも考えられる。周辺グリッドの変数を除いた分析との精度比較も必要である。この課題についてはグリッド間のテクスチャ特徴量や空間的自己相関を回帰モデルに組み込む手法が有用であると考えられるため、データ処理手順を含めて検討する。

また、線形回帰モデルにおいて、GDP は正、人口は負の影響を持つことが推計された。一般的に人口が多いほど経済活動量が大きくなり、このため、夜間光強度も強くなると考えられるが、このモデルでは 2012 年の人口が 2016 年のグリッド別夜間光強度に及ぼす影響を推計している。この結果からは、対象とした都市間で比較すると、2012 年の人口が少ない都市の方が、2016 年の夜間光強度が強くなると解釈できるが、これは、2012 年の夜間光では説明できない部分が反映されていると推測される。すなわち、今回対象としたデータでは人口規模の小さい都市ほど、2012 年よりも夜間光強度が増加していることが示唆される。より解釈のしやすい結果とするためには、前期の断面人口ではなく、対象期間の人口の変化量などを説明変数とする方が望ましいと考えられる。

5. まとめ

本研究では、世界 100 都市を対象に 2012 年の説明変数で 2016 年の夜間光を推計する単一のモデルをニューラルネットワークと線形回帰モデルで作成した。その結果、ニューラルネットワークモデルでは、中間ユニット数 2 で過学習が発生しており、必ずしも非単調性の再現能力が必要とは限らないことが示唆された。また、線型モデルでも一定の推計精度が得られており、非線形変換により、ニューラルネットと同等の精度が得られる可能性が示唆された。

なお、今回は 2012 年のデータにより 2016 年の断面の夜間光強度を求めたが、将来予測をする上では、夜間光強度の変化を推計するモデルも検討の余地がある。ただし、夜間光強度の水準よりも変化量の方が個別的、局所的な影響を受けやすいとも考えられるため、推計精度やパラメータの安定性などを比較することが必要である。

本研究では初めての試みとして、グリッドレベルの夜間光強度モデルの推計を試みたが、さらに様々なパターンの検証が必要なことが分かった。それらは今後の課題である。

6. 謝辞

本研究は中部大学問題複合体を対象とするデジタルアース共同利用・共同研究 IDEAS202107 の助成を受けたものです。

参考文献・データ

1. Masanobu Kii, Nopadon Kronprasert, Boonsong Satayopas: Estimation of transport demand using satellite image: case study of Chiang Mai, Thailand, International Journal of GEOMATE, Vol. 18, Issue 69, pp. 111-117, 2020. <https://doi.org/10.21660/2020.69.9304>