

ドライバの運転動作に基づく個人特性を考慮した 危険運転予測システムの構築

伊藤 桃代, 伊藤 伸一

A Development of Risky Driving Prediction System Based on Driving Behaviors and individual differences

by

Momoyo Ito and Shin-ichi Ito

Many car accidents are caused by driver's deviation from normal condition like carelessness. We aim to construct a driving assist system that is able to detect driver's deviation signal from normal condition. The system detects the deviation signal using driver's time-series head motion information. In this paper, we optimize categorization of driver's head motion using two kinds of unsupervised neural networks: Self-Organizing Maps (SOMs) and Fuzzy Adaptive Resonance Theory. Moreover, we introduce a method to analyze an individual difference in an electroencephalogram (EEG) using a SOM. In order to confirm the individual difference in the EEG, we conduct experiments using real EEG data. The experimental results suggest that it is possible to express the individual difference using SOM.

Key words: driving assistance system, SOMs, Fuzzy ART, EEG analysis, individual characteristics

1. はじめに

近年の安全運転支援技術においては、車内のドライバを観測対象とし、ドライバが安全運転を維持可能かどうか判断するための技術が重要視されている。ドライバが安全運転を維持できていないことを判断する基準としては、主に脇見や居眠り（眠気）が対象とされ、それらを

検出するための技術が研究されている⁽¹⁾⁻⁽³⁾。一方、自動車事故の多くは、ドライバの認知・判断ミスに因ると言われ、その誘発要因としては、ドライバの平常状態からの継続的逸脱が大きく関与していると考えられる。そのため、一過性の脇見や、既に眠気の起こっている状態の検出に加え、ドライバが安全運転を行うことのできる平常状態であるか、それとも、危険運転を引き起こす可能性のある平常状態から逸脱した状態（以下、逸脱状態と表記する）であるかを検出し、ドライバに伝えることで予防安全を実現することが重要と考えられる。

自動車を運転するドライバは、そのスキル、嗜好、癖

など様々な特性を持っているので、個々のドライバ特性に合った運転支援が重要となる。市街地の信号機のない交差点では、出会い頭の事故など数多く発生していることが報告されており、安全運転のためにはドライバが通常の正しい確認行動を行うことが重要である。すなわち、交差点における安全確認動作に着目して、交通事故を引き起こす可能性のある不安全な運転行動を予測し、ドライバに指摘することは有用であると考えられる。運転中の安全確認動作には個人固有な頭部の動きパターンが存在し、注意力低下に伴う逸脱状態を示すシグナルが、このパターンにも表れると予想される。

本プロジェクトでは、ドライバの頭部姿勢の3次元情報（安全確認に伴う首振り動作）を単眼カメラで撮影された2次元画像上での位相変化のみから抽出し、安全確認動作のモデル化を行うことで、危険運転を引き起こすきっかけとなる平常状態からの継続的逸脱（以下、逸脱状態と表記する）を検出するシステムの構築を目的とする。また、このシステムでは、ドライバの心理的個人差を考慮し、個人に合わせたモデルを構築することでより精度の高い逸脱状態の検出が可能となる。そこでその基礎的検討として、心理的個人差を考慮した脳波の個人差を解析することも目的とする。

本稿では、安全確認動作のモデル化のための頭部姿勢定量化手法として、2種類の教師なしニューラルネットワークをハイブリッド化した頭部姿勢分類手法を提案し、その分類特性について考察を加えると共に、脳波の個人差の可視化手法の提案とその評価を行った結果をまとめる。

2. 頭部姿勢定量化手法

2.1. 安全確認動作の分析

筆者らはこれまでに、交差点における安全確認動作について、どのような動作が含まれているのかを分析し、交差点の大きさや、交差点の構成要素（信号機、横断報道、歩道など）により、ドライバの安全確認動作を構成する頭部の動きが異なることを確認している⁽⁴⁾。特に、信号機のない見通しの悪い交差点においては、交差点内

部の状況を確認するために、深く前傾して交差点内を覗き込むように安全確認する動作や、カーブミラーを見上げるといった姿勢が特徴的であった。頭部姿勢の定量化においては、これらの頭部姿勢を分類する必要がある。

2.2. 頭部姿勢定量化手法

安全確認動作には、ドライバ個人ごとの動きの特性（癖）が含まれており、集中力の低下や精神状態の変化が動きの特性にも現れると予想される。すなわち、個人の動きの特性を含めた頭部姿勢の定量化手法が必要となる。全ての人に共通して使用できるモデル（カテゴリの種類と数）では、個人特有な動作をカテゴリ化する事は困難である。本研究では、個人ごとに異なるカテゴリ数を自動的に決定し、分類可能な手法を検討する。ここで、頭部姿勢はカテゴリ数が未知な問題として扱い、2つの教師なしニューラルネットワーク Self-Organizing Maps (SOMs)⁽⁵⁾と Fuzzy Adaptive Resonance Theory (ART)⁽⁶⁾のハイブリッド化による頭部姿勢の分類手法（以下、本手法と記述）を提案する。

本手法の特徴は以下の通りである。初めに SOMs を用いて、画像の位相情報から頭部姿勢を 1 次元空間 (Mapping Unit) へ写像する。SOMs は近傍学習を実現するため、姿勢の似通った Unit ほど近くに分類される。次に、Fuzzy ART を用いて SOMs の分類結果を統合し、最終的な頭部姿勢のカテゴリを形成する。Fuzzy ART は、時間的な連続性（本研究では、姿勢が似ているほど連続していると考えている）を考慮したカテゴリ分類を行うため、SOMs で類似した Unit 同士を並べておくことで、その隣り合う Unit 同士が似ていると判断されれば、カテゴリの統合を行うことができる。つまり、本手法では、カテゴリ数の未知な安全確認動作について、個人の動作に合わせたカテゴリ数の決定が可能となる。本手法のネットワーク構成を Fig. 1 に示す。

個人の安全確認動作の特性を独立した頭部姿勢として抽出するために、SOMs の写像空間の大きさ (Mapping Unit 数) を最適化し、安全確認動作の分類に必要なカテゴリ数を決定する。次に、Fuzzy ART の粒度パラメータ

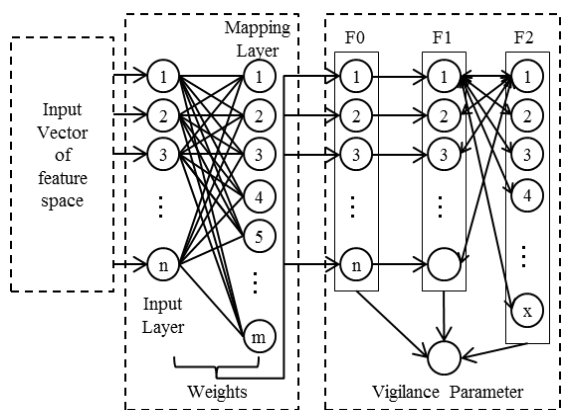


Fig. 1. Network structure of proposed method.

の調整機能を用いて、個人の安全確認動作を特徴付ける頭部姿勢のカテゴリを形成する。ここでは、最終的な個人の頭部姿勢のカテゴリ数が決定されるが、その数はカテゴリをどの程度の粒度で統合するかを左右する Vigilance パラメータの値に左右される。どの程度の粒度で SOMs の結果を統合するのが適当であるかを、その統合結果から考察する必要がある。

2.3. 自己画像特性の評価

(1). SOMs による分類結果

本実験では、実車走行データセット（被験者 A, B, 2 名分）の中から信号機のない見通しの悪い交差点における右左折時のデータを選び使用した。画像サイズは 640×480 ピクセルを 320×240 にリサイズ、カラー画像をグレースケール画像に変換した (Fig. 2(a)参照)。対象動画の画像中心から 240×240 ピクセルのサイズで切り出しを行い、関心領域として設定した (Fig. 2(b)参照)。関心領域に対し、Gabor Wavelets 変換を施す (Fig. 2(c)参照)。Gabor Wavelets 変換後の画像において 10×10 ピクセルを 1 ピクセルに圧縮することで、 24×24 ピクセルの粗視化画像を得る (Fig. 2(d)参照)。この粗視化画像を SOMs の入力とし、頭部姿勢空間のカテゴリライズを行った。すなわち、Fig. 1 の(a)における InputLayer の n は、576 となる。なお、SOMs の Mapping Unit 数は、事前に行った予備実験の結果を踏まえ、本研究では 25 を採用した。

信号機のない交差点における頭部姿勢空間のカテゴリ

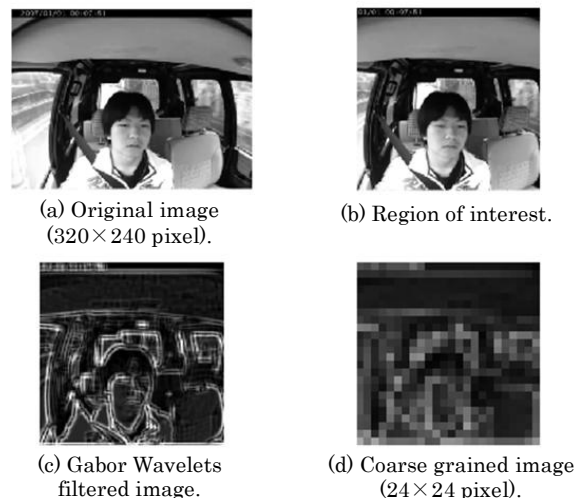


Fig. 2. Details of input data (SOMs).

分類結果の 1 例（被験者 A）を Fig. 3 に示す。Fig. 3 において、横 1 列に並んだ円は、25 個の Mapping Unit を表している。網掛けの Unit は分類時に発火し、画像が分類された Unit を意味する。白抜き of Unit は分類時に未発火となり、画像が分類されなかった Unit を意味する。Fig. 3 下部に示した画像は、各 Unit に分類された姿勢のうち、代表的な姿勢を示した。Unit 1~9 は、正面を向いた姿勢が分類された。Unit 11~14 は、正面を向いた姿勢から、少し前傾した姿勢が分類された。また、Unit 16~21 は、右側に傾きながら右折を行う姿勢が分類された。さらに Unit 23~25 には、深く前傾し、交差点内を覗き込みながら安全確認を行う姿勢が分類された。未発火 Unit は、カテゴリの境界を意味すると考えられる。以上のカテゴリ分類結果は、SOMs により信号機のない交差点における安全確認時の頭部姿勢を、その姿勢ごとに並べて分類可能なことを示している。

(2). Fuzzy ART によるカテゴリ統合結果

Fig. 4 に Fuzzy ART による最終的なカテゴリ統合結果の一例を示す。Fig. 4 は、被験者 B の右折時のデータ 1 回分について、SOMs で 25Unit に分類した後に、Vigilance パラメータの値を 0.950 として Fuzzy ART で最終的なカテゴリに統合した結果である。25Unit に分類されていた

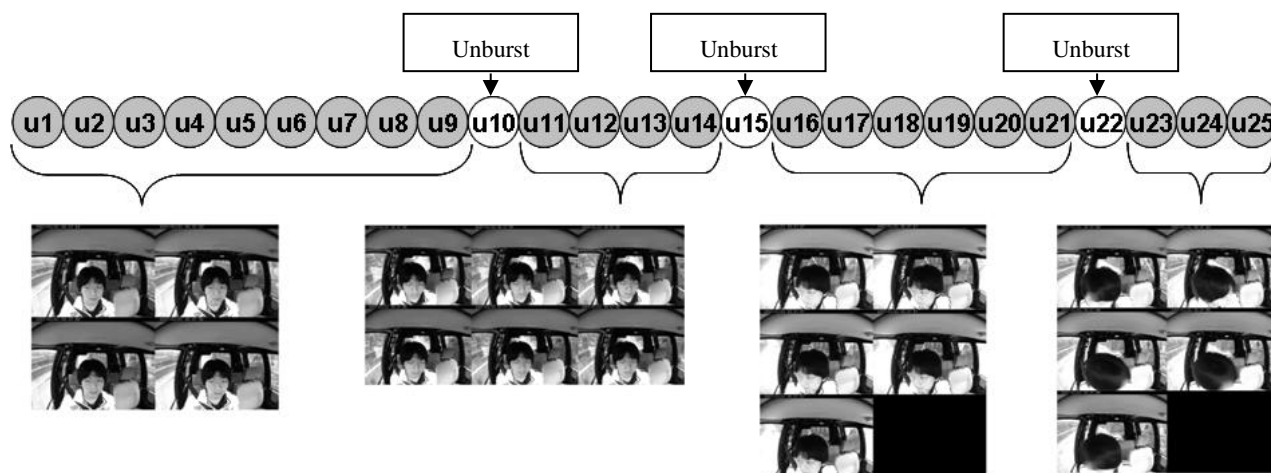


Fig. 3. SOMs step results (subject A).

結果が、10 カテゴリに統合されていることが分かる。なお、この例については、SOMs の分類結果において、Unit14 が未発火 Unit となっている。この結果は、本研究で提案した頭部姿勢の定量化手法により、被験者の頭部姿勢カテゴリ数に合わせたカテゴリ数の決定が可能であることを示している。また、Table 1 に Fuzzy ART の Vigilance パラメータの値を変化させた時のカテゴリ数と、カテゴリ統合状況をまとめた。Vigilance パラメータを変化させたとき、統合されたカテゴリ数の異なることが分かる。ここで、カテゴリ数が異なる場合でも、未発火の Unit (表 1 においては Unit14) を境界にして、左右それぞれの Unit 群 (Table 1 においては Unit1~13 と Unit15~25) の中で統合の行われていることが確認できる。これは、SOMs によりあらかじめ広い写像空間に写像しておき、その結果においてカテゴリの統合を行うことの有意性を示すものである。しかしながら、Vigilance パラメータの最適値については未検討であるため、今後検討する必要がある。

3. 脳波の個人差可視化手法に関する検討

3.1. 自己組織化マップによる個人差評価

脳波の個人差を確認するために、観測される脳波データをなるべく加工せずに分析する。そのため、ノイズ除去および脳波の特徴抽出法には、周波数分析法を採用する。さらに、脳波を分類する識別器には自己組織化マップ(self-organizing map: SOM)を利用する。SOM は教師な

しの学習識別機能を有し^{(5),(7),(8)}、その結果を視覚的に可視化することが可能であるという特性を持つ。本稿においても、その効果を利用し、これまでの研究では確認されていない脳波の個人差を視覚的かつ定量的に評価する方法を提案する。提案手法では、各個人の脳波の特徴量を SOM に学習させ、SOM に自己組織化される脳波パターンの違いを視覚的に確認すると共に、定量的に評価する。また、提案手法の有効性を脳波パターンの分類・識別実験により検証する。実験では、音聴取時の脳波を計測し、脳波から特徴を抽出した後に、SOM を用いて脳波パターンの分類識別を行うと共に、生成された SOM の違いから個人差を分析する。提案手法は、脳波計測部、脳波の特徴抽出部、脳波の個人差分析部で構成されている。また、個人差を分析するために、脳波パターンを分類する問題に適用する。

3.2. 脳波計測

脳波計は実用的な環境下での計測が可能であるヘッドホン型の乾式簡易脳波計測装置 MindTune (MT) を使用する。計測部位は国際 10-20 法における左前頭極 (電極配置 Fp1) にあたる箇所である。計測方法は、左耳朶を基準電極とする基準電極法を採用している。また、MT から観測される脳波データは、付属の解析ソフトを介して PC に取り込まれる。解析ソフトでは、1 秒間の脳波を高速フーリエ変換 (サンプリング周波数: 512Hz) し、0.5Hz 間

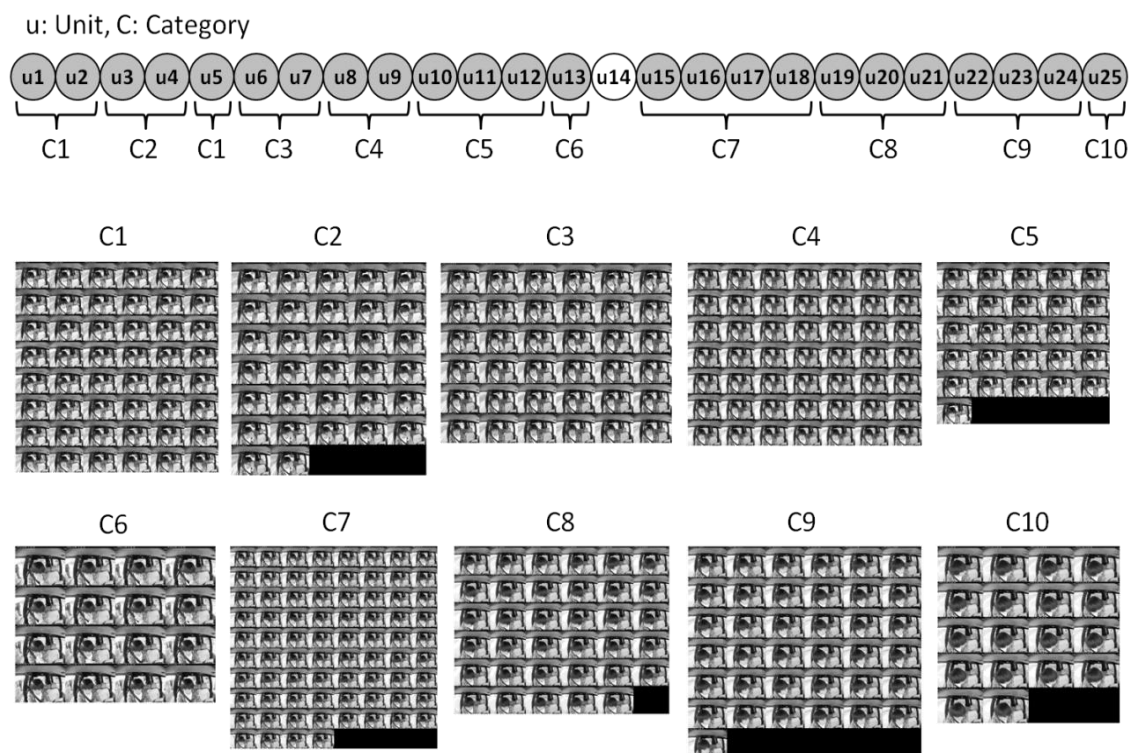


Fig. 4. Integrated result by Fussy ART (subject B).

Table 1. Relation between vigilance parameter and number of category.

Vigilance parameter	Number of category	Unit 1	Unit 2	Unit 3	Unit 4	Unit 5	Unit 6	Unit 7	Unit 8	Unit 9	Unit 10	Unit 11	Unit 12	Unit 13	Unit 14	Unit 15	Unit 16	Unit 17	Unit 18	Unit 19	Unit 20	Unit 21	Unit 22	Unit 23	Unit 24	Unit 25
0.98	18	1	2	3	4	5	6	7	8	8	9	9	10	11	0	12	12	13	13	14	15	15	16	16	17	18
0.97	13	1	1	2	2	3	3	4	4	5	6	6	7	7	0	8	8	9	9	9	10	10	11	11	12	13
0.96	11	1	1	2	2	3	3	4	4	4	5	5	6	6	0	7	7	8	8	8	9	9	10	10	10	11
0.95	10	1	1	2	2	1	3	3	4	4	5	5	5	6	0	7	7	7	7	8	8	8	9	9	9	10

隔で 50Hz まで周波数分析される。さらに、 δ 帯域(1-3Hz), θ 帯域(4-7Hz), low- α 帯域(8-9Hz), high- α 帯域(10-12Hz), low- β 帯域(13-17Hz), high- β 帯域(18-30Hz), low- γ 帯域(31-40Hz), および high- γ 帯域(41-50Hz)に 8 分割される。このとき、各帯域の平均パワースペクトルを計算し、各帯域の代表値が算出される。計測状況はいずれの被験者に対しても、若干の雑音のある計算機室内において実験用のサウンドソファに楽な姿勢で腰を掛けた状態である。また、左耳と額に電極が接触するように MT を装着する。計測中は目を閉じて、口を半開きの状態で行ない、

なるべく体を動かさないように注意を促している。

3.3. 脳波の特徴抽出

解析ソフトから得られる脳波の 8 つの周波数帯域のうち、 θ 帯域, low- α 帯域, high- α 帯域, low- β 帯域および high- β 帯域を有効な周波数帯域として抽出する。 δ 波は深い睡眠時に検出され、ノイズの影響を受けやすい帯域であるため除去し、low- γ 帯域および high- γ 帯域は 30Hz 以上の周波数であり、特殊な事例において観測される周波数帯域であるため除去した。本稿における脳波の特徴

量 x は、5次元であり、各帯域の代表値(平均パワースペクトル)の時間平均で構成される。このとき、FFTによって周波数分析された各帯域の平均パワースペクトルの時間平均を算出する。

$$x = [\theta, low-\alpha, high-\alpha, low-\beta, high-\beta] \quad (1)$$

$$\theta = \sum_{T_start}^{T_end} Pow_{\theta} / TotalTime$$

$$low-\alpha = \sum_{T_start}^{T_end} Pow_{low-\alpha} / TotalTime$$

$$high-\alpha = \sum_{T_start}^{T_end} Pow_{high-\alpha} / TotalTime \quad (2)$$

$$low-\beta = \sum_{T_start}^{T_end} Pow_{low-\beta} / TotalTime$$

$$high-\beta = \sum_{T_start}^{T_end} Pow_{high-\beta} / TotalTime$$

ここで、 $\theta, low-\alpha, high-\alpha, low-\beta, high-\beta$ はそれぞれ、 θ 帯域、 $low-\alpha$ 帯域、 $high-\alpha$ 帯域、 $low-\beta$ 帯域、 $high-\beta$ 帯域の平均パワースペクトルの時間平均を意味する。また、 $Pow_{\theta}, Pow_{low-\alpha}, Pow_{high-\alpha}, Pow_{low-\beta}, Pow_{high-\beta}$ はそれぞれ、 θ 帯域、 $low-\alpha$ 帯域、 $high-\alpha$ 帯域、 $low-\beta$ 帯域、 $high-\beta$ 帯域の平均パワースペクトルを意味する。さらに、 $T_start, T_end, TotalTime$ は特徴量算出の対象となる時間区間の開始時間、終了時間、合計時間をそれぞれ意味する。

3.4. 脳波の個人差分析

個人差を分析するために、SOM 使用する。SOM は Kohonen によって提案された人工ニューラルネットワークの理論に基づくデータ可視化手法の一つであり、分類識別器である。また、任意の分布に従う多次元データに対して近似マップを学習的に作成可能である。さらに、その近似マップを応用して情報可視化技術として利用可能である。本稿では、2次元平面上に近似マップを生成する。そうすることで、2つ以上のマップの相互関係を確認する際に、同位置に配置されているノード間を比較することが可能になる。

学習の方法には、ランダム選択(repeated random sub-sampling validation)法を用い、データセットの $P\%$ を用いて学習する。また、学習後の SOM を可視化する。まず、抽出された学習用のすべての脳波の特徴量にタグ付け(意味づけ)を行ない、そのタグを特徴量が示す脳波パターンとみなす。次に、SOM の各ノードと SOM の学

習に使用したすべての特徴量とのユークリッド距離を算出し、距離が最小となる特徴量を選定する。最後に、選定された特徴量が示す脳波パターンを、そのノードが意味する脳波パターンとみなし、色付けする(例;脳波パターン A : 白, 脳波パターン B : 黒 など)。

個人差を評価するために、SOM 学習の困難度および学習済み SOM の類似度を算出する。これは、個人差があれば、すべての被験者データを混ぜた学習は、単一被験者のデータの学習よりも学習が困難になると容易に推測できるためである。困難度は、脳波パターンの分類識別率を計算することで算出する。まず、学習により生成されたマップに学習に用いた特徴量を再度入力として与える。次に、各ノードと特徴量とのユークリッド距離を計算し、距離が最小となるノードを決定する。また、距離が最小となるノードと特徴量が意味する脳波パターンが一致する場合、脳波パターンの分類に成功したものとしてカウントする。これらの操作をすべての学習に使用した特徴量に適用する。最後に、脳波パターンの分類識別率(Accuracy)を算出する。

$$Accuracy = CorrectNumber / TotalNumber \quad (3)$$

ここで、 $CorrectNumber, TotalNumber$ は、距離が最小となるノードと特徴量が意味する脳波パターンが一致した総数、学習に使用した特徴量の総数をそれぞれ意味する。

また、SOM による可視化結果を定量的に評価するために、マップ間の類似度を算出する。マップ間の類似度(Similarity)は、同じ場所に位置するノードの色が一致しているノードの数をカウントすることで算出する。

$$Similarity = MatchNumber / TotalNodeNumber \quad (4)$$

ここで、 $MatchNumber, TotalNodeNumber$ は、同じ場所に位置するノードの色が一致した総数、ノードの総数をそれぞれ意味する。

3.5. 実験結果と考察

被験者数は5名(男性4名:S1~S4, 女性1名:S5)である。脳波計測は、閉眼・安静・無聴取:15sec, 閉眼・安静・音聴取:15secを15回繰り返す(1セット)。各被験者に対して5セット(脳波計測実験は各被験者に対して一

日一回とした) 行なった。聴取音は 15 種類とし、聴取する順番はランダムに決定した。脳波計測終了後に、音に対する印象評価を実施した。アンケートは「とても嫌い」「嫌い」・「どちらでもない」・「好き」の 4 件法を採用した。また、分類する脳波パターンは、脳波計測終了後に実施した印象評価アンケートに基づいて、「嫌い(Dislike)」・「どちらでもない(Other)」・「好き(Like)」の 3 つとした。なお、印象評価の「とてもきらい」・「嫌い」を合わせて 1 つの「嫌い」としている。また、脳波データは音聴取 1 回あたり 15 秒のデータを 1 データとして、各被験者に対して 75 個のデータを取得した。分析対象の脳波データは、音聴取開始 1 秒を除く 14 秒間としている。これは、最初の 1 秒には、聴覚刺激に対する事象関連電位の混入が容易に想定され、その事象関連電位は音刺激に対するヒトの嗜好が反映されているとは言い難いため、削除した。さらに、SOM のマップサイズは 10×10 とし、学習回数は 10,000 とした。また、ランダム選択法における学習用に使用するデータセットの割合 P を 80(%) と設定した。

SOM のような人工ニューラルネットワークを用いた場合、その初期値によって出力される結果が異なる場合がある。そのため、まず、初期値を固定した状態で、各被験者のデータを別々に学習した (10 回試行; 試行回数とは、学習用データセットを変更した回数を意味する)。このことは、初期値の違いによる影響を抑制する効果を持つ。10 回試行のサンプル結果を Fig. 5 に示す。なお、図中の All はすべての被験者データを一つの SOM に学習させた結果である。白色、灰色、黒色はそれぞれ「好き」「どちらでもない」「嫌い」に対応している。また、Table 2 に定量的に評価された SOM の類似度の平均値と標準偏差(10 回試行)を被験者ごとに示す。さらに、Fig. 6 に学習済みの SOM にそれぞれ再度学習データを入力した場合の脳波パターンの分類識別率の平均値と標準偏差を示す(10(初期値のセット数) \times 10 回試行)。

Fig. 5 において、初期値が同値であるにも関わらず、各被験者において生成されたマップのコントラストが著しく異なった。生成した SOM は 10×10 のノードで形成

されており、各ノードは学習に使用した脳波の特徴量を反映し、近傍のノードには類似した脳波の特徴量が分布するように学習されている。可視化された SOM のノードは、上述する通り、各ノードと最も類似する脳波の特徴量が意味する脳波のパターンに基づいて色づけされている。同一の脳波パターンが比較的隣接していることが確認出来た。また、Fig. 5 (S1) のように「好き」(白色)の脳波パターンは飛び地として分布している場合も確認された (例; 赤丸で囲まれた個所)。SOM は学習データの類似性に基づいて近似マップが作成される特性を持つことから、それらコントラストの違いが個人差を意味している可能性が示唆される (例; 青枠で囲まれた個所)。なお、S4 の結果(Fig. 1 中の(d))は、黒色と灰色で構成された。これは、S4 が「好き」と感じた音が存在しないためであった。また、SOM を適用することで、その違いを視覚的に確認する事が可能になると推測される。さらに、Table 2 において、他の被験者のデータに対するマップとの類似度よりも、同被験者のデータに対するマップ間の類似度が高い。もし他の被験者のデータに対するマップが類似する場合、個人差が著しくないことが示唆され、その類似度も高くなる。しかしながら、他の被験者の結果との類似度は低く、その値も 0.5 未満(0.33~0.49)である。また、同被験者のデータを対象とした場合の SOM 間の類似度は、0.59 以上であった。SOM の初期値設定を 10 通り準備していること、ランダム選択法により学習するデータ群とデータの入力する順番を変更していることを考慮すると、類似度は妥当な値を示していると思われる。一般的に SOM のノードの初期値を変更した場合、マップ上の脳波パターンの分布に変化が見られると予想される。ここで、初期値が変更された SOM に学習用の脳波の特徴量を固定して学習した(初期値のセット数: 10), S1 のサンプル結果を Fig. 6 に示す。(a)~(j)はそれぞれ初期値のセット番号を意味する。赤枠で囲まれている箇所はマップ間の類似度が比較的高い個所である。Fig. 6 の結果に示されるマップ間における脳波パターンの分布が、Fig. 5(S2~S5) に示される他の被験者に対する脳波パターンの分布に比べて、類似していることが分かる。

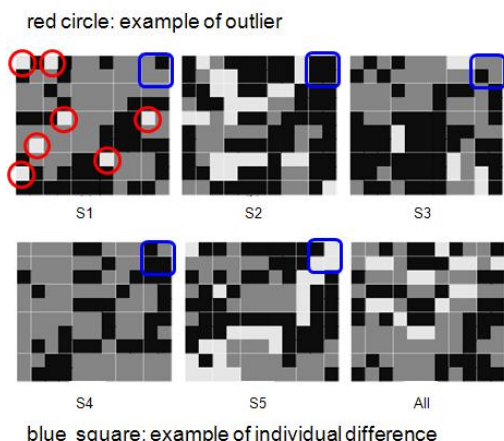


Fig. 5. Example maps on each subject when the initial weight values are same. (a) to (f) are S1 to S5 and all subjects, respectively. White, gray and black nodes indicate LikeSound, Other, DislikeSound, respectively. Red circle and blue square are examples of outlier and individual difference, respectively.

Table 2. Mean and S.D. of similarity on initial parameter sets of SOM that are chosen randomly (10 trials).

	S1	S2	S3	S4	S5
S1	0.67 ±0.03	0.37 ±0.05	0.41 ±0.05	0.49 ±0.04	0.36 ±0.05
S2	—	0.71 ±0.09	0.40 ±0.05	0.33 ±0.05	0.37 ±0.05
S3	—	—	0.66 ±0.01	0.42 ±0.04	0.42 ±0.05
S4	—	—	—	0.74 ±0.02	0.38 ±0.06
S5	—	—	—	—	0.59 ±0.02




Fig. 6. Mean and S.D. of the accuracy rate for learning EEG data sets that are chosen randomly.

これは、同被験者において、抽出された脳波の特徴量間の関連性が安定しているためであると推測される。もし安定した関連性が保たれていない場合、同被験者のマップ間の類似度が低く、かつ、そのばらつきも大きくなるものが推測され、その分布も、Fig. 5 に示す他の被験者

のマップと同様に、著しく異なるコントラストを持つマップが生成されることが容易に推測できる。

また、学習データを SOM の入力とした場合の脳波パターン分類結果において(Fig. 6), すべての被験者のデータを対象とした場合、その分類識別率が 6 割程度であり、学習が困難であったことが確認された。これは、同一の脳波パターンに対する脳波が被験者ごとに異なっているためであると考えられる。一方、被験者ごとでは、脳波パターンの分類識別率は 0.85 以上であり、学習に成功していると思われる。同一の脳波パターンが飛び地にて分布している Fig. 5 の結果を考慮すると、同一の脳波パターンに対する脳波の特徴量が複数存在することが示唆される。しかしながら、その脳波の特徴量は被験者間で抽出された脳波の特徴量に比べて、その特徴量が意味する脳波パターンと脳波の特徴量の関連性に何かしら傾向があることが伺える。もし傾向がない場合は、SOM による脳波パターンの分類識別精度も低く、そのばらつきも大きいと容易に推測される。くわえて、SOM はその傾向をも学習可能であることが示唆される。そして、その傾向は同一の脳波パターンに対して存在する複数の脳波の特徴量間の関連性であると思われるが、この点に関しては不明である。

4. まとめ

本プロジェクトでは、危険運転を引き起こすきっかけとなる逸脱状態を検出するシステムの構築と、心理的個人差を用いたシステムの高精度化を目的とし以下の内容について検討を加えた。

頭部姿勢定量化については、実車データを対象に、2 つの教師なしニューラルネットワーク (SOMs と Fuzzy ART) をハイブリッド化した頭部姿勢分類手法により、頭部姿勢の定量化を行った。その結果、分析結果に基づいた頭部姿勢を、個人の頭部姿勢数に合わせて分類可能であることが明らかとなった。今後は、Fuzzy ART の Vigilance パラメータの最適化について、個人ごとの頭部姿勢数との関連から検討を行うとともに、危険運転予測を行うための頭部姿勢空間の構築について検討を加える

予定である。また、脳波の個人差を評価するため、音聴取時の脳波を計測し、脳波から特徴を抽出した後に、SOMを用いて脳波パターンの分類識別を行うと共に、生成されたSOMの違いから個人差を分析した。その結果、脳波の個人差を可視化できる可能性が示唆された。

謝辞

本稿は、平成23年度徳島大学先端工学教育研究プロジェクトによる研究結果の一部をまとめたものである。本研究を助成くださいました関係者各位に深く感謝の意を表します。

参考文献

- (1) 米川隆：アクティブセイフティ技術の展望と課題，自動車技術会シンポジウム「事故死傷者ゼロを目指す予防安全技術の展望」(2006)
- (2) 稲垣敏之：リスク環境における人と知能機械の協調をデザインする，電子情報通信学会誌，Vol. 89, No. 12, pp. 1026-1031, (2006)
- (3) 石田健二，蜂須賀知理，木村禎祐，上條正義：覚醒低下に伴う顔表情の表出傾向とパフォーマンス・生体信号の変化に関する比較検討，自動車技術会，Vol.40, No.3, pp.885-890, (2009)
- (4) 伊藤桃代，盛紘一朗，井口祐也，佐藤和人，福見稔：危険運転予測のための頭部動き情報と運転シーンの関連性の分析，動的画像処理実利用化ワークショップ2011講演概要集，pp.198-201, (2011)
- (5) T. Kohonen: Self - organized formation of topologicallycorrect feature maps, Biological Cybernetics, vol.43, no.1, pp.59 - 69, (1982)
- (6) G.A Carpenter, S. Grossberg, and D.B. Rosen: Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system, Neural Networks, No.4, pp.759 - 771, (1991)
- (7) Khosrowabadi R, Hiok C Q, Wahab A, and Kai K A, EEG-based Emotion Recognition Using Self-Organizing Map for Boundary Detection, Proceedings of ICPR 2010, pp. 4242 - 4245, (2010)
- (8) T. Kohonen: Self-Organizing Maps, Springer Series in Information Science, 2nd extended edition 1997; 30.