

#### 4. 超スマート社会にむけた高度安全運転支援に関する研究

機械工学系 教授 章 忠, 准教授 三宅 哲夫, 助教 秋月 拓磨, 新潟大学 准教授 今村 孝

##### 4-1 はじめに

交通安全技術の進歩や運転意識の向上により、近年、交通事故死者数は減少傾向にある。しかし、交通事故の発生件数は年間約60万件におよび、依然として社会問題の一つとなっている。事故原因として脇見運転や安全不確認が挙げられ、その中でも漫然運転による事故は約16%を占め、もっとも多い。このことから、ドライバの運転集中度を推定・評価することが予防安全の観点から有効と考える。本研究室では、車両操作情報や生体情報を用いてドライバの運転集中度を推定し、その結果をドライバにフィードバックすることで事故を未然に防止する「漫然運転防止システム」の開発をすすめている。一方で、ドライバ状態の推定には種々の機械学習アルゴリズムを用いたアプローチが提案されている。しかし、単にドライバ状態を推定するだけでなく、その結果を可視化してドライバに提示・フィードバックすることがドライバ支援の観点から有効と考える。

そこで本研究では、ドライバ状態の分類とドライバへの視覚情報の提示を両立するために、自己組織化マップ (Self Organizing Map: SOM) を用いた運転状態の分類・可視化手法を提案する。本稿で構築するシステムは、アクセル踏度やステアリング角度といった車両操作情報、および発汗量を入力データとし、これらの入力データをドライバの運転状態ごとに SOM を用いて分類する。また学習後の SOM を用いてドライバの運転状態を可視化し、ドライバにフィードバックすることを目標とする。

##### 4-2 提案手法

SOMはKohonenによって提案されたニューラルネットワークの一種であり、多次元の入力データをその類似度に応じて2次元平面等の低次元空間に写像し、可視化・分類できる。本研究で構築する SOM の概要を図 4-2-1 に示す。同図内の入力ベクトル  $x$  は SOM の入力層を表し、出力層には六角形 (Hexagonal) 型の出力ノードを  $5 \times 5$  の2次元平面上に配置する。学習フェーズでは、まず (i) 入力ベクトル  $x$  と出力層のすべてのノードとのユークリッド距離を求める。次に (ii) ユークリッド距離が最小にあるノードを勝者ノードとし、その勝者ノードとその近傍ノードの重みを更新式に従い更新する。(i) (ii) のステップをすべての入力ベクトル  $x$  に対して繰り返す。

本研究では、漫然状態を「運転行動以外のタスクに脳のリソースが割かれている状態」と定義する。この定義から運転行動そのものを一次タスク、それ以外の行動を二次タスクとし、運転中のドライバに種々の二次タスク（例えば、会話課題や暗算課題）を課すことで漫然運転状態を実験的に再現する。また、二次タスクを課した際の入力データに「漫然運転状態ラベル」、それ以外の入力データに「通常運転状態ラベル」を付与する。この2種の運転状態ラベルが付与された入力データを用いて SOM の学習を行うことで、SOM の分類結果と運転状態との対応を考察する。なお、ドライバごとに運転操作の癖があることや、漫然運転状態の発現には個人差が大きいことが予測されるため、本研究ではドライバ個人ごとに上記の SOM を生成する。

##### 4-3 検証実験とその結果

###### (1) 被験者データ

以下の検証では、実車を用いた計測実験で収集したデータを用いた。実験は、名古屋大学・武田研究室により名古屋市内の高速道路上で行われた。被験者数は21~60歳の男女46名、走行データ取得時間は3~4分、それぞれ二次タスク有状態を含んだ3回の走行データを取得した。また被験者には、

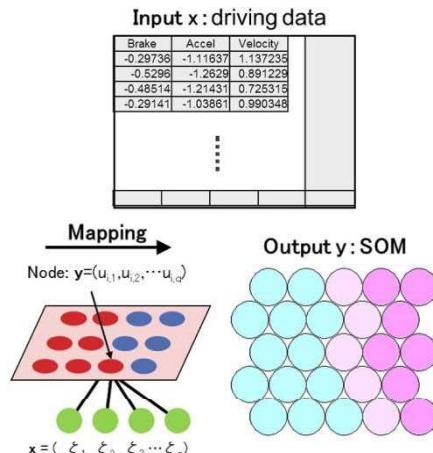


図 4-2-1 提案する SOM の概要

二次タスクとして英数字発話タスクを与えた。表 4-3-1 に示すデータを被験者毎に取得した。なお、収録データはすべて時系列データとし、サンプリングレート 30 [Hz] で各センサを同期して収録した。その後、収録データを 5[sec]ごとに区切り、運転状態ラベル情報（二次タスク無：0, 有：1）とあわせて 1 つのデータセットとし、各系列を平均 0, 分散 1 に標準化した。標準化後の各入力データのヒストグラムを図 4-3-1 に示す。また、データセットを被験者毎に無作為に 2 分割し、一方を SOM の学習データ、もう一方をテストデータとした。

表 4-3-1 被験者データ

項目	単位	
ペダル踏度	N	アクセル踏度[N]-ブレーキ踏度[N]
車両速度	Km/h	
ステアリング角	Deg.	
車間距離	m	前方車両との距離
発汗量	mg/(cm <sup>2</sup> *min)	
ペダル踏度変化量	N/s	ペダル踏度の時間変化量を算出
車両加速度	Km/h <sup>2</sup>	車両速度の時間変化量を算出

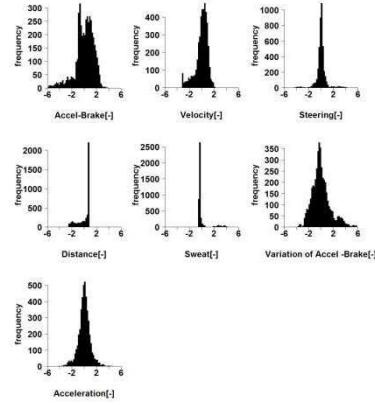


図 4-3-1 被験者データの分布

## (2) 結果と考察

生成された 46 人分の SOM のうち、典型的な例を図 4-3-2 に示す。SOM のノードは運転状態ラベルの割合によって色分けされており、赤に近いほど漫然運転状態ラベルの割合が高く、青に近いほど通常運転状態ラベルの割合が高い。次に被験者 46 名毎に学習データを用いて SOM を生成し、各 SOM にテストデータを分類させ、テストデータの正解ラベルと出力ノードの推定ラベルとの一致率を推定精度として求めた。各被験者の推定精度を図 4-3-3 に示す。同図より、46 名中 30 名の SOM において漫然運転状態の推定精度が 90%以上であった。また推定精度 80%以下の被験者は 5 名であった。推定精度の低い被験者については、実験中の様子をビデオ映像等を用いて調査したところ、例えば、被験者 m6102 の場合、実験走行中に交通渋滞に巻き込まれていた。このことから、今後二次タスクの有無以外にも交通状況等の情報を加味して SOM を構築する必要がある。

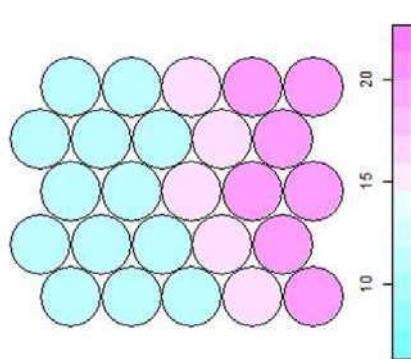


図 4-3-2 分類結果の例（被験者 m6054）

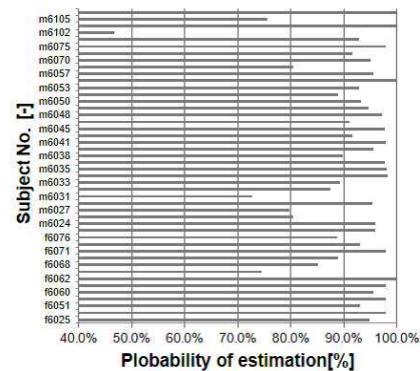


図 4-3-3 被験者毎の推定精度

## 4-4 おわりに

本稿では SOM を用いた漫然運転状態の推定・可視化手法を提案した。また、被験者 46 名分の実車走行実験データ用いて推定精度を評価した。その結果、被験者ごとに生成した個人 SOM について、被験者 46 名中 30 名において推定精度 90%以上を達成した。今後は、生成した SOM を用いて、運転状態をリアルタイムにドライバへ提示・フィードバックするシステムを構築したい。