AI を用いた冬用タイヤ自動判別システムの実用化

西日本高速道路エンジニアリング四国(株) 正会員 ○川西弘一, 林詳悟, 橋本和明, 松田靖博

1. はじめに

冬季の安全走行を確保するため、高速道路会社では冬用タイヤ規制を実施している。この規制はタイヤチェック要員や交通誘導員など多くの人員を確保する必要があり、拘束時間を鑑みると人的、経済的負担が大きい。また、交通量が多いと渋滞が発生することから、チェック作業の省力化と時間短縮が課題となっている。筆者らは平成28年度より冬用タイヤ自動判別システム（以下、判別システム）の開発に着手し、画像処理とAIを用いた判別技術の開発を進めてきた¹⁾。本論は、現場導入結果をもとに、実用化した冬用タイヤ自動判別システムの精度と更なる改善方法について述べる。

2. 冬用タイヤ自動判別システムの概要

2. 1. 判別装置

判別システムの配置状況を写真-1に示す。照明をカメラに対して正反射する位置に配置して撮影する。(図-1)、背面照明の車を横切るタイヤのシルエットを検出し、タイヤが写っている画像のトレッド部分を自動的に切り出し、その撮影画像からタイヤ種別を判別する。なお、高感度カメラを用いることにより、30km/h以下で通過する車両のタイヤを判別することができる。

2. 2. AIによる自動判別

判別のAIには、画像認識で実績があるConvolutional Neural Network（以下、CNN）を採用した。この手法は、特徴が画像内のどこにあっても検知できる移動不変性を有する。教師画像は、スタッドレス、ノーマル、目視で種別が確認できない不明（写真-2）の3分類とした。学習の結果、AI判別モデルの教師データの判別精度は99.3%（表-1a）であったが、ノーマルをスタッドレスとする誤判別（以下、危険側誤判別）が7本発生した。

判別システムは、冬用タイヤ規制においてノーマルのスクリーニングに用いるので、危険側誤判別を0にする必要がある。そこで、教師データに対する類似性評価指標である確信度（0～1の量的データであり1に近いほど類似性が高い）を用いて安全側に調整を行った。表-1bは、AI判別モデルがスタッドレスと判別しても、確信度が0.995以下の場合はノーマルと判別するように調整した結果で、危険側誤判別を0にできたが、スタッドレスのノーマル誤判別は増加し、精度は97.9%と若干低下した。このように、AIは最も精度が高くなるよう自動的に学習を行うが、危険側誤判別を許さない場合、確信度の調整が重要となる。

写真-1 装置配置状況

図-1 カメラと照明の配置

写真-2 AI判別の教師画像例

表-1 教師データ精度検証

a) 確信度考慮無し

		AI判別			
		スタッドレス	ノーマル	不明	合計
目視	スタッドレス	5,928	61	11	6,000
	ノーマル	2	5,632	7	5,641
	不明	5	8	1,485	1,498
	合計	5,935	5,701	1,503	13,139

b) 確信度調整 0.995

		AI判別(確信度0.995以上)			
		スタッドレス	ノーマル	不明	合計
目視	スタッドレス	5,744	245	11	6,000
	ノーマル		5,634	7	5,641
	不明		13	1,485	1,498
	合計	5,744	5,892	1,503	13,139

キーワード 冬用タイヤ, 画像処理, AI, 自動判別, ロジスティック回帰分析

連絡先 〒760-0072 高松市花園町三丁目1番1号 TEL 087-834-1121 FAX 087-834-0150

3. 実用における精度検証

表-2 R1 年度実用精度検証

令和2年2/17, 18, 3/5の西日本高道路管内(福知山, 千代田, 大分)における試行導入結果を表-2に示す。昼夜降雨降雪など様々な条件で撮影したタイヤ本数は、合計27,652本であった。撮影画像を目視してタイヤ種別を確認し、判別システムと比較した結果、危険側誤判別は無く、全体精度は84.1%であった。昨年度撮影画像を用いた机上の検討精度¹⁾が83.7%であったことから、判別システムは実用においても机上と同等の精度が確保できた。

		判別システム			
		スタッドレス	ノーマル	不明	総計
目視	スタッドレス	18,248	3,592	761	22,601
	ノーマル		4,887	32	4,919
	チェーン		3		3
	不明			129	129
	総計	18,248	8,482	922	27,652

4. 判別精度向上の検討

4. 1. 因子の抽出

更なる判別精度向上のため、誤判別の発生因子について分析を行った。画像を確認すると、タイヤ状態や、路面状態、撮影時間帯(写真-3)など、現場では様々な影響を受けている。そこで、ロジスティック回帰による因子の絞り込みを行った。因子は目視確認や現場状況から想定される項目をすべて対象とした(表-3)。分析に用いたデータは、判別システムでノーマルと判別した8,482件とし、判別が一致した正解を0、誤判別を1として分析を行った。

写真-3 誤判別に影響すると思われる画像例

表-3 因子と水準

因子	水準					
	通過速度	0~65km/hの量的データ				
確信度	0~1の量的データ					
路面状態	乾燥	半乾	湿潤	水たまり	シャーベット	積雪
タイヤ状態	乾燥	湿潤	雪付着	半乾乾き		
天候区分	降雨雪無	雨	小雪	雪		
昼夜	昼	夜				
大小型区分	大型車	小型車				
前後輪	前輪	後輪				

4. 2. 精度向上の改善策

表-4に、ステップワイズ変数減少法により絞り込んだ因子とその係数を示す。なお、判別システムのノーマル判別の精度は57.7%(4,890/8,482)であったが、本モデルによる正答率は80.4%であった。すべての因子について分析した結果、最終的に路面状態、昼夜、前後輪、確信度が影響する因子であり、通過速度、タイヤ状態、天候、大型小型区分の影響は小さいことが分かった。Wald統計量と、係数の符号(マイナスは精度向上側)に着目すると、路面が乾燥状態では精度が向上し、水たまりとシャーベット状態では精度が悪化する。明るい昼間の撮影は精度が向上し、前後輪では前輪の精度が高いこと、さらに確信度が1に近いほど精度が向上することがわかる。このことから、以下の改善を行えば、判別精度はさらに向上すると考える。

表-4 分析結果(偏回帰係数)

因子と水準	係数B	標準誤差	Wald	自由度	有意確率
定数α	21.30	1.03	423.92	1.00	0.00
路面状態					
乾燥	-0.70	0.54	1.71	1.00	0.19
湿潤	0.42	0.54	0.61	1.00	0.43
水たまり	1.72	0.54	10.23	1.00	0.00
シャーベット	1.44	0.59	5.92	1.00	0.01
積雪	12.91	40192.97	0.00	1.00	1.00
昼夜					
昼	-0.51	0.07	47.03	1.00	0.00
前後輪					
前輪	-0.30	0.06	27.72	1.00	0.00
確信度	-21.70	0.89	593.77	1.00	0.00

- 1) 路面を、排水や除雪、融雪により良好な状態に保ち、前輪の飛沫の巻き上げを抑制する。
- 2) 夜間の照度不足を補うため、カメラの露光時間の変更や、照明設備の増強を図る。
- 3) 確信度の調整を行い、危険側誤判別が発生しない範囲で最適化を行う。

5. 今後の展開

判別システムは、危険側誤判別が無く、現場においても実用に耐えることが確認できた。今回の検証結果を踏まえて、今後はソフト面だけでなく、環境面やハード面の改良も含めた改善を行うことで更なる判別精度の向上が期待できる。

参考文献

- 1) 廣永厚友ほか; 冬用タイヤ自動判別技術の開発, 土木学会第74回年次学術講演会, 講演番号CS10-29, 2019