

テレマティクスデータからの運転者特性に応じた 安全な経路推薦手法の検討

深津 隼^{1,a)} 川上 朋也¹

概要：近年、スマートフォンなどの持ち運びが可能な端末の普及により、経路推薦サービスが多く利用されている。従来の経路推薦サービスでは、経路長などを考慮した最短の経路が推薦されることが多いが、運転者によっては事故が起きやすい道路区間を経由する経路が推薦される。本研究では、運転者の特性に応じて各道路区間の事故発生率の推定を行い、事故発生率が最小となる経路の推薦手法を提案する。各道路区間を走行した運転者の特徴量をテレマティクスデータから取得することを想定し、取得したデータから、“事故の有無”を目的変数とした二値分類モデルを機械学習により生成する。生成モデルには経路推薦を行う運転者の特徴量を入力し、その運転者がその道路区間を走行したときの事故発生率を予測する。シミュレーションによる評価では、距離を最小とする経路推薦手法と比べ、提案手法は事故発生率が低い経路を推薦できることを確認した。

キーワード：ナビゲーション、交通事故、事故発生率、運転特性、機械学習、二値分類

1. はじめに

近年、スマートフォンやタブレットなどの持ち運びが可能な端末の普及により、経路推薦サービスの利用や研究が多く行われている [1–8]。従来の経路推薦サービスでは、出発地点や目的地の情報を入力し、出発地点から到着地点までの経路長や、所要時間などが最小となる経路が推薦されるものが多くある。また、これらの経路推薦サービスでは、運転者の区別がされておらず、異なる運転者であっても入力した情報が同じであれば同じ経路が推薦される。これらの経路推薦では、運転者によっては事故が起りやすい道路区間を通る経路が推薦され、交通事故に遭うリスクが高くなる可能性があると考えられる。

日本で起きている交通事故の件数はここ数十年減少傾向にあり、それに伴って負傷者数や死者数も減少してきているが、依然として、交通事故は多く発生しており、負傷者数も死者数も多い。交通事故の件数が減少してきた要因として、シートベルトの着用者率の向上や飲酒運転等悪質・危険性の高い事故の減少、車両の安全性向上などが挙げられるが、経路推薦による要因が交通事故の件数の減少に寄

与したという例は、筆者らが調べた範囲では存在しなかった [9]。これより、経路推薦によって交通事故が起りにくい経路を推薦することで、交通事故の件数の減少に寄与できる可能性がある。

また、近年、ICT (情報通信技術) の発展により、テレマティクスという新しい技術を活用したサービスが実用化されてきている [10–14]。テレマティクスとは、自動車などの移動体に通信システムを組み合わせることで、自動車の位置情報や運転者の運転操作などの自動車関連情報をリアルタイムで収集し、活用することが可能な技術であり、これによって得られる情報をテレマティクスデータという。テレマティクスデータによって入手可能な主な情報として、表 1 にまとめる。テレマティクスを活用したサービスとして、あいおいニッセイ同和損害保険株式会社が提供しているサービスに、「Visual Drive」がある [15]。これは、テレマティクスデータを収集するための車載器を自動車のダッシュボードに付け、この車載器と運転者のスマートフォンのアプリと連携させることで、運転者の走行データから安全運転診断等を行い、運転者に対して安全運転を促している。

¹ 福井大学工学部
School of Engineering, University of Fukui, Fukui 910–8507,
Japan

^{a)} hb180967@u-fukui.ac.jp

運転者の特定に関する情報 (特定困難な場合も多い)
走行距離
走行速度
走行時間, 走行時間帯
走行地域 (位置情報)
急加速・急ブレーキの回数
ハンドル操作の安定性 (カーブ操作の滑らかさなど)

2. 関連研究

2.1 個人の嗜好を考慮した経路推薦

石崎らは、ユーザの嗜好に適合する可能性の高い経路を効率的に探索できる経路推薦手法として、P-UCT 手法を提案している [5]。経路推薦サービスを利用するユーザに対して、ユーザ個人の嗜好を反映した経路推薦を行うために、ユーザ個人の嗜好の取得と、経路全体を確認してから経路評価をする機構が必要であると述べている。ユーザ個人の嗜好の取得の実現には、経路評価を好き/嫌いの2段階で格納するために、2クラスのパターン識別器が必要になることから、Support Vector Machine (SVM) による機械学習を採用している。経路全体を確認してから経路評価をする機構の実現には、代表的なモンテカルロ木探索であるUCTを採用している。モンテカルロ木探索では、モンテカルロ・シミュレーションを多数実行して準最適解を求めていくため、経路全体の評価が可能となる。また、経路推薦をモンテカルロ木探索に適用するため、新しい評価指標として、P-UCT 値を提案している。文献 [6] では、P-UCT 手法の高速化にも取り組んでいる。

玉置は、運転者がどのように熟練していくのかという過程に着目し、熟練度を考慮したエージェント・モデルを構築している [8]。玉置は運転者が熟練するに従って走行結果がどのように推移していくかという熟練過程を形式化し、その過程を再現できるような運転者モデルの枠組みを提案している。さらに、熟練度合いに相当するパラメータを持つ運転者モデルを構築し、車両シミュレータと組み合わせることで、目標速度追従運転を対象としたシミュレーションを行い、提案モデルの追従性能や熟練度合いに相当するパラメータが走行結果に与える影響を確認している。

2.2 テレマティクスデータの活用

李らは、顔検出機能などに用いられている AdaBoost のアルゴリズムをベースとして、熟練と未熟練者の運転操作の特徴差の抽出手法を提案している [13]。また、運転操作の特徴差を分析するためにテレマティクスデータの活用を想定している。李らの提案する判別モデルでは、カーブを通過する時、熟練者がスムーズに操作を行うのに対し、未熟練者は操作がふらつくといった挙動の差を操作の周波

数で表せるというところから、実車の計測機能など何らかの方法で取得した運転操作データに対して wavelet 分解を行い、周波数特性から、その運転操作の特徴箇所を見出している。wavelet 分解された各周波数成分は、線形補間により距離で正規化することで、正規化したデータは自社位置と運転操作に対応する。そして、正規化したものに対して窓関数を用いた処理を行い、候補特徴量を生成した後、AdaBoost のアルゴリズムに入力し、特徴を抽出して運転スキルの判別モデルを構築している。また、このモデルの精度を Leave one out という交差検定方法によって判別モデルの識別率を検討し、抽出された結果に従って、未熟練者のドライバにアドバイスを提供する場所と操作を示している。

金子は、国内外の保険会社について、テレマティクスデータを新たなサービス提供や保険商品開発につなげる取り組みが行われている点について概観している [14]。近年、テレマティクスデータを分析して保険料算定に反映させる試みが台頭を見せており、これには、走行距離を保険料に反映させる「走行距離連動型 (PAYD: Pay As You Drive)」と、走行距離だけでなく、急ブレーキ回数等の運転特性を保険料に反映させる「運転特性連動型 (PHYD: Pay How You Drive)」の2種類がある。テレマティクス自動車保険では、従来取得することができなかった運転挙動等の個人的リスクの把握に基づく、より正確で細やかな料率設定が可能となりうるとしている。また、運転者がテレマティクスによって自らの日々の運転をチェックされていることを認識し、かつ、運転者個人の日々の運転挙動がより直接的に保険料に反映させることになるのであれば、運転者には、安全運転を心掛けるインセンティブがより強く働くことになり、それによって交通事故が減れば社会的にメリットになるとしている。テレマティクスは、保険料算出にとどまらず、損害発生の予防、軽減、その他、人々の安心・安全につながるさまざまなサービスにも活用しうるとしている。例えば、運転挙動に関する情報を記録しておくことにより、運転者の運転の癖等を事後的に検証し、改善を促すことができることや、車両の位置情報を把握することで、車両盗難時の車両追跡や早期発見等が可能となるし、高齢運転者等の運転地点を家族が位置情報を把握して見守ることも可能となること、さらに損害調査業務の効率化や、不正請求への適切な対処 (車両への実際の衝撃に係る情報を確認する等) 等にも活用しうると述べている。

3. 運転者特性に応じた経路推薦

3.1 概要

本研究では、運転者に応じて、事故が起こりにくい安全な経路の推薦を目的として、運転者特性に応じた各道路区間の事故発生率を最小とする経路推薦手法を提案する。運転者特性に応じた安全な経路推薦を実現するために、運転

者特性に応じた各道路区間の事故発生率の推定と、出発地点から目的地点までの事故発生率を最小とする経路推薦の2点を考える。本研究では、ある運転者がある道路区間で事故を起こす確率を事故発生率と呼ぶ。

運転者特性に応じた各道路区間の事故発生率の推定では、各道路区間を過去に走行した運転者の情報と、経路推薦を行う運転者の情報をテレマティクスデータからの取得を想定する。取得したこれらのデータを使用して機械学習を行うことにより事故発生率を推定する。

事故発生率を最小とする経路推薦では、最短経路問題を効率的に解くアルゴリズムの一つであるダイクストラアルゴリズムを一部改変して使用する。この経路推薦アルゴリズムにより、出発地点のノードから目的地点のノードまでの事故発生率を最小とする経路推薦を行う。

3.2 運転者特性に応じた各道路区間の事故発生率の推定

運転者特性に応じた各道路区間の事故発生率の推定を行うために、各道路区間を過去に走行した複数の運転者について、運転者それぞれが持つ特徴量をテレマティクスデータの活用して取得する。テレマティクスデータには、運転者の特定に関わる情報、走行距離や走行地域などといった運転者の運転する自動車に関する情報、急加速・急ブレーキの回数、ハンドル操作の安定性などといった運転者の運転操作に関する情報などが含まれている。本研究では、テレマティクスデータから取得できるこれらの情報を運転者が持つ特徴量として使用する。また、少なくとも、その特徴量に道路区間を識別する特徴量“道路区間番号”と、その道路区間を走行したときに事故を起こしたかどうかを判別する特徴量“事故の有無”の2つは含まれていることを想定する。

続いて、各道路区間毎に機械学習を行い、二値分類モデルを生成する。ある道路区間について、取得した運転者の特徴量を訓練データとして訓練データには、テレマティクスデータによって取得した運転者が持つ特徴量を使用する本研究では、機械学習において特定の機械学習手法に依存することはないが、機械学習のモデルには二値分類モデルを使用する。二値分類モデルを生成する際の目的変数には、運転者の特徴量の一つである“事故の有無”を設定し、この特徴量の値は事故を起こしていない場合は0、事故を起こしている場合は1とする。このモデルを各道路区間について同様に生成する。

そして、経路推薦を行う運転者の特徴量(“事故の有無”を除く)をテレマティクスデータから取得し、ある道路区間について作成したモデルに入力として与えると、経路推薦を行う運転者がその道路区間を走行した場合の事故発生率の値が0から1の範囲で出力される。この事故発生率の推定を各道路区間について同様に進行。

以上より、運転者特性に応じた各道路区間の事故発生率

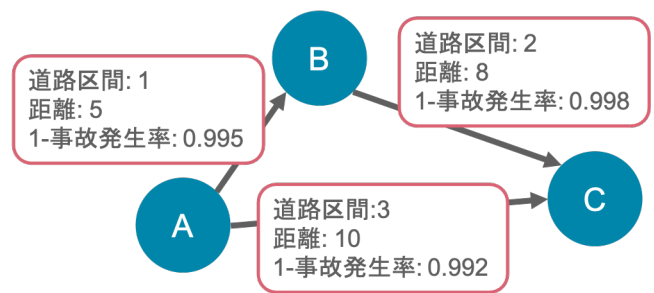


図1 使用する道路ネットワークの例

が推定される。運転者が持つ複数の特徴量をまとめて運転者特性と呼ぶ。

3.3 事故発生率を最小とする経路推薦

本研究で使用する道路ネットワークは、図1のような複数のノードとリンクによって構成されており、ノードは交差点、リンクは道路区間を表している。また、各リンクは、道路区間を識別する番号と、その道路区間の距離、その道路区間の事故発生率から1を引いた値を保持する。

提案する経路選択アルゴリズムでは、各リンクが保持する“1-事故発生率”の値を重みとし、出発地点となるノードから目的地点となるノードまでの“1-事故発生率”が最大となるように経路推薦を行う。これにより、事故発生率が最小となる経路推薦を行う。提案する経路選択アルゴリズムの疑似コードをアルゴリズム1に示す。

4. 評価

4.1 シミュレーション環境

本研究では、Python 3.8を使用し、1台のPC上にシミュレーション環境を構築した。用いたPCはOSがWindows 10で、CPUはIntel Core i7 (4コア/8スレッド, 3.4GHz)、メモリは16GB、ストレージはSSDである。本シミュレーションでは、ある道路ネットワークにおいて、出発地点のノードから目的地点のノードまでの最短経路上にある一部の道路区間で、天候が雨のときに走行した運転者が事故を起こしやすくなっている、というシナリオを考える。

まず、3.2節では、各道路区間を過去に走行した運転者の特徴量をテレマティクスデータから取得することを想定しているが、本シミュレーションでは実際のテレマティクスデータの代わりにダミーデータを作成し、評価に用いる。使用したダミーデータの特徴量とそれぞれの数値の範囲を表2に示す。運転者は表2の全ての特徴量をそれぞれの範囲の数値で保持する。ダミーデータを作成する際には、警察庁や気象庁の統計を基にしている [16-19]。本シミュレーションでは、このダミーデータを使用し、各道路区間を過去に走行した運転者の特徴量を取得する。

次に、各道路区間の二値分類モデルを作成する際の機械学習手法にはXGBoost [20]を用いる。本研究の提案手法

Algorithm 1: 事故発生率を最小とする経路の選択

Input: *list*: 道路区間毎の“1-事故発生率”を保存した二次元リスト (ノード *i* からノード *j* に向かうリンクの重み (“1-事故発生率”) は *list*[*i*][*j*] で表す), *n*: ノードの数

Output: *previous*

```

1 unsearched = [n] // 未探索ノードのリスト
2 safeties = [n] // ノード毎の“1-事故発生率”のリスト
3 previous = [n] // 最短でそのノードの一つ前に到達するノードのリスト
4 for i to n - 1 do
5   unsearched[i] = i
6   safeties[i] = 0
7   previous[i] = -1
8 s = 1
9 safeties[s] = 1
10 while unsearched の要素数 != 0 do
11   unsearched に含まれるノードの中から, safeties の値が最大のノード unsearched[k] を選択する
12   unsearched から, unsearched[k] を削除する
13   for i to n - 1 do
14     if list[k] != 0 then
15       if safeties[i] < safeties[k] * list[k][i] then
16         safeties[i] = safeties[k] * list[k][i]
17         previous[i] = k
18 return previous

```




図 2 学習過程の例




図 3 道路ネットワーク 1

表 2 ダミーデータの特徴量

特徴量 (単位)	範囲
道路区間	1, 2, ...
年齢 (歳)	18, 19, ..., 80
走行距離 (km)	0, 1, ..., 150000
平均速度 (km/h)	10, 11, ..., 50
急加速の回数 (回/h)	0, 1, ..., 10
急ブレーキの回数 (回/h)	0, 1, ..., 10
ハンドル操作の安定性	1, 2, ..., 10
燃費 (km/L)	1 ~ 30
エンジンの回転数 (rpm)	1000, 1001, ..., 4000
月	1, 2, ..., 12
走行時間帯	朝, 昼, 夕-夜, 夜中
天候	晴れ, 曇, 雨, 雪
気温 (°C)	-1 ~ 35
事故の有無	0 (なし), 1 (あり)

では, 特定の機械学習手法に依存することはないが, 勾配ブースティング決定木 (Gradient Boosting Decision Tree, GBDT) を扱うことができ, 汎用性が高く, 比較的精度が高いとされているなどの理由から XGBoost を採用した. GBDT とは, 勾配降下法 (Gradient), ブースティング (Boosting), 決定木 (Decision Tree) の 3 つを組み合わせた手法である. XGBoost におけるパラメータは, 二値分類問

題について学習を行い, モデルの評価指標には LogLoss を使用している. また, 学習の回数の上限を 1000 回とし, 評価指標の誤差が 10 回が変わらなければ終了するように設定を行っている. これらの設定で XGBoost による学習を行ったときの学習過程を可視化したグラフを図 2 に示す.

そして, 本シミュレーションで使用する道路ネットワークは図 3 と図 4 の 2 つを使用する. 図 4 の道路ネットワークは福井県福井市の実際の道路ネットワークを参考に作成した. それぞれの図におけるノード *s* は出発地点, *g* は目的地点であり, リンクに付いている値は各道路区間を識別する番号である. 各道路区間を識別する番号のうち, 図 3 では 7 番, 図 4 では 9, 12 番を天候が雨のときに走行した運転者が事故を起こしやすいように設定している.

最後に, 経路推薦を行う運転者の特徴量を表 3 に示す. 本シミュレーションでは, テストデータ 1 とテストデータ 2 の 2 つの運転者の特徴量を使用し, それぞれの道路ネットワークで同じ学習モデルに入力して事故発生率を推定する. テストデータ 1 とテストデータ 2 の特徴量は, 天候以外は全て同じ値にしており, 天候はテストデータ 1 は“晴れ”, テストデータ 2 では“雨”としている. これらの 2 つの運転者の特徴量に対して, 比較手法 1 として距離を最小

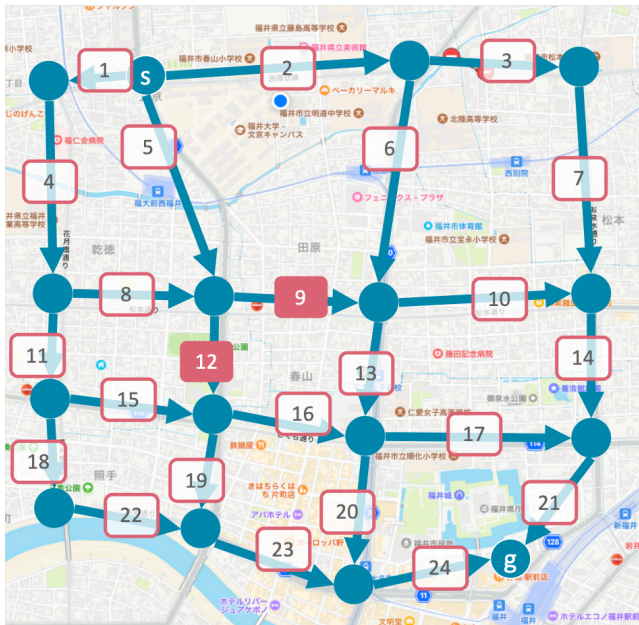


図 4 道路ネットワーク 2

表 3 テストデータ

特徴量 (単位)	テストデータ 1	テストデータ 2
道路区間	1, 2, ...	1, 2, ...
年齢 (歳)	24	24
走行距離 (km)	60811	60811
平均速度 (km/h)	26	26
急加速の回数 (回/h)	5	5
急ブレーキの回数 (回/h)	6	6
ハンドル操作の安定性	5	5
燃費 (km/L)	17	17
エンジンの回転数 (rpm)	1945	1945
月	12	12
走行時間帯	昼	昼
天候	晴れ	雨
気温 (°C)	5.760391	5.760931

とする経路推薦, 比較手法 2 として事故率を最小とする経路推薦, 提案手法として推定した事故発生率を最小とする経路推薦の 3 つの手法を使用し, 評価を行う. また, 事故率とは, 各道路区間の事故数を運転者数で割った値としている.

4.2 シミュレーション結果

図 3 の道路ネットワークにおいて, 4.1 節の通りのシミュレーション環境でシミュレーションを行ったときの結果を表 4, 図 5-7 に示す. 表 4 は, シミュレーションによって各道路区間が持つ距離, 事故発生率, 事故数の値の一例である. 表における事故発生率 (1), (2) はそれぞれテストデータ 1, 2 を使用して推定した事故発生率となっている. この表から, 天候が雨の時に走行した運転者が事故を起こしやすく設定した 7 番の道路区間の事故数が多くなっており, 7 番の道路区間について, テストデータ 2 を使用して推定

した事故発生率がテストデータ 1 を使用して推定した事故発生率よりも大きい値になっていることが確認できる. また, 表 4 の値を使用してそれぞれの手法で経路推薦を行ったときの経路が図 5 のようになっている. 図 4 において, 黄色の線が比較手法 1 である距離を最小とする経路, 緑色の線が比較手法 2 である事故率を最小とする経路, 水色の線がテストデータ 1 を使用して推定した事故発生率を最小とする経路, 紫色の線がテストデータ 2 を使用して推定した事故発生率を最小とする経路である. この図から, 黄色と水色の経路については, 天候が雨のときに運転者が事故を起こしやすいうように設定した 7 番の道路区間を通過する経路を推薦しているのに対し, 緑色と紫色の経路については, 7 番の道路区間を避けるように経路推薦を行っていることが確認できる. これより, 提案手法による経路推薦では, 運転者の特徴量の天候を”晴れ”に設定したテストデータ 1 と”雨”に設定したテストデータ 2 で推薦される経路が異なることから, 運転者特性に応じた事故発生率の推定により, その運転者が事故を起こしにくい安全な経路推薦を行うことができていると考えられる.

また, シミュレーションを 10 回行い, 経路長と事故発生率の平均をまとめたグラフがそれぞれ図 6, 7 である. 図 6 のグラフでは, 比較手法 1 と比較手法 2 による経路推薦ではテストデータによって推薦される経路が変わらないため, 同じ値になっている. 対して, 提案手法による経路推薦では, 距離を最小とする比較手法 1 の経路推薦と比べて経路長が大きくなっていることや, テストデータによって推薦される経路が異なるため, 経路長にも差が現れていることが確認できる. また, テストデータ 1 に比べてテストデータ 2 の経路長が大きくなっているのは, テストデータ 2 では 7 番の道路区間における事故発生率の値が高く推定されやすく, この道路区間を避けるように経路選択を行っているためである. 図 7 のグラフでは, 比較手法の経路推薦に比べて, 提案手法による経路推薦の事故発生率が低いことが確認できる. テストデータ 2 を使用した比較手法 1 の経路推薦による事故発生率が他の値に比べて特にならなくなっているのは, テストデータを使用して推定した事故発生率が高い値になりやすくなっている 7 番の経路を通過する経路選択を行っているためである. これらより, 提案手法では比較手法 1 に比べて経路長は大きくなっているが, 事故発生率は低く抑えられており, 運転者特性に応じて事故発生率が高く推定された道路区間を避けて経路推薦を行っていると考えられる.

図 4 の道路ネットワークにおいて, 4.1 節の環境でシミュレーションを行った結果を表 5, 図 8-10 に示す. それぞれの結果の傾向は図 3 の道路ネットワークを使用した場合と同じであった. しかし, 道路ネットワークにおけるノードやリンクの数が増加したことにより, 比較手法 1 による経路推薦と提案手法に経路推薦の経路長の差が大きくな

表 4 図 3 のリンクが持つ値

道路区間	距離	事故発生率 (1)	事故発生率 (2)	事故数
1	3	0.000002	0.000001	140
2	3	0.000001	0.000019	121
3	8	0.000041	0.000449	109
4	2	0.000073	0.000403	140
5	4	0.000007	0.00008	139
6	7	0.001434	0.002584	134
7	4	0.000003	0.001637	590
8	3	0.00001	0.000212	117




図 5 道路ネットワーク 1 の推薦経路




図 6 道路ネットワーク 1 の平均経路長




図 7 道路ネットワーク 1 の平均事故発生率

ていることが確認できる。これについて、提案手法では、事故発生率が高く推定された道路区間を避けるように経路推薦を行っているため、ノードやリンクの数が増加するに従って経路の組み合わせの数も増加し、距離を最小とする経路推薦を行う比較手法 1 と比べて経路長がより大きく

表 5 図 4 のリンクが持つ値

道路区間	距離	事故発生率 (1)	事故発生率 (2)	事故数
1	2	0.000001	0.000001	124
2	10	0.000001	0.000002	113
3	5	0.000252	0.001212	138
...
9	4	0.000117	0.144052	581
...
12	3	0.000002	0.002704	591
...
23	5	0.000113	0.000814	130
24	4	0.000137	0.000194	131

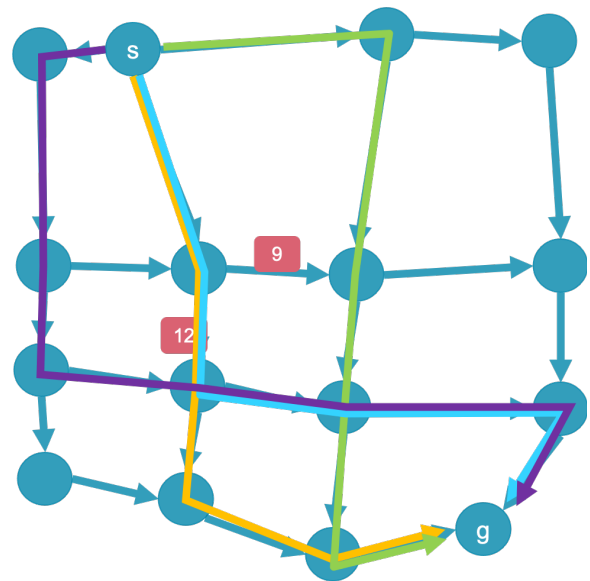


図 8 道路ネットワーク 2 の推薦経路




図 9 道路ネットワーク 2 の平均経路長

なっていくことが考えられる。このような経路推薦では、あるノードから隣接した別のノードに向かうとき、一つのリンクを経由すれば別のノードへ到達するところを複数のノードやリンクを経由した経路が推薦され、余分に迂回してしまう可能性がある。よって、提案手法による経路推薦について、一定の距離以下で事故発生率を最小とする経路を推薦できるようにすることが必要である。

5. 考察

提案手法では、比較手法に比べて経路長が大きくなって

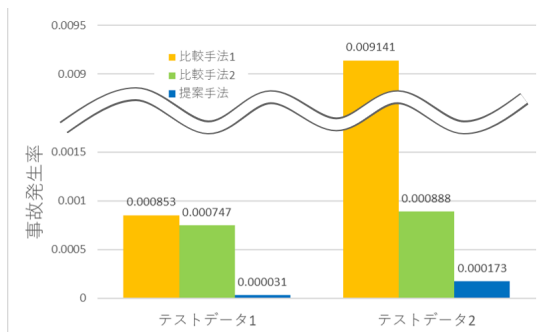


図 10 道路ネットワーク 2 の平均事故発生率

いるが、事故発生率を小さく抑えられていることから、事故発生率が高く推定された道路区間を避けて経路推薦を行うことができていると考えられる。また、提案手法による経路推薦において、運転者の特徴量の一つである天候を“晴れ”に設定したテストデータ 1 と天候を“雨”に設定したテストデータ 2 をそれぞれ使用したときのシミュレーション結果を比較すると、テストデータ 2 はテストデータ 1 に比べて経路長が大きくなっていた。これは、本研究におけるシミュレーションの環境では、天候が“雨”のときに一部の道路区間で事故が起きやすくなるように設定しているため、天候が“雨”という特徴量を持つテストデータ 2 の運転者はその道路区間における事故発生率が高く推定され、その道路区間を避けるように遠回りをした経路が推薦されたためであると考えられる。シミュレーション結果の学習時間については、本研究では使用した道路ネットワークの道路区間の数を一つずつ学習させているため、道路ネットワークの規模が大きくなると学習時間についても大きくなっていくが、実際に実用化される場合には、各道路区間についてそれぞれ並列して学習させられる環境が想定される。そのため、学習データの数にもよるが、少ない時間でモデルを作成することができると考えられる。そして、経路推薦にかかった時間について、本研究で使用した道路ネットワークの規模では、比較手法と提案手法のそれぞれの経路推薦時間のデータが不十分であったため、より大規模な道路ネットワークでシミュレーションを行って評価することが必要であると考えられる。

6. まとめ

本研究では、テレマティクスデータの活用を想定し、運転者特性に応じた事故発生率を機械学習を使用することにより推定した。そして推定した事故発生率を使用し、出発地点から目的地店までの事故発生率を最小とする経路推薦を提案した。提案手法では、比較手法に比べて事故発生率が小さくなる経路を推薦できていることから、安全な経路推薦が行えていることを確認した。また、運転者が持つ特徴量によって推薦される経路が異なることから、運転者特性に応じた経路推薦が行えていることも確認した。

今後の課題として、実際のテレマティクスデータや道路ネットワークを使用して提案手法を評価し、その有用性を確認することが挙げられる。また、提案手法の経路推薦について、比較手法に比べてかなり遠回りをして経路長が大きくなる経路も存在した。よって、距離や走行時間などについて閾値を設け、それらを満たしつつ事故発生率が最小となる経路を推薦することが考えられる。

参考文献

- [1] 片山拓也, 村尾和哉, 田中宏平, 寺田 努, 西尾章治郎: 装着型センサを用いた経路推薦機構を持つナビゲーションシステムの構築, 情報処理学会論文誌, Vol. 50, No. 9, pp. 2350–2359 (2009).
- [2] 伊藤嘉博, 中村嘉隆, 高橋 修, 白石 陽: 都市センシングデータに基づく経路推薦のための空間補間手法の提案と実装, 情報処理学会論文誌, Vol. 54, No. 2, pp. 740–752 (2013).
- [3] 中島伸介, 北山大輔, 濱田恵輔, 角谷和俊: カーナビ利用時の推薦経路と選択経路の差異に基づくルート推薦方式, 情報処理学会論文誌: データベース, Vol. 7, No. 2, pp. 83–92 (2014).
- [4] 徐 家興, 川井 明, 柴田直樹, 伊藤 実: GreenSwirl: 交通渋滞の緩和を目指した信号制御および経路案内方式の提案と性能評価, 情報処理学会論文誌, Vol. 57, No. 1, pp. 66–78 (2016).
- [5] Ishizaki, Y., Koyama, Y., Takayama, T. and Togawa, N.: A Route Recommendation Method Considering Individual User’s Preferences by Monte-Carlo Tree Search and Its Evaluations, *Journal of Information Processing (JIP)*, Vol. 29, pp. 81–92 (2021).
- [6] 石崎雄太, 高山敏典, 戸川 望: モンテカルロ木探索を用いたユーザ個人の嗜好を考慮した経路推薦手法の高速化, マルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウム論文集, pp. 1303–1310 (2020).
- [7] 松井雄資, 吉廣卓哉: 宛先到着遅延を考慮して渋滞を緩和する自動車の経路誘導手法, 情報処理学会論文誌, Vol. 63, No. 2 (2022).
- [8] 玉置 久: 熟練度を考慮したエージェント・モデルの構築—運転者エージェントを例として, 第 4 回横幹連合コンファレンス, 2F1-4 (2011).
- [9] 内閣府: 特集 交通事故死者数半減を目指して, 平成 21 年版 交通安全白書. Available at https://www8.cao.go.jp/koutu/taisaku/h21kou_haku/zenbun/genkyo/h1/h1b1s1_3.html (accessed Feb. 10, 2022).
- [10] 国土交通省自動車局安全政策課: テレマティクス等を活用した安全運転促進保険等による道路の安全. Available at <https://www.mlit.go.jp/common/001061957.pdf> (accessed Feb. 10, 2022).
- [11] 福井県 DX 推進プログラム: テレマティクス技術を活用した安全運転の推進. Available at https://www.pref.fukui.lg.jp/doc/seiki/dx/top_d/fil/program.pdf (accessed Feb. 10, 2022).
- [12] 福井県警察: 県、県警、あいおいニッセイ同和損害保険 (株) の 3 者による「デジタル時代の新たな交通安全対策」にむけた実証が SmartCityX の主要プロジェクトの一つに決定. Available at https://www.pref.fukui.lg.jp/doc/seiki/dx/smartcityx_d/fil/20210623SmartCityX_fukui.pdf (accessed Feb. 10, 2022).
- [13] 李 曙光, 山邊茂之, 佐藤洋一, 平沢隆之, 須田義大: テレマティクスデータ活用を想定した運転操作レベルの判

- 別, 生産研究, Vol. 65, No. 2, pp. 205–210 (2013).
- [14] 金子敬行: テレマティクスを活用した自動車保険, *IATSS Review*, Vol. 43, No. 3, pp. 171–180 (2019).
- [15] あいおいニッセイ同和損害保険株式会社: スマートフォンによる「テレマティクスモニター制度」を2017年1月から実施. Available at https://www.aioinissaydowa.co.jp/corporate/about/news/pdf/2016/news_2016091200318.pdf (accessed Feb. 10, 2022).
- [16] 気象庁: 東京都 天気出現率. Available at <https://www.data.jma.go.jp/tokyo/shosai/bocho/tenki/link.html> (accessed Feb. 10, 2022).
- [17] 気象庁: 過去の気象データ検索. Available at <https://www.data.jma.go.jp/obd/stats/etrn/> (accessed Feb. 10, 2022).
- [18] 警察庁交通局: 令和2年における交通事故の発生状況等について. Available at <https://www.npa.go.jp/bureau/traffic/bunseki/nenkan/030218R02nenkan.pdf> (accessed Feb. 10, 2022).
- [19] 独立行政法人統計センター: e-Stat. Available at <https://www.e-stat.go.jp/> (accessed Feb. 10, 2022).
- [20] Chen, T. and Guestrin, C.: XGBoost: A Scalable Tree Boosting System, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2016)*, pp. 785–794 (2016).