

道路地図および航空写真の特徴量を用いたドライブ風景の推定

奥 健太^{†,a} 山西 良典^{†,b} 松村 耕平^{†,c} 川越 恭二^{†,d}

[†] 立命館大学情報理工学部

a) oku@fc.ritsumei.ac.jp b) ryama@media.ritsumei.ac.jp

c) matsumur@media.ritsumei.ac.jp d) kawagoe@is.ritsumei.ac.jp

概要 我々は、ドライブ風景を考慮した経路推薦システムの実現を目指している。そのためには、道路ネットワークを構成するリンクに対し、山道風景や海沿い風景、田園風景などといったドライブ風景タグを付与する必要がある。既存の道路ネットワークデータとしては、市販のものや OpenStreetMap などがあるが、ドライブ風景タグが付与されたものは見当たらない。また、ドライブレコーダで記録された車載カメラの画像からドライブ風景を推定する方法も考えられるが、カメラ角度の微妙なずれや明るさの変化などによりノイズが多く、データの網羅性も低い。そこで、本稿では、Web から網羅的に収集が可能な道路地図画像および航空写真に着目し、ドライブ風景を推定するために有効な画像特徴量について明らかにする。具体的には、収集したドライブレコーダデータを分析し、ドライブ風景の推定に有効と考えられる画像特徴量について仮説を立案し検証した。また、有効と判断された特徴量を含めた学習モデルを構築し、テストデータを用いたドライブ風景ラベルの推定精度の評価を行った。

キーワード 経路推薦システム, ドライブ風景の推定

1 はじめに

海沿いや山道、田園など、風景を楽しみながら走行することも、快適にドライブすることの重要な要素の一つである。このような背景において、ドライブ風景を考慮した経路推薦システムを実現することの意義は大きい。既存の経路推薦手法では、最短経路や最速経路、人気経路を推薦するものが多いが [2], ドライブ風景を考慮した経路推薦手法は少ない。市販の道路ネットワークデータやフリーで公開されている OpenStreetMap (OSM)¹ などには、ドライブ風景に関する属性が付与されていない。また、このような属性を手で付与するにはコストが大きい。そこで、本研究では、道路ネットワークのリンクデータにドライブ風景タグ（海沿い風景や山道風景、田園風景など）を自動的に付与することを目標とし、ドライブ風景の推定方法について検討する。

経路にドライブ風景タグを自動的に付与する方法の一つとして、GPS 付きの車載カメラで撮影された画像を解析することで、その地点の風景を推定する方法が挙げられる。しかし、カメラ角度の微妙なずれや、天気や時間帯などによる明るさの変化、車載カメラの機種の違いなどがノイズとなり、推定精度に影響を及ぼす。さらに、風景画像を撮影するためには実際にその地点を走行する必要があるため、データの網羅性が低い。

そこで、本研究では、対象地点を上空からみた道路地図画像および航空写真に着目する。例えば、山道風景であれば航空写真をみると周辺が緑色の領域が多い、海

沿い風景であれば道路地図画像をみると水系領域が大半を占める。これらの地図上から得られる画像特徴を用いることで、経路のドライブ風景を推定可能になると考える。道路地図画像および航空写真は、Google Maps Image API² により取得することができるため、網羅的にデータを収集することができる。また、車載カメラで撮影された画像に比べ、画質が均一的である。

本稿では、扱うドライブ風景として、市街地風景、田園風景、山道風景、海沿い風景を対象とし、道路地図画像および航空写真の画像特徴量から、上記の風景の推定方法を検討する。

本研究の貢献は次のとおりである。(1) 収集したドライブレコーダデータを分析し、次の仮説の立案と検証を行った。

仮説 I 対象地点の道路地図画像の青成分が占める割合から、対象地点が海沿い風景であるか否かを判別可能である。

仮説 II 対象地点の航空写真の緑成分が占める割合から、対象地点が山道風景であるか否かを判別可能である。

仮説 III 対象地点の航空写真から検出された画像特徴点数から、対象地点が市街地風景であるか否かを判別可能である。

仮説 IV 対象地点の航空写真から抽出される田畑領域の数から、対象地点が田園風景であるか否かを判

Copyright is held by the author(s).

The article has been published without reviewing.

¹<https://www.openstreetmap.org/>

²<https://developers.google.com/maps/documentation/staticmaps/?hl=ja>

表 1 風景ラベル

風景ラベル	データ数	対象データ数	備考
市街地風景	1,912	908	住宅街, 街道, 郊外含む
田園風景	64	33	農道含む
山道風景	379	175	山間, 峠道含む
海沿い風景	96	57	湖沿い含む
川沿い風景	15	-	別途検討課題
高速道路	755	-	OSM の属性で定義済み
トンネル内	112	-	OSM の属性で定義済み
橋	23	-	OSM の属性で定義済み
駐車場	142	-	ラベル付け作業の都合上設定
その他	1	-	ラベル付け作業の都合上設定

別可能である。

(2) 仮説の検証結果から有効と判断された特徴量を含めた学習モデルを構築し、テストデータを用いたドライブ風景ラベルの推定精度の評価を行った。評価の結果から、車載カメラ画像から抽出した特徴量を用いたときと比べ、道路地図画像および航空写真から抽出された画像特徴量を用いたときの方が良い精度が得られたことを示した。

2 データセット

第 3 章では、第 1 章で提示した仮説の立案に至った経緯を、実際の経路データの分析結果を踏まえ説明する。それに先立ち、本章では、分析に用いるデータセットについて説明する。

経路データの分析には、風景ラベルが付与された経路データが必要になる。既存の道路ネットワークデータには風景ラベルは付与されていないため、本研究では、ドライブレコーダにより撮影された車載カメラ画像を参考に、人手で経路データに対し風景ラベルを付与する。そして、風景ラベルが付与された経路データに対応する道路地図画像および航空写真を収集する。

2.1 ドライブレコーダデータの収集

ドライブレコーダは LVR-SD300HD を用いた。2013 年から 2014 年の期間中 16 日間の娯楽目的のドライブ時のデータを記録した。ドライブレコーダデータには、車載カメラ動画および不定期に記録された³日時情報、緯度・経度、速度、加速度が含まれる。このうち、本分析では、日時情報、緯度・経度、車載カメラ動画から抽出した静止画を用いる。ここで抽出したタプル (日時情報、緯度・経度、静止画) の数は 3,009 件である。

2.2 ドライブ風景ラベルの付与

クラウドソーシングを用い、2.1 節で説明した 3,009 件の静止画を作業者に提示し、表 1 に示す 10 個のラベルを付与してもらった。この 10 個のラベルは、著者が実際の車載カメラ画像を参照しながら、ボトムアップに




図 2 色相スケール

洗い出したものである。1 画像に対し複数のラベルを付与することも許可している。1 画像あたり 3 名の作業者がラベル付けを行い、うち 2 名以上が同一のラベルを付与したものを採用した。

表 1 に示したラベルのうち、本分析では、「市街地風景」、「田園風景」、「山道風景」、「海沿い風景」を対象とする。「川沿い風景」については、最寄りの河川と平行している、などといった幾何学的な特徴を用いることで、推定しようと考えられるが、幾何学的特徴を用いた風景の推定は本稿の範囲を超えており、別途検討課題とする。また、「高速道路」、「トンネル内」、「橋」については、フリーで利用可能な OpenStreetMap 上で定義済みであるため、推定する必要はないと考える。「駐車場」および「その他」については、ラベル付け作業の都合上設定したものであり、風景推定の対象からは除外する。

表 1 に示す対象データ数は、後述する各特徴の抽出に成功したデータ数を表し、本章でのデータ分析および 4 章、5 章における仮説検証、評価は、この対象データを用いて行った。

2.3 道路地図画像および航空写真の収集

Google Maps Image API を用いて、ドライブレコーダデータに含まれる緯度・経度に対応する道路地図画像および航空写真を収集した。ここでは、ズームレベル：18、画像サイズ：640x640、縮尺値：1、フォーマット：JPG、マップタイプ：道路地図、航空写真を指定した。収集したユニークデータ数は、道路地図画像：1,896 件、航空写真：1,782 件である。

3 風景ラベルごとの画像特徴の分析

図 1 に、風景ラベルごとの道路地図画像または航空写真の代表画像を掲載する。以下、風景ラベルごとに画像特徴について分析する。

(a) 海沿い風景

図 1 (a) より、海沿い風景の道路地図画像に着目すると、水系（青成分）の領域が大半を占めることがわかる。そこで、道路地図画像を HSV 色空間で表現する。HSV 色空間は色相（Hue）、彩度（Saturation）、明度（Value）の三つの成分からなる色空間である。ここでは、彩度および明度による影響は無視するため、色相のみに着目する。

色相は、図 2 のように、0° から 360° で表現される。

³記録のタイミングはドライブレコーダの仕様により自動的に決定される。




図 1 風景ラベルごとの道路地図画像および航空写真




図 3 各特徴量に関するカーネル密度推定

本研究では、図 2 中に破線で示しているように色相を 60° ごとの六つの区分に分割して扱い、 i 番目の色相区分を hue_i で表す。つまり、 hue_5 をみることで青成分を抽出することができる。

各画像について、全画素 (640x640) における、 hue_5 に属する (青成分) 画素が占める割合を算出する。図 3(a) は、風景ラベルごとに、青成分画素の占める割合をカーネル密度推定により表したものである。図の横軸は青成分画素の占める割合を表し、縦軸はそのデータ量を密度で表したものである。例えば、図 3(a) の場合、海沿い風景の画像 57 件のうち、青成分画素が $[40\%, 60\%]$ の範囲を占める画像が 39 件あった。そのため、青画素成分の割合 $[0.4, 0.6]$ の範囲における密度が高くなっている。

図 3(a) より、海沿い風景のみが明らかに青成分が大半を占めているのに対し、他の風景では、その割合は小さいことがわかる。以上の結果を踏まえ、次の仮説を立案する。

仮説 I 対象地点の道路地図画像の青成分が占める割合から、対象地点が海沿い風景であるか否かを判別可能である。

(b) 山道風景

図 1 (b) より、山道風景の航空写真に着目すると、緑成分が多く占められていることがわかる。そこで、(a) で述べた海沿い風景と同様に、航空写真を HSV 色空間で表現する。そのうち、緑成分に相当する hue_3 に着目する。

図 3(b) は、航空写真について、風景ラベルごとに、 hue_3 に属する画素の占める割合をカーネル密度推定により表したものである。図 3(b) より、山道風景のみ、比較的緑成分が占める割合が大きいということがわかる。以上の結果を踏まえ、次の仮説を立案する。

仮説 II 対象地点の航空写真の緑成分が占める割合から、対象地点が山道風景であるか否かを判別可能である。

(c) 市街地風景

ここでは、画像特徴点を抽出するために用いられる SIFT 特徴量 [6] を用いる。SIFT 特徴量は、画像中の輝度勾配を基に検出された特徴点ごとに算出される。つまり、SIFT 特徴点が多く検出されるということは、画像中に輝度勾配が大きな点が多く存在するということを示し、これは画像中にクリアに直線や曲線が多く含まれているということを示す。




図4 海沿い風景および市街地風景の航空写真から検出される画像特徴点




図5 航空写真からの田畑領域の抽出

図1(c) からわかるように、市街地風景には施設や建物などの多くの人工物がみられる。自然風景に比べると、このような人工物には画像特徴点が検出されやすい。

図4は、比較のため、(a) 海沿い風景および(c) 市街地風景の航空写真に対し、SIFT 特徴点を検出したものである。図中の円で表された点が検出された特徴点である。図4より、海沿い風景よりも市街地風景の方が特徴点が多く検出されることがわかる。

図3(c)は、風景ラベルごとの SIFT 特徴点数の割合の分布を示したものである。図3(c)より、市街地風景のみ、特徴点数がやや多い傾向がみられる。以上の結果を踏まえ、次の仮説を立案する。

仮説 III 対象地点の航空写真から検出された画像特徴点数から、対象地点が市街地風景であるか否かを判別可能である。

(d) 田園風景

図1(d) からわかるように、田園風景には周辺に田畑が多く広がっていることがわかる。この田畑の数により、田園風景の判別が行えると考える。

航空写真からの田畑領域の抽出は次の手順で行う(図5)。

- (1) 航空写真のエッジを検出し、エッジ画像を取得する。
- (2) エッジ画像に対しラベリング処理を行い領域分割を行う。
- (3) 領域ごとに面積(画素数)および平均色相値を算出する。
- (4) 一定の範囲内の面積および平均色相値をもつ領域を田畑領域とし、その領域数を算出する。

(1)のエッジ検出には、Canny エッジ検出器[1]を用いる。ただし、検出されたエッジは細いため、このままでは次の領域抽出が正確に行うことができない。そこで、エッジを太くする処理を行う。具体的には、エッジ画像中でエッジを表す白色画素の隣接する上下左右4画素の色を白色に変換することで、エッジを太くする。

(4)において、田畑領域に相当する面積および色相値の範囲を定義する必要があるが、本稿では、経験的に面積を2,000画素から20,000画素の範囲とし、また着目する色相区分は hue_2 とした。なお、ここで定めた面積は画像のズームレベルにも依存するため、適切な面積の設定は別途検討課題とする。

風景ラベルごとの田畑領域数の分布を図3(d)に示す。図3(d)より、田園風景のみ、田畑領域数がやや多い傾向がみられる。以上の結果を踏まえ、次の仮説を立案する。

仮説 IV 対象地点の航空写真から抽出される田畑領域の数から、対象地点が田園風景であるか否かを判別可能である。

4 仮説検証

3節で立てた仮説を検証する。仮説Iから仮説IVに対応し、次の帰無仮説を設定する。

I₀ 海沿い風景と、市街地風景、田園風景、山道風景の道路地図画像の青成分の占める割合には差はない。

II₀ 山道風景と、市街地風景、田園風景、海沿い風景の航空写真の緑成分の占める割合には差はない。

III₀ 市街地風景と、田園風景、山道風景、海沿い風景の航空写真から検出された画像特徴点数には差はない。

IV₀ 田園風景と、市街地風景、山道風景、海沿い風景の航空写真から抽出された田畑領域の数には差はない。

各風景ラベルに属するデータ数は、表1の対象データ数に示すとおりである。また、それぞれのデータ分布は、3節で述べたとおり、図3(a)から(d)に示したとおりである。

図のとおり、母集団の正規性は仮定しないため、ノンパラメトリック検定を用いる。また、対応のない2標本の母代表値の差を検定するため、マン・ホイットニーのU検定を用いる。

表2に、各対について得られたU検定(両側検定)による有意確率 p を示す。いずれも、 $p \leq 0.01$ となったため、**I₀**, **II₀**, **III₀**, **IV₀**を棄却する。ゆえに、有意水準 $\alpha = 1\%$ で、各値には差があるといえる。

表 2 各対における U 検定 (両側検定) による有意確率

対象風景	対象の値	市街地風景	田園風景	山道風景	海沿い風景
海沿い風景	青成分の割合	3.19×10^{-37}	1.33×10^{-15}	3.51×10^{-29}	-
山道風景	緑成分の割合	8.10×10^{-36}	1.14×10^{-5}	-	5.28×10^{-6}
市街地風景	特徴点数	-	7.76×10^{-8}	8.03×10^{-13}	4.49×10^{-17}
田園風景	田畑領域数	3.16×10^{-4}	-	1.95×10^{-6}	1.81×10^{-4}

5 評価実験

ドライブ風景の推定において、道路地図画像および航空写真から抽出した画像特徴を用いることの有効性を検証する。4章の仮説検証の結果から有効と判断された特徴量を含めた学習モデルを構築し、テストデータを用いた風景ラベルの推定精度の評価を行った。学習モデルの構築には、機械学習手法の一つである決定木を用いた。

5.1 評価方法

評価対象のデータセットは、表 1 に示す対象データを用いた。風景ラベルによってデータ数にばらつきがあるため、ここでは、1 試行あたり各風景ラベルからランダムに 30 件ずつ抽出した、計 120 件のデータを用いた。

評価は、5 分割交差検定法を用いた。つまり、5 分割したデータセットのうち 4 組 (96 件) のデータセットを学習データとし、残りの 1 組 (24 件) のデータセットをテストデータとする。こうして得られた 5 回の結果を平均して 1 試行分の結果を得る。

テストデータに付与されているラベルを正解ラベルとし、学習モデルにより予測されたラベルとの一致率を推定精度とする。

以上の手順を 20 試行行い、その平均推定精度を基に比較評価を行う。

5.2 比較特徴量

本実験では、学習に用いる特徴量を変えて比較評価を行った。比較対象の特徴量を以下に示す。括弧内の数字は特徴の次元数を表す。

dr_hue (6) 車載カメラ画像の色相 $hue_{1,...,6}$

rmp_hue (6) 道路地図画像の色相 $hue_{1,...,6}$

sat_hue (6) 航空写真の色相 $hue_{1,...,6}$

rmp_sat_hue (12) 道路地図画像の色相 $hue_{1,...,6}$ 、航空写真の色相 $hue_{1,...,6}$

sift_num (1) SIFT 特徴点数

field_num (1) 田畑領域数

target_only (4) 道路地図画像の青成分 hue_5 、航空写真の緑成分 hue_3 、SIFT 特徴点数、田畑領域数

full (14) 道路地図画像の色相 $hue_{1,...,6}$ 、航空写真の色相 $hue_{1,...,6}$ 、SIFT 特徴点数、田畑領域数




図 6 各特徴量を用いた決定木によるドライブ風景の推定精度。図中の*は、full との間に有意差 ($p < 0.01$) がみられたものを示す。

ここで、dr_hue のみ、比較のために用意した車載カメラ画像から抽出した特徴量を示し、それ以外は、道路地図画像および航空写真から抽出した特徴量を示す。

5.3 結果

特徴量ごとの推定精度を図 6 に示す。

図より、全特徴量を用いた full が最も高い精度 (0.566) を示した。dr_hue は、車載カメラ画像から直接色相を抽出し、それを特徴量としたものであったが、比較的低い推定精度 (0.398) であった。対応のある t 検定 (両側検定) を行ったところ、full と dr_hue との推定精度の差には、有意水準 $\alpha = 1\%$ で有意差がみられた ($p = 2.63 \times 10^{-8}$)。この結果より、ドライブレコーダ画像を直接用いず、対象地点の道路地図画像および航空写真から抽出した特徴量を用いることで、ドライブ風景の推定精度を向上できることを確認した。

target_only は、4 章で行った仮説検証の注目対象とした特徴量のみを用いたものである。この推定精度 (0.550) と比べると、注目対象以外の特徴量も含めた、full, rmp_hue, rmp_sat_hue による推定精度 (それぞれ、0.566, 0.553, 0.559) の方が高かった。有意水準 $\alpha = 1\%$ では有意差はみられなかったものの、今回注目対象としなかった特徴量も含めることで、若干の精度向上が見込まれることを確認した。

田畑領域数、SIFT 特徴点数をそれぞれ単独で用いた、field_num, sift_num に関しては、推定精度 (それぞれ、0.343, 0.335) は最も低かった。また、航空写真の色相のみを用いた sat_hue も推定精度 (0.422) は低かった。この結果より、これらは単独で用いるだけではドライブ風景の推定は難しいといえる。一方で、全特徴量を含めた full が高い精度を示したことから、各ラベルを判別す

るための特徴量を用意し、それらを組み合わせて用いることで、推定精度を向上させることができるといえる。今後は、より推定精度を向上させるべく、航空写真からの各特徴量（色相、SIFT 特徴点、田畑領域）の抽出方法について詳細に検討していく。

6 関連研究

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 [4] 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 [10] 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 [10] 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経路を推薦する手法である。Wei ら [9] は、ユーザの軌跡データから多くのユーザが関心をもつ経路をマイニングすることで、人気経路の抽出を行っている。

個人の嗜好に応じた経路を推薦する、個人化経路推薦の研究もある。MyRoute [8] は、ユーザが熟知している経路やランドマークに基づき、ユーザ個人向けの経路を作成している。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 [3] 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経路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経路推薦手法は少ない。ドライブ風景を考慮した経路推薦として、Niaraki ら [7] 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経路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。本研究では、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ことを目指している。

7 まとめ

本稿では、対象地点の道路地図画像および航空写真に着目し、ドライブ風景を推定するために有効な画像特徴量について検証した。1 章で述べた仮説を検証した結果、道路地図画像の青成分、航空写真の緑成分、画像特徴点数、田畑領域数がドライブ風景の推定に特に有効な

特徴量であることを確認した。また、これらの特徴量を含めた学習モデルを構築し、テストデータを用いたドライブ風景ラベルの推定精度の評価を行った。評価の結果から、車載カメラ画像の特徴量を用いたときの推定精度が 0.398 であったのに対し、道路地図画像および航空写真から抽出された画像特徴量を用いたときの推定精度が 0.566 となり、後者の特徴量の方が精度向上に寄与することを示した。

今後は、各特徴量の抽出方法を洗練することでドライブ風景の推定精度向上を試みる。また、実際に道路ネットワークデータと連結することで、ドライブ風景を考慮した経路推薦システムの設計を行う。

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] J. Canny. A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6):679–698, Nov. 1986.
- [2] K.-P. Chang, L.-Y. Wei, M.-Y. Yeh, and W.-C. Peng. Discovering personalized routes from trajectories. In *SIGSPATIAL 2011: Proceedings of the 3rd ACM SIGSPATIAL International Workshop on Location-Based Social Networks*, volume 1, pages 33–40, New York, New York, USA, 2011. ACM Press.
- [3] J. Chung, A. E-c, C. Schmandt, and A. E-a. Going My Way : A User-aware Route Planner. In *CHI 2009: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 1899–1902, 2009.
- [4] R. Dechter and J. Pearl. Generalized best-first search strategies and the optimality of A*. *Journal of the ACM*, 32(3):505–536, July 1985.
- [5] E. W. Dijkstra. A Note on Two Problems in Connection with Graphs. *Numerische Mathematik*, 1:269–271, 1959.
- [6] D. G. Lowe. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 60(2):91–110, Nov. 2004.
- [7] A. S. Niaraki and K. Kim. Ontology based personalized route planning system using a multi-criteria decision making approach. *Expert Systems with Applications*, 36(2):2250–2259, Mar. 2009.
- [8] K. Patel, M. Y. Chen, I. Smith, and J. A. Landay. Personalizing Routes. In *UIST 2006: Proceedings of the 19th annual ACM symposium on User interface software and technology*, pages 187–190, 2006.
- [9] L.-y. Wei, W.-c. Peng, B.-c. Chen, and T.-w. Lin. Eleventh International Conference on Mobile Data Management PATS : A Framework of Pattern-Aware Trajectory Search. In *MDM 2010: Mobile Data Management*, pages 362–377, 2010.
- [10] L.-y. Wei, W.-c. Peng, C.-s. Lin, and C.-h. Jung. Exploring Spatio-Temporal Features. In *Advances in Spatial and Temporal Databases, Lecture Notes in Computer Science*, pages 399–404, 2009.