

ベイズ推論に基づく堆雪幅の確率的な予測

峪 龍一¹・加藤哲平²・内田賢悦³・宗廣一徳⁴

¹正会員 北海道大学大学院工学研究院 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: r-tani@eng.hokudai.ac.jp

²正会員 埼玉大学大学院理工学研究科 (〒160-0004 埼玉県さいたま市桜区下大久保 255)

E-mail: tkato@mail.saitama-u.ac.jp

³正会員 北海道大学大学院工学研究院 (〒060-8628 北海道札幌市北区北 13 条西 8 丁目)

E-mail: uchida@eng.hokudai.ac.jp

⁴正会員 国立研究開発法人 土木研究所 寒地土木研究所 寒地道路研究グループ 寒地交通チーム
(〒062-8602 札幌市豊平区平岸 1 条 3 丁目 1 番 34 号)

E-mail: k-munehiro@ceri.go.jp

道路の堆雪幅をベイズ推論に基づき予測する手法を提案した。先行研究より堆雪幅が増えるに従い、自由走行速度の平均が減少することが知られている。本研究では、過去に観測された自由流における交通観測データから予測モデルのパラメータを推定する。新たに取得したデータから予測される自由走行速度の情報を用いて、離散的に分類された堆雪幅を予測する。離散的に分類された堆雪幅に対応する固有の自由走行速度の確率分布が存在すると仮定すると、観測された流率と密度、自由走行速度の間の確率的な関係を、混合正規帰帰モデルによって表現することができる。本研究では、共役事前分布を適切に設定するという仮定の下で、堆雪幅の予測分布が解析的に導出できることを示した。札幌市内で観測されたデータを用いて、提案する予測モデルの挙動を確認した。

Key Words: Bayesian inference, traffic flow, snow removal

1. はじめに

札幌市のような積雪寒冷地では、冬季の降雪に伴う道路における交通障害が顕著である。路面に積もった雪は除雪作業によって、路側に堆雪する。この堆雪幅が増加すると、幅員が減少して、自動車にとって交通の障害となる。堆雪幅が増加して走行空間を圧迫すると、道路管理者は排雪作業を行う必要がある。効率的な排雪作業を行うためには、適切な排雪計画を立案する必要がある。しかし、排雪計画の前提として重要な、道路ネットワーク全体の各リンクにおける堆雪幅の情報を知ることは難しい。堆雪幅をネットワーク規模で認識することができれば、排雪計画を立案するうえで有用な技術となる。

道路上に設置されたカメラから取得された画像あるいは動画を解析して、堆雪幅を認識できれば簡単である。例えば、画面内のピクセル数と対応する実際の距離をカリブレーションできれば、堆雪幅を観測することができる。しかし、密な道路ネットワークの各リンクにカメラを設置して、常時観測を行うことは非現実的である。ま

た、カメラを用いた観測では、夜間あるいは吹雪による視程障害が発生しているときには観測はできない。

そこで、本研究では常時観測が可能な交通感知器データの利用を前提とした、離散的にカテゴリ化された堆雪幅を予測する手法を提案する。提案する手法はベイズ推論に基づく確率的な予測モデルとして定式化されており、交通観測データから、堆雪幅がカテゴリごとに分類される確率を求める。

Munehiro et al.¹⁾より、堆雪幅が変化すると交通流の基本図（以下、基本図）が変化することがわかっている。峪ら²⁾は Munehiro et al.と同じ交通観測データに階層ベイズモデルを適用して、堆雪幅のカテゴリごとの交通流の基本図を確率的に推定し、堆雪幅の増加に伴い、自由走行速度の平均が単調に減少することを明らかにした。以上の知見を踏まえ、本研究では、自由流における交通観測データに着目し、堆雪幅のカテゴリごとの自由走行速度の確率分布の違いに基づいて、堆雪幅を予測するモデルを開発する。

本研究の構成は以下の通りである。第 2 章ではベイズ

推論に基づく、堆雪幅のカテゴリを予測するモデルを提案する。第 3 章では、札幌市内において観測された交通観測データを本研究で提案する手法に適用した結果を示す。第 4 章では、本研究をまとめ、今後の課題を述べる。

2. 予測モデル

(1) ベイズ線形回帰モデル

堆雪幅の予測モデルを定式化するための導入として、まず、単純なベイズ線形回帰モデル^{2,3)}を示す。ここでは、密度 x_n と流率 y_n の各サンプルがひとつの基本図から生成されているものと仮定する。

密度 $\mathbf{X} = \{x_1, \dots, x_N\}$ が観測されているとき、流率 $\mathbf{Y} = \{y_1, \dots, y_N\}$ と基本図における自由流領域の傾き w (自由走行速度) の同時分布を定義する。

$$p(\mathbf{Y}, w | \mathbf{X}) = p(w) \cdot \prod_{n \in N} p(y_n | x_n, w) \quad (1)$$

ここで、 $p(\cdot)$ は確率密度関数あるいは確率質量関数を表す。 x_n が観測されているとき、 y_n は以下に示す正規分布によって生成されるものとする。

$$p(y_n | x_n, w) = N(y_n | w \cdot x_n, \sigma_y^2) \quad (2)$$

ここで、 σ_y は固定された分散パラメータである。自由走行速度 w は以下に示す正規分布にしたがうと仮定する。

$$p(w) = N(w | \mu_w, \sigma_w^2) \quad (3)$$

ここで、 μ_w と σ_w^2 はそれぞれ平均と分散パラメータである。次に、 \mathbf{Y} と \mathbf{X} がそれぞれ観測されたときの、自由走行速度 w の事後分布を定義する。(1)にベイズの定理を適用すると、事後分布を以下のように得る。

$$p(w | \mathbf{Y}, \mathbf{X}) = \frac{p(w) \cdot \prod_{n \in N} p(y_n | w)}{p(\mathbf{Y} | \mathbf{X})} \quad (4)$$

ここで、 $p(\mathbf{Y} | \mathbf{X})$ は正規化のための定数であるから、分子のみを考えればよい。(4)において、事前分布と尤度がそれぞれ正規分布に従うことから、自由走行速度 w の事後分布は正規分布に従うことが知られている。事後分布とそのパラメータは以下のように表せる。

$$p(w | \mathbf{Y}, \mathbf{X}) = N(w | \hat{\mu}_w, \hat{\sigma}_w^2) \quad (5)$$

ここで、

$$\hat{\sigma}_w^{-2} = \sigma_y^{-2} \cdot \sum_{n \in N} x_n + \sigma_w^{-2} \quad (6)$$

$$\hat{\mu}_w = \hat{\sigma}_w^2 \cdot \left(\sigma_y^{-2} \cdot \sum_{n \in N} y_n \cdot x_n + \sigma_w^{-2} \cdot \mu_w \right) \quad (7)$$

次に、観測された \mathbf{X} と \mathbf{Y} を用いて推定された自由走行速度 w の事後分布を用いて、新たに観測された密度 x_* から、これに対応する y_* についての予測分布 $p(y_* | x_*, \mathbf{Y}, \mathbf{X})$ を導出する。なお、本研究では新たに観測された密度 x_* と流率 y_* から、堆雪幅を予測するモデルの開発を最終的な目的としているが、ここでは一旦、流率 y_* は観測されていないものとして扱う。

自由走行速度 w についての事後分布 $p(w | y_*, x_*, \mathbf{Y}, \mathbf{X})$ を改めて定義する。(4)と同様にベイズの定理を適用する。

$$\begin{aligned} p(w | y_*, x_*, \mathbf{Y}, \mathbf{X}) & \\ = \frac{p(w) \cdot \prod_{n \in N} p(y_n | x_n, \mathbf{Y}, \mathbf{X}, w)}{p(y_* | x_*, \mathbf{Y}, \mathbf{X})} & \quad (8) \end{aligned}$$

(4)と同様に(8)の分子だけを考えると、自由走行速度 w についての事後分布は以下に示す正規分布にしたがう。

$$p(w | y_*, x_*, \mathbf{Y}, \mathbf{X}) = N(w | \mu_*, \sigma_*^2) \quad (9)$$

ここで、

$$\mu_* = \hat{\mu}_w \cdot x_* \quad (10)$$

$$\sigma_*^2 = \sigma_y^2 + \sigma_w^2 \cdot x_*^2 \quad (11)$$

(2) 混合正規回帰モデル

2.(1)では、ひとつの基本図から、密度と流率がサンプルされることを仮定した。つまり、堆雪幅の変化がない状況に対応している。2.(2)では、複数の堆雪幅のパターンがあり、そのパターンに応じて、基本図が変化する状況を考える。つまり、潜在的に K 個の基本図が存在し、そのいずれかの基本図から、密度 x_n と流率 y_n が生成されている状況を考える。この状況を表現するために、混合正規モデル²⁾を回帰問題に適用する。

混合正規モデルにおいて、各サンプルが属する基本図を選択する潜在変数 $\mathbf{s}_n = \{s_{n,1}, \dots, s_{n,K}\}$ を定義する。これは n 番目の観測データが k 番目の基本図から生成される時、 $s_{n,k} = 1$ となり、それ以外のとき、 $s_{n,k} = 0$ ($\forall k \in K$)となるベクトル変数である。

流率 y_n が正規分布から生成されると仮定する。密度 x_n が観測されており、密度 x_n と流率 y_n が基本図 k から生成される時、流率 y_n と自由走行速度 w_k の同時分布は以下のように定義される。

$$p(y_n | x_n, w_k) = N(y_n | w_k \cdot x_n, \sigma_y^2) \quad \forall n \in N \quad (12)$$

すべての基本図 k について考えると、

$$\begin{aligned} p(y_n | x_n, \mathbf{s}_n, \mathbf{w}) & \\ = \prod_{k \in K} N(y_n | w_k \cdot x_n, \sigma_y^2)^{s_{n,k}} \quad \forall n \in N & \quad (13) \end{aligned}$$

ここで、 $\mathbf{w} = \{w_1, \dots, w_K\}$ である。基本図 k の自由流速度 w_k の事前分布は、以下のような正規分布に従うと定義する。

$$p(w_k) = N(w_k | \mu_{w_k}, \sigma_{w_k}^2) \quad \forall k \in K \quad (14)$$

ここで、(14)は(13)に対する共役事前分布となっている。

次に、予測分布を示す。流率 \mathbf{Y} 、密度 \mathbf{X} 、潜在変数 \mathbf{S} がそれぞれ過去に観測されているものとする。ここで、 $\mathbf{S} = (\mathbf{s}_1, \dots, \mathbf{s}_N)$ である。新たに観測された流率 y_* と密度 x_* を生成する元となった基本図 k がわからないものとする。基本図 k に対応する潜在変数 \mathbf{s}_* を予測する分布を導出する。ここで、 $\mathbf{s}_* = (s_{*,1}, \dots, s_{*,K})$ である。各種データが得られたときの潜在変数 \mathbf{s}_* の分布を以下に示す。

$$\begin{aligned} p(\mathbf{s}_* | y_*, x_*, \mathbf{Y}, \mathbf{X}, \mathbf{S}) & \\ \propto p(y_* | x_*, \mathbf{s}_*, \mathbf{Y}, \mathbf{X}, \mathbf{S}) & \\ \cdot p(\mathbf{s}_* | \mathbf{S}) & \quad (15) \end{aligned}$$

(15)の右辺に含まれているパラメータ \mathbf{w} と $\boldsymbol{\pi}$ をそれぞれ周辺化する。まず、(15)の右辺第1項を計算する。

$$p(y_*|x_*, \mathbf{s}_*, \mathbf{Y}, \mathbf{X}, \mathbf{S}) \quad (16)$$

$$= \int p(y_*|x_*, \mathbf{s}_*, \mathbf{w}) \cdot p(\mathbf{w}|\mathbf{Y}, \mathbf{X}, \mathbf{S}) d\mathbf{w}$$

(16)の右辺を \mathbf{w} について周辺化する。まず、(16)の右辺の第2項を計算する。

$$p(\mathbf{w}|\mathbf{Y}, \mathbf{X}, \mathbf{S}) = \prod_{k \in K} p(\mathbf{w}_k|\mathbf{Y}, \mathbf{X}, \mathbf{S}) \quad (17)$$

$$p(w_k|\mathbf{Y}, \mathbf{X}, \mathbf{S}) = \frac{p(\mathbf{Y}|\mathbf{X}, \mathbf{S}, w_k) \cdot p(w_k)}{p(\mathbf{Y}|\mathbf{X}, \mathbf{S})} \quad (18)$$

$$\propto p(\mathbf{Y}|\mathbf{X}, \mathbf{S}, w_k) \cdot p(w_k)$$

$$= p(w_k) \cdot \prod_{n \in N} p(y_n|x_n, w_k) \quad \forall k \in K$$

(8)と同様に、基本図 k の自由走行速度 w_k についての事前分布と尤度はそれぞれ正規分布に従うため、共役性により、事後分布は正規分布に従う。

$$p(w_k|\mathbf{Y}, \mathbf{X}, \mathbf{S}) = N(w_k|\hat{\mu}_{w_k}, \hat{\sigma}_{w_k}^2) \quad \forall k \in K \quad (19)$$

ここで、

$$\hat{\sigma}_{w_k}^{-2} = \sigma_y^{-2} \cdot \sum_{n \in N} s_{n,k} \cdot x_n^2 + \sigma_{w_k,0}^{-2} \quad \forall k \in K \quad (20)$$

$$\hat{\mu}_{w_k} = \hat{\sigma}_{w_k}^2 \cdot \left(\frac{\sigma_y^{-2} \cdot \sum_{n \in N} s_{n,k} \cdot y_n \cdot x_n}{\sigma_y^{-2} \cdot \sum_{n \in N} s_{n,k} \cdot x_n^2 + \sigma_{w_k,0}^{-2} \cdot \mu_{w_k}} \right) \quad \forall k \in K \quad (21)$$

次に、(16)の右辺の第1項を計算する。

$$p(y_*|x_*, \mathbf{s}_*, \mathbf{Y}, \mathbf{X}) = \prod_{k \in K} p(y_*|x_*, \mathbf{s}_{*,k}, \mathbf{Y}, \mathbf{X}) \quad (22)$$

$$= \prod_{k \in K} N(y_*|\mu_{*,k}, \sigma_{*,k}^2)$$

ここで、

$$\mu_{*,k} = \hat{\mu}_{w_k} \cdot x_* \quad \forall k \in K \quad (23)$$

$$\sigma_{*,k}^2 = \sigma_y^2 + \hat{\sigma}_{w_k}^2 \cdot x_*^2 \quad \forall k \in K \quad (24)$$

(22)において、予測する潜在変数を $\mathbf{s}_* = (s_{*,1}, \dots, s_{*,K})$ とすると、 $\mathbf{s}_{*,k}$ とは、その要素 $s_{*,k} = 1$ であり、それ以外の要素が $s_{n,k} = 0$ ($\forall k \in K$)であるベクトルのことである。したがって、(16)は各基本図 k において $s_{*,k} = 1$ となる時、以下のように周辺化される。

$$p(y_*|x_*, \mathbf{s}_{*,k}, \mathbf{Y}, \mathbf{X}, \mathbf{S}) \quad (25)$$

$$= N(y_*|\mu_{*,k}, \sigma_{*,k}^2) \cdot N(w_k|\hat{\mu}_{w_k}, \hat{\sigma}_{w_k}^2)$$

次に、(15)の右辺第2項を計算する。 $p(\mathbf{s}_*|\mathbf{S})$ は予測する潜在変数 \mathbf{s}_* についての予測分布である。

$$p(\mathbf{s}_*|\mathbf{S}) = \int p(\mathbf{s}_*|\boldsymbol{\pi}) \cdot p(\boldsymbol{\pi}|\mathbf{S}) d\boldsymbol{\pi} \quad (26)$$

(26)の右辺第2項にベイズの定理を適用する。

$$p(\boldsymbol{\pi}|\mathbf{S}) \propto p(\mathbf{S}|\boldsymbol{\pi}) \cdot p(\boldsymbol{\pi}) \quad (27)$$

$$= \left\{ \prod_{n \in N} \text{Cat}(s_n|\boldsymbol{\pi}) \right\} \cdot \text{Dir}(\boldsymbol{\pi}|\boldsymbol{\alpha})$$

ここで、 $\boldsymbol{\alpha}$ は $\text{Dir}(\boldsymbol{\pi}|\boldsymbol{\alpha})$ の超パラメータである。 $p(\mathbf{S}|\boldsymbol{\pi})$ はカテゴリ分布、 $p(\boldsymbol{\pi})$ はディリクレ分布にそれぞれしたがうと仮定すると、ディリクレ分布はカテゴリ分布の共役事前分布であるため、 $\boldsymbol{\pi}$ の事後分布である $p(\boldsymbol{\pi}|\mathbf{S})$ は

以下に示すディリクレ分布に従う。

$$p(\boldsymbol{\pi}|\mathbf{S}) = \text{Dir}(\boldsymbol{\pi}|\hat{\boldsymbol{\alpha}}) \quad (28)$$

ここで、 $\hat{\boldsymbol{\alpha}} = (\hat{\alpha}_1, \dots, \hat{\alpha}_K)$ であり、各要素 $\hat{\alpha}_k$ は以下の通りである。

$$\hat{\alpha}_k = \sum_{n \in N} s_{n,k} + \alpha_k \quad \forall k \in K \quad (29)$$

ここで、 α_k ($\forall k \in K$)は $\boldsymbol{\alpha}$ の要素である。 $p(\mathbf{s}_*|\boldsymbol{\pi})$ はカテゴリ分布に従うことから、 \mathbf{s}_* を観測したとみなしたときの $\boldsymbol{\pi}$ の事後分布である。したがって、(26)の日積分関数である、 $p(\mathbf{s}_*|\boldsymbol{\pi}) \cdot p(\boldsymbol{\pi}|\mathbf{S})$ はディリクレ分布に従う。共役性により、ディリクレ分布の予測分布はカテゴリ分布に従うことから、 $p(\mathbf{s}_*|\mathbf{S})$ は以下のように導出される。

$$p(\mathbf{s}_*|\mathbf{S}) = \text{Cat}(\mathbf{s}_*|\boldsymbol{\eta}) \quad (30)$$

ここで、

$$\eta_k \propto \hat{\alpha}_k \quad \forall k \in K \quad (31)$$

$$\sum_{k \in K} \eta_k = 1 \quad (32)$$

一連の計算により、(15)を以下のように再定式化することができる。

$$p(\mathbf{s}_*|y_*, x_*, \mathbf{Y}, \mathbf{X}, \mathbf{S}) = \text{Cat}(\mathbf{s}_*|\boldsymbol{\eta}_*) \quad (33)$$

ここで、

$$\boldsymbol{\eta}_* = (\eta_{*,1}, \dots, \eta_{*,K}) \quad (34)$$

$$\eta_{*,k} \propto p(y_*|x_*, \mathbf{s}_{*,k}, \mathbf{Y}, \mathbf{X}, \mathbf{S}) \cdot p(\mathbf{s}_{*,k}|\mathbf{S}) \quad \forall k \in K \quad (35)$$

$$\sum_{k \in K} \eta_{*,k} = 1 \quad (36)$$

したがって、各種データが得られたときに、 \mathbf{s}_* を予測する分布を導出することができた。

図1は提案する予測手法のグラフィカルモデルである。網掛けしたノードが観測されている変数である。




図1 グラフィカルモデル

3. 数値計算例

(1) 使用するデータ

本研究では札幌市の下手稲通に設置されたカメラから観測された動画データから得られた、5分間交通流率と5分間空間平均速度を使用した^{1,2)}。交通密度は交通流の基本則より、上の交通流率と空間平均速度から簡易的に求めた。本研究は各観測機会における堆雪幅を、0~0.5m, 1~1.5m, 2~2.5mの3つのカテゴリに分類する。堆雪幅の分類ごとに、流率と密度の関係をプロットしたものを図2に示す。

なお、ベイズ推論を行うにあたり、流率 \mathbf{Y} と密度 \mathbf{X} がそれぞれ0と1の間に収まるように正規化した。正規化したデータのうち、正規化された密度が0から0.2までのデータを抽出することにより、疑似的に自由流領域のデータを得た(図3)。以下、本研究では図2のデータを用いて、予測モデルを実証する。




図2 観測データ (流率-密度)




図3 正規化された観測データ (流率-密度)

図3に示すデータから、 \mathbf{Y} と \mathbf{X} 、 \mathbf{S} を得て、予測モデルを構成する各パラメータを求める。したがって、(33)に示す \mathbf{s}_* の予測分布のパラメータ $\boldsymbol{\eta}_*$ が求まる。密度 x_* と y_* をそれぞれ0と0.2の間、0と1の間で変化させたとき、それぞれの組み合わせにおける、(33)のパラメータ $\boldsymbol{\eta}_*$ を堆雪幅のカテゴリごとに、色で表したものが、図4-6である。本数値計算では、堆雪幅のカテゴリ数 K は3である。 $\boldsymbol{\eta}_* = (\eta_{*,1}, \eta_{*,2}, \eta_{*,3})$ であるから、 $\boldsymbol{\eta}_*$ はRGB3成分を表すベクトルと等価である。例えば、図4では堆雪幅のカテゴリが0mまたは0.5mに注目している。密度 x_* と流率 y_* を上を示す範囲で動かして、それぞれの組み合わせにおいて求まる $\boldsymbol{\eta}_*$ の3つの要素のうち、 $\eta_{*,2}$ と $\eta_{*,3}$ は0に固定して、 $\eta_{*,1}$ だけを表示したときに実現される色の分布が図4である。つまり、RGB表色系において、緑成分と青成分が0に固定され、赤成分のみが0から1の範

囲で動いている。同様に、図5と図6はそれぞれ $\eta_{*,2}$ と $\eta_{*,3}$ のみを動かしているため、それぞれ緑成分と青成分のみで実現される色の分布となっている。図4-6における、色の違いは、色に対応する堆雪幅のカテゴリが予測される確率に対応している。なお、図4-6におけるそれぞれの色は、図2-3の散布図と対応している。




図4 堆雪幅の予測 (0mまたは0.5m)

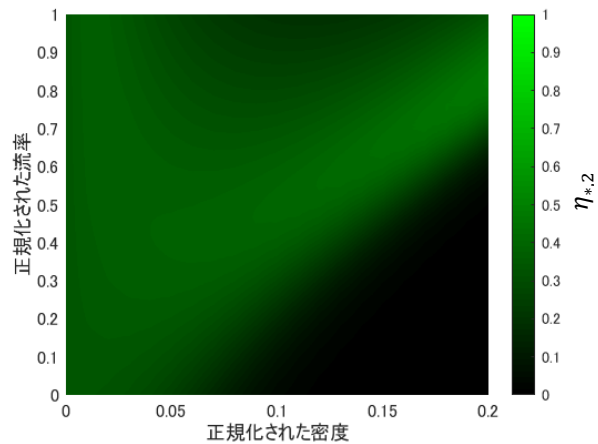


図5 堆雪幅の予測 (1mまたは1.5m)




図6 堆雪幅の予測 (2mまたは2.5m)

図4-6の条件設定にしたがい、(33)のパラメータ $\boldsymbol{\eta}_*$ をRGB3成分を表すベクトルとみなし、かつ $\boldsymbol{\eta}_*$ の3つの要

素をいずれも 0 に固定しないと、実現される色の分布が図 7 である。複数の堆雪幅のカテゴリにおいて予測確率が求まっていることから、 η_* の各要素の値に従い、混ざった色として表現される領域が存在する。

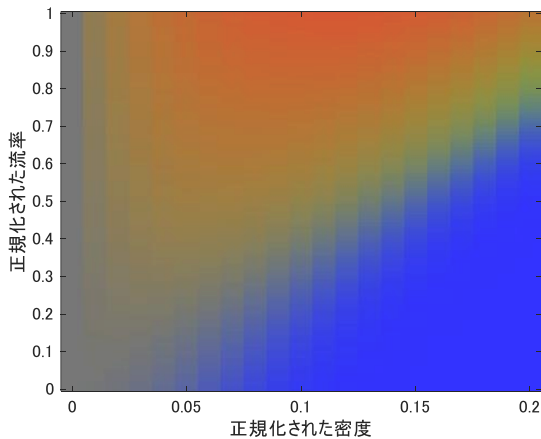


図 7 堆雪幅の予測 (合成)

図 7 において、堆雪幅のカテゴリが {0m, 0.5m} と {2m, 2.5m} として分類される領域が広いのに対して、{1m, 1.5m} として分類される領域は狭い。本研究で使用したデータでは、各堆雪幅のカテゴリに属するデータが重なる領域が大きい。複数のカテゴリが重なる領域においては、予測確率が重なりを反映していることがわかる。

7. おわりに

本研究では、道路上に固定されたカメラから観測された、交通流データを用いて、離散的に分類された堆雪幅のカテゴリを予測する手法を開発した。密度と流率、自由走行時間のそれぞれの確率的な関係を、混合正規回帰モデルとして定式化した。本研究では、共役事前分布の工夫によって、堆雪幅のカテゴリの予測分布が解析的に導出されることを示した。札幌市内で観測された交通データを用いて、提案する予測モデルの挙動を確認した。

本研究で提案する手法は、道路上に固定されたカメラから観測された動画データを利用してパラメータを学習している。一定期間、動画による観測を行い、パラメータを学習できれば、交通感知器から観測される、流率と速度のデータがあれば自由走行速度を予測、すなわち堆

雪幅を予測することができる。すべての道路区間の交通流を動画で観測することは難しいことから、実務への適用としては、代表的な道路構造ごとに動画による交通流観測とパラメータの学習を行えば、類似した道路構造を持つ道路区間において、予測モデルを適用することが現実的であると思われる。

今後の課題として、密度と流率を複数回にわたって観測したデータを用いて、堆雪幅のカテゴリを予測する手法へと拡張することがあげられる。本研究では密度と流率を 1 回だけ観測したデータの組を用いて、堆雪幅の予測を行った。しかし、図 1-2 に示すように、異なる堆雪幅のカテゴリ間に明確な分類境界は存在せず、複数のカテゴリが重なっている。複数回にわたって観測されたデータを用いて、堆雪幅を予測する分布を導出することで、予測の精度を向上させることが期待できる。また、本研究では予測分布を解析的に導出できる例として、共役事前分布を適切にあてはめたものの、予測の精度を向上させるためには、分布形状に関する制約を緩和させることが検討される。この場合、予測分布を求めるにあたり、近似推論を適用しなければならない可能性がある。

現在は、リンクベースで自由走行速度を推定し、堆雪幅の予測を行っている。これを、ネットワーク均衡等を考慮して、ネットワークベースで自由走行速度を推定問題に拡張することも今後の課題である。ネットワークレベルで各リンクにおける自由走行速度を認識することができれば、排雪あるいは排雪を運搬するための、ネットワーク計画問題を考えることができるようになる。

謝辞：本研究の一部は JSPS 科研費 21K20440 の助成を受けたものである。

REFERENCES

- 1) Munehiro, K., Nakamura, N., and sato, M.: Variation of traffic flow due to accumulated snow formation on road, MATEC Web of Conferences, 2019.
- 2) 峪龍一, 本田拓海, 加藤哲平, 内田賢悦, 宗廣一徳: 冬期における路面条件の違いを考慮した交通流パラメータの確率的推定,
- 3) 須山敦志: ベイズ深層学習, 講談社,
- 4) 須山敦志: ベイズ推論による機械学習入門, 講談社,

(?)

STOCHASTIC PREDICTION OF SNOW WIDTH BASED ON BAYESIAN INFERENCE

Ryuichi TANI, Tepei KATO, Kenetsu UCHIDA and Kazuhiro MUNEHIRO

We proposed a method for predicting the snow width at the roadside based on Bayesian inference. Previous studies show that the average free travel speed decreases as the snow width at the roadside increases. In this study, we estimate the parameter of the prediction model from the traffic observation of free flow. We predict the discretely classified snow width at the roadside by using the free travel speed predicted from the newly observed traffic data in the free flow. By assuming that there is a unique probability distribution of free travel speed corresponding to the discretely classified snow width at the roadside, the stochastic relationship between the observed flow rate, traffic density, and free travel speed can be formulated by a mixed normal regression model. This study shows that a predict distribution of the snow width at the roadside can be derived analytically under the appropriate conjugate prior distributions. We applied the proposed prediction model with the data observed in Sapporo.