

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

奥 健太^{1,a)} 山西 良典²

概要: 我々は景観を考慮したルート推薦システムの実現を目指し、道路リンクの景観を自動推定する研究課題に取り組んでいる。我々のこれまでの研究では、景観推定をクラス分類問題として扱い、道路リンクを田園景観、山間景観、都市景観のいずれかのクラスに割り当てる手法を提案してきた。しかし、景観には例えば田園景観の要素と山間景観の要素それぞれがいくらかの比率で含まれるなど、クラス分類では適切な推定が難しいと考えた。そこで、まず予備実験により、景観要素として田園系、山林系、水系、都市系の四つの要素を選定し、これら4要素から構成される景観ベクトルを定義する。つづいて、各景観要素をクラスとみなしたとき、クラス分類問題をクラス確率推定問題に置き換え、与えられた道路リンクについて要素ごとのクラス確率を推定する。推定されたクラス確率を基に道路リンクの景観ベクトルを作成する。なお、本研究では JAXA が公開している土地被覆図の色分布を基に道路リンクの特徴量を抽出する。また、教師ラベルは事前に人手により付与された道路リンクごとの景観ラベルを用いる。淡路島の道路ネットワークを対象に 106,025 件の道路リンクに対し景観ベクトルを作成した。また、航空写真および Google ストリートビューとの比較による定性評価により、本手法による景観ベクトル化手法の妥当性を検証した。

1. はじめに

我々は、道路景観を重視したルートを推薦する景観ウェアドライブルート推薦システム [1] の実現を目指している。このようなルート推薦システムを実現するためには、事前に道路リンクを景観に基づき特徴化しておく必要がある。

我々はこれまでに、JAXA が公開している土地被覆図^{*1}を基に道路リンクの景観を推定する手法 [2] を提案してきた。土地被覆図は、都市、水田、落葉樹など日本全域の土地被覆分類を高精度に算出し、分類ごとに色分けした図である。本研究では後述するように田園系、山林系、水系、都市系といった大まかなレベルでの景観推定を目指している。このようなレベルでの景観推定では、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考えている。

これまでの研究では、景観推定をクラス分類問題として扱い、道路リンクを田園景観、山間景観、都市景観のい

ずれかのクラスに割り当てる手法を提案してきた。しかし、景観には例えば田園景観の要素と山間景観の要素それぞれがいくらかの比率で含まれるなど、クラス分類では適切な推定が難しいと考えた。

本研究では、景観要素として田園系、山林系、水系、都市系の四つの要素を選定し、これら4要素から構成される景観ベクトルを定義し、道路リンクの景観ベクトルを推定する手法を提案する。各景観要素をクラスとみなしたとき、クラス分類問題をクラス確率推定問題に置き換え、与えられた道路リンクについて要素ごとのクラス確率を推定する。推定されたクラス確率を基に道路リンクの景観ベクトルを作成する。

淡路島の道路ネットワークを対象に 106,025 件の道路リンクに対し景観ベクトルを推定した。この推定された景観ベクトルの妥当性を検証するために、景観ベクトルと航空写真および Google ストリートビューとの比較による定性評価を行った。

2. 関連研究

Wei らの最速経路探索 [3] や人気経路推薦 [4]、Patel ら [5] の個人化ルート推薦など、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、ドライブ景観を考慮したルート推薦手法は少ない。ドライブ景観

¹ 龍谷大学
1-5 Yokotani, Seta Oe-cho, Otsu, Shiga, 520-2194, Japan
² 立命館大学
1-1-1 Nojihigashi, Kusatsu-city, Shiga, 525-8577, Japan
^{a)} okukenta@rins.ryukoku.ac.jp
^{*1} http://www.eorc.jaxa.jp/ALOS/lulc/jlulc_jpn.htm

を考慮したルート推薦として, Niaraki ら [6] 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. ドライブ景観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景観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 [1] は, 景観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景観を推定する手法を提案してきた. さらに, 片山ら [2] 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, ドライブ景観の推定精度が向上することを示した. 片山ら [2] の研究では景観推定をクラス分類問題として扱っていたが, 本稿での提案手法ではクラス分類問題をクラス確率推定問題に置き換え, 道路リンクの景観ベクトルを作成することに焦点をあてている.

3. 景観要素の定義

本研究では, 道路景観を構成する基本要素として, 田園系, 山林系, 水系, 都市系の四つの要素を定義する. 本章では, これらを基本要素と定義するに至った過程について述べる. 以下はその過程である.

1) OpenStreetMap^{*2}から日本全国の道路ネットワークデータを取得する. 道路ネットワークデータに含まれる道路リンクには道路種別を表す `type` 属性が与えられている. 道路種別には歩行者向け道路や自転車向け道路なども含まれる. 本研究では自動車向け道路に限定するため, ここでは `type` 属性が `{'unclassified', 'residential', 'tertiary', 'secondary', 'primary', 'trunk', 'motorway', 'motorway_link', 'living_street', 'road', 'trunk_link', 'primary_link', 'tertiary_link', 'secondary_link'}` のいずれかに該当する道路リンクのみを選択する. 結果, 5,798,941 件の道路リンクが選択された.

2) 日本全国の道路リンクからランダムに 2,000 件の道路リンクを抽出する.

3) 抽出した道路リンクについてクラウドソーシングにより景観ラベルを付与する. 景観ラベルとして表 1 に示す 28 個のラベルを用意した. これらの景観ラベルは著者がドライブレコーダにより独自に収集した走行動画からボトムアップに洗い出したものである.

ワーカには道路リンクに対応する Google ストリートビューの画像を提示する. ワーカはその画像を表す景観として相応しいと思う景観ラベルを 28 個のラベルの中から

選択する. 複数の景観に該当すると判断した場合は複数の景観ラベルを選択できる. 選択肢に該当する景観が見当たらない場合は「その他」を選択し, 「XX 景観」の形式で任意の景観の呼称を記入できる. またストリートビューの画像が正常に表示されない場合は「画像が表示されない」のみを選択するように指示している.

1 件の道路リンクあたり 3 名のワーカにラベルを付与してもらった. 重複を含め有効に付与されたラベル数は 7,838 件 — 「その他」は含まれるが, 「画像が表示されない」は含まれない — であった.

4) 28 個の景観ラベルの中から有効な景観ラベルを絞り込む. ここでは, ほとんどの道路リンクにおいて選択されないような低頻度の景観ラベルを除外する.

まず 3 名のワーカがすべて同一の景観ラベルを付与した道路リンクを抽出する. 同一の景観ラベルが付与された道路リンク数は 635 件であった. このうち, 1%未満 (すなわち 6.3 件未満) の景観ラベルについては低頻度景観として以降の処理では除外する. 結果として, 表 1 中で (*) を付与した 12 個の景観ラベルに絞り込んだ.

5) 12 個の景観ラベルをさらに景観ラベル同士の共起性に基づき絞り込む. 例えば, 山間景観と山道景観は意味的にも類似しており, 同一の道路リンクに共起して付与されることが多い. これらのような共起性の高い景観は一つにまとめられるべきであると考えられる.

まず景観ラベル間の類似度を算出する. 各景観ラベルは, そのラベルが付与された道路リンクを要素にもつ集合とみなすことができる. そこで二つの集合の類似度を測る尺度としてジャッカール係数を用いる. 景観ラベルを道路リンクを要素にもつ集合とみなすと, 二つの景観ラベル S_i と S_j の類似度 $\text{sim}(S_i, S_j)$ は, ジャッカール係数を用いて次式で表される.

$$\text{sim}(S_i, S_j) = \frac{|S_i \cap S_j|}{|S_i \cup S_j|}. \quad (1)$$

つづいて次式により任意の二つの景観ラベル間の非類似度を算出する.

$$\text{dis}(S_i, S_j) = 1 - \text{sim}(S_i, S_j). \quad (2)$$

さらに $\text{dis}(S_i, S_j)$ を i 行 j 列目の要素とした非類似度行列 D を作成する.

6) 非類似度行列 D の固有ベクトルを固有値が小さいものから順に 2 個 (v_1 および v_2 とする) 求める. 景観ラベル S_i を 2 次元特徴ベクトル (v_{1i}, v_{2i}) で表す. ここで, v_{1i} はベクトル v_1 の i 番目の要素, v_{2i} はベクトル v_2 の i 番目の要素である.

7) 12 個の景観ラベルを 2 次元特徴空間上に配置する. 図 1 は 2 次元特徴空間における 12 個の景観ラベルの分布を示したものである. 図 1 から大きく五つのクラスタに分

*2 <http://download.geofabrik.de/>

表 1 予備実験において初期に用意した景観ラベル。これらのラベルは著者がドライブレコーダにより独自に収集した走行動画からボトムアップに洗い出した。「(*)」が付いている景観ラベルは出現頻度に基づき絞り込まれた景観ラベルである。

景観	landscape	景観	landscape	景観	landscape	景観	landscape
田園景観 (*)	paddy	岩壁景観	rock	湖景観	lake	旧街道景観	oldhighway
農道景観 (*)	agricultural	峠道景観	notch	池景観	pond	住宅街景観 (*)	residential
草原景観	grassland	森林景観	forest	沼景観	marsh	農村景観 (*)	rural
丘陵景観	hill	林道景観 (*)	woodland	市街地景観 (*)	urban	田舎景観 (*)	country
山麓景観	foothill	並木道景観	avenue	郊外景観 (*)	suburb	高架下景観	girder
山道景観 (*)	mountainpath	海岸景観 (*)	seaside	工業地帯景観	industrial	橋梁景観	bridge
山間景観 (*)	mountain	河川景観 (*)	river	開発地域景観	development	トンネル景観	tunnel




図 1 2次元特徴空間上の景観ラベルの分布。横軸は第1軸を、縦軸は第2軸を表す。特徴空間上での近傍性に基づく12個の景観ラベルは山林系、水系、都市系、郊外系、田園系にまとめられる。

類されることがわかる。例えば、山道景観、山間景観、森林景観は共起頻度が高いため特徴空間上で互いに近傍に配置される。そこで、山道景観、山間景観、森林景観をまとめて山林系とする。他の景観ラベルも同様に、水系、都市系、郊外系、田園系にそれぞれまとめられる。

このうち郊外系については都市系と田園系の間接的な要素であることが、特徴空間上からも経験則からもわかる。そのため郊外系については都市系と田園系を成分として表現する。一方で、水系についても特徴空間上では都市系と山林系の中間に位置するが、経験則からは都市系と山林系を成分として水系を表現できるとはいえない。以上の観測に基づき、田園系、山林系、水系、都市系の四つの要素を道路景観の基本要素として扱う。

4. 道路リンクの景観ベクトル化

本章では道路リンクの景観ベクトル化手法を提案する。なお、本章で説明する景観ベクトル化手法は、我々の先行研究である景観タグ付与手法 [2] を景観ベクトル化手法に拡張したものである。以下、問題定義を述べたうえで、景観ベクトル化手法について説明する。

4.1 問題定義

まず、道路ネットワークおよび景観ベクトルの定義を示したうえで本研究の問題定義を述べる。

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 $G^R = (V^R, E^R)$ で表現される。ここで、 V^R は道路ノードの集合であり、 E^R は道路リンクの集合である。各道路ノードは地理座標系における位置座標 (経度 x , 緯度 y) をもつ。各道路リンク $r_i \in E^R$ は端点 $r_i.s$ および $r_i.e$ をもつ。ここで、 $r_i.s \in V^R$ は r_i の始点、 $r_i.e \in V^R$ は終点である。

定義 2: 景観ベクトル。 景観ベクトルは、3章で定義した4種類の景観要素 (田園系、山林系、水系、都市系) から構成される4次元の確率ベクトルとして定義される。道路リンク r_i の景観ベクトルを $\mathbf{s}_i = (s_{i1}, s_{i2}, s_{i3}, s_{i4})$ で表す。ベクトルの各要素はその景観要素が含まれる確率を表す。したがって、 $\sum_j s_{ij} = 1$ となる。

本研究で扱う問題は、与えられた道路リンク $r_i \in E^R$ について景観ベクトル \mathbf{s}_i を推定することになる。この問題は、景観要素をクラスとみなしたとき、与えられた道路リンクが各クラスに所属する確率 (クラス確率) を推定する問題に帰着される。

4.2 道路リンクの特徴化

提案手法ではクラス分類器を用いて与えられた道路リンクのクラス確率を推定する。クラス分類器を本問題に適用するためには、道路リンクの特徴量および教師ラベル (景観要素) が必要となる。本節では道路リンクの特徴量について述べる。

先行研究 [2] では、土地被覆図に基づき道路リンクの特徴化を行っている。本研究においても同様のアプローチを採用する。まず、土地被覆図について説明し、土地被覆図に基づく道路リンクの特徴化について述べる。

4.2.1 土地被覆図

宇宙航空研究開発機構地球観測研究センター (JAXA EORC) では、ALOS/AVNIR-2 高解像度土地利用土地被覆図を公開している*3。土地被覆図は、日本全域の土地被覆分類を算出したものである。

土地被覆図は、図 2 のように TIFF 形式の画像ファイルで提供されている。画像ファイルは、経度 1° 、緯度 1° ごとに分割して保存されている。対象の経度・緯度ごとに

*3 http://www.eorc.jaxa.jp/ALOS/lulc/jlulc_jpn.htm

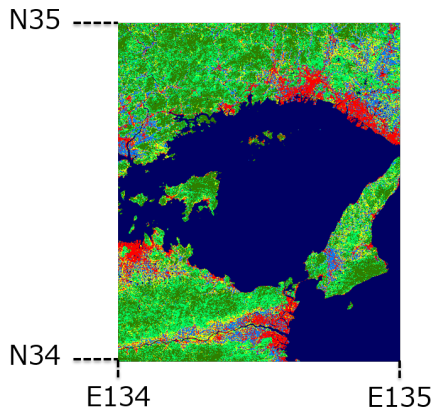


図 2 淡路島が含まれる経度 134°, 緯度 34° の土地被覆図 (LC_N34E134.tif).

コード	カテゴリ	RGB値	色
1	水域 (Water)	(0, 0, 100)	青
2	都市 (Urban)	(255, 0, 0)	赤
3	水田 (Paddy)	(0, 128, 255)	青緑
4	畑地 (Crop)	(255, 255, 0)	黄緑
5	草地 (Grass)	(199, 255, 0)	黄
6	落葉樹 (Deciduous forest)	(0, 255, 101)	緑
8	常緑樹 (Evergreen forest)	(47, 128, 0)	黄緑
10	裸地, 砂地 (Bare surface)	(130, 99, 0)	黄
11	雪氷 (Snow and ice)	(255, 255, 255)	白
-	その他 (other)	(0, 0, 0)	黒

図 3 土地被覆図の土地被覆分類カテゴリ。カテゴリに応じて色分けされている。RGB 値は赤, 緑, 青の順に 0-255 の範囲で表現される。

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名は LC_N34E134.tif となる。図 2 は, 例として淡路島が含まれる経度 134°, 緯度 34° の土地被覆図 (LC_N34E134.tif) を示している。

土地被覆図は土地被覆分類カテゴリに応じて色分けされている。図 3 は, 土地被覆分類カテゴリおよび対応する色 (RGB 値) を示している。図 3 に示すとおり, 土地被覆分類カテゴリとして 10 種類のカテゴリが定義されている。

4.2.2 土地被覆図に基づく道路リンクの特徴化

図 4 に土地被覆図に基づく道路リンクの特徴化の過程を図示する。以下, 道路リンクの特徴化について説明する。

4.2.2.1 地理座標系における位置座標から土地被覆図上の座標へのマッピング

注目する道路リンク r_i について, 土地被覆図から特徴量を抽出するためには, 地理座標系における位置座標から土地被覆図上の座標へマッピングする必要がある。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') へのマッピングは次の手順で行う。

- (1) まず, 位置座標 (x, y) を含む土地被覆図の画像ファイルを選択する。前述のとおり, 土地被覆図の画像データセットには, 経度 1°, 緯度 1° ごとに分割されてお

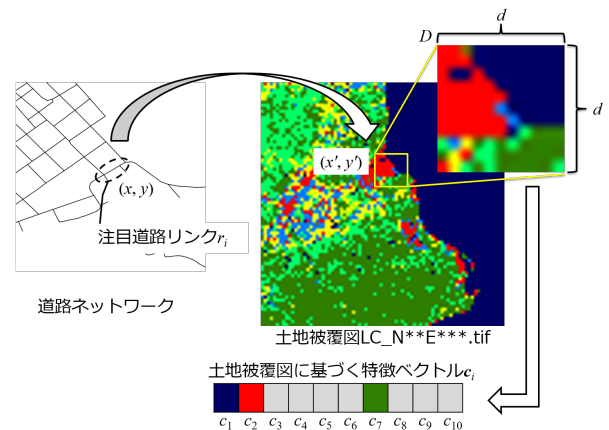


図 4 土地被覆図に基づく道路リンクの特徴化。注目道路リンク r_i の位置座標 (x, y) から土地被覆図上の座標 (x', y') を求める。土地被覆図における座標 (x', y') 周辺の色分布から道路リンクの特徴ベクトル c_i を算出する。

り, LC_N34E134.tif というようなファイル名で保存されている。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。

$$LC_N \& [x] \& E \& [y] \& .tif. \quad (3)$$

ここで, $[x]$ 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) つづいて, 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 3,000pixel × 3,600pixel 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。

$$x' = (x - [x]) \times 3000, \quad (4)$$

$$y' = 3600 - (y - [y]) \times 3600. \quad (5)$$

4.2.2.2 カテゴリ分布に基づく道路リンクの特徴化

土地被覆図上の座標 (x', y') の周辺に分布するカテゴリに基づき, 道路リンク r_i を特徴化する。以下, その手順について説明する。

- (1) 座標 (x', y') を中心とした, $d \times d$ の矩形領域 D を設定する。
- (2) 領域 D 内に含まれるカテゴリごとのピクセル数を取得する。具体的には, 各カテゴリが図 3 に示す RGB 値で表されているため, 各 RGB 値をもつピクセル数を取得する。ここでは, k 番目のカテゴリに対応するピクセル数を c_k とする。
- (3) ピクセル数 c_k を k 番目の要素としたベクトル $(c_1, c_2, \dots, c_{10})$ を作成する。ここで, 土地被覆図で定義されているカテゴリは 10 種類あるので, 10 次元ベクトルが作成される。なお, 表 3 のコードには欠損があるため, コードと k とは一致しない。

- (4) 作成したベクトルについて、ベクトルの要素の和が1となるように正規化する。つまり、次式で正規化する。

$$\mathbf{c} = \frac{1}{d^2} (c_1, c_2, \dots, c_{10}). \quad (6)$$

以上の手順で得られた \mathbf{c} が対象道路リンクの特徴ベクトルとなり、これが道路リンクの特徴量である。

4.3 教師ラベルの付与

次に道路リンクへの教師ラベルの付与方法について述べる。本研究では、クラウドソーシングにより道路リンクへの教師ラベルの付与を行う。対象道路リンク r_i について、次の手順により教師ラベルの付与を行う。

- (1) 対象道路リンク r_i の始点 $r_{i,s}$ と終点 $r_{i,e}$ から中点 (mx, my) および進行方向 θ (真北方向を 0° とする) を算出する。
- (2) Google Street View Image API^{*4}を用いて、中点 (mx, my) を視点とした進行方向 θ のストリートビュー画像を取得する。
- (3) ワーカに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カテゴリとして「田園系」、「山林系」、「水系」、「都市系」、「その他」の中から選択してもらう。ワーカには各景観カテゴリ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。

対象道路リンク 1 件につき 3 名のワーカに回答してもらう。このとき 2 名以上のワーカによる回答が一致した風景ラベルをその道路リンクの教師ラベルとして採用する。

4.4 景観ベクトル化

最終的にクラス分類手法を用いて、与えられた道路リンクの景観ベクトルを作成する。ここでは、学習フェーズと推定フェーズに分けて説明する。

まず、学習フェーズは下記の手順となる。

- (1) 学習データセットとして、 N 対の道路リンク特徴量および教師ラベルを用意する。つまり、学習データセットとして、 $\{(c_1, s_1), (c_2, s_2), \dots, (c_N, s_N)\}$ を用意する。
- (2) クラス分類手法により、学習データセットに基づき学習モデルを構築する。

つづいて、推定フェーズは下記の手順となる。

- (1) 与えられた道路リンク r_i の特徴ベクトル \mathbf{c}_i を得る。
- (2) 特徴ベクトル \mathbf{c}_i を学習モデルに入力し、各景観要素に対応するクラス確率 $s_{i1}, s_{i2}, s_{i3}, s_{i4}$ を求める。
- (3) 得られたクラス確率を要素としたベクトル $\mathbf{s}_i = (s_{i1}, s_{i2}, s_{i3}, s_{i4})$ を作成する。このベクトル \mathbf{s}_i を道路リンク r_i の景観ベクトルとする。

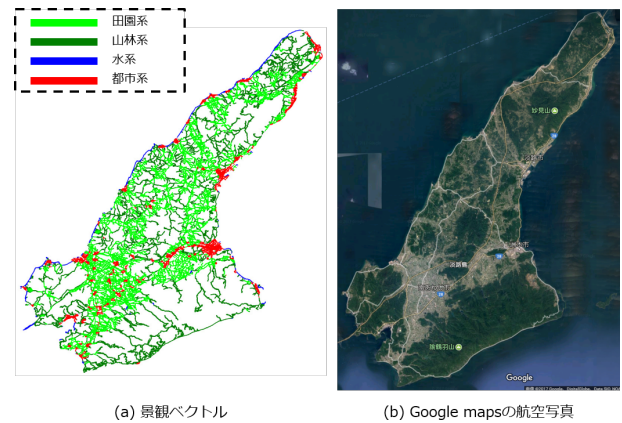


図 5 (a) 淡路島の道路リンクに対し推定された景観ベクトルを可視化したもの。(b) 同地域の Google マップの航空写真。

5. 定性評価

提案手法により推定した景観ベクトルの妥当性を評価するために淡路島の道路ネットワークデータを対象とした定性評価を行った。

5.1 データセット

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。本データセットには 106,025 件の道路リンクが含まれる。このうち、ランダムに 2,000 件の道路リンクを学習データとして抽出した。景観ラベル別のリンク数は、田園系 938 件、山林系 889 件、水系 118 件、都市系 294 件、その他 53 件であった。重複を含め、合計 2,292 件の道路リンクを得た。

5.2 実験パラメタ

4.2.2 項において、土地被覆図上の $d \times d$ の矩形領域 D を設定する必要があることを述べた。本実験では $d = 11$ を用いた。なお、先行研究 [2] 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。

また、4.4 節では、クラス分類手法を用いてクラス確率を推定することを述べた。本実験ではクラス分類手法として、Support Vector Machine (SVM) を用いた。SVM は少ない学習データからでも高精度な結果が得られるという利点がある。SVM は本来は 2 クラス分類手法であり出力値は 2 値となるが、事例と識別平面との距離に着目することにより、推定されたクラスの確信度を判定することができる。この確信度に基づきクラス所属確率を推定することができる [7]。

*4 <https://developers.google.com/maps/documentation/streetview/?hl=ja>



図 6 推定された景観ベクトルと実際の景観との比較. 景観画像は Google ストリートビューから取得した.

5.3 定性評価 1:景観ベクトルと航空写真との比較

図 5(a) は、淡路島の道路リンクに対し推定された景観ベクトルを可視化したものである. 淡緑は田園系, 濃緑は山林系, 青は水系, 赤は都市系をそれぞれ表す. 図には対応する景観要素の値が 0.5 以上の道路リンクを表示している. 一方で, 図 5(b) は, 比較のために同地域の Google マップ*5の航空写真を示したものである.

(a) と (b) を比較しながら, 推定された景観ベクトルの妥当性について検証する.

- 淡路島の大部分は山地と田畑が占めている. (a) においても山林系と田園系が多くを占めていることがわかる.
- (b) において濃緑の領域は山地を表している. これに対応するように (a) においても山林系として推定されている.
- (b) のように山地以外の内陸部はほとんどが田畑である. (a) においても対応する領域が田園系として推定されている.
- 淡路島の中部東側には洲本市がある. (a) において洲本市の領域が都市系として推定されている.
- (a) において海岸線に沿って水系が推定されている.

5.4 定性評価 2:景観ベクトルと実際の景観との比較

景観ベクトルを採用することで, 例えば田園景観の要素と山間景観の要素それぞれがいくらかの比率で含まれるなど, 中間的な景観も表現することができる. このことを評価するため, 推定された景観ベクトルと実際の景観との比較を行った.

図 6 は, 推定された景観ベクトルと実際の景観とを比較したものである. 景観画像は Google ストリートビューから取得した. 左の画像は田園景観を表している. これに対応する道路リンク (link_id = 14175) の景観ベクトルは $c_{14175} = (0.882, 0.023, 0.057, 0.037)$ —順に田園系, 山林系, 水系, 都市系の要素に対応する— と推定されており, 田園系要素が強く現れていることが確認できる. 同様に, 右の画像は山間景観を表している. これに対応する道路リンク (link_id = 98691) の景観ベクトルは $c_{98691} = (0.004, 0.974, 0.019, 0.003)$ と推定されており, 山林系要素が強く現れていることが確認できる. さらに, 中

央の画像は田園要素と山間要素の両方が含まれている. これに対応する道路リンク (link_id = 22778) の景観ベクトルは $c_{22778} = (0.564, 0.401, 0.021, 0.015)$ と推定されている. このように景観ベクトルにおいても田園系要素と山林系要素の両方が含まれるように表現できていることがわかる.

6. まとめ

本研究では, 景観要素として田園系, 山林系, 水系, 都市系の四つの要素を選定し, これら 4 要素から構成される景観ベクトルを定義し, 道路リンクの景観ベクトルを推定する手法を提案した. 淡路島の道路ネットワークを対象に 106,025 件の道路リンクに対し景観ベクトルを推定した. 景観ベクトルと航空写真および Google ストリートビューとの比較による定性評価を行い, 提案手法により推定された景観ベクトルの妥当性を示した. 今後は, 道路リンクの景観ベクトルを用いた景観アウェアルート推薦システムの研究に取り組む.

謝辞

本研究は JSPS 科研費 15K12151 の助成を受けたものです. ここに記して謝意を表します.

参考文献

- [1] Kenta Oku, Ryosuke Yamanishi, Kohei Matsumura, and Kyoji Kawagoe. Drive scenery estimation using image features extracted from roadmap and satellite images. In *Proceedings of the 16th International Symposium on Advanced Intelligent Systems*, pp. 1575–1589, 2015.
- [2] 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, 第 9 回データ工学と情報マネジメントに関するフォーラム論文集 (DEIM 2017) (Web), pp.P4-2, 2017.
- [3] 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.
- [4] 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 *Mobile Data Management*, pp. 362–377, 2010.
- [5] Kayur Patel, Mike Y. Chen, Ian Smith, and James A Landay. Personalizing Routes. In *Proceedings of the 19th annual ACM symposium on User interface software and technology*, pp. 187–190, 2006.
- [6] 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.
- [7] 高橋 和子. 多クラス SVM におけるクラス所属確率を用いたアンサンブル学習の提案. 研究報告音声言語情報処理 (SLP), 2011-SLP-86(2), pp.1–8, 2011.

*5 <https://www.google.co.jp/maps>