

## Recurrent-SOM を用いたドライバモデルの構築と可視化

日大生産工 〇真下 岳 日大生産工 景山 一郎  
日大生産工 栗谷川 幸代 日大生産工 山内 ゆかり

### 1 まえがき

近年、交通事故による事故死は減少する一方で、交通事故自体の件数はあまり変化がない。それは、ブレーキアシストシステムや自動追尾システムなど高度運転支援システムの技術が上がっているためである。現在、事故データの統計解析による事故発生要因の分類、事例解析による事故発生過程の明確化等が行われている。事故発生件数を減らすためには、事故発生要因の定性的な分類だけではなく、ドライバの認知、判断、操舵特性が事故発生に及ぼす影響度の解析も重要となってくる。

従来研究として、大西らによる多変量解析によるドライバモデルの構築[1]の解析方法がある。彼らは、ドライバの制御動作を細かくモデル化するために、誤差逆伝搬ニューラルネットワーク (Back Propagation Neural Network: BPNN) を使用している[2]。だが、BPNN には、大規模な対象データに対する精密な計画・設計や制御ができないといった欠点がある。また、ドライバの自身の認知、判断、操舵特性を取り入れたモデルを構築できていない。

そこで本研究では、この問題に対して、複雑かつ膨大なデータのクラスタリングができる自己組織化マップ (Self-Organizing Map: SOM)[3] を適用し、ドライバ自身の認知、判断を取り入れたドライバモデルの構築を提案する。さらに、SOM に Recurrent 構造を適用した Recurrent-SOM (RSOM)[4] を用いることで、高次元データの可視化を行い、高次元時系列データである実走行における実データの解析を行う。

### 2 従来研究

大西らは重回帰分析[1]や NN[2]を用いて、ドライバモデルの構築、解析を行っている。線形モデルである、重回帰分析で解析した結果は実験結果をある程度説明できるものとなっている。重回帰分析の式を (1) に示す。

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n \quad (1)$$

$y$  = ハンドルトルクまたは、前後方向制御入力 (目的関数)

$a_0$  = 定数項

$a_n$  = 重回帰係数

$x_n$  = 車両状態量及び道路環境情報

この重回帰分析の式から、線形モデルの構築を行った。

さらに、ドライバの細かい制御動作などを表現するために、BPNN を使用した非線形モデルを構築した。これにより、ドライバの制御動作を表現できるモデルを構築し、因子解析を行いドライバの情報処理の過程を表現した。入力情報の影響度の変化が複雑に起こっていた非線形モデルの結果は、線形モデルの結果とほとんど同じになった。

### 3 提案手法

従来研究では、交通事故発生に及ぼす影響としてドライバモデルに使用して実データは、操舵特性と車両データのみであった。本研究では、ドライバの認知、判断を取り入れたドライバモデルの構築を目指し、高次元時系列データの取り扱いに適した RSOM を用いて非線形ドライバモデルを構築する。RSOM で使用する勝者判定、学習の式は(2)~(5)に表す。

$$y_i(t) = (1 - \beta)y_i(t - 1) + \beta(x(t) - w_i(t)) \quad (2)$$

$$\text{勝者判定: } y_d = \min_i \{ |y_i(t)| \} \quad (3)$$

$$\text{学習: } w_i(t + 1) = w_i(t) + hci(t)y_i(t) \quad (4)$$

$$\text{近傍関数: } hci = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_{il}\|^2}{2\sigma^2(t)}\right) \quad (5)$$

SOM はデータの可視化に適しており、不完全な情報から柔軟かつ迅速な判断を行うのに適している。また、現象(データ)から形成し得る認識モデルの様々なバリエーションを人工的に作り出すことができる。また、SOM に Recurrent 層を取り入れることで、入力データに時系列の概念を取り入れ、データの時系列変

Construction and Visualization of Driver Model using Recurrent-SOM

Gaku MASHIMO, Ichiro KAGEYAMA, Yukiyo KURIYAGAWA and Yukari YAMAUCHI

化を表現することが可能になる[4]。

これらの特徴から、本研究で構築するドライバモデルは、複雑で高次元な時系列データに基を視覚的かつ客観的に比較し解析することが可能になるモデルであると考えられる。

#### 4 実験環境

本研究で用いる実験データは、高速道路の往復走行を計4回行った際の車両データである。また、1回走行を行う毎に休憩を取り、休憩時に計測した生体情報を基に、ドライバの状態を解析する。生体情報として、客観的による評価と主観的な評価である。車両データとして操舵角、前方向速度、横方向速度、ヨー角、ヨーレートといった時系列データを用い、1回の走行中の区間として、Ddash区間、F区間、A区間、Cdash区間の順に4つに分けてデータがある。

本研究では最初の1本目とDdashに注目、次元数は車両データの5つからなる5次元とした。競合層の軌跡は黒、赤、青、緑で区間ごと順に分けている。

RSOMの環境設定、競合層のノード数はDATA総数の約1/40の400に設定、学習率 $\alpha$ を0.7、リカレント係数 $\beta$ を0.7、学習回数を10000にした。

#### 5 実験結果および検討

1本目と1~4本目のDdashに着目した二つのSOM、RSOMの競合層、データ空間を表したものを次の図2~5に示す。

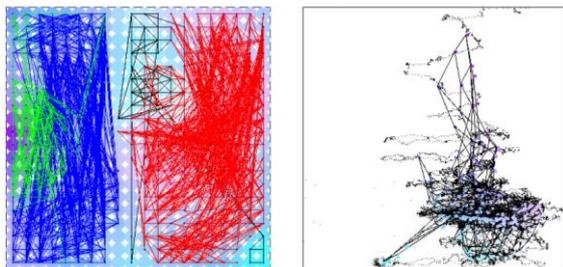


図2.1本目のSOMでの競合層とデータ空間

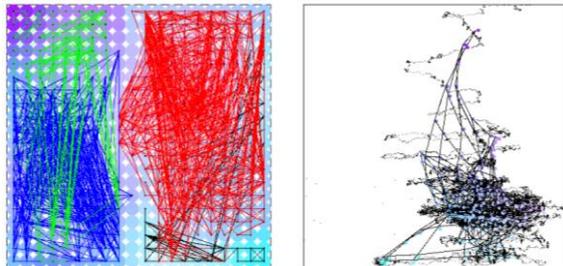


図3.1本目のRSOMでの競合層とデータ空間

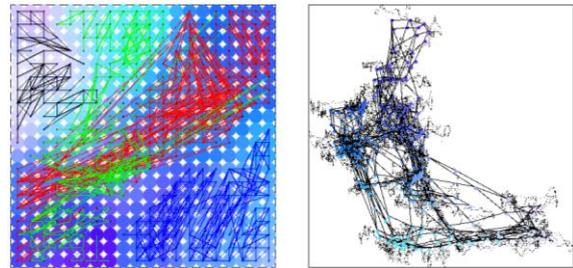


図4.DdashのSOMでの競合層とデータ空間

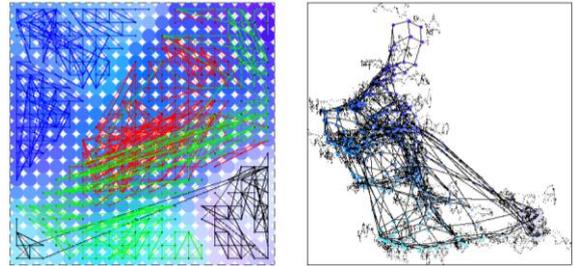


図5.DdashのRSOMでの競合層とデータ空間

SOMではノードが集中しているのでデータの多くをカバーできていないが、RSOMは多少広く分布されているので多くカバーできている。また、データを可視化したことにより1本目の軌跡は前半区間である黒、赤と青、緑の二つに分かれ、黒と赤が類似していた。また、青と緑も類似していた。先頭区間Ddashの4本分のデータでは、2,4本目が類似していて1,3本目はそれぞれ個別の特徴を示した。

今後、生体データなども加味し、ドライバモデルの構築を行う。

#### 6 まとめ

本研究では、SOMとRSOMでのデータの可視化、軌跡を追い、高次元時系列データにおける実データの解析を行った。

#### 「参考文献」

- 1) 大西 信太郎、景山 一郎「多変量解析によるドライバモデルの構築とその操縦動作の因子解析に関する研究」,社団法人自動車技術会学術講演会前刷集No.92-00,pp,25-28 (2000)
- 2) 大西 信太郎、景山 一郎「ドライバモデルの構築に関する研究」, 日本機械学会第9回交通。物流部門大会講演論文集[No.00-50],pp,173-176 (2000)
- 3) T.Kohonen, Self-Organizing Maps, Springer, vol.30, (1995)
- 4) Heikkonen,J., Kaski,K., Koskela,T., and Varsta,M.: Temporal sequence processing using Recurrent SOM, in Proc. Of 2<sup>nd</sup> International Conference on Knowledge-Based Intelligent Engineering System(KSE'98), pp. 290-297 (1989)