

長距離運転行動データベースに基づく 運転行動のモデル化

宇津木明男, 加藤晋, 赤松幹之

産業技術総合研究所, 305-8566 つくば市東 1-1-1

a-utsugi@ni.aist.go.jp

Abstract: 高速道路上での業務運転における運転行動を計測するため、実際の運送業務に用いている大型トラックに運転行動計測装置を搭載し、ドライバーの長時間に渡る運転行動データを収集した。この運転行動データベースを用いて、動的確率モデルによる運転行動のモデリングを試みる。

Keywords: 運転行動モデリング, 動的確率モデル, 長距離運転行動データベース

1. まえがき

長距離運転に伴う運転リスクの変化を運転行動や車両状態等から自動的に検知する技術を開発するためには、運転行動の規範モデルが必要となる。実際の運転行動が規範モデルから逸脱する程度によってその行動の適切さを判定することができる。特に規範モデルが確率モデルによって表現できれば、行動の逸脱度を計測データの尤度から求めることができるようになる。

近年、変量間の複雑な確率的依存関係を表現する枠組みとしてベイジアンネットワークのような確率的構造モデルの利用が盛んになっている¹⁾。伝統的な時系列モデルとして利用されている確率モデルも、動的ベイジアンネットワークの枠組みの中で新たに捉え直され、より複雑な時系列的確率構造を扱えるように拡張されている。

確率的な規範モデルは学習に拠らずトップダウンに構築することも可能であるが、ここでは実際の大型運送トラックによる長距離業務運転に伴って計測されたデータからの学習による構築を目指す。実際の運転行動パターンのバリエーションは非常に多様かつ複雑であり、データの目視によって特徴を定性的に捉えるやり方には限界がある。動的確率モデルの学習手法を用いて、長距離運転行動データから日常的な運転行動の動的確率モデルの自動構築を試みる。

2. 長距離運転行動の計測

運転操作行動・車両状態・交通状況・運転者状態等を計測し、長時間の記録が可能な長距離運転行動計測装置を9台開発した。この長距離運転行動計測装置を実際の運送業務に用いている9台の大型トラックに搭載し、10名のドライバーのデータを半年程度収集している。更に9台の別のトラックに計測装置を載せ換えることにより、最終的にはトラック18台、ドライバー

20名程度のデータを収集する予定である。

2.1 長距離運転行動計測装置の開発

長距離運転行動計測装置の構成を図1に示す。

運転操作行動として、ハンドル角、ペダル（アクセル、ブレーキ）踏み込み量、ペダル上の足の有無、ウィンカー操作等を計測する。ハンドル角、ペダル踏み込み量、足位置の計測にはレーザーセンサを用いる。

車両状態として、車速、エンジン回転数、加速度（3方向）、角速度（3方向）、車両位置等を計測する。3方向の加速度および角速度は、それぞれ加速度計とジャイロを用いて計測する。また、車両位置等（緯度、経度、高度、方位）は自律航法ユニット付きのGPSセンサを用いて計測する。高速道路上の車両位置は、キロポストディスプレイを用いても計測される。

交通状況として、先行車との相対距離・相対速度等を、レーザーレーダーによる車間センサを用いて計測する。また、3台のCCDカメラによって前方および左右後側方の交通状況を撮影する。

運転者状態として、運転者の画像を1台のCCDカメラによって撮影する。

画像データは映像記録装置によりモバイルハードディスクに記録される。その他の計測データはデータ記録装置によりメモリースティックに記録される。センサデータのサンプリングレートを10Hz、画像データのサンプリングレートを4フレーム/秒とすることによって10時間程度の長期記録を可能にした。

計測データを統合して表示するソフトウェアの画面を図2に示す。4分割画面で表示される画像データ、車間センサによる先行車の分布、地図上の車両位置、各センサ値のグラフが表示される。

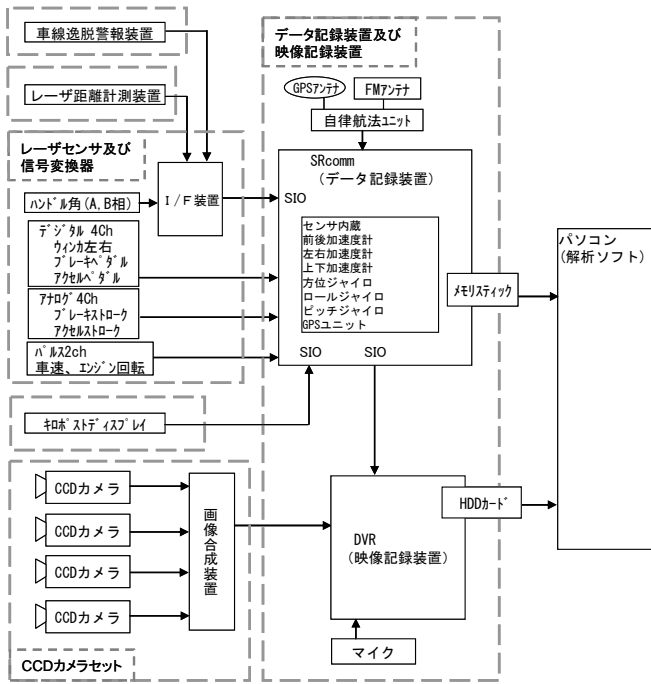


図1 長距離運行動計測装置の構成

データを求めた。縦断データの一部を図3に示す。これらの道路状態に関するデータは、高速道路上の車両位置（キロポスト）を介して、長距離運行動データベースに統合される。




図3 東名高速道路（40～110KP）下り車線の縦断データ

3. 運転行動のモデリング

3.1 長距離運行動データの特徴

大型貨物自動車は最高速度 90km/h の速度抑制装置（スピードリミッタ）の装備が義務付けられているため、急勾配の下り坂以外では 90km/h を超えることはできない。このため高速道路上では 90km/h 未満の一定速度で走行するケースが多い。同一車線の前方に低速車がある場合も、一定速度で先行車に接近した後、車線変更して先行車を追い越すケースが多い。交通量が少なく、車線変更が自由にできる状況では、殆ど減速をしない戦略が採られるものと思われる。

交通量が増加して車線変更が自由にできなくなると、先行車の状態に応じた減速操作をするようになる。比較的交通量が少ない場合は、追い越し車線が空いて追い越しが可能になるのを待つために、一時的な減速をすることがある。更に交通量が増えて、車線変更が困難になると、先行車への追従運転を行うようになる。これは、先行車との相対距離・相対速度の変化に応じて、自車の速度を細かく調整するモードである。

交通状況のモードに応じて、ドライバーは運転制御戦略のモードを適切に切り替える必要がある。特に、モード間の作業量の違いが大きいため、必要な精神的緊張度のレベルも大きく異なってくる。緊張をあまり必要としない交通状況から高い緊張度を必要とする交通状況へのシフトが急になされた場合、ドライバーの運転モードの適切な移行が十分速やかになされない可能性がある。実際、交通量が突然増加するケースはしばしばあり、最もリスクの大きな状況だと考えられる。

交通量のセンシングは比較的容易であるが、ドライ

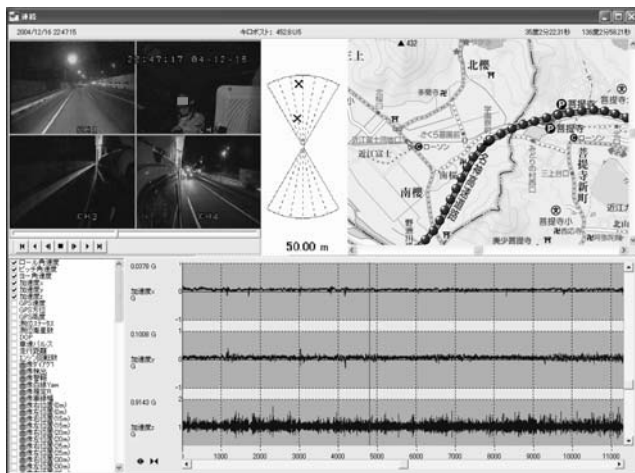


図2 計測データの表示ソフトウェア

2.2 高速道路運転行動の計測と蓄積

東京—大阪間の高速道路（東名高速道路、名神高速道路）を定期運行する 9 台の運送トラックに長距離運行動計測装置を設置し、約半年間の運転行動データを収集している。データはノイズ除去・正規化などの前処理が施された後、RDBMSによりデータベース化される。

また、東名および名神高速道路の道路図面から、横断曲率半径 (R)、縦断勾配、高度などの道路線形デー

バーの運転制御モードの推定は難しい。ここでは、自転車加速度と先行車との相対速度のデータから、運転制御モードを推定する方法について考察する。

3.2 フィードバック系の確率モデル

多変量自己回帰モデル(VAR: Vector Auto-Regressive model)はフィードバック系の解析に良く使われる時系列モデルである²⁾。例として、先行車との相対速度に応じてドライバーが自転車加速度を調整し、相対速度を0に保とうとするフィードバック系を考えよう(図4)。相対速度と自転車加速度をそれぞれ x, y と表す。ドライバーは相対速度 x に応じてペダル操作により自転車加速度 y を変化させる。ドライバーと車両の応答を線形系で近似したものを H_1 とし、残差を e_1 とする。また、 H_2 を符号反転した積分器とする。その出力は自転車の速度を符号反転したものとなる。これを先行車の速度 e_2 に加えることで新たな相対速度 x が得られ、 H_1 への入力として戻ってくる。




図4 フィードバック系のブロック線図

H_1 と H_2 の伝達特性をそれぞれ $B_1/A_1, B_2/A_2$ とする。ここで、

$$A_1 = 1 - a_{11}z^{-1} - a_{12}z^{-2} - \dots - a_{1k}z^{-k}$$

$$B_1 = b_{11}z^{-1} + b_{12}z^{-2} + \dots + b_{1k}z^{-k}$$

$$A_2 = 1 - a_{21}z^{-1} - a_{22}z^{-2} - \dots - a_{2k}z^{-k}$$

$$B_2 = b_{21}z^{-1} + b_{22}z^{-2} + \dots + b_{2k}z^{-k}$$

とする。 z^{-1} は遅延作用素である。また、 e_1 と e_2 は独立な白色ノイズ w_1, w_2 によって駆動されるAR系列 $e_1=(1/A_1)w_1, e_2=(1/A_2)w_2$ と仮定する。このような伝達特性と外乱特性を持つシステムのモデルはARXモデル(Auto-Regression with eXtra inputs)と呼ばれる。2つのARX系の入力と出力をそれぞれ連結したシステム全体は次のようなVAR系列を生成するシステムとみなす事ができる。

$$\begin{bmatrix} y_t \\ x_t \end{bmatrix} = \begin{bmatrix} a_{11} & b_{11} \\ b_{21} & a_{21} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \end{bmatrix} + \dots + \begin{bmatrix} a_{1k} & b_{1k} \\ b_{2k} & a_{2k} \end{bmatrix} \begin{bmatrix} y_{t-k} \\ x_{t-k} \end{bmatrix} + \begin{bmatrix} w_{1t} \\ w_{2t} \end{bmatrix}$$

これはベクトル・行列表記によって、

$$\mathbf{x}_t = \mathbf{A}_1 \mathbf{x}_{t-1} + \mathbf{A}_2 \mathbf{x}_{t-2} + \dots + \mathbf{A}_k \mathbf{x}_{t-k} + \mathbf{w}_t$$

と表すことができる。これは2変量の場合に限らず、一般の多変量時系列に拡張することができる。多変量時系列データにVARモデルを適用し、パラメータ(自己回帰係数 $\mathbf{A}_1, \dots, \mathbf{A}_k$ および白色ノイズの共分散 Σ)を推定することにより、フィードバック系を構成する部分システムの伝達特性と外乱特性を推定することができる。ここでは、更にバイアス \mathbf{b} も考慮し、パラメータとして扱う。

3.3 自己回帰隠れマルコフモデル

VARモデルは、制御特性や外乱特性が時間的に変化しない時系列を表現するモデルである。これらの特性の時間変化を表すために、離散的な隠れ変数(隠れ状態)を導入してVARモデルを拡張したのが自己回帰隠れマルコフモデル(AR-HMM: Auto-Regressive Hidden Markov Model)である。これはMarkov-switching modelとも呼ばれる³⁾。あるいは、隠れマルコフモデル(HMM)の観測変数に、自己回帰型のダイナミクスを加えたものと見なすこともできる。




図5 AR-HMMのDBN構造

図5は、動的ベイジアンネットワーク(DBN)としてのHMMとAR-HMMの違いを示すために良く使われるものである。各円(ノード)は個々の変数を表す。ただし、変数は一般にベクトル値をとるものとし、時刻毎に異なる変数を使う。下段の灰色ノードはデータを持つ観測変数を、上段の白色ノードはデータを持たない隠れ変数をそれぞれ表す。点線の箱は時間スライスを表している。円を結ぶ有向リンクは直接的な確率的依存関係の存在を表す。図5はAR-HMMのDBN構造を表しているが、これから観測変数間リンクを外すとHMMのDBN構造となる。

各ノードは、親ノード(リンクが向けられているノード)の変数を条件に持つ条件付き確率分布を持つ。この確率分布のパラメータをデータから推定することが学習である。HMMとAR-HMMは共に“時不変”のDBNであり、パラメータは全ての時間スライスで共通

である。AR-HMMはDBNとしては“時不変”であるが、上段の隠れ変数が下段のVARモデルのパラメータを切り替えるスイッチの役割を担っており、VARモデルとしては“時変”となる。

パラメータの推定アルゴリズムはここでは詳しく述べないが、HMMの推定アルゴリズムと類似した効率的なアルゴリズムが存在する³⁾。尤度や状態の事後確率の計算に使われるForward-Backwardアルゴリズムおよび初期確率と遷移確率の推定アルゴリズムはHMMと共通である。自己回帰係数と残差共分散の推定には、線形回帰計算に基づくEMアルゴリズムが使われる。

図4に示した追従運転のモデルのうち、ドライバーの行動特性の関わる部分は H_1 と e_1 からなる部分システムである。先行車速度 e_2 のスペクトル特性と符号反転した積分器 H_2 は状態に関わらず一定とみなした方が適切である。このようなパラメータの制約はタイ(tie)と呼ばれ、EMアルゴリズムの内部で容易に実現できる。

パラメータの推定原理としては、最尤推定法が使われることが多いが、HMMやAR-HMMのような混合分布型の確率モデルの場合、最尤推定法は不安定になりうまくいかない場合がある。ここでは、回帰係数と残差分散に事前確率分布を導入し、最大事後確率(MAP: Maximum A Posteriori) 推定を使う。

3.4 長距離運転行動データの解析

車間センサによって捕らえられた先行車との相対距離および相対速度が連続的に変化する区間のデータを切り出し、相対速度と自車加速度を2変量時系列データとして、AR-HMMの学習を行った。センサデータは10Hzのサンプリングレートで計測しているが、解析では10点毎に平均を取り、1秒間隔の時系列として扱った。相対速度と加速度のデータの例を図6の1行目と2行目に示す。また、相対距離を3行目に、自車速度(実線)と先行車速度(点線)を4行目に示す。

状態数 $q=3$ 、VAR次数 $k=2$ のAR-HMMのパラメータ推定を行った。パラメータの初期値は適切な範囲でランダムに生成し、30個の異なる初期値からアルゴリズムをスタートした。このうち、事後確率が最大のものを最終推定値として採用した。回帰係数と残差分散の事前確率分布には共役事前確率分布を用いた。

学習されたAR-HMMモデルによる隠れ状態の推定値を図6の5行目に示す。これはViterbiアルゴリズムによって得られる最尤状態系列に基づいている。また、図7に各状態におけるドライバーのステップ応答の推定値を示す。

最初の約30秒間、ドライバーは先行車の速度変化に拘らず、物理的に可能な最高速度で走行している。このような運転戦略は高速道路上で最も多く見られるものである。その後、先行車の急激な減速に応じてパルス的な減速操作をしている。その後、平均速度が80km/h程度に減少し、ドライバーは先行車に追従運転

するようになる。相対速度から自車加速度へのステップ応答(図7のstate 3)の高いゲインと短い立ち上がり時間がタイトな運転制御特性を示している。

4. まとめ

大型運送トラックによる高速道路上の長距離運転行動データを収集し、長距離運転行動データベースを構築した。このデータベースを用いた運転行動のモデリングとして、AR-HMMによる追従運転のモデリングを行った。

本研究は、文部科学省科学技術振興調整費重要課題解決型プロジェクト「状況・意図理解によるリスクの発見と回避」によって行われるものである。

参考文献

- [1] Stuart J. Russell et al., Artificial Intelligence A Modern Approach 2nd ed., Prentice Hall, 2002.
- [2] 尾崎統ほか, 時系列解析の方法, 朝倉書店, 1998.
- [3] Chang-Jin Kim et al., State-Space Models with Regime Switching, MIT Press, 1999.




図6 データサンプルと状態推定




図7 ドライバーのステップ応答の変化