

運転時心拍の予測と経路探索への応用

田代 むつみ¹・植村 遼²・三輪 富生³・森川 高行⁴

¹正会員 名古屋大学特任講師 未来社会創造機構 (〒464-8603 名古屋市千種区不老町)

E-mail:mutsumi@civil.nagoya-u.ac.jp

²学生会員 名古屋大学大学院 環境学研究所

³正会員 名古屋大学准教授 未来材料・システム研究所

E-mail:miwa@nagoya-u.jp

⁴正会員 名古屋大学教授 未来社会創造機構

E-mail:morikawa@nagoya-u.jp

本研究では、運転中にドライバーに発生するストレスを「心拍数」の変化により定義し、車両から得られるデータや周辺の道路環境などの「運転ストレス要因」から予測するモデルを、個人の違いも考慮して構築した。さらに、レーンレベルの仮想道路ネットワークに対して本モデルを適用し、個々のドライバーにとってストレスの少ない経路をレーンレベルで誘導する、新しい経路探索への応用を検討した。モデルの予測精度向上を目的として、機械学習の1つであるRandom Forestを導入すると同時に、学習データ数の増加と運転ストレス要因の多様化を図った。運転ストレス要因には交互作用があり、これを適切に取り扱うことができるRandom Forestでは、高い精度で心拍数を推定できることを確認した。

Key Words : route search, lane-level navigation, driving stress, heart beat, random forest

1. はじめに

従来、カーナビゲーションシステムにおける経路探索では「距離」や「所要時間」、「移動費用」など、効率性・経済性に関する指標が用いられてきた。しかし、高齢者ドライバー割合の増加や、人口減少に伴う総交通量の減少が予想される現在では、単に早く・安く目的地に到着するだけでなく、ドライバーの安全性・快適性の向上も期待されており、これら心理的要素の指標化が課題となっている。

著者らは既往研究¹⁾において、運転中にドライバーに発生する不快・不安などの「運転ストレス」を、もっとも簡易に測定できる生体指標の1つである「心拍数」の変化により定義した。そして、経路探索のコストとして用いることで、個々のドライバーが苦手な運転シーンを回避する経路をレーン単位で探索する、新しい交通マネジメントシステムの提案を目指した。具体的には、名古屋市内の走行実験²⁾から得られた学生ドライバー3名の心拍数と、道路構造や交通状況などの「運転ストレス要因」との関係のモデル化を、回帰分析により試みた。さらに、レーンレベルネットワークによる経路探索を行うと共に、走行実験により提案手法の有効性を検討した。

一連の研究の結果、運転ストレス要因の定義には、道路の車線数や走行車線位置、車線変更など「レーンレベル」の概念が必要であること、また運転ストレスを「安静時平均心拍数からの差分」として定義し経路探索コストとして用いることにより、従来の「所要時間」を最小化する経路探索よりも、ドライバーにとって落ち着いて走行できる経路を探索できることを確認した。その一方、例えば同じ走行速度であっても、車線数や中央分離帯の有無などの道路構造、さらには周辺の交通状況によって感じ方が異なるように、運転ストレス要因の影響は独立ではなく、各種要因の非線形な影響も考慮できる分析手法の導入が課題となった。

本研究では、運転時心拍数をより精緻に予測することを目的とし、新たに機械学習の1つであるRandom Forest³⁾を導入した。Random Forestは、ランダムにサンプリングされた学習データから複数の決定木(弱学習器)を作成し、その結果を統合(森)することで、交互作用の存在も適切に考慮して、より高い予測性能を得ることができる手法である。学習データ数の増加のため、既往研究で用いた学生ドライバー3名分のデータに加え、本研究では新たに、高齢ドライバー3名の実験データも取り扱った。また、走行実験中に車両前方/後方・車内で撮影

された動画データも新たに利用することで、より多くの「運転ストレス要因」を説明変数として取り扱った。さらに本研究では、得られた運転時心拍数予測モデルを仮想道路ネットワークに適用し、個別最適化経路探索への応用を検討した。

2. 走行実験データの概要

本研究は、2014年12月～2015年2月に、金森ら²⁾が名古屋市内で行った走行実験のデータを使用し、運転時心拍予測モデルを作成した。この実験では、運転時のストレスを把握するため、被験者に生体反応計測機器を装着し、名古屋市内の90分弱の指定コース（商店街、バスレーン、住宅街、山道を含む）を走行している。被験者は健康な20代の男子学生3名、および60代の高齢男性3名である。被験者には事前に指定コースを覚えてもらい、走行中はナビゲーションや、同乗者（後部座席）との発話は行っていない。コースのみを指定し、車線変更のタイミング等は、道路状況に応じて被験者の自由意思で行った。実験は、天候の良い昼間に、各日1回実施し、被験者毎に3～5回程度実施した。本研究ではこのうち、後述する実験データ全て取得できた回について（機器の故障等により、計測データが一部でも欠損した回を除いて）、分析対象とした。表-1に、各被験者の属性を示す。

表-1 被験者属性

被験者	A	B	C	D	E	F
年齢 (歳)	23	23	23	60	66	62
運転歴 (年)	6	6	5	35	45	34
運転頻度	高	中	低	高	高	高
運転の自信	有	有	無	有	有	有
実験数 (回)	4	4	4	3	2	2
データ総数	16661	19320	18777	13660	8795	9587

走行実験では生体反応として脳血流、心電図、呼吸、顔面皮膚温、発汗、筋電図を計測した。同時に、実験車両（トヨタプリウス）からのCANデータ、GPSによる車両位置データ、車両前後と被験者の車内行動の動画データを取得した。運転前後には、5分程度の安静時間を設け、安静時生体反応の計測を行った。

本研究では、既往研究¹⁾と同様、比較的計測が容易な「心拍数」を運転ストレスと定義し、これに影響を与えると思われる「運転ストレス要因」を、表-2の通り32項目抽出して分析に用いた。車両の状態を表すCANデータは実際の計測値を用い、動画データは後にモデルを構築する際に説明変数として使用するため、0, 1の2変数で表現し、各項目が当てはまる、または存在する時に1とした。なお、データはそれぞれ取得間隔が異なるため、

全て1秒毎のデータに変換し、同期することで用いた。

表-2 走行実験から抽出した運転ストレス要因

データ	分類	運転ストレス要因
CAN	車両状態 (3項目)	<ul style="list-style-type: none"> 加速度 (m/s^2) 車速 (km/h) 舵角 (deg)
		<ul style="list-style-type: none"> 片道一車線以下 片道二車線 片道三車線以上 歩道の有無 歩道 街路樹の有無 中央分離帯の有無 中央分離帯 街路樹の有無 山道区間 高速道路 分流路 高速道路 合流路 信号無し交差点 沿道車両出入口
動画	走行車線 (4項目)	<ul style="list-style-type: none"> 車線変更中 左端車線を走行 右端車線を走行 中央 (右/左端以外) を走行
	周辺車両 (6項目)	<ul style="list-style-type: none"> 左車線前方車両の有無 右車線前方車両の有無 同一車線前方車両の有無 左車線後方車両の有無 右車線後方車両の有無 同一車線後方車両の有無
	路上駐車 (1項目)	<ul style="list-style-type: none"> 自車が第一車線走行時の同車線の路上駐車の有無
	自転車歩行者 (4項目)	<ul style="list-style-type: none"> 前方歩行者の有無 前方自転車の有無 右折時の横断者の有無 左折時の横断者の有無
	対向車 (1項目)	<ul style="list-style-type: none"> 分離帯が無い場合の対向車の有無
	運転手挙動 (1項目)	<ul style="list-style-type: none"> 運転手の運転行動外の挙動の有無

図-1に、安静時および運転時の平均心拍数と、心拍数の分散を示す。安静時の心拍数は、日によって、また運転前後で、その平均値が異なる傾向が、全ての被験者において確認された。特に、運転前の方が運転後に比べて、やや心拍数が高い傾向が得られた。このため本研究では、実験日毎に、運転前と後のそれぞれについて95%の範囲のデータで平均値を求め、その平均を「安静時心拍数」と定義した。また、運転時心拍数も同様に、95%の範囲のデータで平均値を求めた。学生と高齢者の間で年齢による傾向は、平均心拍数についてはあまり見られなかったが、心拍数の変動については高齢者の方が小さい結果となった。安静時と運転時の比較では、平均値、分散ともに運転時の方が大きく、外部からのストレス要因によって、心拍数が大きく変動していることが分かる。




図-1 各被験者の平均心拍数 (上段) と心拍数の分散 (下段)

3. 運転時心拍数予測モデルの構築

(1) Random Forestの概要

Random Forest³⁾は、機械学習のアルゴリズムであり、ランダムにサンプリングされた学習データにより複数の決定木 (弱学習器) を作成し、組み合わせることによって精度の高い強学習器を作成する手法である。本研究で扱う「心拍」のように、被説明変数が連続的な数値である場合は、回帰木 (regression tree) による予測問題として、Regression Forest とも呼ばれる。

以下に、本研究で行った、回帰問題におけるRandom Forestのアルゴリズムを示す (図-2)。

【学習】

- 1) 総データ数の7割をランダムに抽出して学習データ x とし、ここから重複を許してランダムサンプリングをして、 B 組のデータセットを作成。
- 2) 全ての説明変数 (32個) から N 個の変数をランダムサンプリングしたものを B 組作成。
- 3) 各サンプルを用いて深さ M の回帰木を B 本作成。木の各枝の分かれ目 (node) には説明変数の判別条件、各枝の先 (leaves) には、被説明変数の出力値 (心拍数平均値) が与えられる。

【評価】

各木の出力値の平均により予測値 y を導出

Random Forest では、作成する木の木数 B が大きいほど精度は高くなるが、木の深さ M はある程度以上になる

と、過学習により予測精度が下がってしまう。本研究では、各回帰木の作成に使用する説明変数の数 N と木の深さ M を同数と設定し、 M と B が予測精度に及ぼす関係を予め系統的に調べた上で、計算効率も考慮して $B=100, M=10$ と設定した。

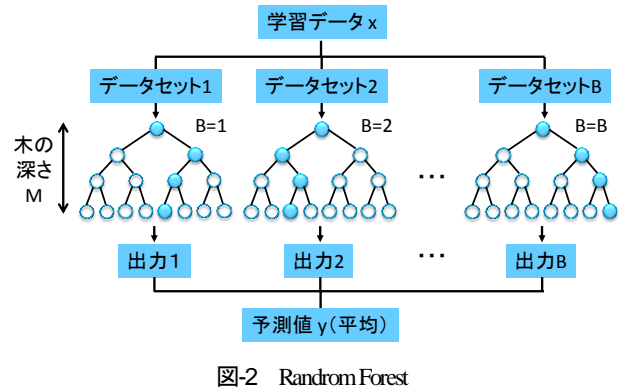


図-2 Random Forest

(2) 運転時心拍数予測モデル

運転時の1秒毎の心拍数 (回/min) を被説明変数とし、表-2 に挙げた運転ストレス要因を説明変数とするモデルを考える。個人によって心拍数の平均値およびその分散も異なること、また運転ストレス要因による心拍上昇の程度も異なることから、本研究では被験者毎にモデルを作成した。

比較のため、既往研究と同様に回帰分析によるモデルと、本研究で新しく導入した Random Forest によるモデルの両方を作成した。ただし、重回帰分析では、表-2 のパラメータのうち「加速度」と「舵角」については、正値をとる場合と負値をとる場合で別の説明変数とし、その絶対値を変数値とした。また、多重共線性を回避するため「単車線」の変数は取り除いた。

図-3 に、予測モデルにより推定した心拍数と、実際の計測心拍数の関係を示す。図中には、各モデルの RMSE の値を併記する。回帰分析に比べて Random Forest の方が 45 度線に近い分布をしており、高い予測精度を持つことが確認できる。図-4 に、時系列に沿った心拍数の計測値と、両モデルによる推定値の例を示すが、ここからも、Random Forest による推定値は、運転中の心拍数の変化を、概ねよく再現できていることが分かる。

なお、図-4 中には、代表的な説明変数の時系列変化も併記したが、車両の状態を表す加速度、速度、舵角が大きく変化する部分では心拍数も変化する様子が確認された。著者らの既往研究¹⁾における走行実験においても、速度が大きい区間では心拍数が上昇し、逆に赤信号による停止中は安静時よりも心拍数が低下する様子が確認されており、走行状態と心拍数には密接な関係があることが分かる。

一方、実際に計測された心拍数は大きく変化しているにも関わらず、両モデルによる推定値では心拍数が変化していない時間帯も数箇所見られた。これらの時間帯について、走行中に撮影した動画データを再度見直してみた結果、被験者が深呼吸をしたり、手で顔をかくなど、運転以外の行動をしていたり、路面の段差等で瞬間的に被験者の体が上下（または左右）に揺れているなど、何らかのイベントが起きていた。そして、これらの情報が 0,1 の 2 変数で起こしたデータに反映されていなかったことが確認された。動画からのデータ起こしは、1 秒毎に動画を停止させて手で記録しており、入力データの精度は課題である。

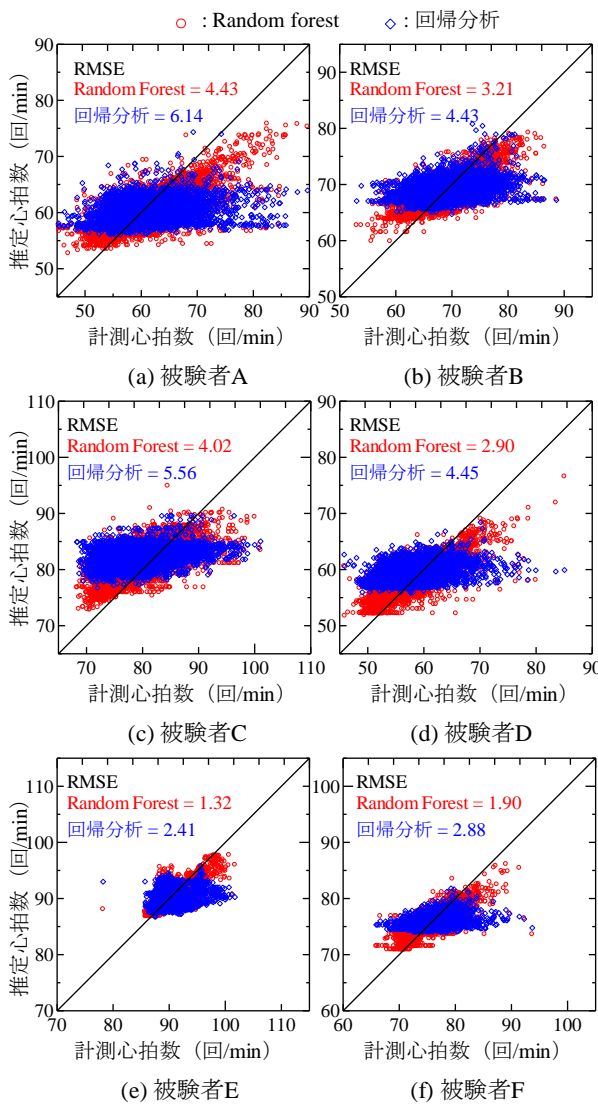


図-3 計測心拍数と推定心拍数の比較

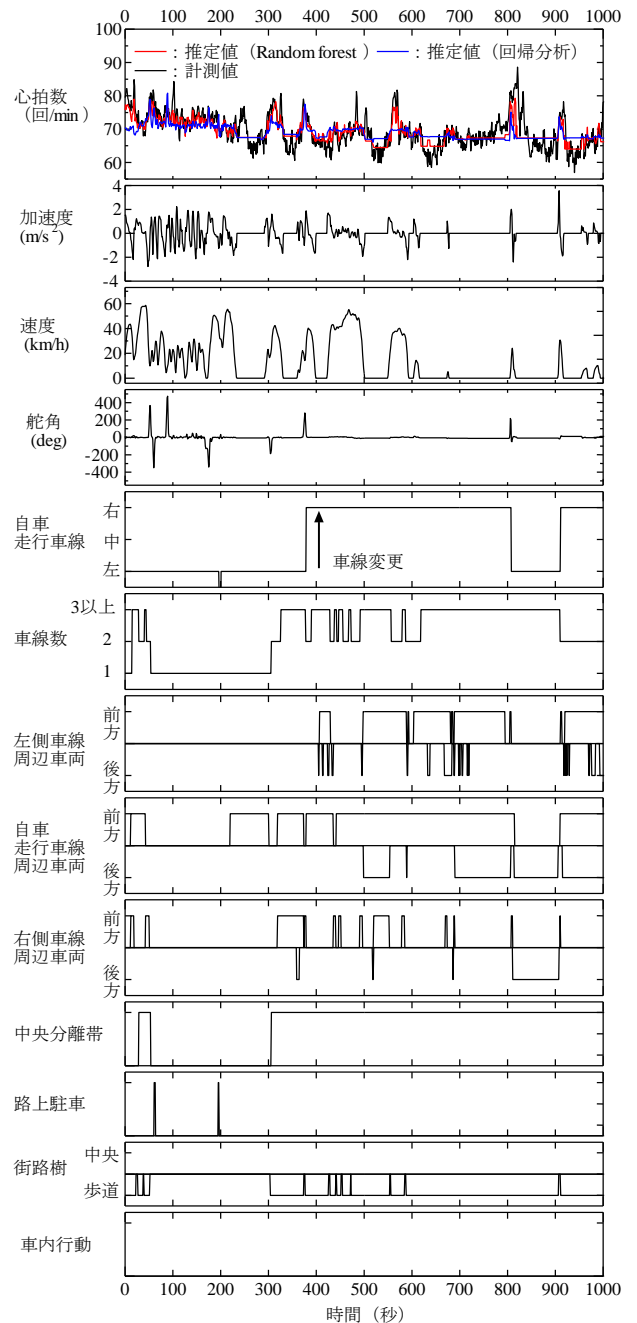



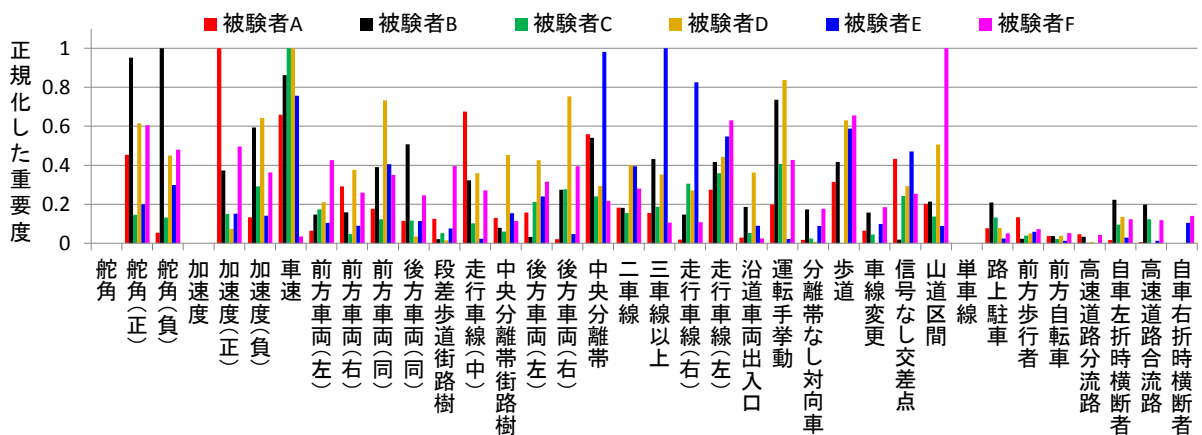
図-4 計測/推定心拍数と説明変数の時系列変化

続いて、心拍数の変動にどの説明変数が大きく影響を与えているかを調べるため、各説明変数の重要度を被験者毎に求めた。Random Forestによる重要度とは、回帰木を構築する際に、該当変数をモデルから除いた際の予測精度の低下量に相当する。また、回帰分析による重要度としては、本研究では標準化回帰係数を用いた。

図-5に、被験者6名分のデータについて、各説明変数の重要度を示す。Random Forestと回帰分析では重要度の定義が異なるのに加え、モデルは被験者毎に作成していることから、ここでは被験者毎の最大値で正規化した値で示している。重要度の大小より、同じ道を走ってもス



(a) Random Forest による重要度



(b) 回帰分析による重要度

図-5 運転時心拍数予測モデルにおける各説明変数の重要度

トレスの感じ方は個人により異なることが分かる。また、同一個人で比較すると、Random Forest と回帰分析では、重要度の大小の順が大きく異なる。Random Forest では、いずれの被験者も、車両状態を示す「加速度」「速度」「舵角」の3つの変数の重要度が大きく、運転時心拍数の変化と関係が強いことが明らかとなった。

運転ストレス要因とした説明変数には交互作用（例えば、中央分離帯が無い時の方が速度の増加によるストレスを感じやすい、車線変更先の車線に前方/後方車両が存在する時の方が車線変更をストレスに感じるなど）があり、Random Forest ではこの存在を自動的に適切に考慮することができるため、高い予測精度が得られたと考えられる。回帰分析でも、交互作用項を導入することはできるが、本研究のように多くの説明変数を用いる場合には容易ではなく、また多重共線性も生じやすくなるため注意が必要となる。

4. 仮想道路ネットワークを用いた経路探索

(1) レーンレベルネットワークの作成

前章で作成した運転時心拍数予測モデルを仮想道路ネットワークに適用し、個別最適化経路探索への応用を検討した。以下では、より高い精度が得られた Random Forest によるモデルを用いる。

心拍数の変化には、道路の車線数や走行車線位置、車線変更など、「レーンレベル」の概念が必要となる。既往研究^リでは、複数車線からなる実道路を用いてレーンレベルネットワークを作成したが、直線部のみを対象としたため、右左折や交差点による影響が考慮できなかった。このため本研究では、最も単純ではあるが、交差点での右左折も表現することのできるレーンレベル仮想道路ネットワークを作成し、経路探索を行った。道路はレーン毎に、直線部、曲線部をポリゴンに分割して表現し、各説明変数（運転ストレス要因）を、以下のルールで各ポリゴンに埋め込んで表現した。一例を図-6に示す。

<車両状態>

- 車速：直線部は 50(km/h)，曲線部は 25(km/h)
- 加速度：前後のポリゴンの車速の変化から計算
- 舵角：直線部は 0(deg)，曲線部は±90(deg)
- 車線変更時は斜め前に進むとして±30(deg)

<道路構造>

片道三車線以上，全て段差歩道と中央分離帯有りとし，それ以外の説明変数は全て 0（無し）

<走行車線>

経路探索で求めたポリゴンの位置に従う

<周辺車両，路上駐車，自転車歩行者>

説明変数毎に，存在の有無を 50%の割合で設定（全ての被験者で共通の値を設定）

<対向車>

分離帯が全て存在し，走行中に見える対向車は無し

<運転手挙動>

簡単のため全て 0（無し）

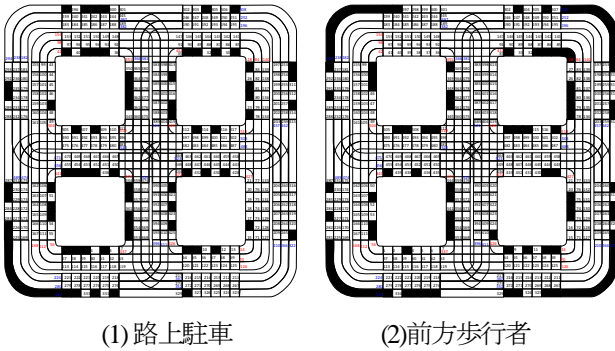


図-6 説明変数の与え方の例

(黒く塗りつぶしたポリゴン：説明変数を 1 (有り) と設定)

(2) 運転時心拍数変化最小経路探索

レーンレベル経路探索には，Dijkstra法を用いた。ポリゴン*i* から *j* に移動する際のコストは，Random Forestによる運転時心拍数予測モデルで求めたポリゴン*i* で発生する心拍数 HR_i (回/min) と安静時平均心拍数 RHR_{ave} と (回/min) の差分に，ポリゴン*i, j* 間の所要時間 t_{ij} (min) を乗じた値とし，以下の式を満たす「ドライバーの心拍数が安静時に比べて大きく上昇する瞬間を避ける経路」を求めた。

$$\min \sum_{i \in E} (HR_i - RHR_{ave}) t_{ij} x_{ij} \quad (\text{回}) \quad (1)$$

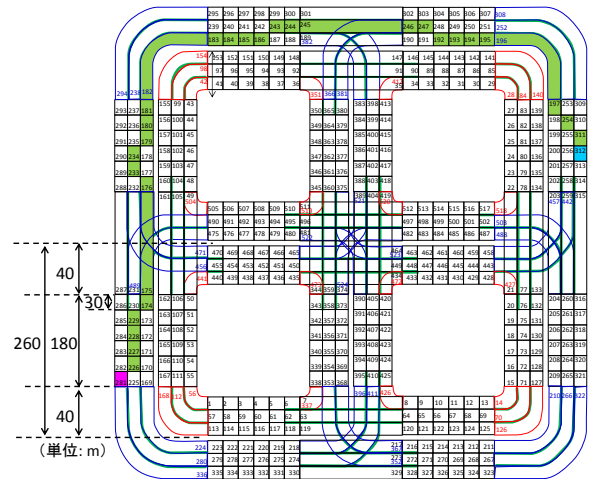
$$\sum_{i: j \in E} x_{ij} - \sum_{j: i \in E} x_{ji} = \begin{cases} 1 & (i = o: \text{起点}) \\ -1 & (i = d: \text{終点}) \\ 0 & (i \in N - \{o, d\}: \text{起終点以外}) \end{cases} \quad (2)$$

ここに， N はポリゴンの集合， E はポリゴンを結ぶ対の

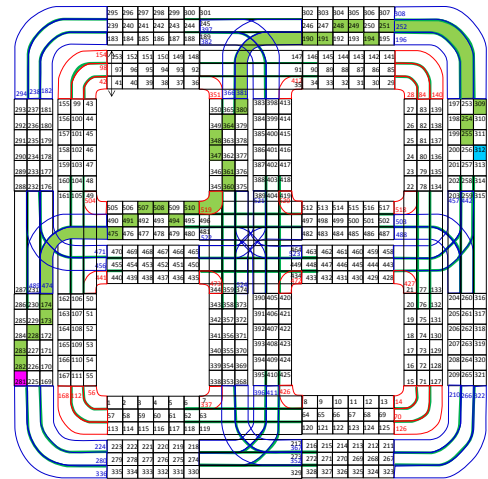
集合であり， $x_{ij} \in \{0,1\}$ である。ポリゴン*i* から *j* の移動に車線変更を伴う場合は， HR_i に車線変更による心拍の増加分が加算される。

経路探索結果を，図-7 に示す。学生と高齢者の中から 1名ずつ，データ数が多くモデルの予測精度が高い被験者 B と被験者 D について経路探索を行った。起終点は同じであるが異なる探索経路が得られ，個人による運転ストレスの感じ方の違いが表現できている。

図-5(a)では被験者毎に正規化しているため，被験者毎の違いが分からないが，例えば「舵角」の重要度は被験者 D に比べて被験者 B は 1.8 倍大きな値であり，被験者 B の方が右左折に対して敏感に反応している。このため，経路探索においても，被験者 B は右左折を避けて外周を走行する結果となったと考えられる。



(a) 被験者 B



(b) 被験者 D




図-7 運転時心拍数の変化最小経路の探索結果

5. 結論

本研究では、運転中にドライバーに発生するストレスを心拍数の変化により定義し、運転ストレス要因（車両の状態や周辺の道路環境）との関係のモデル化を試みた。そして、推定された運転ストレスを経路探索におけるコストとして用いることで、個々のドライバーにとってストレスの少ない経路をレーンレベルで誘導する、新しい交通マネジメント手法を提案目指した。

モデルの予測精度向上を目的として、運転ストレス要因の多様化に加え、機械学習の1つであるRandom Forestを新たに導入し、6名の被験者（学生3名、高齢者3名）に対して、運転時心拍推定モデルを構築した。この結果、運転ストレス要因には交互作用があり、この存在を適切に考慮できるRandom Forestでは、高い精度で運転時心拍数の変化を推定できることを確認した。本研究ではさらに、仮想道路ネットワークに対して推定モデルを適用し、経路探索への応用を検討した。

今後は、さらなるデータ蓄積・分析に加え、より説明力の高いモデル作成のために、運転ストレス要因の多様

化と、より精緻なデータ取得方法の検討が必要と考える。また、音声などによる経路誘導が運転ストレスに及ぼす影響や、所要時間と運転ストレスのトレードオフの関係、車間距離など運転リスクも考慮した探索コストの導入なども課題である。

謝辞：本研究は国立研究開発法人科学技術振興機構（JST）の研究成果展開事業「センター・オブ・イノベーション（COI）プログラム」、およびJSPS科研費26630240の助成を受け行われた。

参考文献

- 1) 田代むつみ, 塚本健太郎, 三輪富生, 森川高行: 運転ストレス最小化に向けたレーンレベル経路探索・誘導効果の検証, 第 53 回土木計画学研究発表会, 2016.
- 2) 金森亮, 久保田穰, 安藤章, 山本俊行, 森川高行: 複数生体データ計測による運転ストレスに関する基礎的分析, 第51回土木計画学研究発表会, 2015.
- 3) Breiman, L.: Random Forests, Machine Learning, Vol. 45, No. 1, pp.5-32, 2001.

(2017. 4. 28 受付)