

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

片山 大輔[†] 奥 健太[†] 山西 良典^{††}

[†] 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

^{††} 立命館大学情報理工学部 〒520-2194 滋賀県草津市野路東 1 丁目 1-1

E-mail: [†]t130459@mail.ryukoku.ac.jp, ^{††}okukent@rins.ryukoku.ac.jp, ^{†††}ryama@media.ritsumei.ac.jp

あらまし ドライブ風景を考慮したルート推薦システムの実現を目指し，ドライブ風景を自動推定する研究課題に取り組んでいる．本稿では，JAXA が公開している土地被覆図に着目し，土地被覆図の色分布を基に道路片の道路風景を推定する手法を提案する．提案する道路風景の自動タグ付け手法は，道路片の特徴化フェーズ，学習フェーズ，道路風景データベース登録フェーズの三つのフェーズから構成される．道路片の特徴化フェーズでは，対象道路を中心とした $d \times d$ の矩形領域— d は土地被覆図上でのピクセル数—における土地被覆図の色分布を基に特徴化を行う．評価実験により， $d = 10$ としたとき，推定精度が 0.70 と最も高くなった．また，土地被覆図上での色分布と Google ストリートビューの道路風景画像とを比較することで，定性的にも適切に風景ラベルが推定されていることを確認した．キーワード ルート推薦システム，風景識別，自動タグ付け

1. はじめに

1.1 問題提起

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 [1] [2]．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 [2] 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片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片の魅力を定義しているが，その道路片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，道路片の特徴の一つとして風景特徴に着目しており，道路風景を重視したルートを推薦する風景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，海沿い風景が好きなユーザには海沿い風景を優先したドライブルートを，田園風景が好きなユーザには，田園風景を優先したドライブルートを推薦する．このような風景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，事前に道路片に対し，道路風景タグを付与しておく必要がある．

道路片に対し道路風景タグを付与する方法として，(a) 人手による風景タグのアノテーションや (b) 車載カメラ画像解析による風景識別 (c) Google ストリートビューの画像解析などが挙

げられる．しかし，(a) に関しては，人手で風景タグを付与することにはコストが大きい．(b) に関しては，撮影時の天気や時間帯などによる明るさの変化や，カメラ角度の微妙なずれ，カメラ機種の違いなどがノイズとなり，風景識別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，データ収集コストが高くデータの網羅性が低い．(c) に関しては，Google ストリートビューの画像は人間であれば，どのような風景かは判断できるものの機械可読なデータとはなっていない．将来的にルート推薦などへの適用を考えると，機械可読な道路ネットワークデータを用意する必要がある．さらに，(b) と同様に画像解析におけるノイズの問題やデータの網羅性の問題—小さい道路などは Google ストリートビューは未対応である—も残る．

我々は これまでに車載カメラ画像の代わりに道路地図や航空写真を用いた風景識別手法を提案してきた [3]．道路地図や航空写真は車載カメラ画像に比べ，画質が均一であるため，これらの画像を用いることで，車載カメラ画像を用いた場合よりも風景識別精度が向上することを示した．文献 [3] においては推定精度 0.566 を示した．

1.2 本研究のアプローチ

本研究では，さらなる風景識別精度の向上に向けて，JAXA が公開している土地被覆図^(注1)の活用を試みる．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．このように十分な調査に基づき作成された土地被覆図を用いることで，道路地図や航空写真を用いるよりもより高精度に風景識別が期待できる点に着目している．

この考えに基づき，本研究では，土地被覆図解析に基づき道路風景を推定し，道路片に対し道路風景タグを自動的に付与する手法を提案する．道路片周辺の土地被覆図の色分布を基に，

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

道路片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片に対し、あらかじめ人手により道路風景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。なお、本研究では、考えられる道路風景のうち、山間風景、田園風景、市街地風景の三つの風景に着目している。その他の風景（海沿い風景や川沿い風景など）については別の研究課題としている。

本研究の貢献は以下のとおりである。

- 土地被覆図を解析することにより、道路片の風景ラベルを予測する手法を提案した。
- 評価実験により、提案手法による風景推定精度が 0.7 であることを示した。
- 参照する土地被覆図の矩形領域のサイズを変えて推定精度を比較した結果、矩形サイズ 10×10 が最も高い精度を示すことを確認した。

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 [4] や A* アルゴリズム [5] 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 [1] 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 [1] 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紹介する手法である。Wei ら [2] 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 [6] 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 [7] 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 [8] 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 [3] 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 [9] の研究および Girres ら [10] の研究が挙げられる。Haklay ら [9] 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 [10] 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。

2.4 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（以降、土地被覆図）を公開している^(注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 1 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。図 1 は、例として、淡路島周辺である経度 134° 、緯度 34° の土地被覆図を示している。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。表 1 は、土地被覆分類カテゴリおよび対応する色 (RGB 値) 示している。

3. 道路風景の自動タグ付け手法

3.1 問題設定

本節では、道路ネットワークおよび道路風景タグの定義を示した上で、問題設定を述べる。

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 は道路片の集合である。各道路ノードは地理

(注2) : <https://www.openstreetmap.org/>

(注3) : http://www.eorc.jaxa.jp/ALOS/lulc/jlulc_jpn.htm




図 1 土地被覆図の例 (LC_N34E134.tif)

表 1 土地被覆分類カテゴリ

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

座標系における位置座標（経度 x ，緯度 y ）をもつ。各道路片 $r_i \in E^R$ 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：道路風景タグ 道路風景タグとして、 $S = \{\text{mountain, paddy, riverside, seaside, urban}\}$ の 5 種類のタグを定義する。それぞれ、山間風景、田園風景、川沿い風景、海沿い風景、市街地風景を表す。これらの風景は、Oku らの先行研究 [3] の定義に則り、ドライブ時に遭遇しやすい風景として選択した。

提案手法では、与えられた道路片 $r_i \in E^R$ について、その道路片から見える道路風景を推定し、適切な道路風景タグ $s_j \in S$ を自動的に付与する。ただし、本論文では、推定対象の道路風景タグとして、 $\{\text{mountain, paddy, urban}\}$ に限定する。他の道路風景タグ $\{\text{riverside, seaside}\}$ の推定については、別の研究課題として取り組んでいる。

3.2 手法の概要

図 2 は提案手法の構成図である。提案手法は、(a) 特徴化フェーズ、(b) 学習フェーズ、(c) データベース登録フェーズの三つのフェーズから構成される。まず、道路データベースに含まれる各道路片を特徴ベクトル化しておく ((a) 特徴化フェーズ)。つづいて、学習用に一部の道路片について風景ラベルを付与しておき、そのラベルを教師ラベルとして学習モデルを構築する ((b) 学習フェーズ)。さらに、ラベルが付与されていない道路片について、構築した学習モデルを用いて風景ラベルを予測し、道路風景データベースに登録する。各フェーズの概要を図 3 に示す。提案手法では、対象とする道路片 r_i 周辺の土地




図 2 提案手法の構成図。(a) 特徴化フェーズ、(b) 学習フェーズ、(c) データベース登録フェーズから構成される。

被覆図を解析することで、適切な道路風景タグ s_j を推定する。

特徴化フェーズにおいては、道路片 r_i の位置座標 (x, y) に対応する土地被覆図上での座標 (x', y') を取得する。土地被覆図において (x', y') の周辺領域の色分布を基に特徴ベクトルを作成する。

学習フェーズにおいては、あらかじめクラウドソーシングにより任意の道路片に正解タグ（道路風景タグ）を付与しておく。この正解タグと道路片の特徴ベクトルの対を学習データとし、機械学習により道路風景ごとの特徴を学習する。

データベース化フェーズにおいては、任意の道路片について、その特徴ベクトルを基に道路風景タグを推定する。道路片と推定された道路風景タグの対をタプルとしてデータベースに登録する。

4. 道路片の特徴化フェーズ

図 4 は土地被覆図に基づく道路片の特徴化の概要を示したものである。

4.1 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

特徴化したい道路片 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。




図 3 特徴化フェーズ，学習フェーズ，データベース登録フェーズの概要。

(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．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．

$$\text{LC_N} \ \& \ [x] \ \& \ \text{E} \ \& \ [y] \ \& \ .\text{tif}. \quad (1)$$

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 $1^\circ \times$ 緯度 1° の範囲が $3000\text{pixel} \times 3600\text{pixel}$ 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．

$$x' = (x - [x]) \times 3000, \quad (2)$$

$$y' = (y - [y]) \times 3600. \quad (3)$$

4.2 カテゴリ分布に基づく対象道路の特徴ベクトル化

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，道路片 r_i を特徴ベクトル化する．

(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，各カテゴリが表 1 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 1 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．

$$\mathbf{c} = \frac{1}{d^2}(c_1, c_2, \dots, c_{10}). \quad (4)$$

得られた $\mathbf{c}$ を対象道路片の特徴ベクトルとする．

5. 学習フェーズ

本論文では，推定対象の道路風景タグとして， $\{\text{mountain}, \text{paddy}, \text{urban}\}$ に限定しているため，道路風景タグの推定は，「その他」を含め4クラスの分類問題に帰着される．

ここでは学習フェーズについて説明する．学習フェーズは図3(b)に示す流れとなる．

(1) 学習データセットとして， N 対の道路風景タグおよび道路片を用意する．ここでは，道路風景タグを教師クラスラベルとして，道路片を特徴ベクトルとして扱う．つまり，学習データセットとして， $\{(s_1, \mathbf{c}_1), (s_2, \mathbf{c}_2), \dots, (s_N, \mathbf{c}_N)\}$ を得る．

(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．

6. 道路風景データベース登録フェーズ

道路風景タグが未知の道路片について，構築した学習モデルにより道路風景タグを推定する．推定した結果，最も適合する道路風景タグをデータベースに登録する．道路風景テーブルは次の関係スキーマで定義する．

`road-scenery (road_id, scenery)` .

ここで，`road_id` は道路片の ID を，`scenery` は道路風景タグを表す．

道路風景テーブルへの登録手順は次のとおりである．

- (1) 推定対象の道路片 r_i の特徴ベクトル $\mathbf{c}_i$ を取得する．
- (2) 学習モデルに対象の特徴ベクトルを入力し，最も適合する道路風景タグ s_i を推定する．
- (3) 対象の道路片および推定された道路風景タグの対をタプル (r_i, s_i) とし，道路風景テーブルに登録する．

7. 評価実験

土地被覆図において参照する矩形領域の大きさとして，妥当な d のとりかたについて検証する．ここでは， d を変えたときの道路風景推定精度を比較する．

7.1 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．さらにそこからランダムに2,000 件の道路片を抽出した．抽出した道路片に対し，クラウドソーシングにより道路風景ラベルを付与した．1 件の道路片に対し，3 名のワーカにラベル付けを行ってもらい，2 名以上のワーカにより付与されたラベルを採用した．なお，ワーカには1 件の道路片に対し複数のラベルを付与することを許している．結果として，表2の風景ラベル付き道路片が得られた．表2には風景ラベルごとの道路片数を示している．重複を含め，合計2,121 件の道路片を得た．

表2 評価実験で用いた道路風景ラベル付き道路片

道路風景ラベル	道路片数
田園風景 (paddy)	938
山間風景 (mountain)	889
市街地風景 (urban)	294

7.2 実験方法

4.2 節で述べたとおり，道路片の特徴ベクトル化は，道路片の位置座標を中心にサイズ $d \times d$ の矩形領域内の土地被覆図の色分布を基に行った．本実験では， d の設定 $d = \{5, 7, 10, 20, 30, 40, 50\}$ による道路風景推定精度の変化を分析する．

評価実験は5分割交差検定法により実施した．つまり，2,121 件のデータをランダムに5分割し，そのうち4組を学習データセットとし，残りの1組をテストデータセットとした．この学習データセットとテストデータセットの対を用いて推定精度を算出する．学習データセットとテストデータセットの対は5パターンになる．この5パターンを基に算出した平均精度を1試行分の結果とする．これを20試行実施し，その平均推定精度を基に比較評価を行う．

ここで，機械学習手法としては決定木を用いた．また，推定精度とは，全テストデータのうち，学習モデルにより予測された風景ラベルと正解データとが一致した割合を表す．

7.3 定量分析

図5に， d を変えたときの推定精度の変化を示す．図5より， $d = 10$ のとき最も高い精度0.70を示した． d を大きくしていくと推定精度が低下していき， $d = 50$ のときには0.61という精度にとどまった．一方で， $d = 10$ よりも小さくしていくとやはり推定精度が低下した．

以上の結果より，特徴ベクトル算出の対象となる矩形領域を広くとりすぎると，ノイズが多く含まれ推定精度が低下する原因となる．一方で，矩形領域を狭くすると，推定に必要な情報が削減されてしまい，やはり推定精度の低下を招く．このように適切な矩形領域のサイズを設定することで，推定精度向上に寄与することを確認した．

7.4 定性分析

予測された各風景ラベルの妥当性を，Google ストリートビューの画像を基に定性的に検証する．図6は，田園風景，山間風景，市街地風景と正しく推定された道路片における土地被覆図および Google ストリートビュー画像の対である．土地被覆図の $\times$ 印が道路片の位置を表す．ここでは，7.3 節で最高精度を示した $d = 10$ を採用している．すなわち，道路片を中心にサイズ 10×10 の土地被覆図を参照している．

(a) は田園風景と予測された道路片である．土地被覆図より，水田や畑地が多く分布していることがわかる．Google ストリートビューにおいても田園風景であるということは明らかである．(b) は山間風景と予測された道路片である．土地被覆図より，落葉樹や常緑樹が多く分布していることがわかる．Google ストリートビューにおいても，両側に樹木がみえることから山




図 4 土地被覆図に基づく道路片の特徴化




図 5 矩形領域のサイズによる推定精度の変化

間風景であるといえる。(c) は市街地風景と予測された道路片である。土地被覆図より、ほぼ都市で占有されていることがわかる。Google ストリートビューにおいても建物がみえることから、市街地風景であるといえる。

8. ま と め

本研究では、対象地点の土地被覆図解析に基づき道路風景を推定し、道路風景タグを自動的に付与する手法を提案した。道路風景の自動タグ付け手法は道路片の特徴化フェーズ、学習フェーズ、道路風景データベース登録フェーズの三つのフェーズから構成される。道路片の特徴化フェーズでは、対象道路を中心とした $d \times d$ の矩形領域における土地被覆図の色分布を基に特徴化を行う。

評価実験により、 $d = 10$ としたとき、推定精度が 0.70 と最も高くなった。このように適切な短形領域のサイズを設定することが、推定精度向上に寄与することを示した。また、土地被覆図上での色分布と Google ストリートビューの道路風景画像とを比較することで、定性的にも適切に風景ラベルが推定され




図 6 正しく風景が推定された道路片周辺の土地被覆図と Google ストリートビュー画像との関係

ていることを確認した。

今回の評価実験における推定精度 0.70 は、Oku らの先行研究 [3] で示した推定精度 0.566 を上回る。これと比較すると、土地被覆図を用いた本研究の手法は大きく精度向上に寄与することが期待できる。ただし、本論文では、対象の道路風景を山間風景、田園風景、市街地風景の三つの風景に限定するなど、Oku ら [3] の実験条件とは異なるため参考程度の結果である。

今後は、実験条件を統一して比較したい。また海沿い風景および川沿い風景の推定については別の研究課題として取り組んでいる。将来的には、これらの研究と統合し、道路風景データベースを構築したい。

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。

文 献

- [1] 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.
- [2] 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.
- [3] 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.
- [4] Edsger Wybe Dijkstra. A Note on Two Problems in Connexion with Graphs. *Numerische Mathematik*, Vol. 1, pp. 269–271, 1959.
- [5] Rina Dechter and Judea Pearl. Generalized best-first search strategies and the optimality of A*. *Journal of the ACM*, Vol. 32, No. 3, pp. 505–536, jul 1985.
- [6] 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.
- [7] Jaewoo Chung and Chris Schmandt. Going My Way : A User-aware Route Planner. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 1899–1902, 2009.
- [8] 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.
- [9] 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.
- [10] Jean-Francois Girres and Guillaume Touya. Quality Assessment of the French OpenStreetMap Dataset. *Transactions in GIS*, Vol. 14, No. 4, pp. 435–459, 2010.