

2022/08/06

理論談話会#16

理論合宿

A statistical approach to small area synthetic population generation as a basis for carless evacuation planning

Mohammad Motaleb Nejad, Sevgi Erdogan, Cinzia Cirillo

Journal of Transport Geography, Vol. 90, 102902, (2021)

M1 近藤愛子

1. Introduction
2. Literature review
3. Small area population estimation problem [課題の特定, 問題設定]
4. Methodology
5. Anne Arundel county application [実証分析]
6. Conclusions

問題意識

- 低所得、車を所有しない住民が最も影響を受けやすい
(ハリケーンKatrina, Rita, Maria)
- 彼等が避難できるよう、(公共)交通サービスの提供が必要

効果的な避難輸送サービスの提供のため

目標

車を持っていない脆弱な層が
どこに住んでいるのかを知る



- 「車避難が前提」という点は日本とは違う？
- 日本では徒歩避難してほしいのに、の方が問題としては大きい
津波や、豪雨などのハザード直前の避難で渋滞
- 豪雨・台風避難で、事前の広域避難とかがポピュラーになれば、大事になりそう
交通弱者の特定など

目標 車を持っていない脆弱な層が
どこに住んでいるのかを知る

車保有と社会人口学的特性に相関があれば特定できるが...

課題

- 特性は標本調査のものしかわからない
- その標本の取得範囲(PUMA*)は、災害で被害を受ける範囲より大きい
本研究の調査対象のAnne Arundel County(1070km²)は4つのPUMAに分けられる
23区の面積が約630km²
- Census tractなら、災害リスクを考慮するのに十分な小ささだが、サンプルが少ない
1000-8000人規模。PUMAの下位ネスト

▷ **小地域内人口の特性**を適切に表す、**合成人口を生成する**手法の開発




Fig. 1. Two layers of geographical area, large geographical area (B), and small area (A).

十分に説明している、と言える数の標本を得られるのはB
避難を考慮するにはAレベルでの情報が必要（緑の地域は避難必要ない）


十分な信頼性を得るためには、合成人口は以下の2つの条件を満たす必要

1. 地域ごとの、要素間の従属関係が保存される

- 地域内では、同じ社会人口学的特性（e.g. 教育、世帯収入、婚姻歴等）を持つ個人は、子供の人数や車の有無について、同じ傾向を持っている
- ただし、地域間でこの傾向は異なる

2. 各要素の分布が実データと一致する

- 例えば、世帯収入の分布



Census tract (=右図のAに相当)では、**サンプルが少なすぎる**ため、1. の従属関係を導くのは困難

仮定 PUMA (=右図のBに相当)内では、1. の従属関係は同じ

▷ PUMAのデータより従属関係を推定し、Census tractの各要素の分布を満たす人口を合成

従属関係の構造をcopula estimationにより捉える

必要な条件

1. 要素間の従属関係の保存
2. 各要素の分布が実データと一致




Fig. 1. Two layers of geographical area, large geographical area (B), and small area (A).

Copulaとは? Sklar(1959)が提唱

d 次元の周辺分布を、同時分布に写像する関数 C をCopula関数と呼ぶ

$$C: [0,1]^d \text{ marginal distributions of } d \text{ dimensional multivariate data} \rightarrow [0,1]^1 (1)$$

H を d 次元の連続変数の同時分布とし、 F_k を k 番目の変数の周辺分布とすると、

$$H(x_1, x_2, \dots, x_d) = C\{F_1(x_1), F_2(x_2), \dots, F_d(x_d)\} \quad x_1, x_2, \dots, x_d \in \mathbb{R} (2)$$

n 個の観測からなる多変量データがある時、 i 番目の観測、 k 次元目の変数に対して経験周辺分布 F_k^i とランク R_k^i は

$$F_k^i = \frac{R_k^i}{n} (3)$$

$$R_k^i = \sum_{j=1}^n 1(x_k^j < x_k^i) (4)$$

式(1)-(4)を用いて、経験コピュラ(empirical copula)は

$$C_n(f_1(x_1), \dots, f_d(x_d)) = \frac{1}{n} \sum_{j=1}^n 1(F_1^j(x_1) < f_1, \dots, F_d^j(x_d) < f_d) \quad (5)$$

Sklarはすべての多変量連続変数群に対して、式(1)を満たす少なくとも1つのparametric関数が存在することを示した

経験コピュラ（観測されているデータ）に近い
parametricコピュラを見つけたい



本研究で用いられたコピュラ関数→
Archimedean copulaというfamily
陽関数で、1つのパラメータ θ で
記述できるという特徴がある

Table 1

Three most popular Archimedean copulas.

Copula	Multivariate Copula C_θ	Range of the θ
Clayton	$[\max\{f_1^{-\theta} + f_2^{-\theta} + \dots + f_d^{-\theta} - d + 1; 0\}]^{-1/\theta}$	$\theta \in [-1, \infty] \setminus \{0\}$
Frank	$-\frac{1}{\theta} \log \log \left[1 + \frac{\prod_{i=1}^d (\exp(-\theta f_i) - 1)}{\exp(-\theta) - 1} \right]$	$\theta \in \mathbb{R} \setminus \{0\}$
Gumbel	$\exp[-(\sum_{i=1}^d (-\log \log f_i)^\theta)^{1/\theta}]$	$\theta \in [1, \infty)$

選んだcopula関数が従属関係をうまく表現できているか？

▷統計検定

帰無仮説：従属関係をあらわす C_θ (=真のコピュラ?)が選定したcopula familyに含まれる

経験コピュラとパラメトリックコピュラの距離を用いた方法 Genest and Remillard(2008), Genest et al.(2009)
距離はFermanian(2005)による $C_n(u) = \sqrt{n}(C_n - C_{\theta_n})$

Cramér-Von-Mises statistics $S_n = \int_{[0,1]^d} C_n(U)^2 dC_n(U) = \sum_{i=1}^n \left(C_n(U_i) - C_{\theta_n}(U_i) \right)^2$ (8)
累積分布関数 F^* と経験分布 F_n を比べる指標
経験コピュラ
パラメトリックコピュラ

$n \rightarrow \infty$ のときの S_n の極限分布はわからない、parametric bootstrapで近似する→P値の計算

P値が大き→棄却することができない→copula familyにfitする

普通は、帰無仮説を棄却して逆を示す、



1. 元データ X_n^d
 - i. データにターゲットコンピュータを最尤法でfitさせる: $C_{\hat{\theta}}$
 - ii. データの経験コンピュータ: C_n
 - iii. S_n を計算

2. データをサンプリング X_n^{*d}
 X_n^{*d} に対してi.-iii.を繰り返す

▷2.をK回繰り返す。i回目の S_n^* を $S_{n,i}^*$ と書くとP値は

$$P = \frac{1}{K+1} \left[\sum_{i=1}^K 1(S_{n,i}^* \geq S_n) + 0.5 \right] (9)$$

Copulaが統計検定をクリアしたら、それを用いて合成人口を生成する

↓大きい範囲のデータ(PUMA)

Copulaは擬似観測値を与える i.e.依存関係は保たれているが、標準化?された値

累積分布関数の逆関数を用いて、合成人口に変換

↑小さい範囲のデータ(Census Tract)




Fig. 3. Flowchart of the population-synthesizing algorithm.

データから合成人口を得るまでのフローチャート

累積分布関数 F に従う乱数 X を発生させたいとしたら
→ $[0,1]$ の一様分布の乱数 U を用いて、
 $X = F^{-1}(U)$ とすればいい



特定の依存関係をもつ乱数列 X_1, \dots, X_d がほしいので
→コピュラ $C(u_1, \dots, u_d)$ に従う乱数ベクトル U_1, \dots, U_d を発生させ、
 $X_i = F^{-1}(U_i)$ とすればよい



対象地域：Anne Arundel county

面積：1070km²

PUMAが4つ含まれる

使用データ：

1. PUMS (Public Use Micro Samples)


- あるPUMAに属するサンプル
- American Community Survey

2. 2010 Decennial Census Data


- Census tractレベル
- 10年ごと、国勢調査のようなもの

3. IRS Income Data

- Zip codeごと
- 各census tract内に、そのzip codeを持つ人の割合がわかる→Census tractレベルに変換



PUMA Level



Census Tract Level

Archimedean copula:

Clayton, Gumbel, Frank, Joe

で検定を実施

→Claytonを採用

Table 1 再掲: parametric コピュラ
Three most popular Archimedean copulas.

Copula	Multivariate Copula C_θ	Range of the θ
Clayton	$[\max\{f_1^{-\theta} + f_2^{-\theta} + \dots + f_d^{-\theta} - d + 1; 0\}]^{-1/\theta}$	$\theta \in [-1, \infty] \setminus \{0\}$
Frank	$-\frac{1}{\theta} \log \log \left[1 + \frac{\prod_{i=1}^d (\exp(-\theta f_i) - 1)}{\exp(-\theta) - 1} \right]$	$\theta \in \mathbb{R} \setminus \{0\}$
Gumbel	$\exp[-(\sum_{i=1}^d (-\log \log f_i)^\theta)^{1/\theta}]$	$\theta \in [1, \infty)$

各PUMAに対するコピュラのパラメータは以下の通り

Table 2

Estimated parameters for Clayton copula for census tracts within Anne Arundel county.

PUMA	Copula	Statistics	P-value	Estimated parameter (θ)
1201	Clayton	156.74	0.9995	0.30082
1202	Clayton	139.65	0.9995	0.33478
1203	Clayton	173.25	0.9995	0.28861
1204	Clayton	158.7	0.9995	0.29214

各census tractの人口(人数)に対応する擬似観測値を生成



Census data, IRS Income data から
世帯人数, 世帯の種類, 収入, 子供の有無と年齢, 家庭の就労者の数, 年齢, 性別, 雇用状況, 人種の情報を持つ合成人口の生成

車の所有有無を二項ロジットで推定 (Bierlaire, 2018)

データ：Maryland州の2017 National Household Travel Survey

$$U_{\text{no car}} = 0$$

$$U_{\text{car}} = \beta_0 + \beta_{\text{CH1}} + \beta_{\text{WIF}} + \beta_{\text{inc1}} + \beta_{\text{inc2}} + \beta_{\text{inc3}} + \beta_{\text{R1}} + \beta_{\text{R2}} \#(10)$$

定数項 世帯の就労者数
子供の数 収入below poverty

収入low middle アフリカ系
収入middle アジア系

Table 3

Results of Binomial Model used to estimate car ownership.

Name	Value	Robust std. err	Robust t-test	P-value
Alternative Specific Constant - 0 car	0.00	Fixed		
Alternative Specific Constant – at least one car	0.583	0.180	3.24	0.00
Number of children in the household (CH1)	1.01	0.802	1.26	0.21
Personal income < \$25 k (inc2)	1.55	0.369	4.20	0.00
Household income \$25 K - \$50 k (inc3)	3.65	0.468	7.81	0.00
Household income \$50 K - \$75 k (inc4)	3.93	0.588	6.68	0.00
Race - African American (R1)	-1.35	0.562	-2.40	0.02
Race – Asian (R2)	-2.06	0.795	-2.59	0.01
Number of workers (WIF)	0.745	0.262	2.85	0.00

車所有の二項ロジットを、
p14の合成人口に対して配分し可視化

Low income: 世帯収入が \$25,000未満と設定

- 色が暗いほど低収入世帯が多い
- 円が大きいほど車を持たない世帯が多い



示唆

- 低収入世帯が多い地域ほど、車を持たない世帯が多い。
- 車を持たない世帯は北部に集中している




Fig. 8. Car ownership and income level for Census Tracts within Anne Arundel County.

成果

Copulaをつかった合成人口の生成手法

- 要素間の従属関係、隠された相関関係の保持
- より広い範囲のデータと、狭い範囲のデータを併せて使うことで地域間の差異を表現

課題

- 適切なコピュラ選定のための検定手法の特定
- 細かい範囲でのデータがない/非公開、などのデータの限界

応用例

- 低所得者や障害者、車を持たない世帯の居住部のアクセス性
- アクティビティモデルのより詳細なインプット

▷ 必要な人に必要なものが届く、（避難）政策の立案

- Sklar, A., 1959. Fonctions de répartition à n dimensions et leurs marges. Publ. Inst. Statist. Univ. Paris 8, 229–231.
- Genest, C., Rémillard, B., 2008. Validity of the parametric bootstrap for goodness-of-fit testing in semiparametric models, Annales de l'Institut Henri Poincaré, Probabilités et Statistiques. Institut Henri Poincaré 44 (6), 1096–1127.
- Genest, C., Rémillard, B., Beaudoin, D., 2009. Goodness-of-fit tests for copulas: a review and a power study. Insurance: Math. Econ. 44 (2), 199–213.
- Fermanian, J.-D., 2005. Goodness-of-fit tests for copulas. J. Multivar. Anal. 95 (1), 119–152.
- Bierlaire, M., 2018. PandasBiogeme: A short introduction. Technical Report TRANSP-OR 181219, Transport and Mobility Laboratory, ENAC, EPFL, Lausanne, Switzerland.