

## テクニカルノート

## ドライブレコーダを用いた交通事故発生予測

瀧本 祥章<sup>1,a)</sup> 田中 佑典<sup>1</sup> 倉島 健<sup>1</sup> 山本 修平<sup>1</sup> 大川 真耶<sup>1</sup> 戸田 浩之<sup>1</sup>

受付日 2020年6月9日, 採録日 2020年6月30日

**概要:** 近年, 交通事故に関する大量のデータがドライブレコーダによって収集されている. 本稿では, ドライブレコーダデータを活用し, 交通事故の発生予測を行う手法を提案する. 提案手法は生存分析に基づいており, 前方映像と自車の位置情報を入力とし, 交通事故が発生するまでの猶予時間を予測できる. 生存分析におけるハザード関数を, 前方映像を入力としたニューラルネットワークと, 自車の位置情報を入力としたニューラルネットワークを用いてモデル化する. これにより, 歩行者や障害物などの周辺状況の時間的変化, および, 地域における事故の発生しやすさに基づいた予測が可能となる. また, モデルのパラメータは対数尤度を損失関数とした誤差逆伝播法により最適化が可能である. 実データを用いた実験により, 提案手法が既存手法よりも事故発生の猶予時刻を正確に予測できることを示す.

キーワード: 生存分析, 深層学習, ドライブレコーダ

## Predicting Traffic Accidents with Dashboard Cameras

YOSHIAKI TAKIMOTO<sup>1,a)</sup> YUSUKE TANAKA<sup>1</sup> TAKESHI KURASHIMA<sup>1</sup> SHUHEI YAMAMOTO<sup>1</sup>  
MAYA OKAWA<sup>1</sup> HIROYUKI TODA<sup>1</sup>

Received: June 9, 2020, Accepted: June 30, 2020

**Abstract:** Large amounts of data on accidents are being collected by dashboard cameras (dashcams). We propose a survival analysis model for predicting the accident occurrence time from data gathered by a dashboard camera in this paper. The hazard function of the proposed model is modeled by a convolutional recurrent neural network whose input is video data and a neural network whose input is location data. Thus, our model can predict accidents considering (1) changes in the situation of own car and surroundings based on the video and (2) the frequency of accidents from location data. The model parameters are estimated by backpropagation using the negative log-likelihood as the loss function. Experiments on real-world dashcam data show that our model can more accurately predict accident occurrences than baseline models.

**Keywords:** survival analysis, dashboard camera, traffic accident

## 1. はじめに

近年, ドライブレコーダが急速に普及し, 多くの運転データが収集されるようになった. 特に, 交通事故などの特定のイベントに関連する運転データは EDR データ (Event Data Recorder) と呼ばれる. EDR データは, イベントの前後数十秒間の車両の前方映像や, GPS による位置情報, 加速度などのセンサデータなどで構成される. その膨大さ

から, EDR データには, 都市部や地方, 対車両や対歩行者などの多様な状況の交通事故について, 発生までの過程を示す記録が含まれることが期待できる. そのため, これらの EDR データを活用することにより, 様々な状況下において交通事故の発生を予測できるようになると考えられる. 事故予測の実現によって, 運転手への警告, 急ブレーキや急旋回などの対応が可能になり, 運転者支援システムの発展が期待できる.

既存研究 [1], [2] では, 事前に収集された EDR データを元に学習を行い, 交通事故の発生予測に取り組んでいる. 具体的には, 入力として過去から現時点までの映像を受け

<sup>1</sup> 日本電信電話株式会社 NTT サービスエボリューション研究所  
NTT Service Evolution Laboratories, NTT Corporation,  
Yokosuka, Kanagawa 239-0847, Japan

<sup>a)</sup> yoshiaki.takimoto.ar@hco.ntt.co.jp

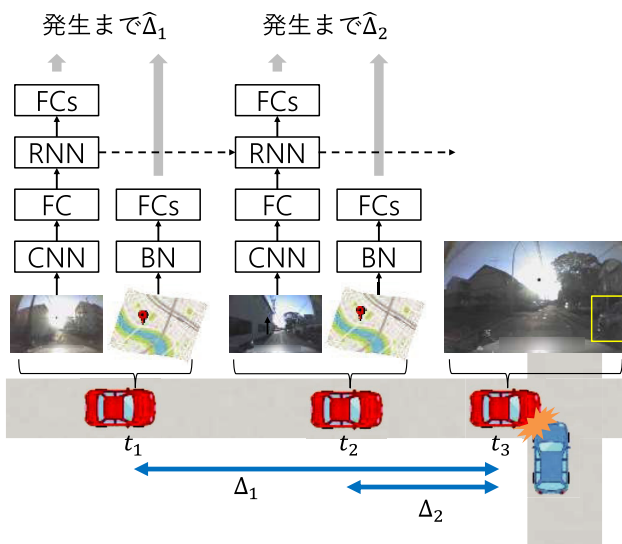


図 1 提案手法の全体像

Fig. 1 Overall of the proposed method.

取り、近い将来に交通事故が発生するか否かを示す“危険”や“安全”のようなラベルを出力する。しかし、交通事故が発生するまでの猶予時間が分からないため、運転手への警告や急ブレーキなど複数考えられる対応から、最適な対応を選択することは困難である。

そこで本稿では、発生の有無のみではなく、交通事故発生までの猶予時間を予測するタスクに取り組む。具体的には、入力はいくつかの既存研究と同様に、過去から現時点（図 1 中の  $t_1$  や  $t_2$ ）までの映像を受け取るが、発生有無を表すラベルではなく交通事故発生までの猶予時間  $\hat{\Delta}_1 = t_3 - t_1$  ( $\hat{\Delta}_2 = t_3 - t_2$ ) を出力する。これにより、状況に応じた対応を選択することが可能になる。たとえば、推定時間が 6 秒の場合には運転手への警告のみを行い、1 秒の場合には急ブレーキをかけるといったことが考えられる。

交通事故発生までの猶予時間予測を実現するため、我々は生存分析モデルに基づく手法を提案する。生存分析では、イベント（交通事故）を含むデータと含まないデータ双方を用いて学習し、イベントが発生するまでの時間を予測する。また、ハザード関数と呼ばれる関数によってイベントの発生しやすさをとらえる。提案手法では、2つのハザード関数の和によってハザード関数をモデル化する。1つ目のハザード関数は Convolutional Recurrent Neural Network (CRNN) [3], [4] を用いてモデル化し、ドライブレコーダの前方映像を入力として、歩行者や障害物などの周辺環境の時系列変化をとらえる。CRNN は Convolutional Neural Network (CNN) と Recurrent Neural Network (RNN) で構成され、CNN によって時刻ごとの自車と周辺環境の状態をとらえ、RNN によってその時系列変化をとらえることを可能にする。2つ目のハザード関数は、交通事故の発生が都市部や地方などの場所の特性に依存することから、位置情報を入力としてモデル化を行う。

本稿の主な貢献は以下のとおりである。

- 生存分析を用いて EDR データから交通事故の発生を予測する最初の試みである。
- 映像と位置情報を入力とする生存分析モデルを提案する。モデルのパラメータは負の対数尤度関数を損失関数として、標準的な誤差逆伝播法によって学習できる。
- 実際のドライブレコーダデータを用いた実験によって、映像と位置情報双方のデータを効果的に利用することにより、既存手法よりもイベント発生までの猶予時間を正確に予測できることを示す。

## 2. 関連研究

### 2.1 映像を用いた事故の発生予測

映像を用いて事故の発生を予測する手法として、いくつかの手法が提案されている [1], [2], [5], [6]。Zeng らは、映像中の危険な領域と事故の発生確率を求めるマルチタスク学習により、被写体となる人物の転倒などを予測する手法を提案した [5]。Wang らは、乳幼児に生じうる事故について、乳幼児の行動速度が遅いことを考慮した事故までの時間に応じた重み付きの損失を提案した [6]。Chan らはドライブレコーダによって得られる映像から、自車の前方で、自動車やバイクなどの交通物体どうしの衝突が数秒以内に発生するか否かを予測するために、Dynamic Spatial Attention (DSA) を提案した [1]。DSA は映像中の各画像から物体検出した結果を、時系列を考慮しつつ適切に処理するための Attention 機構である。また、Suzuki らは自車と他の交通物体との間の事故を予想する課題を解決するため、カリキュラム学習に基づく新しい損失関数を提案した [2]。しかし、これらの手法 [1], [2], [5], [6] は数秒以内に事故が発生するか否かを高精度に分類することを目的としており、発生までの時間は出力されない。これに対し、本稿では“交通事故は 3 秒後に発生する”など、発生までの猶予時間を具体的に予測する問題に取り組む。

### 2.2 生存分析

生存分析では、死亡や故障などのたかだか 1 回しか発生しないイベントについて、その発生までの時間を分析する手法であり、医療やクラウドファンディングなど多くの分野に適用されている [7]。生存分析を用いることにはイベント発生までの時間をとらえられるだけでなく、イベントがしばらく発生しない場合を考慮できるといった利点がある。生存分析と深層学習を組み合わせた手法としては、文献 [8], [9], [10], [11], [12], [13], [14] があげられる。Zhu らは医療画像から患者の寿命を推定するために DeepConvSurv と呼ばれるハザード関数を CNN でモデリングする手法を提案した [8], [9], [10]。また、Ren らは離散化した予測対象時間の系列  $t_1, t_2, \dots$  と現在の特徴量  $\mathbf{x}$  の組  $(t_1, \mathbf{x}), (t_2, \mathbf{x}), \dots$  を入力とする RNN を用いて

ハザード関数をモデル化した [11]. しかし, これらのモデル [8], [9], [10], [11] で提案されるモデルは時系列情報を扱えない. そのため, 時系列変化がイベントに大いに関連する交通事故発生予測ではその精度は制限される.

時系列データを扱う手法としては文献 [12], [13], [14] があげられ, RNN を生存分析に組込んでいる. しかし, 文献 [12], [13] は施設への訪問など, 複数回発生する一連のイベント間の関係に焦点を当てており, 1 系列に対し, イベントがただか 1 度のみ想定される本稿のタスクには適さない. また, 文献 [14] は SNS のアカウント凍結などをイベントとして早期検出を行うが, 解くタスクは文献 [1], [2] と同様に凍結されるか否かの分類であり, 発生までの猶予時間を出力できない. したがって, これらの手法は本稿のタスクに直接適用することはできない. これらの手法に対し, 我々は CRNN によってハザード関数をモデル化し, 猶予時間の出力を行う. これにより, 生存分析フレームワークで映像を処理できるようになる. さらに, 提案手法では映像に含まれる時系列変化のみでなく, 位置情報も考慮してイベント発生までの時間を予測する.

### 3. 問題設定

本稿では EDR データを用いて学習を行う. EDR データについて以下のように定義する.

**定義 1** EDR データ  $v_i = \{(\mathbf{x}_{ij}, t_{ij}, l_{ij}) \mid j = 1, \dots, J_i\}$  は前方画像  $\mathbf{x}_{ij}$ , 時刻  $t_{ij}$ , 位置座標  $l_{ij}$  の 3 つ組 (以下, フレーム) を  $J_i$  個持つ集合である. なお,  $i$  は EDR データ固有の識別子であり,  $j$  は各 EDR データ内において記録された順序を表すフレームの識別子である.

**定義 2** イベントラベル  $\delta_i \in \{0, 1\}$  は EDR データ  $v_i$  の最終フレーム, すなわち,  $t_{iJ_i}$  でイベントが発生した場合 1, 発生していない場合 0 となる指示変数である.

なお, この定義は 1 つの EDR データにただか 1 つのイベントがあることを前提としている. 複数のイベントが EDR データ内に存在する場合には, EDR データを分割することにより, 容易に前提に従った EDR データを用意することが可能である.

次に, 本稿における問題設定を次のように定義する.  $\{(v_i, \delta_i)\}_{i=1}^I$  を学習データとして, 未知の EDR データ  $v^* = \{\mathbf{x}_j^*, t_j^*, l_j^*\}_{j=1}^{J^*}$  を入力としたときに, 将来イベントが発生する時刻  $t$  と EDR データの最終時刻  $t_j^*$  の差である猶予時間  $\Delta^* = t - t_j^*$  を推定する. なお,  $I$  は学習データのサンプル数を表す.

### 4. 準備

提案手法はイベント発生時間の推定に広く用いられる生存分析に基づいている. 以下では, 生存分析について簡単に説明する [7].

生存分析はイベントの発生しやすさをハザード関数に

よって表現する. ハザード関数は,

$$h(\Delta) = \lim_{d\Delta \rightarrow 0} \left[ \frac{P(\Delta \leq t < \Delta + d\Delta \mid t \geq \Delta)}{d\Delta} \right] \quad (1)$$

と定義される. ここで,  $t$  はイベントの発生時刻,  $d\Delta$  は微小時間を表し,  $P(\bullet)$  は時間間隔中にイベントが発生する確率を表す. すなわち, ハザード関数  $h(\Delta)$  は時刻  $\Delta$  までイベントが発生しなかった場合に, その直後の時刻  $\Delta + d\Delta$  までにイベントが発生する確率を表す. また, 観測  $\{(\Delta_i, \delta_i)\}_{i=1}^I$  が与えられたとき, 尤度は,

$$P(\{\Delta_i\}_{i=1}^I \mid h(\Delta)) = \prod_{i=1}^I \left\{ [h(\Delta_i)]^{\delta_i} \cdot \exp \left[ - \int_0^{\Delta_i} h(u) du \right] \right\} \quad (2)$$

と表され, これを最大化することによりモデルのパラメータを推定できる.

猶予時間の予測には, 生存関数  $S(\Delta) = \exp[-\int_0^{\Delta} h(u) du]$  を用いて, 文献 [15] や事前定義した閾値などにより決定できる. なお, 生存関数  $S(\Delta)$  は  $\Delta$  までイベントが発生しない確率を表す. 本稿では, 猶予時間の期待値, すなわち,  $\mathbb{E}[\Delta] = \int_0^{\infty} \Delta h(\Delta) S(\Delta) d\Delta$  を予測値とする.

### 5. 提案手法

#### 5.1 モデルの定式化

提案手法は生存分析に基づいており, 図 1 のように 2 つの要素 (映像, 位置情報) を考慮する. 映像には, 周囲の歩行者などの交通事故の兆候が含まれることが想定される. また, 位置情報にも, 重要な情報が含まれていることが想定される. たとえば, 現在位置の近くに学校や公園がある場合, 子供が通りを横断する可能性が高いと考えられる. 以上のことから, 2 つの要素によってハザード関数を,

$$h(\Delta \mid v_{ij}) = h^{\text{img}}(\Delta \mid \{\mathbf{x}_{ik}\}_{k=1}^j) + h^{\text{loc}}(\Delta \mid l_{ij}) \quad (3)$$

のように設計する. ここで,  $v_{ij}$  は時刻  $t_{ij}$  までの EDR データ, すなわち,  $v_{ij} = \{(\mathbf{x}_{ik}, t_{ik}, l_{ik}) \mid k = 1, \dots, j\}$  を表す. また,  $h^{\text{img}}(\Delta \mid \{\mathbf{x}_{ik}\}_{k=1}^j)$  は自転車やその周囲の時系列変化から定まるハザード関数を表し,  $h^{\text{loc}}(\Delta \mid l_{ij})$  は位置情報から定まるハザード関数を表す. これらの詳細は後述する.

##### 5.1.1 映像によるハザード関数

ハザード関数  $h^{\text{img}}(\Delta \mid \{\mathbf{x}_{ik}\}_{k=1}^j)$  は入力として, 映像, すなわち, 時刻ごとの画像を受け取る. そこで, CRNN, すなわち, CNN と RNN によって,

$$h^{\text{img}}(\Delta \mid \{\mathbf{x}_{ik}\}_{k=1}^j) = \exp[f^{\text{img}}(\{\mathbf{x}_{ik}\}_{k=1}^j; \theta^{\text{img}})] \quad (4)$$

のようにモデル化する. ここで  $f^{\text{img}}(\bullet)$  は CRNN によって入力映像に対し, 非線形変換を行いスカラー値にする関数であり,  $\theta^{\text{img}}$  はそのパラメータである. また, ネットワークは図 1 のように画像の特徴を抽出するための CNN

層、次元を圧縮するための全結合 (FC) 層、時系列情報をとらえる RNN 層、スカラー値に変換する FC 層で構成される。本稿では、CNN 層には VGG [16] を、RNN 層に Gated Recurrent Unit (GRU) [17] を用いた。またここでは簡単のため、ハザード関数は予測時間  $\Delta$  に依存せず、一定の値をとるものとした。なお、ハザード関数には、ワイブル分布に従う確率変数の確率密度関数など、任意の解析的に積分可能である関数を用いることが可能である。より複雑で一般的なハザード関数は精度の向上に貢献することが期待される一方、より多くの計算量や学習データが必要となることが想定される。

### 5.1.2 位置情報によるハザード関数

ハザード関数  $h^{loc}(\Delta | l_{ij})$  は入力として、位置情報、すなわち、緯度と経度を受け取る。本稿では、図 1 のように Batch Normalization (BN) 層と FC 層によって非線形変換を行い、スカラー値にする関数  $f^{loc}(\bullet)$  を用いて、

$$h^{loc}(\Delta | l_{ij}) = \exp[f^{loc}(l_{ij}; \theta^{loc})] \quad (5)$$

のようにモデル化する。なお、 $\theta^{loc}$  は  $f^{loc}(\bullet)$  のパラメータを表す。

## 5.2 パラメータの推定

各ハザード関数のパラメータは、負の対数尤度を損失関数として、誤差逆伝播法により推定できる。式 (2) から尤度は、

$$\begin{aligned} P(\mathbb{D} | h(\Delta)) &= \prod_{i=1}^I \prod_{j=1}^{J_i} \left\{ [h(\Delta_{ij} | v_{ij})]^{\delta_i} \right. \\ &\quad \left. \cdot \exp \left[ - \int_0^{\Delta_{ij}} h(u | v_{ij}) du \right] \right\} \quad (6) \end{aligned}$$

のように書き下せる。なお、式中の  $\mathbb{D}, \Delta_{ij}$  はそれぞれ  $\mathbb{D} = \{(v_i, \delta_i)\}_{i=1}^I, \Delta_{ij} = t_{iJ_i} - t_{ij}$  を表す。各データ  $i$  の各時刻  $t_{ij}$  における尤度の積を最大化するため、任意の時刻から正確な予測が行えることが期待される。また、積分部分は、 $f^{img}$  および  $f^{loc}$  が  $u$  に依存しないため、

$$\begin{aligned} &\int_0^{\Delta_{ij}} h(u | v_{ij}) du \\ &= \int_0^{\Delta_{ij}} [h^{img}(u | \{\mathbf{x}_{ik}\}_{k=1}^j) + h^{loc}(u | l_{ij})] du \\ &= \int_0^{\Delta_{ij}} \left\{ \exp[f^{img}(\{\mathbf{x}_{ik}\}_{k=1}^j)] + \exp[f^{loc}(l_{ij})] \right\} du \\ &= h(\Delta_{ij} | v_{ij}) \Delta_{ij} \quad (7) \end{aligned}$$

のように計算可能である。

## 6. 評価実験

### 6.1 データセット

実際の EDR データを用いて提案手法の有効性を確認す

る。本稿の目標は、交通事故発生までの猶予時間を予測することであるが、交通事故をともなう EDR データの蓄積は進んでいるものの、現時点では不十分である。そこで本稿では、文献 [2] で交通事故予測手法の検証に用いられたヒヤリハットデータベース [18] を使用した。ここで、ヒヤリハットは交通事故ではないものの、急ブレーキなどの対処が必要な危険な状態である。実験のために、まずヒヤリハットデータベースから 1,800 個のヒヤリハットデータと、1,800 個の安全、すなわち、ヒヤリハットを含まないデータをランダムに抽出した。抽出した各データは静岡市の都市部をタクシーが走行中に縦方向の 0.45 G 以上の加速度を観測した際に、それをトリガとして収集され、人手によってヒヤリハットの有無を表すラベルが付加されている。また、各データには 30 fps でトリガの前 10 秒、後 5 秒の映像が記録されており、本稿ではトリガのタイミングをイベント発生時刻とみなした。前処理によってヒヤリハットデータはトリガを最終時刻として長さが 1 秒から 10 秒になるように映像を抽出した。これは、各ヒヤリハットデータにトリガ (イベント) を含める必要があることと、データ長からトリガ時刻を予測できなくするためである。また、安全なデータについてはイベントが含まれていないことから長さが 1 秒から 15 秒になるようランダムに映像を抽出した。また、データセットは学習用に 60%、ハイパーパラメータのチューニング用に 20%、残りの 20% を評価に用いた。

### 6.2 評価指標

予測精度を評価するために、2 つの評価指標を用いた。1 つ目は、Capped Mean Absolute Error (CMAE) である。CMAE は Mean Absolute Error (MAE) と同様に予測猶予時間と正解の猶予時間の差を評価するが、予測値に

$$CMAE = \frac{\sum_{\{(i,j) \in \mathbb{D} | \delta_i = 1\}} |\Delta_{ij} - \min(\hat{\Delta}_{ij}, \tau)|}{|\{(i,j) \in \mathbb{D} | \delta_i = 1\}|} \quad (8)$$

の式中的ように上限を定めるという点で異なる。なお、 $\tau$  は予測値の上限を設定するための閾値であり、本稿ではデータセット中に 15 秒以上のデータが存在しないことから 15 秒に設定した。これは、15 秒よりも大きな予測値はイベントがしばらく発生しないことのみを表し、具体的な値に意味はないためである。CMAE は予測誤差の評価は行えるが安全なデータに対する評価、すなわち、イベントがしばらく発生しない状態をとらえられるか評価できない。そこで、2 つ目の評価指標に生存分析の文脈でよく用いられる Concordance index (c-index) [19] を用いる。C-index はモデルがすべてのデータの猶予時間を適切に順序付けできた度合いを表し、精度が良いほど大きい値 (上限 1) をとる。

### 6.3 比較手法

比較は 2 種類の深層学習に基づくベースライン手法と、

表 1 各モデルの予測結果に対する評価指標の値

Table 1 C-index and CMAE for near-miss prediction.

|                               | C-index | CMAE (seconds) |
|-------------------------------|---------|----------------|
| ClassifierBase                | 0.649   | 3.82           |
| DeepConvSurv                  | 0.661   | 3.73           |
| Proposed1 (w/o location data) | 0.686   | 3.42           |
| Proposed2 (w/ location data)  | 0.687   | 3.29           |

提案手法について位置情報を考慮するものとししないもので行った. 具体的な比較手法は以下のとおりである.

**ClassifierBase** はマルチクラス分類に基づくモデルであり, 入力として映像を受け取り, イベント発生までの猶予時間を表すクラスラベルを出力する. クラスには10種の危険クラスと1種の安全クラスの合計11種を用意した. なお, 各危険クラスは“0秒後から1秒後”から“9秒後から10秒後”までであり, 1秒単位で猶予時間を表す. また各クラスの予測猶予時間は, 危険クラスについては中央値, すなわち, 1秒後から2秒後であれば1.5秒後とし, 安全クラスは $\tau = 15.0$ 秒後とした.

**DeepConvSurv** 文献 [8] は生存分析に基づく手法であり, 画像  $\mathbf{x}_j^*$  のみを入力とし, 猶予時間を出力する.

**Proposed1** は位置情報を含まない提案手法であり, 映像  $\{\mathbf{x}_j^* \mid j = 1, \dots, J^*\}$  を入力とし, 猶予時間を出力する.

**Proposed2** は5章で述べた提案手法であり, 映像と位置情報  $\{(\mathbf{x}_j^*, l_j^*) \mid j = 1, \dots, J^*\}$  を入力とし, 猶予時間を出力する.

また, 各々の手法について, CNNにはPlaces365 [20] で事前学習したVGGを用い, 最適化手法にはadabound [21]を用い, 他のユニット数や学習率などのハイパーパラメータについてはc-indexに基づいて手法ごとに決定した.

### 6.4 実験結果

実験結果は表1のとおりである. 画像のみを用いて時系列を扱わないDeepConvSurvの精度が, 映像を扱うClassifierBaseよりも精度が高いことから生存分析によるアプローチが有望であることが分かる. さらに, Proposed1はDeepConvSurvに対し, Proposed2はProposed1に対し, より精度が高いことが確認できる. そのため, RNNと位置情報の両方がそれぞれ精度向上に貢献することが分かる.

図2(a)は正解猶予時間 $\Delta_{ij}$ を3つの範囲に分け, それぞれのCMAEを示したものであり, 図2(b)は同じ範囲で $h^{img}$ と $h^{loc}$ の $h$ に占める割合を表したものである. 図2(a)から, CMAEについて猶予時間が長いほど全体的に精度が劣化する傾向にあることが見て取れる. しかし, Proposed2では精度の劣化が比較的抑えられていることが分かる. これは, 猶予時間が長い場合, ヒヤリハットの原

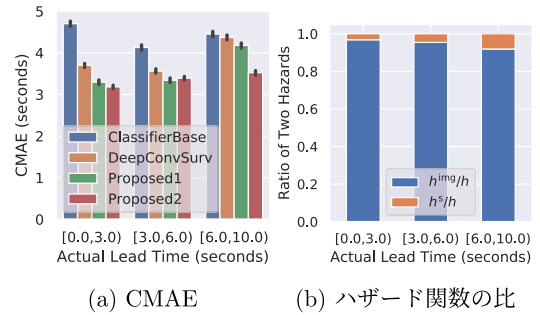


図 2 正解猶予時間ごとの比較

Fig. 2 (a) CMAE versus actual lead time. (b) Ratio of  $h^{img}$  and  $h^{loc}$  versus actual lead time.

因が映像に映っておらず, 映像から予測することが難しいものの, 位置情報がそのような場合に予測性能を高めるのに効果的であることを示唆する. このことは, 図2(b)からも位置情報に基づく $h^{loc}$ の占める割合が, 猶予時間が長い程大きいことが確認できることからいえる. なお, 正解猶予時間 $\Delta_{ij}$ が[0.0, 3.0)の場合であっても, 3秒以上と大きな値となっている. これは予測に失敗, すなわち, 危険であるにもかかわらず安全であると予測した結果がCMAEにおいては支配的であるためと考えられる. 実際, 正解猶予時間 $\Delta_{ij}$ が[0.0, 3.0)の場合の, 各手法における予測猶予時間と正解猶予時間の差の中央値はClassifierBaseが1.13秒, DeepConvSurvが1.20秒, Proposed1が0.992秒, Proposed2が0.967秒となっている.

### 7. まとめ

本稿では, ドライブレコーダで収集された映像と位置情報に基づいて, 自車が遭遇する交通事故の発生までの猶予時間を予測する課題に取り組んだ. 具体的には, 生存分析にCRNNを組み込むことで, 映像(高次元時系列特徴)を扱えるように拡張し, さらに位置情報の考慮も行った. 実際に収集されたドライブレコーダを用いた実験では, 提案手法による2つの拡張が効果的であることを確認した. 今後の課題としては, 実際の事故データを用いた検証や, CNNやRNN部分のネットワーク構造の検討, 加速度センサーなどの新たな情報源の追加, 文献[11]などのより複雑で柔軟なハザード関数の導入などによる精度向上があげられる.

**謝辞** 本研究は, 国立大学法人東京農工大学スマートモビリティ研究拠点の提供する「ヒヤリハットデータベース」を利用した. ここに記して謝意を示す.

### 参考文献

[1] Chan, F.-H., Chen, Y.-T., Xiang, Y. and Sun, M.: Anticipating accidents in dashcam videos, *ACCV*, pp.136-153, Springer (2016).  
 [2] Suzuki, T., Kataoka, H., Aoki, Y. and Satoh, Y.: Anticipating Traffic Accidents with Adaptive Loss and Large-

- scale Incident DB, arXiv:1804.02675 (2018).
- [3] Cakır, E., Parascandolo, G., Heittola, T., Huttunen, H. and Virtanen, T.: Convolutional recurrent neural networks for polyphonic sound event detection, *TASLP*, Vol.25, No.6, pp.1291-1303 (2017).
  - [4] Adavanne, S., Pertilä, P. and Virtanen, T.: Sound event detection using spatial features and convolutional recurrent neural network, *ICASSP*, pp.771-775, IEEE (2017).
  - [5] Zeng, K.-H., Chou, S.-H., Chan, F.-H., Carlos Niebles, J. and Sun, M.: Agent-centric risk assessment: Accident anticipation and risky region localization, *CVPR*, pp.2222-2230 (2017).
  - [6] Wang, P.-J., Lien, S.-F. and Lee, M.-S.: A Learning-Based Prediction Model for Baby Accidents, *ICIP*, pp.629-633, IEEE (2019).
  - [7] Wang, P., Li, Y. and Reddy, C.K.: Machine learning for survival analysis: A survey, *CSUR*, Vol.51, No.6, pp.1-36 (2019).
  - [8] Zhu, X., Yao, J. and Huang, J.: Deep convolutional neural network for survival analysis with pathological images, *BIBM*, pp.544-547, IEEE (2016).
  - [9] Yao, J., Zhu, X., Zhu, F. and Huang, J.: Deep correlational learning for survival prediction from multimodality data, *MICCAI*, pp.406-414, Springer (2017).
  - [10] Zhu, X., Yao, J., Zhu, F. and Huang, J.: WSISA: Making Survival Prediction From Whole Slide Histopathological Images, *CVPR* (2017).
  - [11] Ren, K., Qin, J., Zheng, L., Yang, Z., Zhang, W., Qiu, L. and Yu, Y.: Deep recurrent survival analysis, *AAAI*, Vol.33, pp.4798-4805 (2019).
  - [12] Jing, H. and Smola, A.J.: Neural survival recommender, *WSDM*, pp.515-524, ACM (2017).
  - [13] Yang, G., Cai, Y. and Reddy, C.K.: Spatio-Temporal Check-in Time Prediction with Recurrent Neural Network based Survival Analysis, *IJCAI*, pp.2976-2983 (2018).
  - [14] Zheng, P., Yuan, S. and Wu, X.: Safe: A neural survival analysis model for fraud early detection, *AAAI*, Vol.33, pp.1278-1285 (2019).
  - [15] Ogata, Y.: On Lewis' Simulation Method for Point Processes, *IEEE Trans. Inf. Theory*, Vol.27, No.1, pp.23-31 (1981).
  - [16] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *CoRR*, Vol.abs/1409.1556 (2014).
  - [17] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y.: Learning phrase representations using RNN encoder-decoder for statistical machine translation, arXiv:1406.1078 (2014).
  - [18] Raksincharoensak, P.: Drive Recorder Database for Accident/Incident Study and Its Potential for Active Safety Development (2013), available from (<http://web.tuat.ac.jp/~smrc/pdf/Driverrecorder.pdf>).
  - [19] Harrell, F.E., Lee, K.L. and Mark, D.B.: Multivariable Prognostic Models: Issues in Developing Models, Evaluating Assumptions and Adequacy, and Measuring and Reducing Errors, *Statistics in Medicine*, Vol.15, No.4, pp.361-387 (1996).
  - [20] Zhou, B., Lapedriza, A., Khosla, A., Oliva, A. and Torralba, A.: Places: A 10 million Image Database for Scene Recognition, *TPAMI* (2017).
  - [21] Luo, L., Xiong, Y., Liu, Y. and Sun, X.: Adaptive Gradient Methods with Dynamic Bound of Learning Rate, *ICLR*, New Orleans, Louisiana (2019).



瀧本 祥章

2017年名古屋大学大学院情報科学研究科博士課程前期課程修了。同年日本電信電話株式会社に入社。現在、NTTサービスエボリューション研究所でデータマイニング，時空間データ分析の研究開発に従事。日本データベース

学会会員。



田中 佑典 (正会員)

日本電信電話株式会社サービスエボリューション研究所研究員。2011年神戸大学工学部電気電子工学科卒業。2013年京都大学大学院情報学研究科システム科学専攻博士前期課程修了。

同年日本電信電話株式会社入社。以来，機械学習，データマイニングに関する研究に従事。2020年京都大学大学院情報学研究科システム科学専攻博士後期課程修了。博士(情報学)。電子情報通信学会，人工知能学会各会員。



倉島 健 (正会員)

日本電信電話株式会社 NTT サービスエボリューション研究所特別研究員。2004年同志社大学工学部知識工学科卒業。2006年京都大学大学院情報学研究科社会情報学専攻修士課程修了。

同年日本電話株式会社入社。以来，ユーザ行動分析，データマイニングの研究開発に従事。2014年京都大学大学院情報学研究科社会情報学専攻博士後期課程修了。博士(情報学)。2016年より1年1カ月間，米国スタンフォード大学客員研究員。ACM，電子情報通信学会，日本データベース学会各会員。



山本 修平

2012年筑波大学情報学群知識情報・図書館学類卒業。2014年同大学大学院図書館情報メディア研究科博士前期課程修了。2016年同大学院同研究科博士後期課程修了。博士(情報学)。同年日本電信電話株式会社に入社。デー

タマイニング，時空間データ分析に関する研究開発に従事。日本データベース学会会員。



### 大川 真耶

2014年東京大学大学院理学系研究科物理学専攻修士課程修了。同年日本電信電話株式会社（NTT）入社，サービスエボリューション研究所で機械学習・データマイニングの研究に従事。



### 戸田 浩之

1997年名古屋大学工学部材料プロセス工学科卒業。1999年同大学大学院工学研究科材料プロセス工学専攻博士課程前期課程修了。同年日本電信電話株式会社入社。2007年筑波大学大学院システム情報工学研究科コンピュー

タサイエンス専攻博士後期課程修了。博士（工学）。情報検索，データマイニングの研究に従事。現在，NTT サービスエボリューション研究所主幹研究員。電子情報通信学会，日本データベース学会，人工知能学会，ACM 各会員。

(担当編集委員 天方 大地)