

冬期の路面状態別の車両挙動に関する特徴

(国研) 土木研究所寒地土木研究所 寒地交通チーム ○奥村 航太
(国研) 土木研究所寒地土木研究所 寒地交通チーム 齊田 光
(国研) 土木研究所寒地土木研究所 寒地交通チーム 伊東 靖彦

冬期の道路維持管理には路面状態の把握が必要であるが、路面状態を網羅的に捉えることは容易ではない。一般車両のプロブデータから路面状態の推定が可能とした場合、冬期の道路維持管理に有益な情報となる。従って本研究では走行調査から得た加速度、各車輪速度等のプロブデータを用いて路面状態を推定するモデルを構築した。結果として平均値等の車両挙動の統計値が路面状態の推定に寄与する傾向がわかった。

キーワード：除雪・防雪、冬期路面管理、路面状態、プロブデータ、機械学習

1. はじめに

(1) 背景

冬期の道路維持管理作業には除排雪や凍結路面の発生を抑制する凍結防止剤の散布がある。これらの作業を適切なタイミングで行うことで、凍結路面によるスリップ交通事故の危険性を減少させることが可能である。つまり、適切なタイミングによる冬期の維持管理作業を行うためには路面状態を把握することが重要である。しかし、刻一刻と変化する冬期の路面状況を網羅的に把握し、路面対策を行うことは容易ではない。従って、一般交通のプロブデータを冬期の道路維持管理に活用することが可能であれば、その課題解決の一策となり得る。

(2) 既往研究

プロブデータから路面状態を推定する既往研究を以下にまとめる。NEXCO東日本グループの取り組み¹⁾ではタイヤ内部に加速度センサを取り付け、100 m毎に路面判別を行う技術開発を行った。路面状態に応じて凍結防止剤を自動散布することで、凍結防止剤の削減効果が見られた。しかし、タイヤ内部の装置は高価なものであることから高速道路会社の管理車両への普及に留まっている。瀬尾ら²⁾はETC2.0プロブデータを活用して凍結路面を客観的に管理できる可能性を示唆した。これにより雪氷路面の把握は維持管理をより効率的にすることが期待されている。しかし、ETC2.0プロブデータはリアルタイムに取得できない等の課題がある。齊田ら³⁾は路面のすべり抵抗値を計測し、それと車載カメラの映像の突き合わせを行い、画像認識技術を用いた路面のすべり抵抗値の推定モデルを構築した。しかし、新雪に覆われた路面表層部の推定精度が低下する等の課題がある。佐々木ら⁴⁾は積雪寒冷地においてスリップ発生地点の検知を行うため、スリップ時のプロブデータを基に分析を行った。そこでGPS速度、各車輪速度の差分、ハンドル操

舵角からスリップ地点を検出できることを明らかとした。しかし、路面状態の分類に関する検討は行われていない。

これらの研究のように、プロブデータから冬期における路面状態の推定やスリップ箇所の検出を行った既往研究が存在する。さらに、近年は機械学習手法を用いて大量のデータから高い推定結果を算出することが可能になっている。しかし、車体の加速度、車輪速度、ハンドル操舵角といったプロブデータを用いて路面状態を推定し、機械学習手法を活用した研究は見当たらない。

(3) 目的

本研究では一般国道、都道府県道、市道において走行調査を行い、調査車両から得られたプロブデータから路面状態別の車両挙動の関係性を示す。また、プロブデータを説明変数、路面の計測車両から得られた路面状態データを目的変数として機械学習モデルを構築した。この機械学習モデルにより、プロブデータから路面状態を推定する手法を提案することが本研究の目的である。

2. 調査方法

(1) 調査日程と路線及び車両

走行調査は2022/27から2022/24の間において12回行った。走行した路線は図-1に示す2つの走行経路である。路線Aは札幌市内の環状通から二十四軒手稲通に至る走行経路であり、路線Bは路線Aから途中で分岐し国道5号線から小樽市内に至る走行経路である。

本研究では路面状態を判別する車両（以下、計測車両、写真-1）とプロブデータを取得する車両（以下、調査車両）を用いた。また調査車両は一般的なSUVであり、その諸元を表-1に示す。計測車両と調査車両の2台体制である理由は、計測車両には路面のすべり摩擦抵抗値を計測する装置を牽引しており、プロブデータとして計

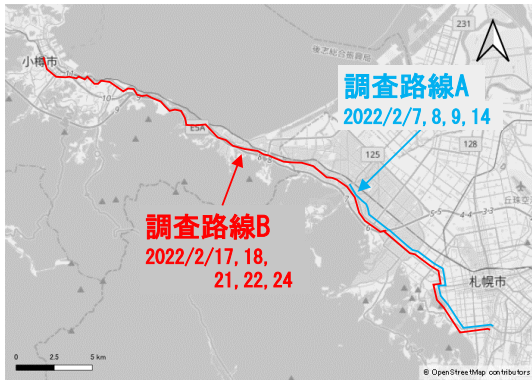


図-1 調査経路

測する加速度やヨーレートに、この装置が影響を与える可能性があると考えられたためである。

(2) 路面状態の判別と取得方法

計測車両を用いて取得したデータの一覧を表-2に示す。路面分類の判断は乾燥・湿潤・シャーベット・圧雪・凍結の5種類として助手席に乗車する作業員が目視で判定した。路面状態の記録には調査車両に搭載したタブレットPCの路面状態入力システム(図-2)を用いた。また路面状態を分類する際、例えば圧雪路面やシャーベット路面等が混在する判断が難しい場合は両方を記録した。その場合は図-2の赤枠において、上段で主な路面状態、下段で一部の路面状態をそれぞれ、タッチパネルで選択した。なお、路面状態は10 Hzのサンプリング周波数で記録した。

(3) プローブデータの取得方法

図-3に示すようにプローブデータを取得する調査車両は計測車両を先頭にして追走した。プローブデータは車両用故障診断機を用いて取得した。車両用故障診断機は自動車に搭載されているコンピューターにアクセスし、各種センサの状態を調べることが可能な装置である。取得可能なデータは診断機や自動車の種類によって異なる。今回のデータサンプリング周波数は約2.3 Hzである。

また本調査で使用した車両用故障診断機では位置情報を収録できないため、調査車両にスマートフォンを搭載して、そのGNSS受信機能を利用し車両用故障診断機のデータとスマートフォンのGNSSデータの時刻で照合した。またGNSSのサンプリング周波数は1 Hzのため、1秒毎のデータ間を按分するように線形補完にて10 Hzのデータを作成した。その上で約2.3 Hzの走行挙動データに時刻が近い位置情報を付与した。調査車両にて取得したデータは表-3に示す通りである。

(4) 路面状態データとプローブデータの結合方法

次に2章2節で得た路面状態のデータと2章3節で得たプローブデータの結合を行った。GNSSの誤差を加味し、



写真-1 計測車両

表-1 調査車両の諸元

全長×全幅	4610×1795 mm	駆動方式	フルタイム AWD
最低地上高	220 mm	横滑り防止装置	あり
タイヤ幅	225 mm	トランスミッション	CVT
ホイールベース	2640 mm	デフロック	なし
トレッド[前/後]	1545/1555 mm	ホイールサイズ	17インチ

表-2 計測車両の取得データ

取得データ	単位	サンプリング周波数
路面状態 (5分類)	—	10Hz
車速パルス	km/h	—
GNSS緯度経度	—	—
時刻	—	—

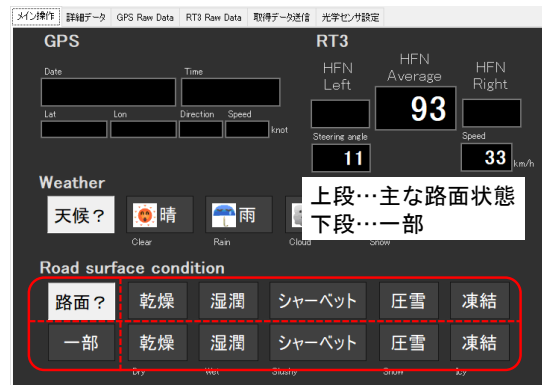


図-2 路面状態入力システム




図-3 データの照合

双方のデータにおける位置座標の直線距離 (以下「直線距離」とする。) が一番近いデータ同士を結合した。ただし、路面状態データとプローブデータの観測時刻が30

秒以内であり、直線距離が25 m以内である場合とした。これは双方の車両間において時空間的に乖離がある場合についてデータ分析の対象外とするためである。

3. データの取得とデータセットの構築

(1) 日別による走行距離と路面状況の集計

調査によるデータの取得状況について、観測時刻、気温と路面温度、路面状態別の計測延長を表4に示す。表4における路面状態別の計測延長は長くなるにつれて濃い赤色で示している。また、全ての走行調査においてABS(アンチロック・ブレーキ・システム、Antilock Braking System)やTCS(トラクションコントロールシステム、Traction Control System)の作動は見られなかった。

(2) プローブデータによる新たな特徴量の算出

プローブデータから得られた指標を基に、新たな指標として、 V_{diff} ：前方車輪速度差[km/h]、 V_{per} ：前方車輪速度割合[-]、 α_{diff} ：ハンドル操舵角変化量[degree]、 α_{sp} ：ハンドル操舵角速度[degree/s]、 V_{ave} ：四輪平均車輪速度[km/h]、 S ：スリップ率[-]を算出した。それらの計算式を下記に示す。ただし、スリップ率の算出式に関しては制動時の車輪のロックと駆動時の車輪の空転を考慮するため鈴木らの研究⁹⁾を参考にした。

$$V_{diff} = V_{fr} - V_{fl}$$

$$V_{per} = \begin{cases} \frac{V_{diff}}{V_{fr}}, & V_{fr} > V_{fl} \\ \frac{V_{diff}}{V_{fl}}, & V_{fl} > V_{fr} \\ 0, & V_{fl} = V_{fr} \end{cases}$$

$$\alpha_{diff} = \alpha_t - \alpha_{t-t_f}$$

$$\alpha_{sp} = f * \alpha_{diff}$$

表-3 調査車両のプローブデータ

取得装置	取得データ	単位	サンプリング周波数
車両診断 ツール	各車輪速度(4輪)	km/h	2.3 Hz
	前後加速度	m/s ²	
	左右加速度	m/s ²	
	ヨーレート	degree/s	
	ハンドル操舵角	degree	
	アクセル開度	%	
	ブレーキ圧	MPa	
	時刻	—	
スマート フォン	GNSS位置座標	—	10 Hz
	GNSS速度	km/h	
	方位角	degree	
	時刻	—	

$$V_{ave} = \frac{V_{fr} + V_{fl} + V_{rr} + V_{rl}}{4}$$

$$S = \begin{cases} \frac{V_{ave} - V_g}{V_{ave}}, & V_{ave} > V_g \\ \frac{V_g - V_{ave}}{V_g}, & V_g > V_{ave} \\ 0, & V_g = V_{ave} \end{cases}$$

ただし、

- V_{fr} : 前方右前車輪速度[km/h]
- V_{fl} : 前方左前車輪速度[km/h]
- V_{rr} : 後方右前車輪速度[km/h]
- V_{rl} : 後方左前車輪速度[km/h]
- α : ハンドル操舵角[degree]
- t : 観測時刻
- f : 調査車両のサンプリング周波数(約 2.3 Hz)
- t_f : 調査車両のサンプリング周期($1/f \approx 0.43$ 秒)
- V_g : GNSS 車速[km/h] とする。

表-4 調査時のデータ取得状況

調査 番号	路線	調査日	計測時刻		外気温[°C]			路面温度[°C]			路面状態別の計測延長 [km]				合計
			開始	終了	最低	平均	最高	最低	平均	最高	湿潤	シャーベット	圧雪	凍結	
1	A	2/7	10:08	11:54	0.3	2.8	5.8	-6.3	0.1	11.5	8.7	6.8	6.2	0.0	21.7
2			16:30	18:45	-1.7	-0.7	0.6	-7.4	-3.1	5.6	0.1	0.0	2.0	26.1	28.2
3		2/8	9:27	11:04	-1.6	-0.1	1.1	-5.7	0.7	5.4	26.4	0.8	0.8	0.2	28.2
4			16:20	18:38	-1.8	-0.7	1.6	-4.5	-2.1	6.1	0.3	3.8	0.0	23.2	27.3
5		2/9	9:22	11:20	-2.2	-0.8	1.4	-3.9	-0.3	7.5	14.0	16.9	0.0	0.0	30.8
6			16:20	18:32	-1.5	0.4	6.6	-4.3	-1.5	13.5	2.3	0.0	0.0	27.4	29.7
7		2/14	16:18	18:10	-0.7	0.3	3.1	-4.9	-1.1	3.6	16.6	0.0	0.0	14.4	30.9
8	B	2/17	20:01	23:18	-1.0	0.2	4.6	-3.7	-0.9	8.0	30.8	22.3	0.1	21.8	75.0
9		2/18	10:02	13:29	-1.8	-0.5	1.8	-3.4	2.4	10.0	51.6	10.5	0.0	1.8	63.8
10		2/21	9:51	13:52	-1.2	0.7	6.9	-3.7	-1.2	3.6	0.6	5.8	36.4	25.6	68.4
11		2/22	10:24	14:43	-2.6	-1.2	1.2	-4.5	-2.0	5.8	0.5	6.6	29.2	38.4	74.7
12		2/24	16:30	21:14	-2.0	0.6	6.8	-4.9	-1.2	6.4	39.9	6.9	1.2	15.7	63.8
合計											191.8	80.5	75.9	194.4	542.6

(3) データセットの概要

目的変数は調査車両で観測した路面状態であり、説明変数は図-4で示すように3つに分けた。説明変数IIはプローブデータから得られたデータ並びに3章2節で算出した特徴量である。これらは時系列データであるため、各観測時刻 t から5秒前までのデータを格納したデータセットを作成した。つまり、プローブデータの取得周波数の約2.3 Hzに5秒を乗算し四捨五入によって、12地点分のプローブデータを説明変数Iとして活用した。また説明変数IIは説明変数Iの12地点における各変数の平均値と分散、最小値、最大値である。説明変数IIIは計測車両より取得した気温と路面温度のデータである。

(4) 機械学習モデルを用いた路面状態推定方法

本論文において、モデルとは入力されたデータから評価や判定を行った結果を出力するものをいう。ここでは調査車両から得られたプローブデータから路面状態の評価や判定を行った。本研究では推定結果を出力する時間が短く、単純な構造に関わらず良好結果が得られることが知られているランダムフォレストで機械学習モデルを構築した⁶⁾。またランダムフォレストは説明変数の寄与度を確認できる利点がある。

a) ランダムフォレストの概要

ランダムフォレストは決定木を複数活用した機械学習法である。各決定木による予測値と目的変数との差を減少させるように学習し決定木を追加していくものである。ランダムに説明変数を抽出し複数の決定木から出力結果を多数決や平均化することで、分類や回帰を行うことができる。分類の予測結果は各決定木の多数決によって予測値が定まる。

b) データセットの分割

全調査分のデータセットは約13万行になった。一般的に教師ありの機械学習モデルの構築は学習データと検証データに分割する。学習データとはモデルの構築のみに活用するデータ群であり、検証データはそのモデルの精度を確認するために活用する。その分割方法について、今回のモデルの構築は2つ方法を行った。1つ目は全データから学習データ数と検証データ数の比が7:3となるように無作為で分割した。これをモデルA（無作為分割による学習モデル）とする。一方、分割方法の2つ目は調査回数の合計12回の出動のうち調査番号1、5、8、10を学習データとして、それ以外を検証データにした。この分割は観測された路面状態について、学習データ内の偏りを均すように設定した。これを推定モデルB（日別分割による学習モデル）とする。

モデルAの構築では一般的な機械学習手法による推定結果モデルの妥当性を確認することができる。このようなモデル構築の例として、似た分野の既往研究では計測した路線等の条件を付さず全サンプルを学習データと検証データに分割し評価している研究が挙げられる⁷⁾。

4. 分析結果

(1) 路面状態別プローブデータの傾向

凍結路面等の摩擦係数が低い路面ではスリップ率の増大や各車輪の速度差が生じると考えられる。したがって、路面状態毎に前方車輪速度の差やその傾向を示す。その際、車輪速度の差や割合において路面状態を分類するための基準を示す。

図-5は前方右車輪速度と左車輪速度関係を示す。この図は縦軸を前方右車輪速度、横軸を前方左車輪速度とした。図-5の右側に示す散布図は各車輪速度が20~25 km/hにおける走行状態を拡大したものである。破線は左右車輪速度の割合が±2.5%の直線であり、左右の車輪速度差が5%範囲内を(A)、5%範囲外を(B)とする。表-5は路面状態別の車輪速度差の分析結果を示す。湿潤路面では(B)に相当するデータ数が(A)に対して5%未満であるのに対し、シャーベット、圧雪、凍結路面では6%以上であった。この理由として摩擦係数が低い雪氷路面の出現が

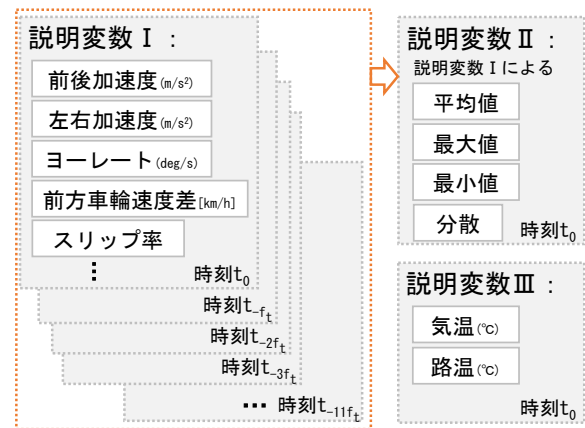


図-4 説明変数の作成




図-5 前方右車輪速度と左車輪速度の関係

表-5 路面状態別の車輪速度差の分析結果

路面状態	湿潤	シャーベット	圧雪	凍結
5%範囲内(A)	47,930	21,422	23,304	57,719
5%範囲外(B)	2,236	1,344	1,845	3,613
範囲外割合	4.67%	6.27%	7.92%	6.26%
左右車輪速度差 3 km/h以上	0	2	20	31

影響していると考えられる。また、左右車輪速度差 V_{diff} の絶対値が3 km/h以上であるデータは湿潤路面では見られず、凍結や圧雪路面に出現することがわかった。ただし、これらの分析はハンドル操舵角による車輪の速度差を考慮できていないことに留意する必要がある。

(2) プローブデータによる路面状態の推定結果

プローブデータから得られた車両挙動を説明変数にして路面状態の推定を行った。推定モデルAとBにおける推定結果は表-6にまとめた。評価指標として再現率、適合率、F値、正解率を用いる。再現率は各路面状態のデータ数に対して推定によって正しく分類できた割合を示す。適合率は各路面状態の推定に対して実際に正しい分類である割合を示す。F値は再現率と適合率の調和平均を示す。正解率は検証データの総数に対して正しく分類されたデータ数を割った値である。

推定モデルAのF値は84.2%であり、モデルBは32.2%であった。モデルAの推定精度が高くなったことについて、モデルAは路面状態の学習を行う際、無作為にデータを抽出したため、観測時刻に近いデータが学習データと検証データに含まれていたことが原因として考えられる。一方、モデルBは学習データと検証データの区分において、表-4に示す調査日程を基準とした計測番号で指定した。つまりモデルBはモデルAのように観測時刻に近いデータが学習データと検証データに入っている可能性を排除したものである。

モデルBの推定結果について、湿潤路面と圧雪・凍結路面について、分けられた傾向が読み取れる。さらに表-7に示す説明変数の寄与度を確認すると説明変数の路面温度が路面状態を予測する上で最も重要な変数として位置づけられている。これらによって、路面温度から湿潤路面もしくは凍結路面と分類されている可能性が推察される。次いで左右加速度や前方車輪速度に関する平均値等の統計的な指標の特徴量が上位に挙げられている。また、スリップ率が大きい値を示す場合は車輪が空転傾向にあり、小さい値の場合は車輪がロックする傾向である。表-7に示す通り、スリップ率の最大値と最小値の寄与度が上位の変数であることから、説明変数IIを活用したモデルの構築は車輪の空転やロック等の傾向を考慮できた可能性がある。一方、説明変数Iで挙げた12地点分の変数の寄与度は全体的に低い傾向にあった。

以上の結果より、学習データと検証データを日別分割によってモデルを構築した場合、異なる路線や日時ではモデルの推定精度が低下することが明らかになった。つまり、モデルの頑健性に改善の余地があると考えられる。

5. おわりに

本研究ではプローブデータと路面状態の関係性について、前方車輪速度差から得られた傾向を述べた。また

表-6 路面状態別の推定結果
モデルA（無作為分割による学習モデル）

		推定値				合計	再現率
		湿潤	シャーベット	圧雪	凍結		
実測値	湿潤	10,082	14	65	769	10,930	92.2%
	シャーベット	654	3,008	114	860	4,636	64.9%
	圧雪	165	23	4,283	1,054	5,525	77.5%
	凍結	385	24	107	12,639	13,155	96.1%
	合計	11,286	3,069	4,569	15,322	F値	84.2%
	適合率	89.3%	98.0%	93.7%	82.5%	正解率	87.6%

モデルB（日別分割による学習モデル）

		推定値				合計	再現率
		湿潤	シャーベット	圧雪	凍結		
実測値	湿潤	15,949	4,048	3,619	4,960	28,576	55.8%
	シャーベット	2,378	1,259	2,546	2,446	8,629	14.6%
	圧雪	331	670	3,908	3,212	8,121	48.1%
	凍結	5,704	4,954	10,581	12,150	33,389	36.4%
	合計	24,362	10,931	20,654	22,768	F値	32.2%
	適合率	65.5%	11.5%	18.9%	53.4%	正解率	42.3%

表-7 説明変数の寄与度（一部抜粋）

説明変数	寄与度
路面温度< α_0 >	0.0788
気温< α_0 >	0.0571
左右加速度<平均値>	0.0108
前方車輪速度差割合<最小値>	0.0103
前方車輪速度差<分散>	0.0096
スリップ率<最大値>	0.0092
前方車輪速度差割合<分散>	0.0088
スリップ率<最小値>	0.0088
⋮	⋮
ブレーキ圧< α_5 >	0.0009
ブレーキ圧< α_6 >	0.0009
ブレーキ圧<最小値>	0.0005

本研究では機械学習のランダムフォレストを用いて、プローブデータから路面状態を推定する手法を提案した。以下に得られた結果を示す。

- 前方車輪速度の差と路面状態の関係に着目すると湿潤路面に対してシャーベット、圧雪、凍結路面において左右の車輪速度の差が大きい傾向を定量的に示した。特に左右車輪速度差が3 km/h以上の閾値を設けると雪氷路面を判別できる可能性が高いことがわかった。
- 学習データと検証データを無作為に分けてモデルを構築した場合、推定精度のF値は90%程度となった。しかし、異なる路線や日時ではモデルの推定精度が低下することが明らかになった。
- 路面状態を推定するためには説明変数IIIである路面温度の寄与度が大きいことがわかった。一方、プローブデータの5秒間における統計的な指標の説明変数IIIは説明変数IIに対して路面状態の推定に有効であった。

本研究にて構築したモデルは取得したプローブデータの観測点毎の学習であり、過去の観測点の影響を考慮した時系列の学習ではない。したがって今後は時系列を考慮した分析でモデルの構築を進めると共に、プローブデータの蓄積を行い、一般車両が走ることによって路面状態を把握できるシステム開発を目指す。さらに車輪速度やハンドル操舵角といったより詳細なデータを活用し、道路の維持管理に有益なデータの発信する研究に繋げたい。

参考文献

- 1) 東日本高速道路株式会社 (2016)、凍結防止剤最適自動散布システム (ISCOS) の導入について、<https://www.e-nexco.co.jp/assets/pdf/activity/technique/02.pdf> (2023年1月13日閲覧)
- 2) 瀬尾亜希子、船岡直樹、金木大輔 (2021)、ETC2.0プローブデータを活用したスリップ検出手法の構築、交通工学研究発表会論文集、41、199-206
- 3) 齊田光、大廣智則、畠山乃 (2020)、深層学習を用いた冬期路面すべり摩擦係数推定技術に関する基礎的検討、寒地土木研究所月報 第826号
- 4) 佐々木正大、鈴木理、浜岡秀勝 (2008)、プローブデータを用いた車両スリップの検知に基づくスリップ路面情報提供システムの構築、土木計画学研究・論文集、25、909-917
- 5) 鈴木理、濱口慎平、浜岡秀勝 (2007)、高精度車両挙動データを用いた路面状態の推定方法、土木計画学研究・論文集、24、803-811.
- 6) 波部斉 (2012)、ランダムフォレスト、研究報告コンピュータビジョンとイメージメディア (CVIM)、31号、pp. 1-8
- 7) 中村一樹、砂子宗次朗、上石勲 (2022)、スマートフォン画像を用いたAI路面判定システムの開発、第38回寒地技術シンポジウム、CD-ROM