

細粒度人口分布推定のためのマルチモーダル超解像

武田 直人^{1,a)} 上坂 大輔¹ 小林 亮博^{1,2}

概要：ユーザのスマートフォン位置情報を集計した細粒度人口分布は、自治体の交通管理や小売企業の新規出店などの都市アプリケーションに重要な知見となる。しかし、細かい粒度のグリッドで位置情報を集計した場合、膨大なストレージコストが必要な点や、人口の少ない地方部では本来の人口分布を表現するのに十分なサンプルが集まらないため、粗い粒度で集計する必要がある点が課題となる。数百 m 単位のグリッドで集計された粗粒度人口分布から数十 m 単位のグリッドで集計された細粒度人口分布を推定することで、ストレージコストの大幅な削減やサンプル数の少ない地方部における細粒度人口分布の把握が期待できる。この課題を解決するために、我々は、コンピュータビジョンの分野において静止画の解像度を上げるために利用される超解像技術を応用した手法を提案する。提案手法は、(1) CNN ベースの超解像モデルにより人口分布の解像度を上げるネットワークと、(2) 地図画像の RGB 情報などの補助情報をチャンネルとして追加することにより推定精度を向上させるネットワークで構成されている。東京都の人口分布を学習データとし、茨城県つくば市における細粒度人口分布を推定した実験の結果、提案手法の有効性が確認された。

Multi-Modal Super-Resolution Method for Fine-Grained Population Distribution Estimation

1. はじめに

都市の人口分布とは、ある時間帯の人口の地理的な分布であり [21]、自治体の都市計画 [12]、交通管理 [2]、災害発生時の救援物資の需要把握 [9]、パンデミックのリスク評価 [10], [11]、小売企業による店舗の開店や閉店の意思決定 [1] などの都市アプリケーションに重要な知見となる。人口分布は数年に一度、国勢調査で集計されるが、居住地を基準とする数 km から数百 m 単位のグリッドで集計されるため、地域の詳細な人口をリアルタイムに把握することはできない。一方で、スマートフォン経由で測位した GPS 位置情報からユーザ数を集計する方法 [15] は、リアルタイムかつ任意のグリッドサイズでの集計が可能である。しかし、人口の少ない地方部において位置情報を細かい粒度で集計すると、サンプル数が不十分なため信頼性の低い人口分布（たとえば、多くのグリッド内人口がゼロを示す）が計算される。また、過去の細かい粒度で測定した人口分布

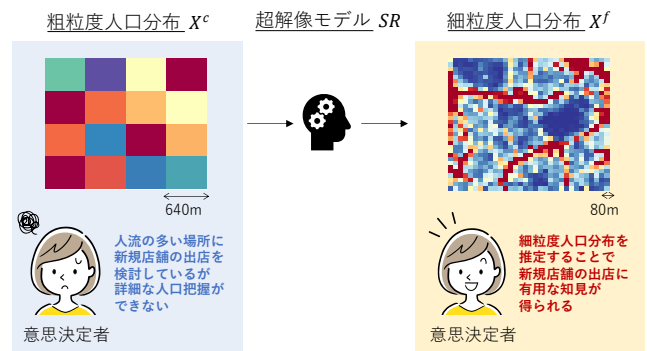


図 1: 細粒度人口分布推定の概要。640m のグリッドで集計した人口分布から、80m のグリッド人口分布を推定している ($\times 8$)。グリッドの色は人口量を表す (青が最低値, 赤が最大値のヒートマップ)。

を保存しておくためのストレージコストも課題である。数百 m 単位のグリッドで集計された人口分布 (以下、粗粒度人口分布) から、数十 m 単位のグリッドで集計された人口分布 (以下、細粒度人口分布) を推定すること (図 1) で、サンプル数の少ない地域における詳細な人口分布の把握やストレージコストの大幅な削減が期待できる。

粗粒度人口分布から細粒度人口分布を推定する手法とし

¹ KDDI 総合研究所
KDDI Research, Inc., Fujimino, Saitama, 356-8502, Japan.

² KDDI
KDDI Corporation.

a) no-takeda@kddi.com

て、コンピュータビジョンの分野で発展した超解像技術を応用した手法が提案されている [8], [20]. これらの研究では、粗粒度人口分布と細粒度人口分布のペアを CNN ベースの超解像モデルに学習させることで推定を実現しているが、訓練と検証に使われる都市は同一という前提があるため、地方部の推定には地方部における細粒度人口分布が必要となり、現実的ではない. そこで、本研究では、粗粒度人口分布と細粒度人口分布のペアを十分に得ることができる都市部で訓練したモデルを利用して、地方部における細粒度人口分布を推定する手法を提案する. 提案手法は、推定精度を向上させるための補助情報として地図画像の RGB 情報を利用してマルチモーダルな学習と推定を行う. 地図画像は、全国で同一の基準で描画されているため、モデルはグリッド内の地図上の色やグリッド内に描画されている道路、建物と人口分布との関係を学習することが期待される. 我々の知る限り、細粒度人口分布推定に地図の画像情報を利用した既存研究は存在しない. 本論文の貢献は、(1) 超解像モデルに人口分布と地図画像の RGB 情報との関係を学習させるフレームワークの提案、(2) 超解像のベースモデルを変更した場合の細粒度人口分布推定に与える影響の調査、(3) ユーザのスマートフォン GPS の実データを利用した提案手法の有効性の評価、の 3 点である.

2. 問題設定

本章では、既存研究 [8], [20] を参考に粗粒度人口分布から細粒度人口分布を推定する問題を定式化する.

2.1 人口分布

ある時間帯のエリアを H 個 \times W 個のグリッドで分割し、それぞれのグリッド内のユニークユーザ数をカウントした分布を人口分布 $X \in \mathbb{R}_+^{1 \times 1 \times H \times W}$ とする. また、粗粒度人口分布を $X^c \in \mathbb{R}_+^{1 \times 1 \times H \times W}$ 、細粒度人口分布を $X^f \in \mathbb{R}_+^{1 \times 1 \times nH \times nW}$ で表す. ここで、 n は、超解像の倍率を示し、粗粒度人口分布の各グリッドは、細粒度人口分布では、 $n \times n$ のグリッドに分割される. 図 1 は、1 辺が 640m のグリッド ($H \times W = 4 \times 4$) で構成されている粗粒度人口分布から、1 辺が 80m のグリッド ($nH \times nW = 32 \times 32$) の細粒度人口分布を推定する例を示している ($n = 8$).

2.2 補助情報

本研究では、推定精度を向上させるために補助情報を利用して超解像モデルを訓練する. 補助情報は、推定の目標とする細粒度人口分布推定と同じ解像度のものが利用され、 $A^f \in \mathbb{R}_+^{1 \times M \times nH \times nW}$ で表す. M は、補助情報の次元数を示しており、地図画像の RGB 情報のみを利用する場合、 $M = 3$ となる.

2.3 補助情報を利用した細粒度人口分布推定問題

本研究の目的は、粗粒度人口分布 X^c と補助情報 A^f とを利用して細粒度人口分布 X^f を推定する超解像モデル SR を訓練することである. SR は、訓練時に、 K 件の粗粒度人口分布 $X^c \in \mathbb{R}_+^{K \times 1 \times H \times W}$ と細粒度人口分布 $X_{ref}^f \in \mathbb{R}_+^{K \times 1 \times nH \times nW}$ および $A^f \in \mathbb{R}_+^{K \times M \times nH \times nW}$ が与えられ ($K \gg 1$. 1 時間単位で集計した人口分布ペアが 1 ヶ月分あるとすると、 $K = 24 \times 30 = 720$ 件となる.), 粗粒度人口分布から細粒度人口分布を推定するためのパラメータや細粒度人口分布と補助情報との関係を学習する. 推定時には、 $X^c \in \mathbb{R}_+^{1 \times 1 \times H \times W}$ と $A^f \in \mathbb{R}_+^{1 \times M \times nH \times nW}$ を入力とし、 $X^f \in \mathbb{R}_+^{1 \times 1 \times nH \times nW}$ を出力する.

3. 関連研究

本章では、まず、本研究の検証で用いる GPS ベースの手法を含む人口分布の集計方法について関連研究を紹介する. 次に、既存の細粒度人口分布の推定研究を、各グリッドの特徴量を学習した回帰モデルを利用する手法、コンピュータビジョンの分野で発展した超解像モデルを応用する手法とに分けて紹介する.

3.1 人口分布の集計

人口分布は数年に一度、自治体による国勢調査やパーソントリップ調査で集計される. しかし、国勢調査で集計される人口分布は居住地を基準とした静的な分布 (すなわち、深夜帯の分布) であり、1 日単位や 1 時間単位の都市の様子を把握することはできない. また、人の移動を把握するために行われるパーソントリップ調査は、アンケートベースで実施されるが、調査負担の大きさ、データ取得期間が特定の調査日のみであり、リアルタイムな移動を把握できない点などが課題であり、実施する都市圏は減少傾向にある [22]. そこで、通信技術により収集したリアルタイムな人口分布が、都市の様子を反映する重要な情報源となっている [6].

都市の人口分布を短い時間スケールで集計する代表的な方法は、交通量データを取得することであり、ナンバープレート認識システム (LPR) や、マイクロ波レーダー、磁力計などのセンサーを道路に設置することで収集される [3], [20]. また、鉄道の IC カード履歴を利用して、駅周辺の人口分布を推定する方法 [18] もある. しかし、これらの方法では、歩行者や自転車に乗るユーザを反映することはできない. 我々は都市の細粒度人口分布を推定することで、自治体による交通管理だけでなく、小売企業による店舗の開店や閉店の意思決定の知見を提供することが目的であるため、歩行者を含む都市全体の人口分布を集計することが望ましい. 一方で、スマートフォンから取得された GPS 位置情報は、ユーザの許諾を得たうえでアプリケーション経由で収集され [17], 単位時間ごとにグリッド内の

ユニークユーザー数を集計することで、ユーザーの交通状況に関わらず都市の人口分布を把握することが可能である [15].

スマートフォン GPS から集計した人口分布の課題として、サンプル数が十分に集まらない地方部において、信頼性の低い細粒度人口分布が計算される点があげられる。本研究では、スマートフォン GPS から集計した人口分布を利用するが、信頼性の高い細粒度人口分布が計算できる都市部で学習したモデルを利用して地方部の細粒度人口分布を推定する。

3.2 細粒度人口分布の推定研究

3.2.1 回帰モデルを利用した手法

細粒度人口分布は、粗粒度人口分布の各グリッドを複数の小さなグリッドに分割した分布であるため、グリッドに対して特徴量を定義して回帰モデルを訓練することで推定することが可能である [14], [19]. Stevens ら [14] は、各グリッドに対して土地被覆データや、衛星画像、夜間照明データなどの大量の補助情報の特徴量として、ランダムフォレストを訓練する手法を提案した。Zhao ら [19] は、各グリッドに対して人口分布に影響を与えるグリッドの特徴（政府機関、ショッピング施設など）を明らかにし、夜間照明データなどの補助データと組み合わせる上で、線形回帰モデルとランダムフォレストモデルを利用して細粒度人口分布を推定した。これらの研究では、国勢調査で集計された静的な人口分布から細粒度人口分布を推定しており、特定の時間帯に限定された説明性しか持っていない（夜間照明データなど）多くの補助データセットに依存している [20] ため、1日単位や1時間単位の動的な人口分布の推定が難しい。

3.2.2 超解像モデルを利用した手法

近年、コンピュータビジョンの分野で発展した超解像モデルを応用した細粒度人口分布推定手法が提案されている [8], [20]. 画像の超解像モデルと細粒度人口分布推定の大きな違いは、人口分布はグリッドに関する外部知識（道路、建物など）に大きく影響される点である。Zong ら [20] は、回帰モデルを利用した手法が多くの補助データセットに依存していることを課題とし、画像の超解像モデルである SRCNN [4] に粗粒度人口分布と比較的入手が容易な補助データセットである POI 分布とを学習させることで細粒度人口分布を推定する手法を提案した。Liang ら [8] は、ResNet ベースの超解像モデルを提案し、曜日、天気などの補助情報を利用することで推定精度が向上することを示した。これらの研究では、学習と検証を同一の都市で行うことが前提とされており、学習のために粗粒度人口分布と細粒度人口分布のペアが必要である。しかし、サンプル数が十分に集まらない地方部においては信頼性の低い細粒度人口分布を基に学習されるため、真の人口分布とは相関の低い疎な人口分布が推定されてしまう。そこで本研究では、都市部における粗粒度人口分布と細粒度人口分布ペアで学

習させたモデルによる地方部の細粒度人口分布推定に取り組む。また、補助情報として、入手が容易であり、都市部と地方部で共通の特徴を学習できることが期待される地図画像を利用する手法を提案する。

4. 地図画像を利用したマルチモーダル超解像

本章では、地図画像などの補助情報を利用した細粒度人口分布推定手法の詳細を説明する。提案手法のフレームワークを図 2 に示す。超解像モデル SR は、CNN ベースの超解像モデルを利用した画像特徴学習部に、人口分布と補助情報との関係を学習する補助情報学習部を連結したモデルであり、粗粒度人口分布 X^c が入力されると、細粒度人口分布 X^f を出力する。提案手法は、 SR を最適化するパラメータ θ_G を求めるために、 K 件の X^c 、 X^c に対応する正解の細粒度人口分布 X_{ref}^f および補助情報 A^f により訓練される。 θ_G は式 (1) によって求める。

$$\hat{\theta}_G = \arg \min_{\theta_G} \frac{1}{K} \sum_{k=1}^K L_G(SR_{\theta_G}(X_k^c, A_k^f), X_{ref_k}^f). \quad (1)$$

ここで、 $SR_{\theta_G}(X^c, A^f) = X^f$ であり、 L_G は、 SR の学習のための損失関数である。提案手法では、画像の超解像モデル [7], [16] を参考にして、複数の損失関数を組み合わせた損失関数 L_G を設計する (4.3 節)。

4.1 画像特徴学習部

画像特徴学習部は、目標の粒度まで人口分布の解像度を上げる役割を持つ。深層学習技術を用いた画像の最も基本的な超解像モデルは SRCNN (Super-Resolution Convolutional Neural Network) [4] であり、既存の細粒度人口分布推定研究でも利用されている [20]. しかし、SRCNN は、MSE (Mean Squared Error) の最小化を目的として学習されるため、高周波成分の推定が難しく、平滑化された画像が出力されやすいという課題がある [7]. 細粒度人口分布では、人口が密なグリッド（駅、オフィスなど）と疎なグリッド（森林、公園など）が隣接することがあるため、高周波成分の推定は重要である。

本研究では、密なグリッドと疎なグリッドが隣接するといった「人口分布らしさ」を考慮した推定を行うために敵対的学習を導入した超解像モデルを利用する。図 2 の画像特徴学習部は画像の超解像モデル ESRGAN (Enhanced Super-Resolution Generative Adversarial Networks) [16] における Generator のネットワーク構造をベースにしている。画像特徴学習部に入力された X^c は、ノイズの低減や特徴量の伝達の強化を目的とした複数の RRDB (Residual-in-Residual Dense Block) 層を通過する。抽出された特徴量マップは、倍率が n のとき、 $F \in \mathbb{R}_+^{1 \times n^2 \times H \times W}$ のテンソルであり、PixelShuffle [13] という手法でアップサンブ

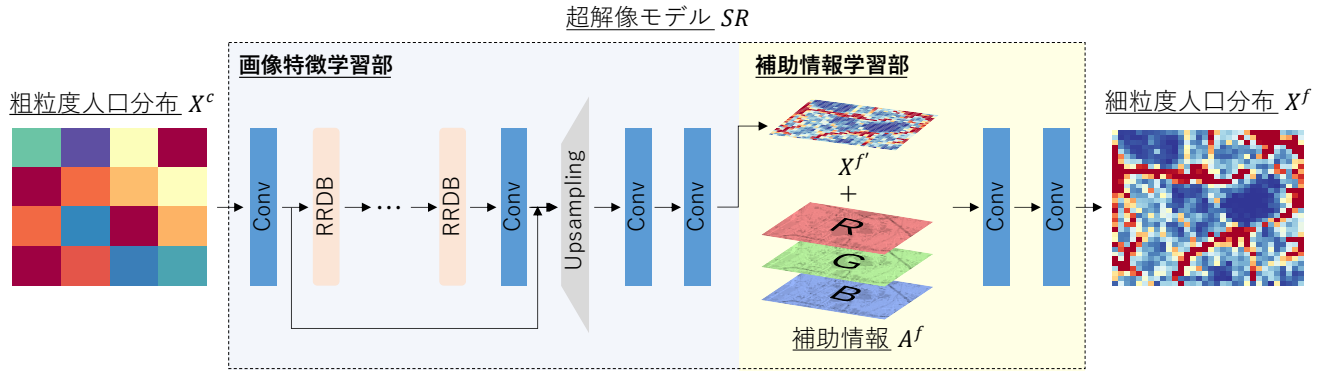


図 2: 提案手法のフレームワーク. 超解像モデル SR は, 粗粒度人口分布 X^c を入力とし, 細粒度人口分布 X^f を出力する. X^c は CNN ベースの既存モデル (ESRGAN) により目標の粒度まで解像度を上げた ($X^{f'}$) あとに, 同じ解像度の補助情報 A^f を画像の別チャネルとして追加し, CNN レイヤを通して, X^f を推定する.

リングされる. PixelShuffle は, n^2 のチャンネルを持つテンソルを 1 チャンネルの幅と高さを持つテンソルに展開する機能を持ち, 格子状のノイズの低減が期待される. 画像特徴学習部は, 以上のネットワークにより, $X^c \in \mathbb{R}_+^{1 \times 1 \times H \times W}$ から $X^{f'} \in \mathbb{R}_+^{1 \times 1 \times nH \times nW}$ を推定する.

なお, 提案するフレームワークにおいて, 画像特徴学習部で使用する超解像モデルは変更可能である. 5 章では, SRCNN と ESRGAN を利用した場合の比較実験を行い, 細粒度人口分布推定に適したモデルを考察する.

4.2 補助情報学習部

補助情報学習部は, 画像特徴学習部で出力された細粒度人口分布 $X^{f'}$ を正解人口分布に近づける役割を持ち, 複数の補助情報と 2 層の畳み込み層を利用する. 補助情報 $A^f \in \mathbb{R}_+^{1 \times M \times nH \times nW}$ は, $X^{f'}$ の各グリッドに 1 対 1 で紐づく情報を持つテンソルであり, $X^{f'}$ の別チャネルとして追加する. 本研究では, 補助情報として既存研究では検討されていない地図の画像情報を利用する. まず, 推定対象のグリッドの地図画像を, $X^{f'}$ と同サイズの RGB チャネルのテンソルとして表現 ($M = 3$) し, $X^{f'}$ の別チャネルとして追加する. なお, 本研究では, 地図画像の解像度を $X^{f'}$ の解像度に合わせる方法として, 基本的な拡大, 縮小手法である Bicubic 法を利用している. その後, 2 層の畳み込み層を通して, 人口分布と地図画像との関係性を学習する. これにより, 補助情報学習部は, 地図画像の情報を踏まえた上で, 細粒度人口分布 X^f を推定する.

4.3 最適化

提案手法のフレームワークは, 粗粒度人口分布 X^c から, X^f を推定する一貫した深層学習ネットワークを利用するため, X^f と X_{ref}^f との間で損失 L_G を計算することにより, 誤差逆伝搬を通じてモデルを学習させることができる. 本研究では, 超解像モデルとして利用する ESRGAN の損失関数を参考に, 細粒度人口分布が平均的に正しく推定で

きたかどうかを評価する MAE (Mean Absolute Error) を示す L_1 と, 敵対的損失である L_{adv} を利用して L_G を計算する. また, L_{adv} には, 詳細なテクスチャの再現に有効とされる Relativistic Average Discriminator [5] を利用する. Relativistic Average Discriminator では, 識別器 D が, X^f と X_{ref}^f を入力として受け取り, X_{ref}^f が X^f よりも実データに近い確率を評価する. それぞれの損失の計算方法を下式に示す.

$$L_G = \alpha L_1 + \beta L_{adv}, \quad (2)$$

$$L_1 = \mathbb{E}_X |X^f - X_{ref}^f|, \quad (3)$$

$$L_{adv} = -\mathbb{E}_{X_{ref}^f} [\log(1 - D(X_{ref}^f, X^f))] - \mathbb{E}_{X^f} [\log(D(X_{ref}^f, X^f))], \quad (4)$$

$$L_D = -\mathbb{E}_{X_{ref}^f} [\log(D(X_{ref}^f, X^f))] - \mathbb{E}_{X^f} [\log(1 - D(X_{ref}^f, X^f))]. \quad (5)$$

ここで, α と β は, 2 つの損失のバランスを取るためのハイパーパラメータである. また, L_D は, 識別器の損失を示す.

5. 実験

本章では, 提案手法の有効性を検証するために, 東京都 (都市部) で収集した GPS を集計した人口分布を利用して, 茨城県つくば市 (地方部) における細粒度人口分布を推定する実験を行う. データセットの作成方法, 比較手法および評価方法を述べた後, 定量的な評価と推定結果の可視化による定性的な評価を行う.

5.1 実験設定

5.1.1 データセットの作成

本実験では, 東京都の 2 次メッシュ (1 辺 10km) の一つであるメッシュコード 533945 を学習エリアとして利用した. 人口分布は, 許諾を得たユーザのスマートフォンから 2021 年 3 月 1 日 ~ 2021 年 5 月 31 日の 92 日間に収集された GPS を利用して 1 日ごとに各グリッドのユニーク

表 1: 茨城県つくば市の各計測地点における通過人数の総計.

計測地点	01/25 (火)	01/26 (水)	01/27 (木)	02/01 (火)	02/02 (水)	02/03 (木)
A	881	851	862	718	655	665
B	992	912	905	936	762	929
C	2,053	2,105	2,174	2,002	1,826	2,114
D	1,607	1,491	1,663	1,362	1,217	1,395

ユーザ数を集計した。学習に利用される粗粒度人口分布は、図 2 に示す粗粒度人口分布 X^c と同様に 640m のグリッドで構成される $H \times W = 4 \times 4$ の人口分布とし、1 件の人口分布は 1 辺 2.56km の領域から分割することで作成される。様々な人口分布の特徴を反映したデータを作成するために、学習エリアからランダムに 2.56km の領域を 300 回クリッピングした。したがって、訓練データは $300 \times 92 = 27,600$ 件の人口分布となる。粗粒度人口分布とペアとなる細粒度人口分布は、320m のグリッドで構成される 8×8 ($n = 2$) の人口分布 ($\times 2$)、160m のグリッドで構成される 16×16 ($n = 4$) の人口分布 ($\times 4$)、80m のグリッドで構成される 32×32 ($n = 8$) の人口分布 ($\times 8$) の 3 つの倍率をスマートフォン GPS の集計グリッドサイズを変更することにより作成した。なお、人口分布は学習時に平均値と標準偏差により標準化した上で学習させた。

検証データは茨城県つくば市における 2022 年 1 月 25 日から 2022 年 1 月 27 日および 2 月 1 日から 2 月 3 日までの 6 日間において、1 辺 2.56km の領域で収集した GPS を 640m のグリッドで分割した 4×4 ($H = W = 4$) の粗粒度人口分布とした (図 3 (a))

細粒度人口分布と対応する地図画像は、OpenStreetMap^{*1} で提供されている API^{*2} を利用して取得した (図 3 (c))。本実験では、取得した地図画像の RGB をそのまま利用する提案手法 1 (ESRGAN+MAP) と、モデルが地図の特徴を学習しやすいうように簡単な RGB 調整をした地図を利用する提案手法 2 (ESRGAN+MAP_{adj}) とを比較する。なお、RGB はそれぞれ 0 ~ 255 の値を取り、人口分布と同様に標準化した上で学習させる。図 3 (d) に、提案手法 1 で利用する地図を示す。提案手法 2 で利用する地図は、大きな道路を示す色をすべて R (255, 0, 0) に変換し、緑地を示す色をすべて G (0, 255, 0) に変換している (図 3 (e))。

5.1.2 比較手法

地図の画像情報を利用した提案手法の有効性を検証するために、ナイーブな手法 (Mean Partition, Bicubic)、提案手法における画像特徴学習部のモデルを変更した手法 (SRCNN, ESRGAN) の 4 つの比較手法を実装した。詳細は以下の通りである。

- **Mean Partition (Mean):** 粗粒度人口分布の人口

*1 <http://www.openstreetmap.org>.

*2 <https://wiki.openstreetmap.org/wiki/API>.

を均等に分配する手法。

- **Bicubic:** 画像の拡大に利用される一般的な手法。
- **SRCNN:** 画像の超解像にはじめて CNN を利用したモデルであり、3 層の CNN レイヤから構成される。既存の細粒度人口分布推定手法のベースモデルとしても利用されている [20]。
- **ESRGAN:** 4.1 節で説明した敵対的学習を通して画像を生成する超解像モデル。

5.1.3 評価方法

各手法により、図 3 (a) に示す粗粒度人口分布を入力として細粒度人口分布を推定し、定量評価と可視化による定性評価を行った。定量評価については、都市全体における各倍率の真の人口分布を観測することは不可能であるため、GPS の集計粒度を変更した人口分布を正解データとする評価 (定量評価 1) と、人手でカウントした人流との評価 (定量評価 2) の 2 つの評価を行った。

定量評価 1. GPS を集計するグリッドサイズを変更した人口分布を正解データとして、各倍率 ($\times 2$, $\times 4$, $\times 8$) についてピアソンの相関係数を計算し、6 日間の中央値を評価した。しかし、図 3 (b) に示すように、アプリケーション利用者の少ない地方部の細粒度人口分布を GPS を用いて集計した場合、多くのグリッド内人口がゼロとなるため、正解データとしての信頼性が低い可能性がある。そこで、 $\times 8$ (80m) については、定量評価 2 により、人手でカウントした人流との相関も評価する。

定量評価 2. 我々は、 $\times 8$ (80m) の細粒度人口分布の正解データを、図 3 (c) に示す 4 地点の人流を人手でカウントすることにより作成した。各地点ごとに 1 名か 2 名の測定員によって、午前 7 時から午後 7 時までに通過する歩行者および自転車をカウントした総計を表 1 に示す。提案手法と比較手法により各日付ごとの細粒度人口分布を推定し、4 地点を含むグリッドの推定人数とカウントした通過人数とのピアソンの相関係数を計算し、6 日間の中央値を評価した。

定性評価. 各手法における 2022 年 1 月 25 日 (火) の $\times 8$ (80m) の推定結果を可視化することで、提案手法の有効性を考察した。

5.1.4 ハイパーパラメータ

ESRGAN、提案手法 1、提案手法 2 は、オリジナルの ESRGAN と同様に 2 段階の学習により訓練した。具体的には、 L_1 のみで 50 epoch 訓練した後に、 L_1 と L_{adv} で 10

表 2: 相関係数による各手法の定量評価の結果. 括弧内の数字は推定した人口分布のグリッドサイズを示す.

Methods	定量評価 1: 集計粒度を変更した人口分布との相関			定量評価 2: カウントした人流との相関
	×2 (320m)	×4 (160m)	×8 (80m)	×8 (80m)
Mean	0.698	0.556	0.405	-0.150
Bicubic	0.714	0.548	0.403	0.608
SRCNN	0.062	0.501	0.380	0.411
ESRGAN	0.574	0.395	0.273	0.846
提案手法 1 (ESRGAN+MAP)	0.763	0.641	0.515	0.860
提案手法 2 (ESRGAN+MAP _{adj})	0.608	0.443	0.317	0.833

epoch 訓練した. これにより, 前半の訓練で人口分布のおおまかな特徴を学習し, 後半の訓練で人口分布の詳細な特徴を学習することが期待される. 利用した Residual block の数はオリジナルの ESRGAN と同様に 23 とし, L_1 の係数 α と L_{adv} の係数 β はそれぞれ調整の結果, $\alpha = 0.01$, $\beta = 0.005$ とした. また, 細粒度人口分布は, はじめに ×2 モデルで推定した結果を ×4 モデルに入力するように ×2 ずつの断続的な推定を行った. なお, 他の比較手法 (Mean, Bicubic, SRCNN) は断続的に推定をするよりも推定精度が高かったため, 一度に対象の倍率まで推定するモデルを訓練した.

5.2 実験結果

提案手法と比較手法による細粒度人口分布推定の定量評価の結果を表 2 に示す. また, 図 3 (a) で示した粗粒度人口分布 (2022 年 1 月 25 日 (火)) を入力として各手法で推定した細粒度人口分布 (×8) の可視化結果を図 4 (a) ~ (f) に示す.

表 2 から, 提案手法 1 は, 定量評価 1, 2 のいずれにおいても, 最も高い相関を示しており, 細粒度人口分布推定のために地図情報を利用することの有効性が確認できた. 単純な手法である Mean と Bicubic は, 定量評価 1 においてはある程度高い相関を示しているが, 定量評価 2 では ESRGAN を利用した手法と比較して相関が低かった. これは, グリッド全体で評価する場合, 平均的な人口を推定すれば, 相関が高くなる一方で, 特定のグリッドに限定して評価した場合, そのグリッドの人口の大小を正確に推定する必要があるためと考えられる. 提案手法 2 は, 定量評価 1, 2 のいずれにおいても提案手法 1 よりも相関が低かった. これは, 提案手法 2 は, 道路や緑地以外のグリッドについて, 特徴を考慮しないためと考えられる.

一方で, 提案手法 2 で推定した細粒度人口分布を可視化すると (図 4 (f)), 道路には人口が集中しやすく, 緑地にも人がおり, それ以外のグリッドには人がいない, などの特徴を明確に表現していることが分かる. この結果から, 地図画像を調整することは, モデルに対して人口分布の特徴を学習させることに有効と示唆された.

提案手法 1 と提案手法 2 (図 4 (e), (f)) の課題として, 地

図上の西側の人口分布を推定できていないことがあげられる. 西側部分は住宅街であり, 細かい道路が密集しているが (図 3 (c)), 図 3 (d), (e) では解像度を推定対象の人口分布に合わせたことにより, 特徴が失われている. この課題は, 適切な地図画像の調整やグリッドの POI 情報を表すレイヤを補助情報として追加することで解決できる可能性があるが, 今後の課題である.

ESRGAN と SRCNN を比較すると, ESRGAN を用いた手法 (図 4 (d), (e), (f)) は, 他の手法とは異なり, 密なグリッドと疎なグリッドが隣接するような「人口分布らしさ」を表現できているが, SRCNN (図 4 (c)) は, 人数の多いグリッドを中心として連続的に人口を推定しており, 人口分布の表現力が低い. この結果から, 都市部で学習させたモデルを利用して地方部の人口分布を推定する場合のベースモデルとして, ESRGAN のような敵対的学習を利用したモデルを利用することの有効性が確認できた.

5.3 今後の課題

本実験により, 都市部の人口分布を利用して地方部の細粒度人口分布を推定する問題において, 敵対的な学習と地図画像を補助情報として利用することが有効であることが分かった. 今後, 以下のような拡張を検討している.

GPS が全く得られない地域の細粒度人口分布の推定. 提案手法では, スマートフォン GPS の集計グリッドサイズを変更して粗粒度人口分布と細粒度人口分布のペアを学習させたが, 今後は粗粒度人口分布の代替データソースとして基地局位置情報の利用を検討している. 基地局位置情報による人口分布は, 人口の少ない地域でも多くのユーザーのデータを利用できるが, 1 つの基地局で広範囲をカバーするため, 都市部でも数百 m 以上, 地方部では数 km 以上という非常に粗い粒度で計算することしかできない. 基地局位置情報を利用して計算した粗粒度人口分布とスマートフォン GPS を利用して計算した細粒度人口分布のペアを学習させることで, GPS が全く得られない地域の細粒度人口分布の推定が期待できる. さらに, 将来的には地図と細粒度人口分布のペアをモデルに学習させることで, 発展途上国などの基地局位置情報も入手不可能な地域の細粒度人口分布の推定や, 都市計画や防災のために仮想的な街の地

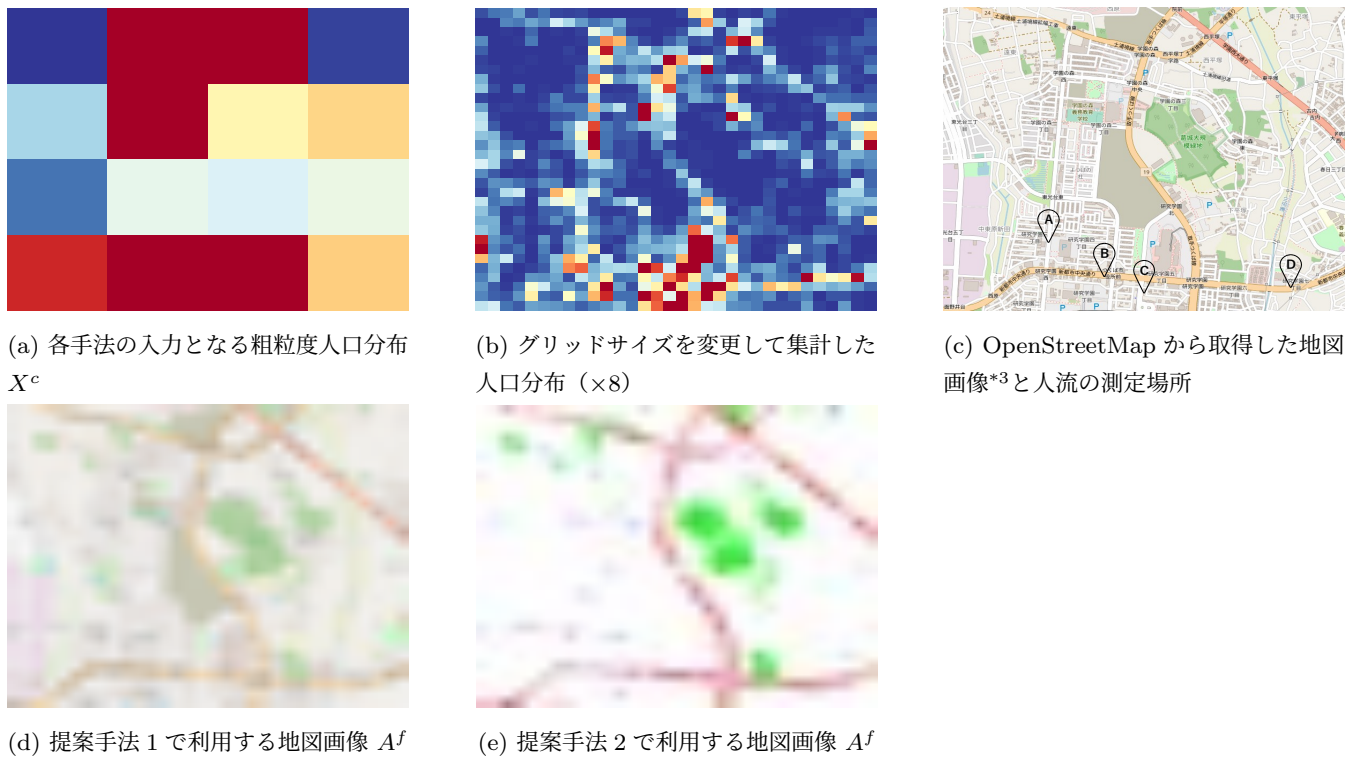


図 3: 実験に利用する人口分布と地図画像. (d) と (e) は、解像度を人口分布に合わせている.

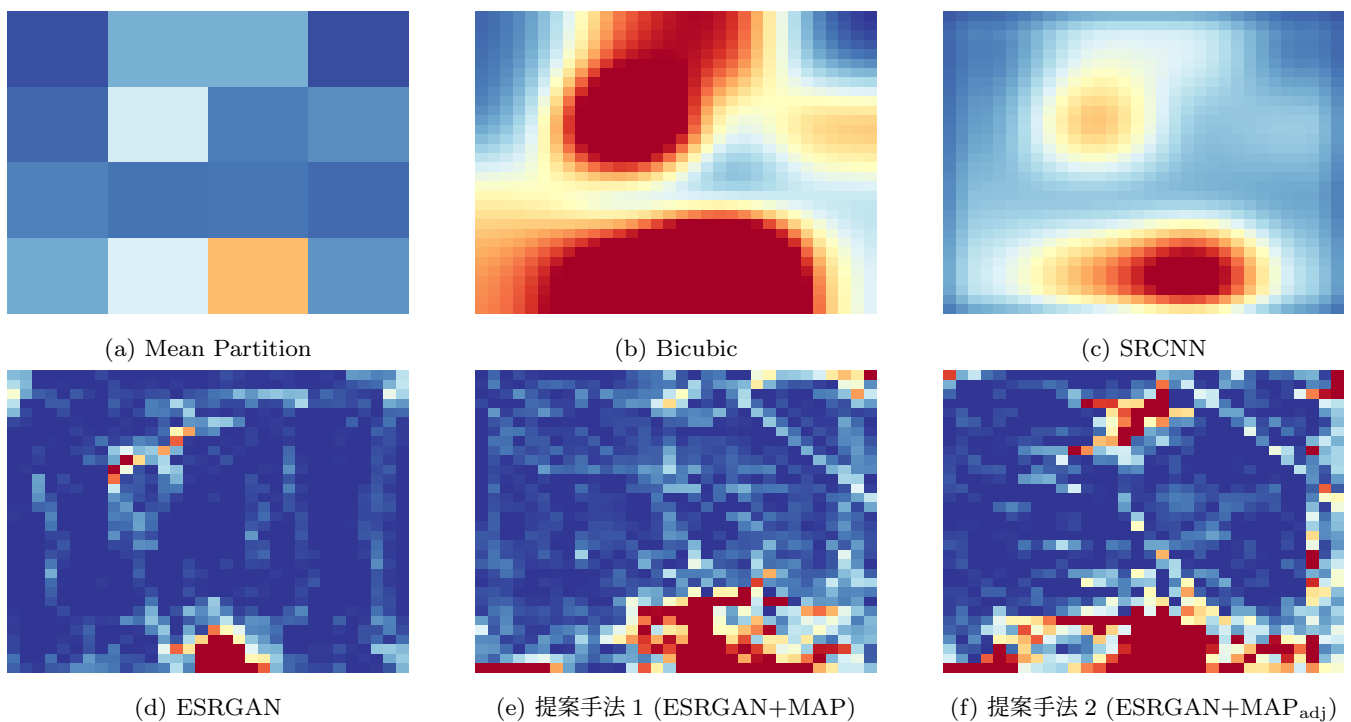


図 4: $\times 8$ (80m) の各手法における推定結果 X^f .

図 (道路の追加や閉鎖などを反映) における人流予測が期待される.

推定精度の向上に寄与する地図画像の表現方法の確立.
 補助情報の解像度を推定対象となる粒度に合わせる提案手法は、各グリッドにおける人口とグリッドの特徴とを 1 対

1 で学習させることができる利点があるが、図 3 (d), (e) の西側のように、細かい情報が失われてしまう. 一方で、提案手法は図 4 (e), (f) に示すように、利用する地図画像によってモデルの表現力を変更できる. そのため、細かい道路のエッジを抽出した画像を別チャンネルとして追加することや、各グリッドの情報を保持したまま解像度を合わせる

*3 (C) OpenStreetMap contributors

方法を検討している。

6. おわりに

本研究では、都市部で収集したスマートフォン GPS を集計した粗粒度人口分布と細粒度人口分布のペアを利用して、地方部の細粒度人口分布を推定する手法を提案した。提案手法は、コンピュータビジョンの分野で発展した超解像モデルをベースとし、地図画像などの補助情報を組み合わせることで推定精度を向上させることができる。東京の人口分布（都市部）を学習データとし、茨城県つくば市（地方部）を検証データとした実験の結果、敵対的な学習と補助情報として地図画像が有効であることが分かった。今後は、時間粒度の変更、検証エリアの拡大を進めるとともに、基地局位置情報による粗粒度人口分布と GPS による細粒度人口分布のペアなどの異なるデータソースを利用した学習と推定を検討している。

参考文献

- [1] Bahrami, M., Xu, Y., Tweed, M., Bozkaya, B. and Pentland, A. S.: Using Gravity Model to Make Store Closing Decisions: A Data Driven Approach, *Expert Systems with Applications*, Vol. 205 (2022).
- [2] Chavhan, S. and Venkataram, P.: Commuters' Traffic Pattern and Prediction Analysis in a Metropolitan Area, *J. on Vehicle Routing Algorithms*, Vol. 1, pp. 33–46 (2018).
- [3] Chen, H., Cai, M. and Xiong, C.: Research on Human Travel Correlation for Urban Transport Planning Based on Multisource Data, *Sensors*, Vol. 21, No. 1 (2021).
- [4] Dong, C., Loy, C. C., He, K. and Tang, X.: Image Super-Resolution Using Deep Convolutional Networks, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 38, pp. 295–307 (2016).
- [5] Jolicoeur-Martineau, A.: The Relativistic Discriminator: A Key Element Missing from Standard GAN, *arXiv* (2018).
- [6] Khodabandelou, G., Gauthier, V., El-Yacoubi, M. and Fiore, M.: Population Estimation from Mobile Network Traffic Metadata, *2016 IEEE 17th Int'l Symposium on A World of Wireless, Mobile and Multimedia Networks, WoWMoM*, pp. 1–9 (2016).
- [7] Ledig, C., Theis, L., Huszar, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z. and Shi, W.: Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network, *2017 IEEE Conf. on Computer Vision and Pattern Recognition, CVPR*, pp. 105–114 (2017).
- [8] Liang, Y., Ouyang, K., Jing, L., Ruan, S., Liu, Y., Zhang, J., Rosenblum, D. S. and Zheng, Y.: UrbanFM: Inferring Fine-Grained Urban Flows, *Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining, KDD*, pp. 3132–3142 (2019).
- [9] Lin, A., Wu, H., Liang, G., Cardenas-Tristan, A., Wu, X., Zhao, C. and Li, D.: A Big Data-Driven Dynamic Estimation Model of Relief Supplies Demand in Urban Flood Disaster, *Int'l J. of Disaster Risk Reduction*, Vol. 49 (2020).
- [10] Qiu, Y., Chen, X. and Shi, W.: Impacts of Social and Economic Factors on the Transmission of Coronavirus Disease 2019 (COVID-19) in China, *J. of Population Economics*, Vol. 33, No. 4, pp. 1127–1172 (2020).
- [11] Ren, H., Zhao, L., Zhang, A., Song, L., Liao, Y., Lu, W. and Cui, C.: Early Forecasting of the Potential Risk Zones of COVID-19 in China's Megacities, *Science of The Total Environment*, Vol. 729 (2020).
- [12] Serrano-López, R., Linares-Unamunzaga, A. and San Emeterio, C. M.: Urban Sustainable Mobility and Planning Policies. A Spanish Mid-Sized City Case, *Cities*, Vol. 95 (2019).
- [13] Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A. P., Bishop, R., Rueckert, D. and Wang, Z.: Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network, *2016 IEEE Conf. on Computer Vision and Pattern Recognition, CVPR*, pp. 1874–1883 (2016).
- [14] Stevens, F. R., Gaughan, A. E., Linard, C. and Tatem, A. J.: Disaggregating Census Data for Population Mapping Using Random Forests With Remotely-Sensed and Ancillary Data, *PLoS One*, Vol. 10, No. 2 (2015).
- [15] Takeda, N., Kamisaka, D., Legaspi, R., Mishima, Y. and Minamikawa, A.: Event Detection and Event-Relevant Tweet Extraction with Human Mobility, *Mobile and Ubiquitous Systems: Computing, Networking and Services, MobiQuitous*, pp. 3–23 (2021).
- [16] Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y. and Loy, C. C.: ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks, *Proc. of the European Conf. on Computer Vision Workshops, ECCV Workshops*, pp. 63–79 (2018).
- [17] Yabe, T., Tsubouchi, K., Sudo, A. and Sekimoto, Y.: A Framework for Evacuation Hotspot Detection after Large Scale Disasters Using Location Data from Smartphones: Case Study of Kumamoto Earthquake, *Proc. of the 24th ACM SIGSPATIAL Int'l Conf. on Advances in Geographic Information Systems, SIGSPACIAL*, pp. 3–23 (2016).
- [18] Yamaki, S., Lin, S. and Kameyama, W.: Detection of Anomaly State Caused by Unexpected Accident using Data of Smart Card for Public Transportation, *2019 IEEE Int'l Conf. on Big Data, Big Data*, pp. 1693–1698 (2019).
- [19] Zhao, G. and Yang, M.: Urban Population Distribution Mapping with Multisource Geospatial Data Based on Zonal Strategy, *ISPRS Int'l J. of Geo-Information*, Vol. 9, No. 11 (2020).
- [20] Zong, Z., Feng, J., Liu, K., Shi, H. and Li, Y.: DeepDPM: Dynamic Population Mapping via Deep Neural Network, *Proc. of the Thirty-Third AAAI Conf. on Artificial Intelligence, AAAI*, pp. 1294–1301 (2019).
- [21] 寺田雅之, 川上 博, 岡島一郎, 篠崎俊哉, 坂下昭宏: モバイル空間統計の実用化に向けた取り組み, 情報処理学会デジタルプラクティス, Vol. 6, No. 1, pp. 35–42 (2015).
- [22] 中野 敦, 森尾 淳, 菊池雅彦, 井上 直: 交通関連ビッグデータとパーソントリップ調査の特徴に関する一考察, 第 53 回土木計画学研究発表会・講演集, pp. 2073–2076 (2016).