

# AI を用いたネットワーク交通流 ブレイクダウン発現予測モデル

森本 裕治<sup>1</sup>・吉井 稔雄<sup>2</sup>・坪田 隆宏<sup>3</sup>

<sup>1</sup>学生会員 愛媛大学 工学部環境建設工学科 (〒790-8577 愛媛県松山市文京町 3 番)  
E-mail:morimoto.yuji.16@cee.ehime-u.ac.jp

<sup>1</sup>正会員 愛媛大学大学院 生産環境工学専攻 教授 (〒790-8577 愛媛県松山市文京町 3 番)  
E-mail:yoshii@cee.ehime-u.ac.jp

<sup>1</sup>正会員 愛媛大学大学院 生産環境工学専攻 講師 (〒790-8577 愛媛県松山市文京町 3 番)  
E-mail:t.tsubota@cee.ehime-u.ac.jp

本研究では MLNN モデル(以下"AI モデル")を用いて、ネットワーク交通流ブレイクダウンの発生を予測するモデルの構築を行う。具体的にはプローブ観測結果からマクロな視点でエリアの交通流状態を推定する手法を構築し同手法によって推定されるエリア交通流状態の遷移に基づいてネットワークブレイクダウン発生の有無を判定する方法を考察する。そして、予測時点における直前 12 時間のエリア交通流状態の推移を入力とし、予測時点から 1 時間の間におけるブレイクダウン発生の有無を予測する AI モデルを構築する。AI モデルを松山道路ネットワークに適用した結果、AI モデルがロジスティック回帰モデルよりも高い精度で予測するとの結果を得た。

**Key Words:** Network ブレイクダウン, エリア交通流状態, ROC, AUC

## 1. はじめに

2011 年 3 月 11 日に発生した東日本大震災によって、東京の道路ネットワークにおいてグリッドロック現象が確認された。グリッドロック現象は、道路ネットワークの一部が機能不全に陥ることを表すが、この機能不全はネットワーク全体に拡がり、やがて道路ネットワークの性能が低下する。このようなブレイクダウン現象が発現すると、渋滞による時間損失や環境負荷が著しく増加することとなる。これらの損失を軽減するためには、事前にネットワークブレイクダウンの発現を予測し、適切な交通制御を実施することが求められる。ここで、ブレイクダウン現象は、リンクやノード単位で発生する現象ではなくネットワークに於いて発生するものであることから、その発生をミクロな視点から捉えることは困難である。そこで、本稿では、一定の拡がりを持つ道路ネットワークエリアを対象として、マクロな交通流動量（以下、"エリア流率"）とマクロな交通密度（以下、"エリア密度"）を用いたネットワーク全体の交通流状態（以

下、"エリア交通流状態"）を用いて、マクロな視点からブレイクダウン現象を捉える方法を提案し、その発現を予測する AI モデルの構築を行う。

## 2. エリア交通流状態

本研究では以下の方法により、プローブ車両走行軌跡を用いてエリア交通流状態を推定する。

### (1) プローブエリア流率とプローブエリア密度

対象道路ネットワークエリア内を走行したプローブ車両軌跡データを用いて算定される、1 時間単位での総走行台キロと総走行台時を集計し（式 (1)、式 (2)）、それぞれ、プローブエリア流率、プローブエリア密度として定義する。

$$q_t = \sum_{i \in A_t} d_{it} \quad (1)$$

$$k_t = \sum_{i \in A_t} k_{it} \quad (2)$$

ここで、

- $q_t$ : 時間帯  $t$  におけるプローブエリア流率 [台・km/1 時間]
- $k_t$ : 時間帯  $t$  におけるプローブエリア密度 [台・時間/1 時間]
- $d_{it}$ : 時間帯  $t$  におけるプローブ車両  $i$  の走行距離 [km]
- $k_{it}$ : 時間帯  $t$  におけるプローブ車両  $i$  の走行時間 [時間]
- $A_t$ : 時間帯  $t$  に対象エリア内を走行したプローブ車両の集合

## (2) 正規化

プローブデータとしては、ETC2.0 の車両軌跡データを用いるが、ETC2.0 は現在普及途上であり、時間の経過とともにその台数が増加している状況である。このようにサンプル率が経時的に変化していることから、プローブ車両によるデータを全車によるデータに拡大するためには、同サンプル率を継続的に把握することが必要となる。

一方で道路ネットワーク内の全車の交通流動、すなわち総走行台キロや総走行時間、を把握することは容易ではない。そこで、プローブ車両によるプローブエリア流率とプローブエリア密度の正規化を行う。具体的には、まず、平日と休日別に 1 か月平均のプローブエリア流率 [台・km/1 時間] とプローブエリア密度 [台・時/1 時間] を算定する (式(3), 式(4))。これらの算定値は、プローブ混入率の増加の程度と比例関係にあると考えられることから、プローブエリア流率ならびにプローブエリア密度を、それぞれ平均的な 1 時間あたりの両値で除すことにより、プローブエリア流率ならびにプローブエリア密度の正規化を行い、それぞれエリア流率ならびにエリア密度と定義する (式(5), 式(6))。

$$\bar{q}_m = \frac{\sum_{t \in M} q_t}{\sum_{t \in M} 1} \quad (3)$$

$$\bar{k}_m = \frac{\sum_{t \in M} k_t}{\sum_{t \in M} 1} \quad (4)$$

$$Q_t = \frac{q_t}{\bar{q}_m} \quad (5)$$

$$K_t = \frac{k_t}{\bar{k}_m} \quad (6)$$

ここで、

- $\bar{q}_m$ : 1 か月平均のプローブエリア流率 [台・km/1 時間]
- $\bar{k}_m$ : 1 か月平均のプローブエリア密度 [台・時/1 時間]
- $M$ : 1 か月の平日または休日の時間帯の集合
- $Q_t$ : 時間帯  $t$  におけるエリア流率
- $K_t$ : 時間帯  $t$  におけるエリア密度

## (3) 分析に用いるデータ

本研究の分析は、図-1 に示す愛媛県庁を中心とした 9km×9km の道路ネットワークエリアを対象とする。また、ETC2.0 プローブデータは、平成 27 年 4 月 1 日から平成 28 年 3 月 31 日の 1 年間、366 日分を使用する。ただし、高速道路や自動車専用道路は対象外とする。



(1 メッシュ=500m×500m)

図-1 分析対象エリア

## 3. ブレイクダウンの判定方法

ブレイクダウン現象の発生の有無を判定するために、分析対象とした 366 日を対象にエリア交通流状態の時間推移を調べた。図-2 には目視によりブレイクダウンが発生していると判断されるサンプル、図-3 には目視によりブレイクダウンが発生していないと判断されるサンプルを示す。それぞれの図は 0 時から 10 時までのエリア交通流状態を表している。

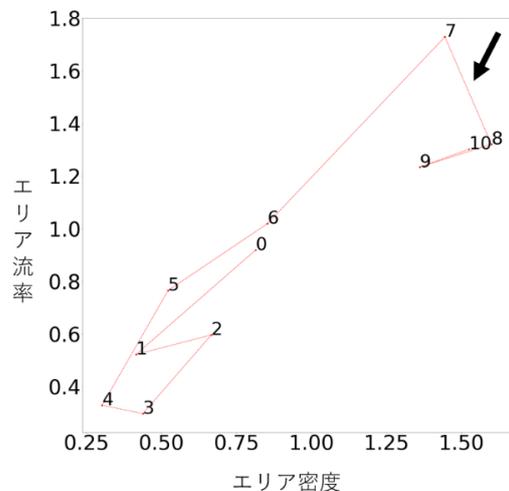


図-2 目視でブレイクダウンが確認できるエリア交通流状態の時間推移

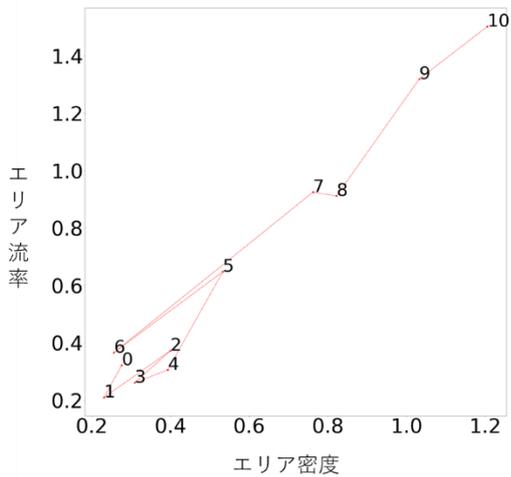


図-3 目視でブレイクダウンが確認できない  
エリア交通流状態の時間推移

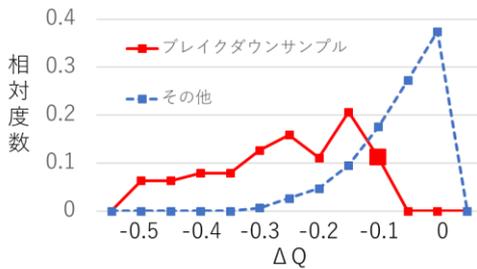


図-4 ブレイクダウンと判定されたサンプルとされな  
かったサンプルにおける、 $\Delta Q$ の相対度数分布

図-2 中の矢印が示すエリア交通流状態の変化に認められるように、ブレイクダウン発生時には、エリア密度が増加しているにもかかわらずエリア流率が低下する方向にエリア交通流状態が変化する。また、ブレイクダウン発生後には、特にエリア流率が大きく減少することとなる。そこで、1時間前のエリア交通流状態との比較に於いて、エリア密度の変化量を $\Delta K$ 、エリア流率の変化量を $\Delta Q$ とし、 $\Delta K > 0$ かつ $\Delta Q < 0$ を満足するエリア交通流状態の変化ベクトルを抽出したところ、366日の全8,781サンプルのうち、661サンプルが該当ベクトルとして抽出された。同661サンプルについて、目視によりブレイクダウンと判定した63サンプルと、それ以外の598サンプルの別に $\Delta Q$ の出現頻度を集計した結果を図-4に示す。実線で示されている、ブレイクダウンと判定されたサンプルは、全て $\Delta Q < -0.1$ となっていることから、 $\Delta K > 0$ かつ $\Delta Q < -0.1$ をブレイクダウン発生との判断を行う条件とした。

一方の点線で示されている、ブレイクダウンと判定されなかった598サンプルでは、ブレイクダウンではないにもかかわらず大きくエリア流率が減少しているサンプルが多数出現しているが、これらは、一時的に大きくエリア流率が減少しているものの、次の1時間ではエリア

流率が回復しているサンプルである。

ここで、一旦ブレイクダウン現象が発現すると、回復に時間を要することから、1時間程度ではエリア流率が回復しないと考えられる。そこで、エリア流率が大きく減少していても次の時間帯に同流率が回復しているサンプルについてはブレイクダウンとは判定しないものとした。

#### 4. AIモデル概要

ブレイクダウンの発生を予測するモデルには、多層ニューラルネットワークを用い、ディープラーニングによってパラメータを決定するモデルの構築を行った。以下に、構築したモデルの概要と説明力について示す。

##### (1) 学習用データと検証用データ

構築するモデルの概要を図-5に示す。エリア密度、エリア流率、プローブエリア流率をプローブエリア密度で除した全プローブの平均速度、ならびに平日休日のダミー変数、それぞれ予測時点までの12時間帯分、計48データを入力とし、ブレイクダウン発生の可能性を $[0,1]$ の実数で出力するモデルとした。2015年5月から2016年3月までのデータを学習データとして、モデルパラメータを同定した後、2015年4月のデータを検証データとして、再現精度を検証した。

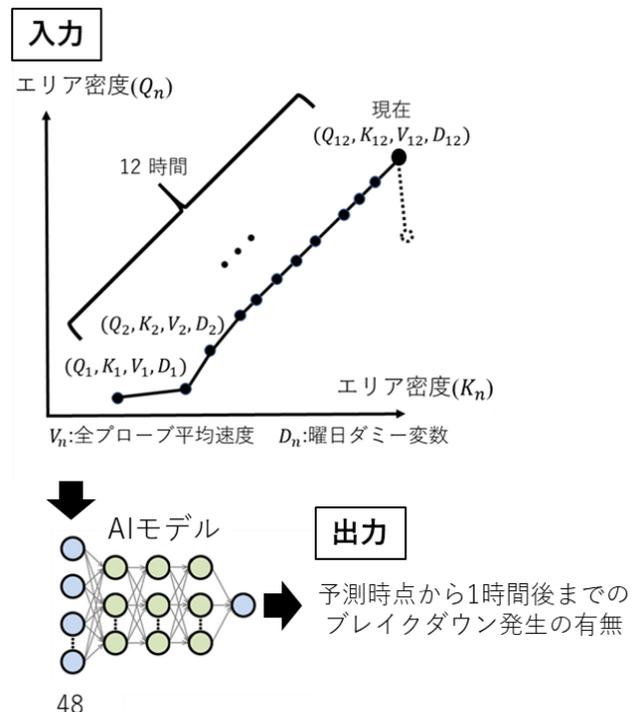


図-5 AIモデル概要

(2) モデルの構造

AI モデルの再現性は、そのネットワーク構造に大きく依存するため、隠れ層の数、各層におけるユニット数、活性化関数、および学習データを何回繰り返して学習させるかを表すエポック数の設定を変えて高い再現性を有するモデルの特定を行った。なお本研究では全結合層のみを採用した。上記構造に関する試行錯誤を重ねた結果、**図-6**に示すように隠れ層 3 層、ノード数は 1 層目から順に、20、10、10とし、活性化関数にはRelu関数、エポック数は 80、目的関数には 2 値交差エントロピー誤差(BCE)を用いた。ここで、BCEを式(7)に示す。

$$BCE = \frac{1}{n} \sum_{t=0}^n \{-a_t \log(1 - p_t) - (1 - a_t) \log p_t\} \quad (7)$$

$a_t$  : 時間帯 $t$ における実際のブレイクダウン発生の有無 (1もしくは0)  
 $p_t$  : 時間帯 $t$ の予測値( $0 \leq p \leq 1$ )  
 $n$  : 全時間帯数

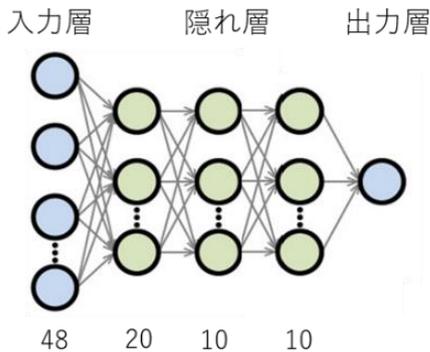


図-6 AI モデルのネットワーク構造

(3) ロジスティック回帰モデル

AI モデルの再現精度を比較するため、AI モデルと同様に、ブレイクダウンの発生の有無を予測するロジスティック回帰モデルを構築する。エリア密度、エリア流率、プローブエリア流率をプローブエリア密度で除した全プローブの平均速度、ならびに平日休日のダミー変数、それぞれ予測時点までの 12 時間帯分、計 48 データを入力とし、ブレイクダウン発生の可能性を[0,1]の実数で出力するモデルとした。回帰式は式(8)で表され、推定結果で有意になった変数については、**表-1**に示す。

$$p = \frac{1}{1 + e^{-(a_1x_1 + a_2x_2 + \dots + a_nx_n + b)}} \quad (8)$$

$a_n$  : 偏回帰係数  $b$  : 切片

表-1 ロジスティック回帰推定結果

説明変数	係数	Z値	P値
定数項	-11.31	-3.29	0.00101 **
1時間前エリア流率	5.67	4.35	1.37e-05 ***
1時間前エリア密度	-4.18	-2.83	0.00473 **
1時間前全プローブ平均速度	0.27	-4.73	2.21e-06 ***
サンプル数	8049		
最終対数尤度	307.77		
初期対数尤度	401.83		
尤度比 $\rho^2$	0.23		

\*: 5%有意, \*\*: 1%有意, \*\*\*: 0.1%有意

4. 評価指標

(1) ROC 曲線(Receiver Operating Characteristic Curve)

ブレイクダウン発生の有無について、直接的に「ブレイクダウンが発生する」「ブレイクダウンが発生しない」のいずれかにて予測を出力するモデルを構築した際の予測結果評価指標としてAUCを用いる。

表-2 閾値による予測データの分類表

		予測	
		事故あり	事故なし
実際	事故あり	True Positive(TP)	False Negative(FN)
	事故なし	False Positive(FP)	True Negative(TN)

表-2に示すように、ブレイクダウンの有無で2値のいずれかを出力するモデルでは、「ブレイクダウンが発生」と予測した際に「実際に発生した」True Positive(TP), 「実際には発生しなかった」False Positive(FP)のいずれかの状況が出現する。また、「ブレイクダウンが発生しない」と予測した際も同様に「実際に発生しなかった」True Negative(TN), 「実際には発生した」False Negative(FN)のいずれかの状況、計4つの状況が出現する。このとき、モデルの予測精度は式(9)に示すAccuracy (正解率)として算出評価することが可能である。もちろん予測正解率のTPとTNの割合が高くなれば予測精度が高いということを示す。

ここで、本研究のように稀少事象を対象として取り扱う場合、例えば、すべての出力を「ブレイクダウンが発生しない」としておくことで高い正解率が実現する。一方、本研究によるモデルは、計算によって[0,1]の出力値  $p(0 \leq p \leq 1)$ を出力するモデルとなっており、予め設定された閾値と  $p$  との大小関係から「ブレイクダウンが発生する」「ブレイクダウンが発生しない」の判定を行うモデルであることから、閾値の値を変化させた場合に、

上記4つの状況の出現割合が異なる結果を得ることができる。そこで、閾値の値を[0,1]で変化させた場合のそれぞれで、式(10)、式(11)に示す False Positive Rate (以下では“FPR”)と True Positive Rate (以下では“TPR”)を算出する。前者のFPRは、実際にブレイクダウンが発生しない場合に「ブレイクダウンが発生する」と誤って予測していた割合、後者のTPRは、実際にブレイクダウンが発生する場合に「ブレイクダウンが発生する」と正しく予測していた割合を示し、閾値の増加に伴って前者と後者ともに単調に減少する。例えば、閾値を0.0として、全ての予測結果を「ブレイクダウン発生する」とした場合には、(FPR, TPR)=(1.0, 1.0)となり、逆に閾値を1.0として全ての予測結果を「ブレイクダウンが発生しない」とした場合には (FPR, TPR)=(0.0, 0.0) の結果が得られる。

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$\text{False Positive Rate} = \frac{FP}{FP + TN} \quad (10)$$

$$\text{True Positive Rate} = \frac{TP}{TP + FN} \quad (11)$$

続いて、算出結果を図-7に示すFPR-TPR平面にプロットし、閾値ごとに異なる各点を連続的につなぐROC曲線を用いて予測結果を評価する。図-7中の座標(0.0, 1.0)は、実際にブレイクダウンが発生した際に全て「ブレイクダウン発生」と予測し、実際にブレイクダウンが発生しない場合に全て「ブレイクダウン発生無し」と予測した状況、すなわち100%予測が的中している状況を示し、各点が図中左上に位置すればするほど良い結果を示すこととなる。そこで、ROC曲線も左上に近づけば近づくほどモデルの予測精度が高いと結論づけられる。このことから、ROC曲線右下部の面積、すなわちAUC値(Area Under the Curve)を以て予測精度の評価指標とする。

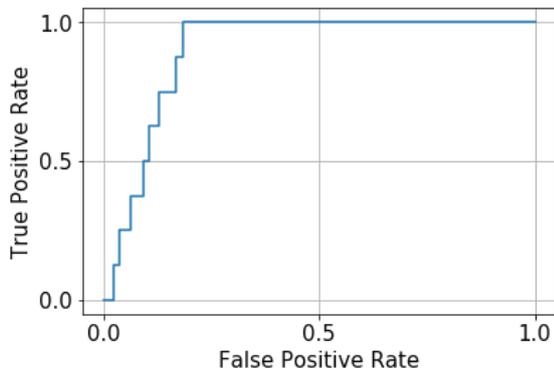


図-7 ROC 曲線の例

## 6. 結果

図-8に AI モデルとロジスティック回帰モデルの、AUC 値による精度の比較を示す。AI モデルにおける AUC 値は 0.93 である一方、ロジスティック回帰モデルでは 0.87 であった。すなわち、従来の手法である回帰モデルよりも AI モデルによる予測精度が高いとの結果が得られた。AI モデルの精度が高くなった理由としては、モデルが有するパラメータ数が多いことが挙げられる。

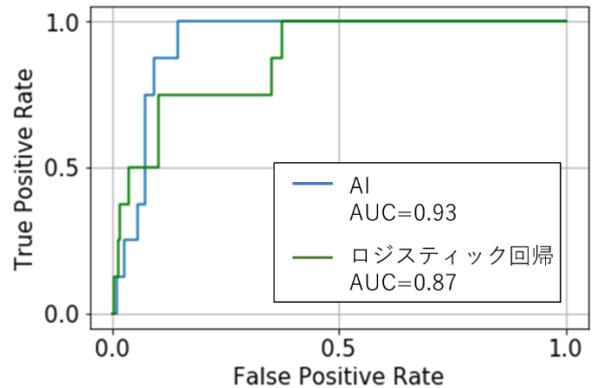


図-8 モデルの AUC 値による比較

## 7. おわりに

本研究では、エリア流率とエリア密度の変化量に基づいてブレイクダウン発生の有無を判定し、AI を用いて同ブレイクダウンの発生を予測するモデルを構築した。構築した AI モデルと従来の手法であるロジスティック回帰モデルとの精度比較を行うことで、AI モデルの予測精度が高いことを確認した。

今後は、エリア交通流状態の推移を予測するモデルを構築し、事故発生等による MFD の変化を考慮しつつ、ブレイクダウンの発生を事前に予測する手法の構築を行う。

**謝辞：** 本研究は道路政策の質の向上に資する技術開発の研究「交通理論と AI 学習による非日常の発見とアラート発信（代表：桑原雅夫）」の支援を受けて実施し、国土交通省から ETC2.0 プローブデータを頂いた。ここに謝意を表する

### 参考文献

- 1) Daganzo, C.F.: Urban gridlock: Macroscopic modeling and mitigation approaches, Transportation Research Part B: Methodological, Vol41, No.1, pp.49-62, 2007.

- 2) プローブデータを活用した MFD の特性及び要因に関する基礎的研究, 尾高慎二, 吉井稔雄, 藤井浩史, 神戸信人, 土木計画学研究・講演集(CD-ROM), 2018. (2020.3.8 受付)

### Development of a breakdown probability estimation model using the MLNN

Yuji MORIMOTO, Toshio YOSHII and Takahiro TSUBOTA

This research developed an estimation model to predict the network breakdown occurrence. MLNN is employed as the model. The macroscopic traffic states are defined by total vehicle kilometers per unit time and total number of vehicles in the network area obtained by probe data, and the macroscopic variables are used as the input. The model can output the likelihood of the breakdown occurrence. After the network breakdown phenomena has been defined, the developed MLNN model is applied to the signalized road network in Matsuyama. The results showed that the model can predict the network breakdown occurrence more accurately than the Logistic regression model.