画像データ源の違いによる道路景観推定精度の比較

渡邊　耕平†　　奥　　健太†

† 龍谷大学理工学部　〒 520-2194 滋賀県大津市瀬田大江町横谷 1-5
E-mail: †t140518@mail.ryukoku.ac.jp, ††okukenta@rins.ryukoku.ac.jp

あらまし　本研究では，景観アウェアドライブルート推薦システムの実現を目指している．景観アウェアドライブルート推薦システムは，景観を重視したドライブルートを推薦するシステムである．例えば，海沿い景観が好きなユーザには海沿い景観を優先したドライブルートを，田園景観が好きなユーザには，田園景観を優先したドライブルートを推薦する．このような推薦システムを実現するためには，事前に道路ネットワークデータに対し，山道景観や海沿い景観，田園景観などといった景観タグを付与しておく必要がある．先行研究 [1] では JAXA が公開している土地被覆図を入力とし，決定木による景観タグ付与手法を提案してきたが，他のデータを入力したときに比較評価は行っていない．本研究では，土地被覆図の他に，航空写真およびストリートビュー画像を学習データとして用い，景観推定精度の比較を行う．なお，学習手法としては畳み込みニューラルネットワークを用いた．

キーワード　景観推定，土地被覆図，航空写真，ストリートビュー，畳み込みニューラルネットワーク

1. はじめに

自動車は単なる移動手段だけでなく，ドライブすること自体が娯楽の一つとなっている．ドライブの楽しみ方の一つとして，海沿い風景や田園風景など好きな風景を眺めながら走りたいという要求もある．このような要求においては，必ずしも最短ルートなど効率性を重視したルートを提示することが最適解であるとは限らず，多少迂回してでもユーザの要求に合うルートを提示することが求められる．

ルート推薦システムは，出発地と目的地を指定すると，その間のルートを提示する．既存のルート推薦システムは，最短ルートや最速ルート，人気ルートを推薦するものが多い [2] [3]．ここで，先述のように，最短ルートや最速ルートは必ずしも先の要求を満たすとは限らない．人気ルート推薦は，多くの人々が関心をもっているルートを推薦する手法である．Wei ら [3] は，ユーザの軌跡データから多くのユーザが関心をもつ道路リンクをマイニングすることで，人気ルートの抽出を行っている．このような推薦システムは集合知に基づき道路リンクの魅力を定義しているが，その道路リンクがどのような特徴を有するか内容に踏み込んだ解析はなされていない．

本研究では，道路リンクの特徴の一つとして景観特徴に着目しており，景観を重視したルートを推薦する景観アウェアドライブルート推薦システムの実現を目指している．例えば，海沿い景観が好きなユーザには海沿い景観を優先したドライブルートを，田園景観が好きなユーザには，田園景観を優先したドライブルートを推薦する．このような景観アウェアドライブルート推薦システムを実現するためには，事前に道路リンクに対し，道路景観タグを付与しておく必要がある．

我々は，これまでに道路地図や航空写真，土地被覆図 (注1) を用いた景観推定手法を提案してきた [4] [1]．先行研究 [1] では，土地被覆図解析に基づき道路景観を推定し，道路リンクに対し景観タグを自動的に付与する手法を提案した．道路リンク周辺の土地被覆図の色分布を基に，道路リンクを特徴ベクトル化しておく．併せて，無作為に抽出した道路リンクに対し，あらかじめ人手により景観ラベルを付与しておく．これを正解データとし，機械学習手法を用いて学習モデルを生成する．先行研究 [1] では，機械学習手法として決定木を用いた．テストデータを用いた評価実験により景観推定精度が 0.700 であることを示した．ただし，先行研究 [1] では，他のデータを入力としたときの精度との比較は行えていない．

本研究では，土地被覆図に加え，航空写真およびストリートビュー画像を入力画像としたとき，画像データ源の違いによる景観推定精度の比較を行う．また，機械学習手法として，画像識別において精度向上が期待できる畳み込みニューラルネットワークを採用する．比較を行った結果，土地被覆図を入力画像としたときの推定精度が最も高いことを示した．

(注1)：http://www.eorc.jaxa.jp/ALOS/lulc/jlulc_jpn.htm

2. 関連研究

2.1 ルート推薦システム

最短経路探索アルゴリズムとして，ダイクストラ法 [5] や A* アルゴリズム [6] が挙げられる．これらのアルゴリズムでは，入力された始点と終点において，道路ネットワーク上のリンクに付与されたコストに基づき，総コストが最小となるような経路を選択する．

最速経路探索 [2] は，リンクの距離ではなく，リンクを通過するための旅行時間に着目し，旅行時間が最小となるような経路を選択する．Wei ら [2] は，GPS の軌跡データから速度パターンをマイニングすることで旅行時間を推定している．

人気経路推薦は，多くの人々が関心をもっているルートを推薦する手法である．Wei ら [3] は，ユーザの軌跡データから多くのユーザが関心をもつルートをマイニングすることで，人気ルートの抽出を行っている．

個人の嗜好に応じたルートを推薦する，個人化ルート推薦の研究もある．MyRoute [7] は，ユーザが熟知しているルートやランドマークに基づき，ユーザ個人向けのルートを作成している．MyRoute では，ランドマークをユーザ自身で入力する必要があるのに対し，Going My Way [8] では，ユーザの個人的な GPS ログデータから，ランドマークを自動的に特定している．

以上のようにこれまでに多くのルート推薦手法が提案されているが，我々の調査した限りでは，ドライブ風景を考慮したルート推薦手法は少ない．ドライブ風景を考慮したルート推薦として，Niaraki ら [9] の研究がある．この研究では，オントロジーにより道路属性を定義している．ドライブ風景も属性の一つとして定義されているため，この属性を用いることでドライブ風景を考慮したルート推薦を可能にしている．しかしながら，オントロジーのフレームワークについては詳細に説明されているものの，オントロジーの構築方法については述べられていない．

Oku ら [4] は，風景アウェアルート推薦システムの実現に向けて，対象地点の道路地図画像および航空写真の画像特徴量から自動的にドライブ風景を推定する手法を提案した．本研究では，道路地図および航空写真の画像の代わりに土地被覆図を用いることで，ドライブ風景の推定精度向上を目指している．

2.2 OpenStreetMap

OpenStreetMap (OSM) (注2)は，フリーの地理情報データを作成することを目的としたプロジェクトである．道路地図などの地理情報データを誰でも利用でき編集できる．OSM の道路データは，道路ネットワークデータの形式で提供されている．つまり，ノードとリンクの形式となっている．OSM のデータは，OpenStreetMap Data Extracts (http://download.geofabrik.de/) からダウンロードできる．全世界のデータが公開されているが，地域別にダウンロードできるようになっている．データはシェープファイル（shp）の形式で提供されており，PostgreSQL で取り込むことができる．

2.3 OpenStreetMap データアセスメント

OSM に付与された道路属性の正確性を評価する研究として，Haklay ら [10] の研究および Girres ら [11] の研究が挙げられる．Haklay ら [10] は，イギリスの高精度の地図である Ordnance Survey (OS) と比較することで，OSM に付与された道路属性の正確性を分析している．OSM が開始された 2004 年 8 月以降，London と England を対象にしている．分析の結果，OSM の情報は平均 6m 以内の精度で正確であることを示している．Girres ら [11] は，BD TOPO IGN のデータを正解データとして，フランスの OSM について，その精度を評価している．Geometry Accuracy， Attribute Accuracy， Semantic Accuracy， Completeness などの八つの観点から評価を行っている．これらの OSM データアセスメントに関する研究に対し，本研究では，道路風景の推定を行っており，既存の OSM には付与されていない属性を対象としている．

(注2)：https://www.openstreetmap.org/

3. 問題定義

定義 1：道路ネットワーク． 道路ネットワークは有向グラフ $G = (V, E)$ で表現される．ここで，V は道路ノード集合であり，$E \subseteqq V \times V$ は道路リンク集合である．

定義 2：道路ノード． 道路ノード $v_i \in V$ は交差点や道路の終端を表す．v_i はその地理座標系の位置座標として経度 $v_i.x$ および緯度 $v_i.y$ をもつ．

定義 3：道路リンク． 道路リンク $e_k = (v_i, v_j) \in E$ は，始点ノード v_i から終点ノード v_j へ向かう有向リンクである．本稿では簡略化のため，e_k の始点ノードを $e_k.s$，終点ノードを $e_k.d$ として表す．e_k の位置座標 $(e_k.x, e_k.y)$ は e_k の中点として次式で表す：

$$(e_k.x, e_k.y) = (\frac{e_k.s.x + e_k.d.x}{2}, \frac{e_k.s.y + e_k.d.y}{2}). \quad (1)$$

また，e_k の始点 $e_k.s$ から終点 $e_k.d$ への進行方向 θ（真北方向を 0° とする）を次式で表す：

$$\theta = \begin{cases} 90^\circ & \Delta_x > 0 \text{ かつ} \\ & \Delta_y = 0 \text{ のとき} \\ 270^\circ & \Delta_x < 0 \text{ かつ} \\ & \Delta_y = 0 \text{ のとき} \\ 180^\circ + \frac{180^\circ}{\pi} \arctan \frac{\Delta_x}{\Delta_y} & \Delta_y < 0 \text{ のとき} \\ \frac{180^\circ}{\pi} \arctan \frac{\Delta_x}{\Delta_y} & \text{それ以外のとき} \end{cases}, \quad (2)$$

ただし，$(\Delta_x, \Delta_y) = (e_k.d.x - e_k.s.x, e_k.d.y - e_k.s.y)$.

さらに，逆方向 θ' を次式で表す：

$$\theta' = \begin{cases} \theta + 180^\circ & \theta < 180^\circ \text{ のとき} \\ \theta - 180^\circ & \theta \geqq 180^\circ \text{ のとき} \end{cases}, \quad (3)$$

定義 4：景観ラベル． 景観ラベルとして $S = \{rural, mountain, water, urban\}$ の 4 種類のラベルを定義する．各要素は，順に田園系，山林系，水辺系，都市系に対応する．なお，これら 4 種類のラベルは先行研究 [1] の予備実験により定義されたものである．

本研究で取り組む課題は，与えられた道路リンク e_k について，その道路リンクから見える景観ラベル $s_i \in S$ を推定することである．

4. 入力画像データの取得および拡張

与えられた道路リンク e_k における土地被覆図，航空写真，ストリートビュー画像を取得する．ここでは，各画像データの取得方法とデータ拡張を説明する．

4.1 土地被覆図の取得

先行研究 [1] にしたがって，道路リンク e_k 周辺の土地被覆図を取得する．まず，地理座標系における位置座標 (x, y) から土地被覆図上の座標 (x', y') へのマッピングする．得られた (x', y') 周辺の土地被覆図画像を道路リンク e_k の画像データとする．具体的な手順は以下のとおりである：

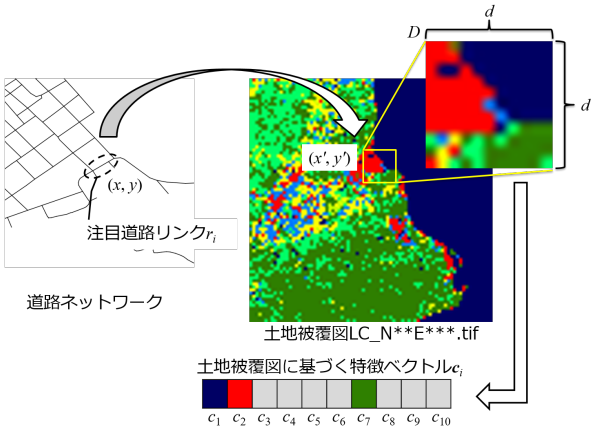

図 1　道路リンクから周辺領域の取得

(1)　(x, y) を含む土地被覆図の画像ファイルを選択する．土地被覆図の画像データセットには，経度 1°，緯度 1° ごとに画像ファイル（TIF 形式）が分割されて保存されている．対象の経度・緯度ごとに “LC_N**E***.tif” というファイル名で保存されている．例えば，経度 134°，緯度 34° に対応する画像ファイルは “LC_N34E134.tif” となる．したがって，位置座標 (x, y) が含まれる画像ファイル名は次式で求められる：

$$\text{LC_N} \ \& \ \lfloor x \rfloor \ \& \ \text{E} \ \& \ \lfloor y \rfloor \ \& \ \text{.tif}. \qquad (4)$$

ここで，$\lfloor x \rfloor$ は床関数であり，実数 x 以下の最大の整数を表す．また，& は文字列の連結を表す．

(2)　選択した画像ファイルにおける位置座標 (x, y) に対応する座標 (x', y') を求める．土地被覆図の一つの画像ファイルは，経度 1° × 緯度 1° の範囲が 3000pixel × 3600pixel のサイズで表されている．したがって，位置座標 (x, y) に対応する座標 (x', y') は次式で求められる．

$$(x', y') = ((x - \lfloor x \rfloor) \times 3000, (y - \lfloor y \rfloor) \times 3600). \qquad (5)$$

(3)　座標 (x', y') を中心とした $d \times d$ の矩形領域 D を設定する．

(4)　領域 D 内に含まれる画像を道路リンク e_k の画像データとする．

4.2　航空写真の取得

先行研究 [1] にしたがって，道路リンク e_k 周辺の航空写真を取得する．ここでは，Google Static Maps API(注3) を用いて，道路リンクの位置座標 $(e_k.x, e_k.y)$ を中心とした航空写真を取得する．具体的には，API のパラメタとして下記を指定する：

```
{center: e_k.x, e_k.y, zoom: z, size: 224x224,
    scale: 1, format: JPEG, maptype:
    satellite}
```

得られた JPEG 画像を道路リンク e_k の画像データとする．本研究ではズームレベル z ごとの識別精度の比較も行う．取得するズームレベルの範囲は $13 \leqq z \leqq 21$ とした．

(a) データ拡張前　　(b) データ拡張後

図 2　データ拡張により得られた画像データ例．(a) はデータ拡張前のストリートビュー画像である．(a) の画像を回転および反転することで，(b) のようにデータ拡張を行っている．

4.3　ストリートビュー画像の取得

Google Street View Image API(注4) を用いて道路リンク e_k のストリートビュー画像を取得する．ここでは，道路リンクの位置座標 $(e_k.x, e_k.y)$ および進行方向 θ を API に指定することで，その位置座標から進行方向のストリートビュー画像を取得する．具体的には，API のパラメタとして下記を指定する：

```
{pitch: 0, size: 450x450, location:
    e_k.x, e_k.y, heading: θ}
```

また，同様に逆方向 θ' のストリートビュー画像も取得する．得られた 2 枚の JPEG 画像を道路リンク e_k の画像データとする．

4.4　画像データの拡張

景観ラベルごとの画像データ数を均等にするため，Keras の `ImageDataGenerator` を用いてデータの拡張を行う．`ImageDataGenerator` には下記のパラメタを与える：

- `rotation_range` $= [-20, 20]$
- `width_shift_range` $= [-0.1, 0.1]$
- `horizontal_flip` $=$ `True`

`rotation_range` は回転角度の許容範囲で，今回は $-20°$ から $20°$ までの回転角度とした．`width_shift` は水平移動の許容範囲で，今回は -10%から $+10\%$ までの水平移動とした．`horizontal_flip` は水平反転のフラグで，今回は水平反転あり（`True`）とした。また，画像データに対して，最低 1 枚はデータ拡張するように調整した．

データ拡張により得られた画像データの例を図 2 に示す．図 2 の (a) はデータ拡張前のストリートビュー画像である．(a) の画像を回転および反転することで，(b) のようにデータ拡張を行っている．

5.　畳み込みニューラルネットワークによる景観ラベル推定

本研究では，画像認識の推定に優れている畳み込みニューラルネットワーク（以降，CNN）を用いて景観ラベルの推定を行う．本研究で用いる CNN の構造を図 3 に示す．図 3 に示すとおり，畳み込み層 6 層，全結合層 3 層の 9 層で構成されている．畳み込み層のフィルターのサイズは 3×3 としている．プーリング層のプーリング領域のサイズは 2×2 とし，MaxPooling を用

(注3)：https://developers.google.com/maps/documentation/static-maps/?hl=ja
(注4)：https://developers.google.com/maps/documentation/streetview/?hl=ja

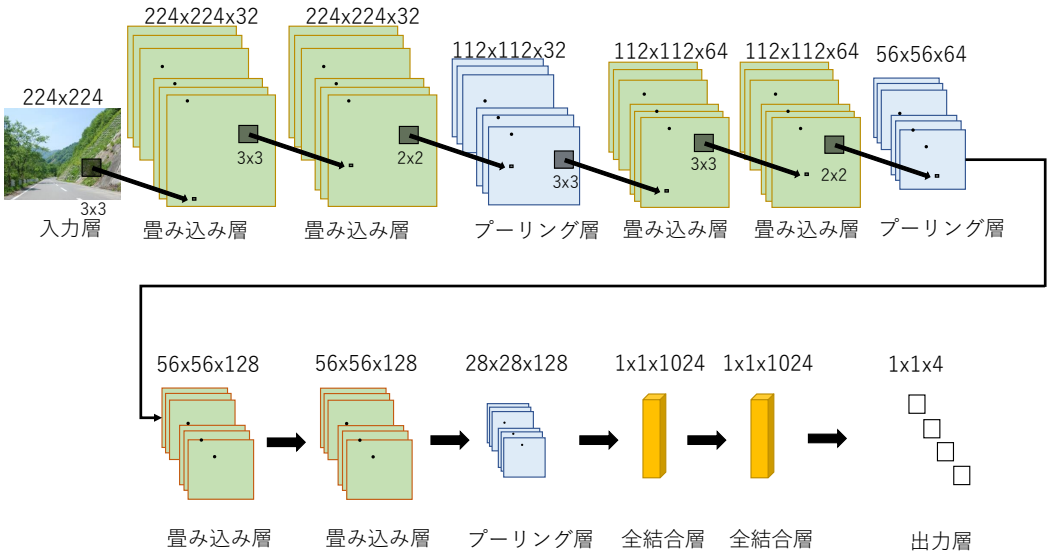

図 3　本研究で用いた畳み込みニューラルネットワークの構造．畳み込み層 6 層，全結合層 3 層の 9 層で構成されている．

表 1　実験に用いた道路リンク数．(a) 景観ラベル別の景観ラベルを付与した延べ道路リンク数．(b) ストリートビュー画像の取得に成功した道路リンク数．(c) データ拡張後の景観ラベル別の画像データ数．(d) 学習データ数．(e) テストデータ数．

	田園系	山林系	水辺系	都市系	合計
(a)	938	889	118	294	2,239
(b)	628	525	90	255	1,498
(c)	1,256	1,256	1,256	1,256	5,024
(d)	628	628	628	628	2,512
(e)	628	628	628	628	2,512

いている．活性化関数には ReLU を用い，出力層には Softmax を用いる．出力層のユニット数は，景観ラベル数に合わせ 4 としている．

この CNN に画像データおよび教師ラベルを入力し学習モデルを構築する．得られた学習モデルに対し，推定対象の画像データを入力することで景観ラベルを推定する．

6.　景観ラベル推定精度の比較

入力画像データとして土地被覆図，航空写真，ストリートビュー画像を与えたとき，CNN による景観推定精度を比較する．

6.1　データセット

実験用データセットとして淡路島の道路ネットワークデータを用いる．OpenStreetMap の道路ネットワークデータから淡路島の領域内のみのデータを抽出した．抽出した道路ノード数は 102,506 件，道路リンク数は 106,025 件である．

この道路リンクから無作為に 2,000 件の道路リンクを抽出し，教師ラベルとして景観ラベルを付与した．景観ラベルはクラウドソーシングにより付与した．ワーカに道路リンクに対応するストリートビュー画像を提示し，相応しいと思われる景観ラベルとして「田園系」,「山林系」,「水辺系」,「都市系」,「その他」の中から選択してもらった—ワーカには各景観ラベルにどのような景観が含まれるかについて例示している—．なお，ワーカには複数選択を許可している．1 件の道路リンクに対し，3 名のワーカにラベル付けを行ってもらった．このとき，2 名以上のワーカによる回答が一致した景観ラベルをその道路リンクの教師ラベルとして採用した．

景観ラベルが付与された道路リンク数を表 1 の (a) 行に示す．これらの道路リンクに対応する土地被覆図，航空写真，ストリートビュー画像の各画像データを取得した．ただし，ストリートビュー画像に関してはすべての道路リンクに対して取得できるというわけではない．そこで，画像データ源間におけるデータ数を公平にするため，ストリートビュー画像が得られた道路リンクのみを実験対象とする．表 1 の (b) 行にストリートビュー画像の取得に成功した道路リンク数を景観ラベル別に示す．

また，景観ラベル間で画像データ数を均等にするため，4.4 節で述べたデータ拡張によるオーバーサンプリングを行った．データ拡張後の景観ラベル別の画像データ数は表 1 の (c) 行に示すとおりである．

(c) 行に示した画像データをさらに無作為に 2 分割し，学習データとテストデータに分ける．表 1 の (d) および (e) 行に，それぞれ景観ラベルごとの学習データ数およびテストデータ数を示す．本実験では，これら (d) および (e) 行に示した学習データおよびテストデータを用いて評価を行う．

6.2　パラメタ設定

入力画像データのうち，土地被覆図および航空写真を取得する際には，それぞれのパラメタを設定しておく必要がある．本節では，それぞれのパラメタ設定について述べる．

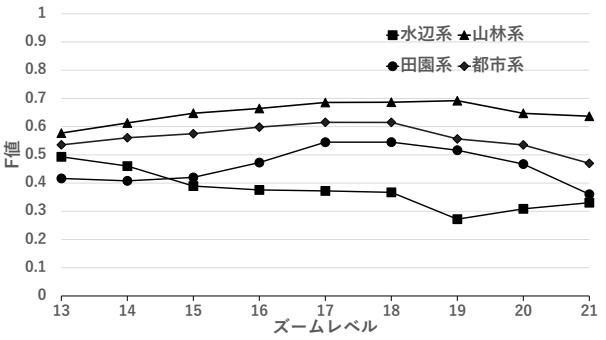

図 4　景観ラベルごとのズームレベルによる F 値の変化．横軸はズームレベルであり，縦軸は F 値を表す．

6.2.1　土地被覆図

4.1 節で述べたとおり，土地被覆図の取得範囲として矩形領域 D のサイズ $d \times d$ を設定する必要がある．本実験では先行研究 [12] にならって $d = 11$ を用いる．なお，先行研究 [1] では，$d = \{5, 7, 10, 20, 30, 40, 50\}$ による道路景観推定精度の変化を分析したところ，$d = 10$ のときに最も高い精度を示した．ただし，本実験においては道路リンクの中点が矩形領域 D の中心になるように設定することが望ましいと考えたため，$d = 11$ を採用した．

6.2.2　航 空 写 真

4.2 節で述べたとおり，航空写真の取得においてはズームレベル z を設定する必要がある．そこで，ズームレベルを $\{13, 14, 15, 16, 17, 18, 19, 20, 21\}$ と変えたとき F 値（後述）の比較を行う．

図 4 は，ズームレベルによる景観ラベルごとの F 値の変化を示したものである．横軸がズームレベルであり，縦軸が F 値である．この結果から平均的にはズームレベル 17 のときに F 値が最大となった．したがって，航空写真の取得においてはズームレベル 17 を採用する．

6.3　画像データ源ごとの混同行列に基づく分析

表 2 に画像データ源ごとの混合行列を示す．(a) 土地被覆図，(b) 航空写真，(c) ストリートビュー画像をそれぞれデータ源としたときの混同行列である．例えば，(a) において，正解ラベルが rural の画像に対し，rural と予測された数は 396 件，mountain と予測された数は 123 件であることを示す．また，表 2 には，景観ラベルごとの再現率，適合率，F 値を示している．それぞれ次式で算出される：

$$\text{再現率} = \frac{\text{予測ラベル } k \text{ と正解ラベル } k \text{ が一致した数}}{\text{正解ラベル } k \text{ の合計数}}, \quad (6)$$

$$\text{適合率} = \frac{\text{予測ラベル } k \text{ と正解ラベル } k \text{ が一致した数}}{\text{ラベル } k \text{ と予測された合計数}}, \quad (7)$$

$$F \text{ 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}}. \quad (8)$$

さらに，最終列には再現率，適合率，F 値の平均を示している．

まず，画像データ源ごとの平均 F 値に着目する．表 2 より，土地被覆図，航空写真，ストリートビュー画像の平均 F 値はそれぞれ，$0.651, 0.556, 0.541$ であった．この結果のとおり，全体としては土地被覆図を画像データ源としたときの方が景観ラベルの推定精度が最も高かった．航空写真やストリートビュー画像は撮影時の状況によって画質にばらつきがあるのに対し，土地被覆図ではあらかじめ整備されたデータであり画質に一貫性がある．この結果は，我々の先行研究 [1] [12] において，「田園系，山林系，水辺系，都市系といった大まかなレベルの景観推定においては，現状の技術では車載カメラ画像や道路地図，航空写真等の画像に対して画像処理を適用するよりも，土地被覆図を用いた方が安価な計算量で十分な性能の景観推定が可能になる」という主張を支持するものであるといえる．

7. おわりに

本研究では，土地被覆図，航空写真およびストリートビュー画像を入力画像としたとき，画像データ源の違いによる景観推定精度の比較を行った．機械学習手法として，画像識別において精度向上が期待できる畳み込みニューラルネットワークを採用した．比較を行った結果，土地被覆図を入力画像としたときの推定精度 0.651 が最も高いことを示した．

しかしながら，この推定精度 0.651 は，先行研究 [1] で示した，決定木による推定精度 0.700—この値は実験条件が異なるため参考値である—を下回った．今回は，機械学習手法として 9 層の畳み込みニューラルネットワークを用いたが，層の設計についてより検証する必要がある．

謝　　辞

本研究は JSPS 科研費 JP15K12151,JP16HO5932 の助成を受けたものです．ここに記して謝意を表します．

文　　献

[1] 片山大輔, 奥健太, 山西良典．土地被覆図解析に基づく市街地，田園，山間道路風景の自動タグ付け．In *DEIM Forum 2017*, pp. P4–2, 2017.

[2] Ling-yin Wei, Wen-chih Peng, Chun-shuo Lin, and Chen-hen Jung. Exploring Spatio-Temporal Features. In *Advances in Spatial and Temporal Databases, Lecture Notes in Computer Science*, pp. 399–404, 2009.

[3] Ling-yin Wei, Wen-chih Peng, Bo-chong Chen, and Ting-wei Lin. Eleventh International Conference on Mobile Data Management PATS : A Framework of Pattern-Aware Trajectory Search. In *[MDM2010]Mobile Data Management*, pp. 362–377, 2010.

[4] Kenta Oku, Ryosuke Yamanishi, Kohei Matsumura, and Kyoji Kawagoe. Drive scenery estimation using image features extracted from roadmap and satellite images. In *ISIS2015: Proceedings of the 16th International Symposium on Advanced Intelligent Systems*, pp. 1575–1589, 2015.

[5] Edsger Wybe Dijkstra. A Note on Two Problems in Connexion with Graphs. *Numerische Mathematik*, Vol. 1, pp. 269–271, 1959.

[6] Rina Dechter and Judea Pearl. Generalized best-first search strategies and the optimality af A*. *Journal of the ACM*, Vol. 32, No. 3, pp. 505–536, jul 1985.

[7] Kayur Patel, Mike Y. Chen, Ian Smith, and James A Landay. Personalizing Routes. In *UIST 2006: Proceedings of the 19th annual ACM symposium on User interface software and technology*, pp. 187–190, 2006.

[8] Jaewoo Chung and Chris Schmandt. Going My Way : A User-aware Route Planner. In *[CHI2009]Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 1899–1902, 2009.

表 2　画像データ源ごとの混同行列．(a) 土地被覆図，(b) 航空写真，(c) ストリートビュー画像をそれぞれデータ源としたときの混同行列を示す．各表の下段には景観ラベルごとの再現率，適合率，F 値を示している．

		予測ラベル				計
		rural	mountain	water	urban	
正解ラベル	rural	396	123	22	87	628
	mountain	101	454	52	21	628
	water	60	79	384	105	628
	urban	123	39	66	400	628
計		680	695	524	613	2,512
再現率		0.631	0.723	0.611	0.637	0.650
適合率		0.582	0.653	0.733	0.653	0.655
F 値		0.606	0.686	0.667	0.645	0.651

(a) 土地被覆図.

		予測ラベル				計
		rural	mountain	water	urban	
正解ラベル	rural	341	84	75	128	628
	mountain	96	457	59	16	628
	water	120	130	190	188	628
	urban	84	12	94	438	628
計		641	683	418	770	5,024
再現率		0.543	0.728	0.303	0.697	0.568
適合率		0.532	0.669	0.455	0.569	0.556
F 値		0.537	0.697	0.363	0.627	0.556

(b) 航空写真.

		予測ラベル				計
		rural	mountain	water	urban	
正解ラベル	rural	310	126	91	101	628
	mountain	112	420	48	48	628
	water	79	85	291	173	628
	urban	73	73	138	344	628
計		574	704	568	666	2,512
再現率		0.494	0.669	0.463	0.548	0.543
適合率		0.540	0.597	0.512	0.517	0.541
F 値		0.516	0.631	0.487	0.532	0.541

(c) ストリートビュー画像.

[9] Abolghasem Sadeghi Niaraki and Kyehyun Kim. Ontology based personalized route planning system using a multi-criteria decision making approach. *Expert Systems with Applications*, Vol. 36, No. 2, pp. 2250–2259, mar 2009.

[10] Mordechai Haklay. How good is volunteered geographical information ? A comparative study of OpenStreetMap and Ordnance Survey datasets. *Environment and Planning*, Vol. 37, No. 4, pp. 682–703, 2010.

[11] Jean-Francois Girres and Guillaume Touya. Quality Assessment of the French OpenStreetMap Dataset. *Transactions in GIS*, Vol. 14, No. 4, pp. 435–459, 2010.

[12] 奥健太, 山西良典. 土地被覆図からの景観要素抽出に基づく道路リンクの景観ベクトル化. 情報処理学会研究報告, 第 2017-DBS-1 巻, pp. 1–6, 2017.