

## 頭部姿勢と表情の時系列変化に着目した注意散漫状態の検出 Detection of Distracted State Focusing on Time Series Changes of Head Posture and Facial Expression

鷺津 友貴<sup>†</sup>      佐藤 和人<sup>†</sup>      松井 悠馬<sup>†</sup>  
Tomoki Washizu    Kazuhito Sato    Yuma Matsui

禹 ハンウル<sup>‡</sup>      間所 洋和<sup>†</sup>      門脇 さくら<sup>‡</sup>  
Hanwool Woo      Hirokazu Madokoro    Sakura Kadowaki

### 1. はじめに

日本国内の交通事故による死傷者数は減少傾向にあるが、平成 29 年のデータでは、死者数は 3694 人、負傷者数は 58 万 850 人となっており、依然として深刻な状況が続いている[1]。死亡事故の原因として、ドライバの漫然運転による事故の発生件数は全体の 15.3%を占め、最も高い割合となっている。この漫然運転を引き起こすドライバの内部状態は、注意散漫状態と疲労状態に分けられる。疲労状態は、覚醒水準が低い状態を示し、眠気や居眠りが具体的な原因である。注意散漫状態は、注意資源の配分が悪い状態を示し、考え事状態やぼんやり状態、焦り・イライラ状態が具体的な原因である。疲労状態の検出方法は実用化されつつあるが[6][7][8]、注意散漫状態の検出方法は未だに確立されていない。我々は注意散漫状態の検出を目指しており、先行研究では、視線と顔向きに着目し、ドライバの注意散漫状態を特徴付ける行動パターンの抽出を行った[2][3]。この研究ではドライバの視線の移動量を定量化の対象に扱っており、ドライバの身体情報や運転情報を取り入れ、ベイジアンネットワークを介して運転行動モデルを構築した。この視線情報や運転情報の計測は、ドライビングシミュレータ(Driving Simulator: 以後 DS と略記する)において Figure 1 のコースを使用した走行シナリオによって行った。研究結果として、視線情報が高精度で検出された場合、注意散漫状態になった時、多くのドライバは視線の移動量が減少するという結果が得られた。しかし、視線情報を高精度で検出することは困難であることが分かった。また、実装に際して装置が大掛かりになるという課題も挙げられた。

本研究では、先行研究で計測したドライバの頭部画像を対象に、階層成長型リカレント SOM によるカテゴリ分類を行う。これによって、頭部姿勢と表情それぞれの注意散漫状態を特徴付ける運転行動パターンの検出が可能か分析を試みる。また、U-matrix と階層成長型リカレント SOM の分類結果を比較することにより、提案手法の有効性を示す。

### 2. 周辺研究

現在の自動運転レベルは、レベル 0 からレベル 5 までであるうちのレベル 2「部分運転自動化」に該当する。次の段階であるレベル 3「条件付運転自動化」では、システムが全ての運転タスクを限定領域で実行すると定義されている[4]。しかし、システムが運転継続困難と判断した場合、ド




Figure 1. 走行コース

ライバはシステムの介入要求等に対して適切に応答する必要がある。そのため、ドライバの内部状態を推定する研究が行われている。視線情報によるドライバの内部状態を推定する研究の一例として、C.Braunagel ら[5]は、自動運転レベル 3 を模擬した走行実験による、高度運転支援システム(ADAS)の研究を行っている。システムが運転タスクを実行している間、ドライバは携帯電話の操作や車載ナビゲーション画面の閲覧などといった二次的タスクを実行し、ドライバの眼と頭の動きの測定により、運転交代の質の評価を行った。この実験で、運転交代の質が低いドライバのうち、運転交代の直前にシステムが警告を促したのは 63%となり、視線検出の精度が低いという結果が得られた。これらの結果から、視線追従のみによる ADAS は精度が低いという課題が挙げられた。

疲労状態の推定技術としては、車載カメラで捉えた顔向きや顔の状態から注意力や覚醒度を検知する手法[6][7]、車両挙動からドライバの覚醒度低下を検知する手法[8]が実用化されつつある。(株)SUBARU はドライバモニタリングシステムを搭載した北米仕様車両を発表した。搭載されたシステム[9]は、近赤外線カメラと光学式カメラを使用しており、前者で顔認識を行い、後者で運転への集中度や居眠りなどを検知する。このシステムは「居眠り」「強い眠気」「わき見」「眠気」の4段階でドライバの状態を評価し、音とディスプレイ表示による警告を促す他、アイサイトとの連携によりブレーキ等への介入タイミングを早めることも可能とされる。

<sup>†</sup> 秋田県立大学, Akita Prefectural University

<sup>‡</sup> SmartDesign 株式会社, SmartDesign Corp.

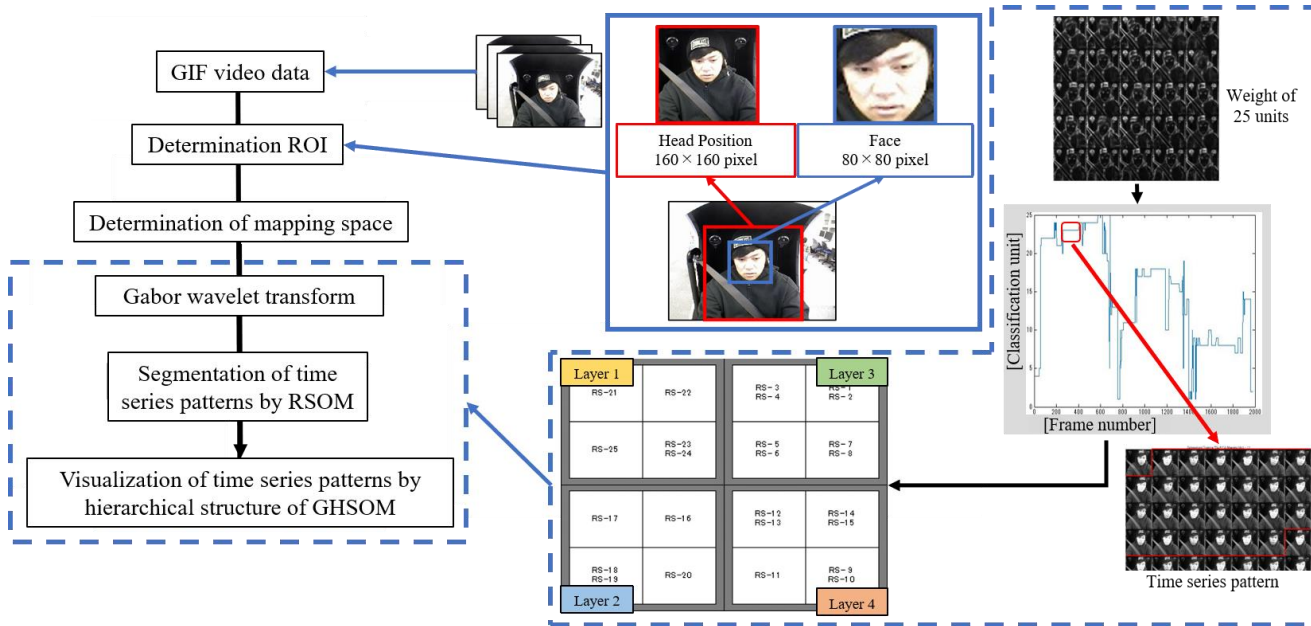


Figure 2. RGHSOM の処理フロー

### 3. 走行シナリオ概要

実験で使用する走行コースとしては、共同研究を行っている徳島大学常三島キャンパス周辺を模擬したコース (Figure 1) を使用した。走行コースは 5ヶ所の無信号交差点で構成されており、通過する順番にそれぞれ交差点 1, 2, 3, 4, 5 と定義する。ここで交差点 1, 2 は、見通しの悪い交差点となっている。本研究では、被験者 12 名が運転集中状態と注意散漫状態の 2 種類の状態で走行シナリオを実施し、本論文では被験者 1 名の走行コース 1 周分のデータを使用した。被験者は男子学生 10 名 (C, D, E, H, I, J, K, L, M, N), 女子学生 2 名 (F, G) の計 12 名で、事前に実験内容についての説明を十分に行い、実験への参加の同意を得た。また、実験内容は秋田県立大学研究倫理審査委員会の承認を得ている。

本研究では、運転集中状態は運転タスクのみを実行し、注意散漫状態は運転タスクと暗算タスク (3 秒間隔で 1 桁同士の簡単な加減算を行う) を実行する状態を定義し、これにより注意散漫状態を模擬した。

### 4. 提案手法

#### 4.1 リカレント SOM によるセグメント化

頭部姿勢と表情は、視線変化や口角の変化などの動的情報によって創出される。このような時系列的变化の特徴を捉えるため、Kohonen の SOM (Self-Organizing Map) を拡張したリカレント SOM (Recurrent Self-Organizing Map : 以後 RSOM と略記する) の特性 [10] を取り入れる。これにより頭部姿勢と表情を時系列に考慮した写像をすることで、1 ステップ前に入力したデータとの変化を学習し、その変化の特徴を含めた写像を可能とする。しかし、SOM も含め RSOM のアルゴリズムには学習前にマップサイズを決定しておかなければならないという欠点を有する。



Figure 3. RSOM によって分類された原画像

#### 4.2 階層成長型 SOM による可視化

Dittenbach らの階層成長型 SOM (Growing Hierarchical Self-Organizing Map : 以後 GHSOM と略記する) の手法 [11] は、階層化だけでなくマップサイズの成長も促すため、対象問題に最適なマップサイズを自動設定できるとともに、可視化特性にも優れる。このアルゴリズムは、各層の各マップは独立した SOM から構成されるため、学習も完全に独立で行われる。

本研究では、頭部姿勢と表情を RSOM によって分類し、そこで得られた重みを GHSOM によって可視化する手法を提案する。この手法を、階層成長型リカレント SOM (Recurrent Growing Hierarchical Self-Organizing Map : 以後 RGHSOM と略記する) と定義する。提案手法の処理フローを Figure 2 に示す。データセットとなる頭部姿勢および表情は、 $640 \times 4800$  ピクセルの gif 動画を用い、頭部姿勢では  $160 \times 160$  ピクセル、表情では  $80 \times 80$  ピクセルの対象領域を設定した。次に、それら対象領域内をガボールウェーブレット変換し、RSOM に入力した。写像空間は 1 次元の 25 ユニットの重みとした。RSOM によって分類された原画像の一例を Figure 3 に示す。これは、左から右に時系列変化を分類したフレームであり、RSOM の結果に基づいている。これにより、RSOM の結果を基に近傍近似によって時系列的に連続な画像が写像されていることが確認できる。最後に、RSOM で得られた 25 個の重みを GHSOM に入力する。

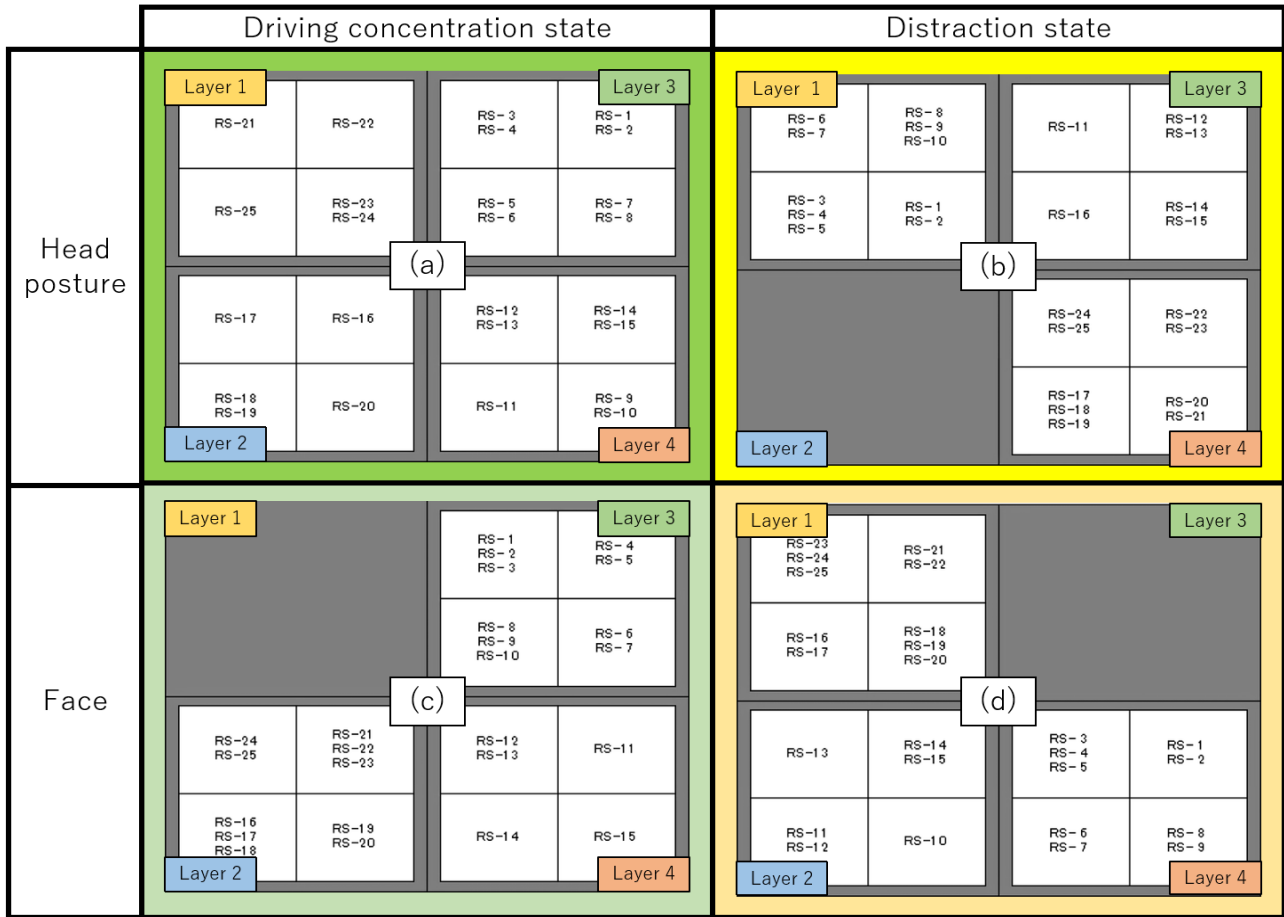


Figure 5. RGHSOM による分類結果

Figure 4 は、25 個の重みの可視画像を 5 個ずつ横に並べた画像である。これより、隣どうしの重み可視画像が類似しているため、連続したユニットの重みが近傍写像されていることが確認できる。

### 4.3 U-matrix による可視化

U-matrix は、ユニット間の重みベクトルの距離情報を基に、隣接するユニットの類似度を算出し、その空間的な分布を可視化する教師あり学習の一手法である[12]。Figure 5 で示すように、正方格子上に配置されたユニット(j,k)は、8 個の隣接するユニットを持つ。類似度として算出される値を  $U_{mat}$  と定義すると、(j,k)-(j+1,k)間や(j,k)-(j,k+1)間といった横方向と縦方向に隣接するユニットの  $U_{mat}$  は次式のように表される。

$$U_{mat}(j,k)(j+1,k)=|w(j,k)-w(j,k+1)|$$

ここで、 $w(j,k)$  は格子点(j,k)における結合荷重である。また、(j,k)-(j+1,k+1)間や(j,k+1)-(j+1,k)間といった斜め方向に隣接するユニットの  $U_{mat}$  は式(1)のように表される。

本研究では、教師データにはRGHSOMで得られたラベルを用い、入力データには元画像データを用いた。

$$U_{mat} = \frac{j,k}{j+1,k+1} = \frac{|w(j,k) - w(j+1,k+1)| + |w(j,k+1) - w(j+1,k)|}{2\sqrt{2}} \quad (1)$$



Figure 4. 重みの可視画像

## 5. 実験結果と考察

本実験において「直進」, 「交差点進入～一時停止」, 「右折動作」の 3 区間に分けて実験を行ったが、特徴的な運転行動パターンが現れた区間は「交差点進入～一時停止」と「右折動作」であったため、本研究ではこの 2 区間について着目した。

運転集中状態と注意散漫状態における時系列変化の分類結果を Figure 5 に示す。左上のマップ(a)は運転集中状態の頭部姿勢、右上のマップ(b)は注意散漫状態の頭部姿勢、右下のマップ(c)は運転集中状態の表情、右下のマップ(d)は注意散漫状態の表情を表している。

### 5.1 頭部姿勢の時系列変化に着目した分析

頭部姿勢における運転集中状態では、Figure 5 のマップ(a)より、交差点 1 に該当するユニットが Layer 1 の RS-23~25 に分類された。ここで、RS-23, 24 のユニットに分類された元画像の時系列変化を Figure 6 に示す。これより、交差点 1 における安全確認動作を視線で行っている時系列変化が確認できる。これは、RS-25 のユニットにおいても同様な時系列変化が確認できた。また、交差点 2 に該当するユニットは Layer 2 の RS-17・18 に分類され、この元画像においても、同様な安全確認動作を視線で行っていることがわかった。これらのことから、交差点 1 と交差点 2 では視線による安全確認動作の時系列変化を確認できることがわかった。更に、Figure 5 のマップより、運転集中状態では、交差点 1 と交差点 2 のときのドライバの頭部姿勢が、共通して一つの Layer に分類されていることがわかった。

一方、注意散漫状態では、マップ(b)より、交差点 1 に該当するユニットが Layer 4 の RS-22・24 に分類された。交差点 2 に該当するユニットは Layer 1 の RS-5, Layer 3 の RS-12・15, Layer 4 の RS-20・23 に分類された。これより、交差点 1 と交差点 2 の結果を比較すると、交差点 1 では、一つの Layer に分類されているのに対し、交差点 2 では、複数の Layer に付置されていることがわかった。

運転集中状態と注意散漫状態の結果を比較すると、運転集中状態では交差点 1 と交差点 2 が共通して一つの Layer に分類されたが、注意散漫状態では複数の layer に付置された交差点が存在した。

これは、見通しの悪い交差点において必要とされる安全確認動作について、運転集中状態では実施されており、注意散漫状態では疎かにしていた部分があったためであると考えられる。

### 5.2 表情の時系列変化に着目した分析

表情における運転集中状態では、マップ(c)より、交差点 1 に該当するユニットが Layer 3 の RS-1~4 に分類された。交差点 2 に該当するユニットは Layer 3 の RS-9・10, Layer 4 の RS-12 に分類された。これより、交差点 1 と交差点 2 の結果を比較すると、交差点 1 では、一つの Layer に分類されているのに対し、交差点 2 では、複数の Layer に付置されていることがわかった。

一方、注意散漫状態では、マップ(d)より、交差点 1 に該当するユニットが Layer 2 の RS-10・11・15 に分類された。交差点 2 に該当するユニットは Layer 1 の RS-16・17, Layer 2 の RS-10 に分類された。これより、交差点 1 と交差点 2 の結果を比較すると、交差点 1 では、一つの Layer に分類されているのに対し、交差点 2 では、複数の Layer に付置されていることがわかった。

運転集中状態と注意散漫状態の結果を比較すると共通して、交差点に該当するユニットが複数の layer に付置された。

これは、見通しの悪い交差点において必要とされる安全確認動作について、表情を対象領域に設けた場合は特徴量




Figure 6. 交差点 1 における運転集中状態の頭部姿勢

が頭部姿勢と比較して、少ないことが原因であると考えられる。

### 5.3 運転集中状態における頭部姿勢と表情の比較検討

運転集中状態における頭部姿勢と表情を比較すると、Figure 5 のマップ(a)とマップ(c)より、一層目の分類結果が頭部姿勢では Layer 1~4, 表情では Layer 1~3 で構成され、表情の方が頭部姿勢に比べ、Layer 数が少ない結果になった。

これは、頭部姿勢では姿勢の動きによる時系列変化によって分類するのに対し、表情では顔向きや顔を構成するパーツの動きによる時系列変化によって分類されたためであると考えられる。また、頭部姿勢の対象領域は表情よりも広いため、頭部姿勢の方が表情と比べて時系列変化の特徴が多くなり、Layer 数も多くなったと考察する。

したがって、表情を対象領域に設けた場合は、時系列変化の特徴量が頭部姿勢と比較して少ないことが、Layer 数の違いからも裏付けられ、5.2 の考察と一致することがわかった。

### 5.4 注意散漫状態における頭部姿勢と表情の比較検討

注意散漫状態における頭部姿勢と表情を比較すると共通して、交差点に該当するユニットが複数の Layer に付置された。

これは、注意散漫状態においては、安全確認動作を疎かにしている部分があったことが原因であると考えられる。そのため、RGHSOM による分類では、特徴的な運轉行動パターンとなる安全確認動作の有無による分類ができず、頭部姿勢と表情で同様な結果が得られたと考えられる。

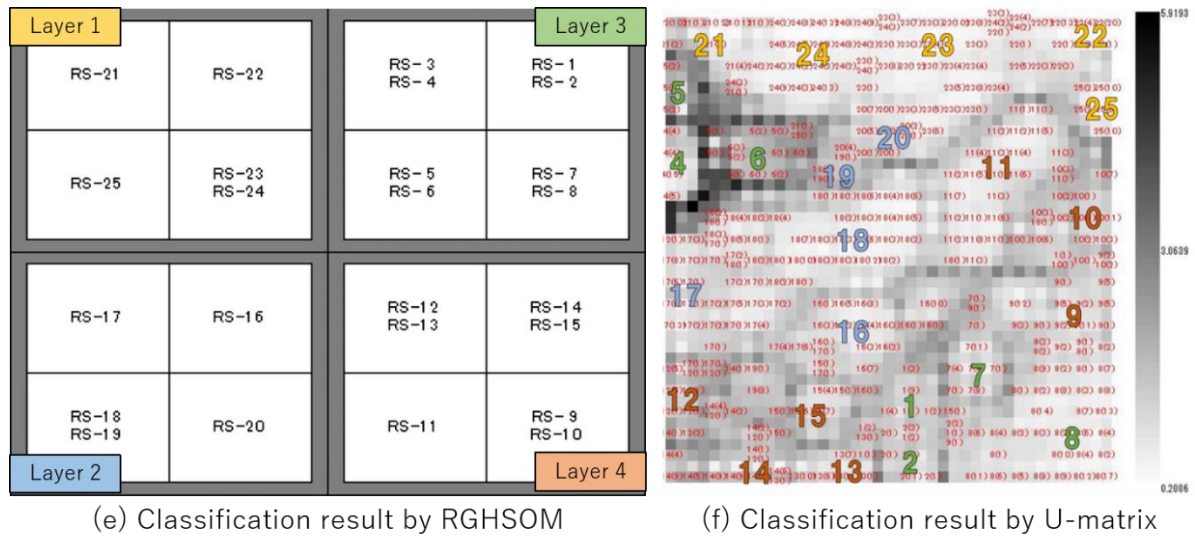


Figure 7 頭部姿勢の RGHSOM と U-matrix による分類結果

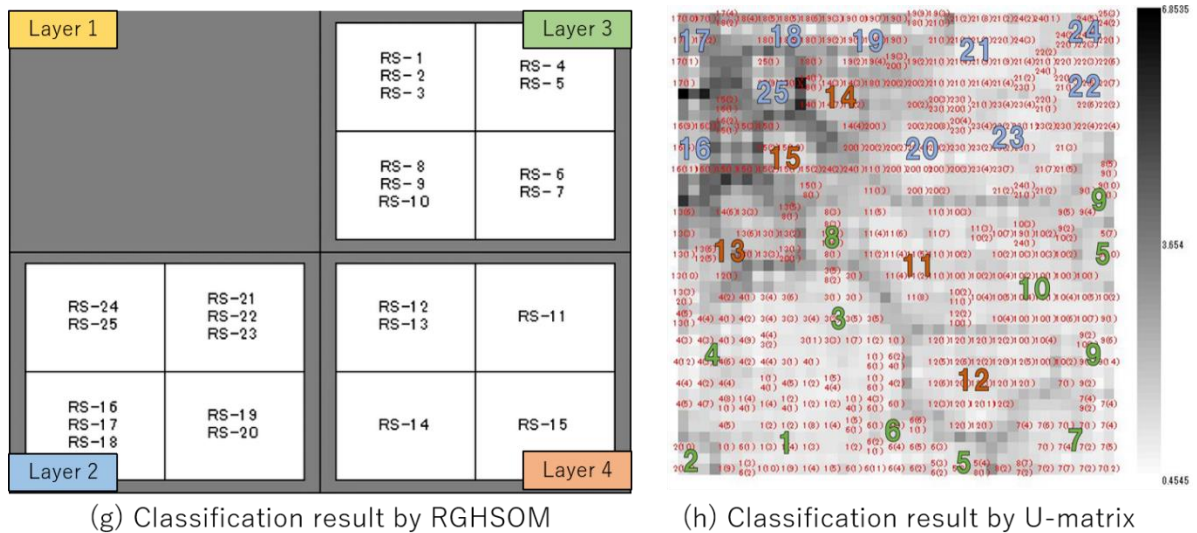


Figure 8. 表情の RGHSOM と U-matrix による分類結果

したがって、注意散漫状態における頭部姿勢と表情は、見通しの悪い交差点において特徴的な運転行動パターンが検出されていないことがわかる。

### 5.5 RGHSOM と U-matrix の比較と考察

RGHSOM と U-matrix による分類の比較を行う。運転集中状態における頭部姿勢の RGHSOM と U-matrix による分類結果を Figure 7、表情の RGHSOM と U-matrix による分類結果を Figure 8 に示す。Figure 7 と Figure 8 における数字と文字色は、RGHSOM における Layer とユニット番号と同期しており、黄は Layer 1、青は Layer 2、緑は Layer 3、橙は Layer 4 に該当する。

Figure 7 の(e)では、交差点 1 における行動パターンは Layer 1、交差点 2 における行動パターンは Layer 2 に分類されている。頭部姿勢の U-matrix による分類結果では、(f)のように RS-4・5・6 における境界が(e)と異なって設けられている。これより、RGHSOM と U-matrix とでは異なる境界が設けられていることがわかる。

この原因として、RGHSOM は特徴的な行動パターンを時系列的にセグメント化し、分類結果を階層構造によって可視化していることに対し、U-matrix は元画像データの各 1 枚を近傍学習し、二次元構造によって境界を設けているためであると考えられる。

表情の U-matrix による分類結果では、Figure 8 の(h)のように RS-2 における境界が鮮明であり、(g)における分類結果と異なる境界が設けられている。

これは、RGHSOM による分類において表情を対象領域に設けた場合は、特徴量が頭部姿勢と比較して、少ないことが原因であると考えられる。そのため、表情では見通しの悪い交差点に該当するユニットに画像が分類され、境界が適切に表現されていないと考察できる。

一方、5.1 において安全確認動作が実施されたと考えられるユニット、RS-23~25 に着目すると U-matrix の分類結果では同一カテゴリに分類されたことがわかる。これにより、見通しの悪い交差点に該当するユニットに画像が分類され、境界が適切に表現されているものと推察する。した

がって、安全確認動作の有無による分類を行うことによって、頭部姿勢と表情それぞれの注意散漫状態を特徴付ける運転行動パターンの検出が可能であると考察できる。

## 6. 結言

本研究では、RGHSOM によって頭部姿勢と表情の時系列変化に着目したカテゴリ分類し、注意散漫状態の検出を行うことを目的として研究を行った。また、U-matrix による分類結果と RGHSOM の分類結果を比較することによって、特徴的な運転行動パターンの考察を行った。その結果、以下の点が明らかになった。

- RGHSOM の分類によってドライバの運転集中状態と注意散漫状態で比較したところ、見通しの悪い交差点において必要とされる安全確認動作の有無に違いがあるといえる。
- RGHSOM の入力データとなる対象領域として、ドライバの頭部姿勢と表情で比較したところ、対象領域の大きさが時系列変化の特徴量に関係することが認められる。
- U-matrix は RGHSOM のラベルを教師データとした場合、安全確認動作にあたる頭部姿勢の分類が可能であるということが認められる。
- 特徴的な運転行動パターンの検出において、安全確認動作の有無による分類によって、注意散漫状態を特徴付けることが可能であるといえる。

今後の課題としては、ドライバ固有の運転行動パターンの検出を行いたいと考えている。この個人固有の運転行動モデルを構築できた場合、個人でも共通な運転行動パターンが現れると予想されるためである。そのために、被験者 1 名の長期的なデータを拡張して運転行動パターンの分類と分析を行う予定である。

## 参考文献

- [1] 内閣府, “平成 29 年度 交通事故の状況及び交通安全施策の現況”, (2018), [https://www8.cao.go.jp/koutu/taisaku/h30kou\\_haku/zenbun/genkyo/h1h1b1s1\\_2.html](https://www8.cao.go.jp/koutu/taisaku/h30kou_haku/zenbun/genkyo/h1h1b1s1_2.html)
- [2] 沢田石真史, 佐藤和人, 間所洋和, 門脇さくら, “身体情報に着目した DMT(Driver Monitoring Tool)の試作”, FIT2016, (2016)
- [3] M.Sawataishi, K.Sato, H.Madokoro, M.Ito, S.Kadowaki, “Driver Internal State Estimative Model for Distracted State Detection”, IEEE SMC, (2017)
- [4] 高度情報通信ネットワーク社会推進戦略本部・官民データ活用推進戦略会議, “官民 ITS 構想・ロードマップ 2019”, (2019), <https://www.kantei.go.jp/jp/singi/it2/kettei/pdf/20190607/siryou9.pdf>
- [5] C.Braunagel, W.Rosenstiel, E.Kasneeci, “Ready for Take-Over? A New Driver Assistance System for an Automated Classification of Driver Take-Over Readiness”, IEEE Intelligent Transportation Systems Magazine, Vol.9, pp.10-22 (2017).
- [6] P.Smith et al., “Determining Driver Visual Attention with One Camera”, IEEE Trans. on Intelligent Transportation Systems, Vol.4, No.2, pp.596-614 (2011).
- [7] Y.Dong et al., “Driver inattention monitoring system for intelligent vehicles: a review”, IEEE Trans. on Intelligent Transportation Systems, Vol.12, No.2, pp.596-614 (2008).
- [8] 田中 他, “車両挙動に基づくドライバの異常状態推定技術の開発”, 自動車技術会学術講演会前刷集, No.95-12 (2012).
- [9] 中尾 真二, “スバル フォレスター 新型, ドライバモニタリングシステムに注目すべき理由”, emerging media Response (2018).
- [10] Ozge Yeloglu and A. Nur Zincir-Heywood, Malcolm I. Heywood, “Growing Recurrent Self Organizing Map,” Systems, Man and Cybernetics, 2007. ISIC. IEEE International Conference on, 7-10 (2007)
- [11] M.Dittenbach, D.Merkl and Rauber “The Growing Hierarchical Self-Organizing Map”, S.Amari and C.L.Giles and M.Gori and Puri, editors, Proceeding of the International Joint Conference on Neural Networks (IJCNN 2000), Vol.6, pp.15-19, Italy, IEEE Computer Society (2000).
- [12] A.Ultsch, “Clustering with SOM U C”, Proc. Workshop on Self-Organization Maps, Vol.5, pp.75-82 (2005).