

18. トンネル工事の作業ライン生産性の可視化方法に関する研究

株式会社まざらん
株式会社キック
西松建設株式会社

○西垣 重臣
才原 勝敏
鬼頭 夏樹

1. はじめに

トンネル工事建設機械（ドリルジャンボ、ブレーカ、サイドダンプ、吹付け機など）が形成する作業ラインの生産性を可視化する予測判別モデルについて報告する。

この予測判別モデルの構築に際して、我々の研究活動で培った学習の仕方と蓄積してきた数理モデルを転移学習するとともに、強化学習の一つである Actor-Critic の枠組みを活用する。転移学習とは、ある問題を効果的かつ、効率的に解くために、別の関連した問題のデータや学習結果を再利用することをいう。Actor-Critic とは、試行錯誤の結果を評価して、より良い行動を選択して学習していく制御の枠組である。

まず、関連する研究と予測判別モデルの特徴について述べる。つぎに、研究対象とするトンネル工事の概要を示す。そして、転移学習の過程と Actor-Critic に枠組みに基づいた予測判別モデル、そして、このモデルの適用結果などを報告する。最後に、まとめと今後の課題を示す。

2. 関連する研究

切羽前方探査、変位予測、3Dレーザースキャナによる三次元形状計測、地盤判別、掘削機の自動化など多種多様な研究がある¹⁾。これらの研究をみると、トンネル建設機械稼働管理に関して、転移学習や強化学習を活用した研究は少ないようである。

今までに、再帰分割手法を活用した不安全行動のテンプレート²⁾、協働的施工作業のための施工プロファイル³⁾、急峻な作業道において稼働する林業機械のオペレータを支援する取り組み⁴⁾などに関する研究を行ってきた。

予測判別モデルを構築する際に、これらの研究活動で培った学習の仕方と蓄積してきた数理モデルを改良のうえ再利用する。この予測判別モデルの特徴をつぎに示す。

- (1) トンネル工事建設機械の稼働により励起される三軸加速度の時系列データを対象とする。
- (2) このデータから有用なパターン、傾向など

を検出し、判断基準としての閾値などを形式化し、予測判別モデルを構築する。

(3) このモデルにより作業種別ごとの実稼働時間と全実稼働時間、サイクルタイム（ピッチタイム）、ラインバランス・ロスなどの定量的指標を出力する。ラインバランス・ロスとは、建設機械編成バランスによる作業配分の非効率性を示す定量的評価指標である、

(4) これらの定量的評価指標と時系列グラフ、箱ひげ図、ピッチダイヤグラムなどのグラフをインフォグラフィックスとして自動的に生成する。ピッチダイヤグラムとは各建設機械の稼働時間のバランス状態を図示したものである。

ピッチタイムとボトルネック、そしてラインバランス・ロスの関係を図-1に示す。

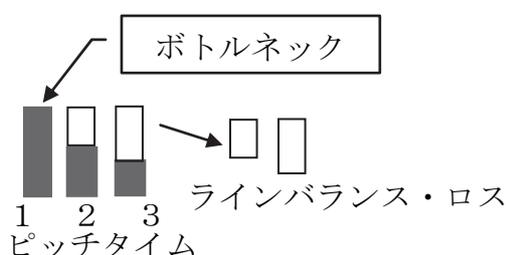


図-1 ピッチタイムとボトルネック、そしてラインバランス・ロスの関係

(5) 強化学習の一つである Actor-Critic の枠組みに基づいて予測判別モデルを構築し、適用する。

(6) 利用者は、これらの定量的評価指標とインフォグラフィックスを一目みることで、作業ラインの生産性の現況を視覚的に理解できる

(7) 結果として、作業ライン生産性の可視化により適時的確な意思決定と迅速な対策の促進が期待できる。

2. 工事概要

研究対象とするトンネルは、高知県幡多郡黒潮町佐賀橋川～拳ノ川間における全長 665m の

山岳トンネルである。このトンネルは高知県高岡郡四万十町金上野から幡多郡黒潮町拳ノ川にかけて計画されている自動車専用道路である一般国道56号片坂バイパスの最も終点側に位置する(図-2)。



図-2 片坂バイパス全体図

国道56号片坂地区は、急カーブ(R=80m以下7箇所)と急勾配(最急縦断勾配7%)の連続により事故危険箇所となっているとともに、落石や法面崩壊等の災害危険箇所となっている。このバイパスは、災害時の危険箇所の回避および南海地震・東南海地震に備えるための代替路線として整備が進められている。この事業により、安全で円滑な通行が可能となり、将来は四国8の字ネットワークの一端を担うとともに、高知西南地域における地域間交流の活性化に寄与することが期待されている。

2.1 地形概要

当該地域は標高200~400mの山地であり、周辺は隆起した地形面が強い侵食を受け形成された地形区で、「伊与木川侵食面」と称される。全体に山頂や稜線が狭く尖った山体形状を呈するとともに、斜面は急峻であり、尾根から山麓までおおむね一様な傾斜を示す。

拳ノ川トンネルは、延長665mのトンネルで、測点No. 101+50付近で最大土被り約80mとなる。測点No. 100+60付近、No. 103+70付近、No. 105+10付近で沢地の下を通過し、土被りはそれぞれ約20m、約20m、約15mである。

坑口部の地形とトンネル軸線との関係は、起点側で斜面直行型、終点側で尾根部進入型となる。また、終点側坑口に緩んだ尾根が認められる。

2.2 地質概要

当該地域周辺の基岩地質は、四万十帯北帯に属する、中生代白亜紀の野々川層と呼ばれる地層である。この地層は砂岩、泥質岩およびその互層で構成され、当地区では泥質岩優勢層を主体とする地層が分布する。地層の構造は場所により変化するが、概ね東西方向の走向を有し、

北傾斜となる。泥質岩は、岩自体に割れ目が非常に多く、破碎された箇所も多い。このため、場所によっては地表面下10m以上の深さまで土砂状に強風化するところもある。

具体的には、トンネル全線において露頭レベルで確認できる断層が5条存在すると想定されており、トンネル掘削への影響が懸念されていた(図-3)。

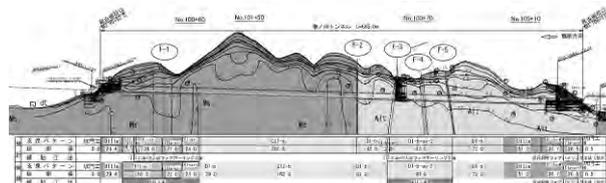


図-3 地質縦断図

3. 転移学習過程と予測判別モデル

3.1 センサ

工事現場におけるデバイス機器類の管理の煩雑を軽減するために、スマートフォンGalaxy S3に内蔵されている3軸加速度計を使用する。このセンサは計測データのログ機能とデータ送信を担うアプリケーションを持つ。そのアプリケーションの画面を図-4に示す。ここで得られる計測データの変数名は、時刻、x軸加速度、y軸加速度、z軸加速度などである。

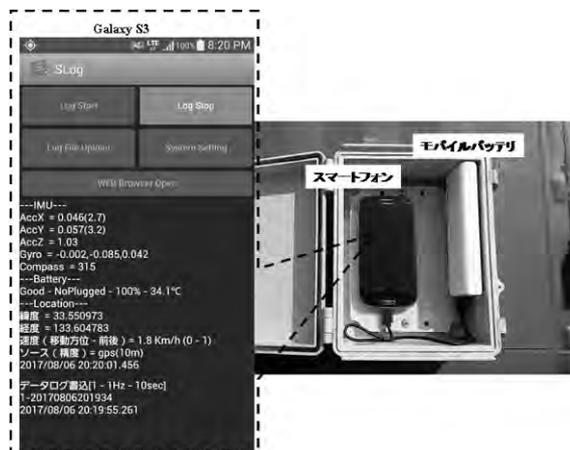


図-4 スマートフォンのアプリケーション画面

3.2 転移学習過程

本研究で採用した転移学習過程について述べる。今までの研究から、バックホウ、ブルドーザなどの建設機械の稼動によって励起する加速度応答値の平均値と分散の変化点、そしてその時刻を把握することにより、その実稼動時間を計算できることが分かっている。この情報と知

識をトンネル工事の作業ラインを形成する建設機械の生産性を可視化する予測判別モデルの開発に再利用する。

ここでの転移学習過程は、教師付きデータによる学習と目標とする教師なし観測データの学習に分かれる。

(1) 教師付きデータを得るための事前調査

作業種別ごとの時系列データの経時変化に注目する。対象とする建設機械とその作業種別の名称（ラベル）を以下に示す。

- ①ドリルジャンボ：上半穿孔，下半穿孔，ロックボルト
- ②ブレーカ：こそく
- ③サイドダンプ：ざり出し
- ④吹き付け機：一次吹き付け，二次吹き付け，支保工建て込み，下半吹き付け

これらの建設機械にスマートフォンを車載し、ワンシフト（昼番）間の三軸加速度を計測した。このときのサンプリング周波数は100HZである。同時に、作業種別ごとの開始時刻と終了時刻を目視判断で作業時間記録表に記録した(図-5)。両者をつき合わせて教師（ラベル）付き学習データを編集した。

作業内容	機械名称	エンジンON	エンジンOFF	作業開始	作業終了	エンジンON	エンジンOFF	備考
穿孔・装薬	ドリルジャンボ	10:07	10:08	10:13	11:15	10:07	11:21	
発破						11:15		11:24
ズリだし	サイドダンプ	11:40		11:43	12:19		12:30	11:40~11:45
コンク	ブレーカ	11:40		11:43	11:40		12:37	
一次吹き付け	吹き付け機	12:37		12:38	12:42			
支保工建て込み	吹き付け機	12:37		12:48	14:20			
二次吹き付け	吹き付け機			14:21	14:23	14:23	14:24	
下半吹き付け	吹き付け機				14:24	14:24	14:43	
カストリ	ブレーカ	14:23		14:24	14:34		14:42	
ロックボルト	ドリルジャンボ	14:43	14:48	14:50	15:38			

図-5 作業時間記録表

この学習データを解析することで得た知見をつぎに示す。

- ① 上下方向加速度の経時変化をみると、発破特に衝撃を受けて建設機械の自由落下事象が発生している。
- ② 平均値と分散の変化と作業種別
加速度応答値の波形変化をみると、平均値と分散の変化に作業種別の違いがよく表れる。ドリルジャンボの作業種別の違いは、三軸加速度の前後方向加速度の波形変化によく表れる。吹き付け機の作業種別の違いは、三軸加速度の左右方向加速度の波形変化によく表れる。
- ④ ブレーカは前後方向加速度の、サイドダンプは左右方向加速度の分散の違いにより実稼働

を把握できる。

(2) 目標とする観測データの学習

長期間に亘るサンプリング周波数 100Hz の計測は、データ容量を非常に大きくし、計算負荷が重たくなる。そこで、実務適用時を想定して、サンプリング周波数を 1Hz とする。

この観測データは教師なし学習データである。この学習データの経時変化は事前調査時の学習データと類似の動きを示す。そこで、事前調査時の学習データで得られた知見に基づいて、この教師なし学習データの一部を取り出し、作業種別のカテゴリを付与して教師つき学習に整形する。

ドリルジャンボの前後方向加速度の波形変化を図-6 に、作業種別ごとの前後方向加速度の箱ひげ図を図-7 に、それぞれ示す。この図は、中央値を中心とした範囲値（上限値と下限値）により作業種別を識別できることを示唆している。

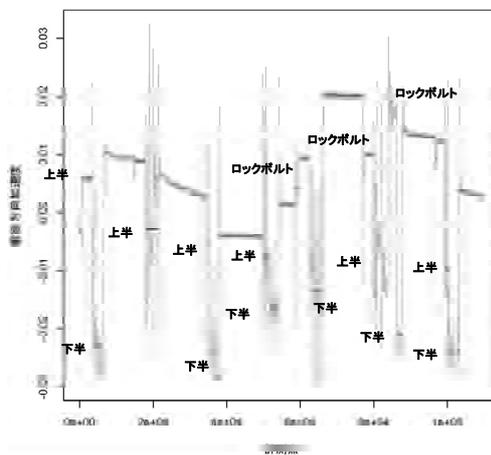


図-6 ジャンボドリルの前後方向加速度の波形変化と作業種別のカテゴリ

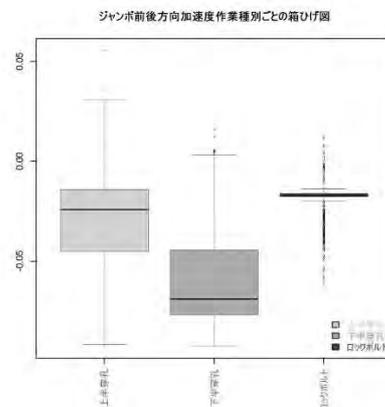


図-7 ジャンボドリルの前後方向加速度作業種別ごとの前後方向加速度の箱ひげ図

事前調査時の学習過程において得た知見と同様に、三軸加速度の経時変化をみると、特定の軸に待機時と実稼働時の分散が大きく異なる現象をみてとれる。そこで、分散の変化点とその時刻を検出することで、実稼働時間を計算する。

3.3 Actor-Critic の枠組みと予測判別モデル

Actor-Critic の枠組みに基づいた予測判別モデルの概要を図-8 に示す。

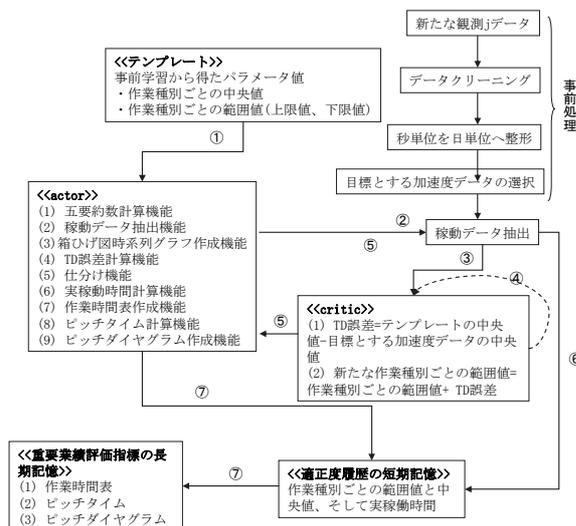


図-8 Actor-Critic の枠組みに基づいた予測判別モデルの概要

予測判別モデルは、テンプレート、actor, critic, 適正度履歴(eligibility trace)⁵⁾ の短期記憶、重要業績評価指標の長期記憶などで構成される。

(1) 事前処理

新たな観測データを入手したとき、先ず、データクリーニングを行い、1秒単位の計測データを日単位に整形する。データクリーニングでは、既定の配列ではないレコード、欠測値を含むレコード、外れ値などを除去する。外れ値の除去には中央値絶対偏差(MAD: Median Absolute Deviation)を使う。つぎに、三軸加速度のうち目標とする加速度の軸を選択する。そして、分散の変化点とその時刻を捉え、稼働状態のデータを抽出する。

(2) テンプレート

テンプレートは、事前学習から得たハイパーパラメータ値である作業種別ごとの中央値と作業種別ごとの範囲値(上限値, 下限値)を持つ。ハイパーパラメータとは、学習を行う際に、これまでの知見に基づいて、予め設定しておかなければいけないパラメータである。

(3) 観測データの構造

予測していない作業環境の変化や事象生起により新たなデータは構造的に学習モデルのもの

と異なるかもしれない。例えば、歪みや尖りの変化と中央値の上方または下方にシフト、トレンドの発生、不規則変動の顕著な発生、欠測値の増加、新しい事象の発生などのような事象が想定される。

このような事象に直面したときは、センサの点検、計測データの品質チェックとデータクリーニング、ノイズ進入ルートの探索と遮断、予測・判別モデルのハイパーパラメータ調整などのような対策が必要になる。

対象とする計測データの構造が学習データの構造と乖離していないかを見る。その簡便な方法として、日単位の箱ひげ図の時系列グラフを作成する。ドリルジャンボの稼働データの箱ひげ図の時系列グラフを図-9 に示す。中央値の変動がみてとれる。

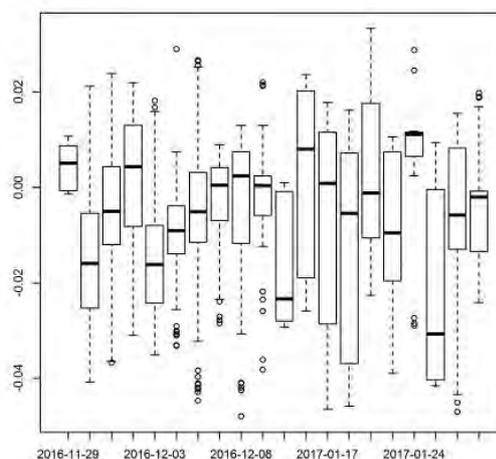


図-9 ドリルジャンボの稼働データの箱ひげ図の時系列グラフ

(4) Actor の行動

- ① Actor は行動選択と実行能力を持ち、テンプレートが持つパラメータ値を使って、目標とする計測データを解析する。
- ② Actor は、その計測データの分散の変化点とその発生時刻を把握する。分散の第一四分位数を閾値として、これを超える分散が発生している時刻に建設機械は稼働していると判断する。この判断に基づいて、稼働データを抽出する。
- ③ Actor は、目標とする稼働データの中から、作業種別ごとの中央値を中心として範囲値内にある計測値を選択する。その計測時刻を対象にして日単位の稼働時間を計算し合計を取る。
- ④ Critic は、actor による解析結果を評価する。計測値の中央値と学習モデルの中央値との差で

ある TD (temporal-difference)誤差により作業種別ごとの範囲値を補正する。

- ⑤Actor は Critic の評価結果を受けて、目標とする計測データを再度解析し、作業種別ごとの範囲値と中央値、そして実稼働時間を出力する
- ⑥これらの出力結果は適正度履歴として短期記憶される。
- ⑦Actor は、短期記憶情報に基づいて、重要業績評価指標である作業時間表、ピッチタイム、ピッチダイヤグラムなどの可視化情報を出力する。これらの可視化情報は長期記憶される。

3.4 中央値絶対偏差

中央値は、データの中心性を計る尺度であり、平均値よりは外れ値の影響を受けない。中央値を中心としたバラツキを考慮したい。そこで、中央値絶対偏差を活用する⁶⁾。中央値絶対偏差は、観測データの各値からその中央値を引いた値の絶対値の中央値として(1)式により計算される。

$$MAD(x) = median(abs(x, -median(x))) \quad (1)$$

ここで、MAD: 中央値絶対偏差、abs(): 絶対値、median()は中央値を計算する関数である。作業種別ごとの範囲値（上限値、下限値）の計算と外れ値の検出に(2)式を用いる。

$$outlierMAD = K \times abs(x - median(x)) / MAD(x) \quad (2)$$

ここで、K: cut off パラメータ、abs()は絶対値を取る関数などである。

3.5 分散の変化点の検知方法

時系列データの変化点を検知する手法として、2分割(binary segmentation)と最適分類⁷⁾に習い、観測データの分散の変化点を検知する手順をつぎのようにする。

- 手順1: 目標分割数を決める。
- 手順2: 時系列データを走査し、群間分散と全分散の尤度比が最も大きい点でデータを2分割する。
- 手順3: 2分割したデータ群、それぞれに手順2を適用する。
- 手順4: 分割したデータ群数が目標分割数に達したら、手順を終了する。

4. 予測判別モデルの適用

学習データ計測以後に計測されたデータに、予測判別モデルを適用した結果を報告する。

作業記録表から計測期間の稼働時間を抽出して作成した作業時間表を表-1 に示す。予測判別

モデルの出力である作業時間表を表-2 から表-5 に示す。

表-1 作業記録表に基づく作業時間表

建設機械	作業種別	作業時間(分)	サイクルタイム(分/m)
ジャンボドリル	削岩ロックボルト	479	3.74
ブレーカ	こそく	78	0.61
サイドダンプ	ずり出し	225	1.76
吹き付け機	吹き付け・支保工建て込み	538	4.2
作業時間合計(分)		1320	10.31
進行長(m)		128	

表-2 ドリルジャンボ作業時間表

	時間(分)	比率%
待機時間	3863	89.421
上半穿孔時間	58	1.343
下半穿孔時間	265	6.134
ロックボルト時間	127	2.94
稼働時間	457	10.579
全計測時間	4320	100

表-3 ブレーカ作業時間表

	時間(分)	比率%
待機時間	4247	98.3
こそく時間	73	1.7
全計測時間	4320	100

表-4 サイドダンプ作業時間表

	計測時間(分)	比率%
待機時間	4098	95
ずり出し時間	222	5
全計測時間	4320	100

表-5 吹き付け機作業時間表

	計測時間(分)	比率%
待機時間	3765	87.153
一次吹き付け時間	31	0.718
二次吹き付け時間	196	4.537
下半吹き付け	97	2.245
支保工建て込み時間	200	4.63
稼働時間	555	12.847
全計測時間	4320	100

サイクルタイム(分/m)の棒グラフとラインバ

ランスロス率のインフォグラフィックスであるピッチダイヤグラムを図-10に示す。このピッチダイヤグラムから、吹き付け機による作業がボトルネックとなっていることが分かる。ラインバランスロス率は(3)式で求められる。ここでピッチタイムはサイクルタイムを指す。

ラインバランスロス率 = (工程数 × ボトルネック工程のピッチタイム - 各工程のピッチタイムの合計時間) / (工程数 × ボトルネック工程のピッチタイム) (3)

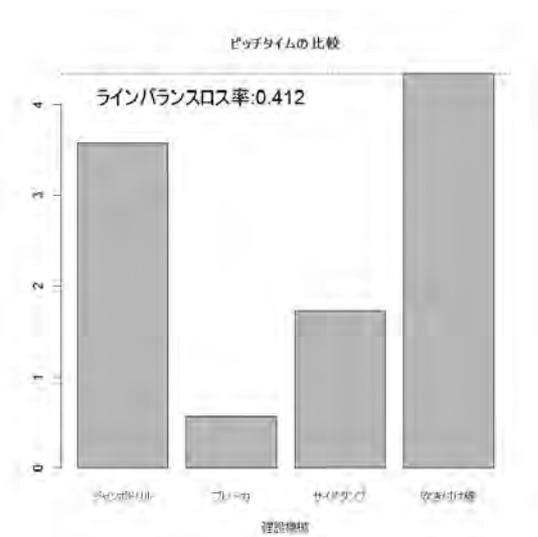


図-10 ピッチダイヤグラム

この予測判別モデルの予測能力を示す汎化誤差を表-6に示す。予測判別モデルを目標とするデータに適用した作業時間と作業記録時間表の作業時間の差を汎化誤差とする。表-6をみると、予測判別モデルの出力結果は、作業記録時間に大凡合っていることが分かる。

表-6 汎化誤差 単位：分

建設機械	作業記録時間	作業計算時間	汎化誤差
ジャンボドリル	479	457	22
ブレーカ	78	73	5
サイドダンプ	225	222	3
吹き付け機	538	555	-17
作業時間合計	1320	1307	13

5. まとめと今後の課題

転移学習による学習過程と Actor-Critic の枠組みに基づいた予測判別モデルについて報告した。そして、このモデルが箱ひげ図時系列グラフ、実稼働時間、ピッチダイヤグラムなどの作業ライン生産性可視化情報を出力することを示した。これらの情報は日単位でフィードバックされる。

利用者はこれらの情報を一目みることで、トンネル工事の作業ライン生産性の現況を理解することができる。

今後の課題をつぎに示す。

- (1) 新たなトンネル工事現場への転移学習による予測判別モデルのブラッシュアップ
- (2) 素早くより良い予測判別モデルを構築するための学習の仕方の学習，言い換えれば仕事術 (work hacks) の整理。ここで、仕事術とは、効率良く仕事をこなし、高い生産性を上げ、仕事のクオリティを高めるための工夫をいう。
- (3) トンネル工事の作業ライン生産性を可視化する動的モニタリング・システムの構築。ここで、動的とは情報の経時変化をいう。このモニタリング・システムは、一定間隔，例えば、5分乃至10分間隔で情報を更新する。

参考文献

- 1) 電力工事委員会 技術部会 電力情報化施工WG: 電力土木における情報化施工・ICT活用に関する調査, 電力土木における情報化施工・ICT活用に関する調査報告書, 28_4章2.2 山岳トンネル④No.4.2-22~No.4.2-26, 2017.
- 2) S. Nishigaki, J. Vavrin, N. Kano, T. Haga, J. Kunz and K. Law : "Human ware, Human Error, and Hiyari-hat: a Template of Unsafe Symptoms," Journal of Construction Engineering and Management, ASCE, Vol. 120, No. 2, pp. 421~442, 1994.
- 3) S. Nishigaki, H. Sugiura, T. Takamura, H. Ogura and K. Hatori: "STUDY ON FRAMEWORK OF CONSTRUCTION PROFILE FOR COLLABORATIVE AND INTELLIGENT CONSTRUCTION," Journal of Applied Computing in Civil Engineering, Vol.14, 2005.
- 4) Katsutoshi Saibara, Shigeomi Nishigaki, Fujio Matsuda, Shinichi Kubota: "Contrivances to Assist Forest Machine Operator on Forest Road with Steep Slope," Proceedings of the 31st ISARC, pp. 458-465, 2014.
- 5) Singh, S. P. and Sutton, R. S.: "Reinforcement Learning with Replacing Eligibility Traces," Machine Learning, Vol. 22, pp. 123-158, 1996.
- 6) Christophe Leys, Christophe Ley: "Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median," Journal of Experimental Social Psychology, YJESP-03038; No. of pages: 3; 4C, 2013.
- 7) A. J. Scott and M. Knott: "A Cluster Analysis Method for Grouping Means in the Analysis of Variance," Biometrics, pp. 507~512, Vol. 30, No. 3, 1974.