

(24) トンネル重機のマシンビジョン AI 判別 による工程管理の現場試行

松元 和伸¹・鈴木 亮汰²・山本 剛司³・渡辺 孝弘⁴

¹正会員 飛鳥建設株式会社 技術研究所 第一研究室 (〒270-0222 千葉県野田市木間ヶ瀬 5472)
E-mail: kazunobu_matsumoto@tobishima.co.jp

²正会員 飛鳥建設株式会社 技術研究所 第一研究室 (〒270-0222 千葉県野田市木間ヶ瀬 5472)
E-mail: ryouta_suzuki@tobishima.co.jp

³非会員 沖電気工業株式会社 ソリューションシステム事業本部 社会インフラソリューション事業部
ビジネス開発部第三チーム (〒108-8551 東京都港区芝浦 4-10-16)
E-mail: yamamoto762@oki.com

⁴非会員 沖電気工業株式会社 ソリューションシステム事業本部 社会インフラソリューション事業部
ビジネス開発部第三チーム (〒108-8551 東京都港区芝浦 4-10-16)
E-mail: watanabe710@oki.com

山岳トンネル建設工事では、トンネル掘削の進捗・掘削速度が生産性に大きな影響を与える。生産性を高めるためには、掘削サイクルの短縮が重要であり、大型重機の導入・高機能化にとどまらず、掘削サイクル中の重機トラブルや材料ロス等、生産性を阻害する要因を排除することが重要である。しかし、掘削進行を阻害する要因を詳細に調査・把握するためには、担当者による作業状況監視が必要であり、多大な労力が必要なことから、十分な管理を行うことが困難であった。そのため、重機の不調による時間・材料のロスや、それにつながる予兆が見逃され、生産性の低下に繋がっていた。

そこで、作業員や建設重機・車両の位置・動きの分析等を通じた作業支援に着目して、IoT・AIを活用した工程管理システムを開発し、PRISM 予算の活用による現場試行を行った。

本論文では、本試行の技術・試行結果・課題・導入効果などについて報告する。

Key Words: AI, machine vision, process control

1. はじめに

山岳トンネル建設工事では、トンネル掘削の進捗・掘削速度が生産性に大きな影響を与える。生産性を高めるためには、掘削サイクル（掘削、ずり出し、建込み、吹付け、ロックボルト）の短縮が重要であり、これまでもハード面では大型重機の導入による生産性向上が図られてきている。ソフト面からは掘削サイクル中の重機トラブルや材料ロス等、生産性を阻害する要因を排除することが重要である。しかし、掘削進行を阻害する要因を詳細に調査・把握するためには、担当者が常にトンネル切羽付近で作業状況を監視する必要があり、多大な労力が必要なことから、十分な管理を行うことが困難であった。そのため、重機の不調による時間・材料のロスや、それにつながる予兆が見逃され、生産性の低下に繋がっていた。

そこで、作業員や建設重機・車両の位置・動きの分析

等を通じた作業支援に着目し、IoT・AIを活用した工程管理システム開発し、現場で試行した。

本報論文では、本試行の技術概要とその結果および課題、導入効果について報告する。

2. 試行概要

(1) システム概要

本システムは、IoT・AIを活用して重機および人を自動的に判別し、工程管理を行うものである。システムの概要を図-1に示す。まず、AIによる重機判別のための学習データを取得し、AIエンジンを構築する。次に、3D LiDAR&カメラ一体型センサをトンネル切羽近傍の左右側壁に設置（図-2）し、同センサで取得した位置情報と映像の解析・統合処理を行い、対象重機や作業員の正確な3次元位置情報を算出する。同時に、機械学習を行




図-1 システムの概要



図-2 センサとセンサ設置状況

表-1 主要画像データ取得枚数

撮影時期	左カメラ	右カメラ	合計
第1回撮影	3,879	3,760	7,639
第2回撮影	580	605	1,185
合計	4,459	4,365	8,824

った AI エンジンにより施工重機の種類と作業工程を自動判別し、映像を記録する。記録情報を標準サイクルと比較することにより、作業遅延の要因を抽出し、作業遅延状況と原因をタイムリーに把握し、すみやかに遅延を解消することが可能となる。

(2) 現場概要

試行実験は、内閣府沖縄総合事務局発注の「平成30年度赤嶺トンネル（北側）工事」にて、2020年12月8日～2021年3月18日の期間で2回（各5日間）実施した。第1回試行実験は3章に示すCASE1のAIエンジン、第2回試行実験はCASE2のAIエンジンを用いた。

3. 重機判別検証実験

(1) AI エンジン構築のための学習

第1回撮影データと第2回目撮影の画像データ（遠距離データ）を合わせて学習した。表-1に学習用画像データの取得枚数を示す。AIエンジン向け学習用画像データは2回で合計8,824枚である。表-2には学習用画像データ8,824枚に含まれる重機の種類とそれぞれの画像データ数を示す。第1回撮影では各重機ともに左右カメ

表-2 建設重機別学習用画像データ

重機分類	第1回撮影		第2回撮影		合計
	左カメラ	右カメラ	左カメラ	右カメラ	
バックホウ	1,042	1,357	304	311	3,014
サイドダンプ	972	955	191	193	2,311
10tトラック	587	604	115	132	1,438
ブレーカー	567	530	236	128	1,461
吹付け機	1,400	1,264	180	134	2,978
ドリルジャンボ	1,215	1,064	150	106	2,535
アジテータ車	825	781	141	34	1,781
モルタル台車	592	444	85	111	1,232
学習対象外	47	130	0	0	177
合計	7,247	7,129	1,402	1,149	16,927

表-3 5日間の平均重機判別率（CASE1）

重機分類	正判別率	誤判別率
バックホウ	37.6%	12.9%
サイドダンプ	16.6%	0.1%
10tトラック	19.5%	15.9%
ブレーカー	38.7%	0.2%
吹付け機	32.7%	40.8%
ドリルジャンボ	4.5%	0.4%
アジテータ車	3.8%	1.6%
モルタル台車	0.0%	0.0%
学習対象外	25.4%	138.3%

表-4 5日間の平均重機判別率（CASE2）

重機分類	正判別率	誤判別率
バックホウ	36.1%	24.5%
サイドダンプ	11.7%	0.1%
10tトラック	32.3%	0.2%
ブレーカー	20.6%	1.9%
吹付け機	76.0%	70.8%
ドリルジャンボ	0.0%	0.0%
アジテータ車	45.5%	12.4%
モルタル台車	8.5%	31.5%
学習対象外	9.4%	1.1%

ラデータ合わせて約1,000台～2,000台（延べ台数）、第2回撮影データは左右カメラデータ合わせて約200台～600台（延べ台数）となった。

本現場で撮影された画像を基に学習したAIエンジンの効果を検証するために、以下の2種類のAIエンジンを用いた。

CAES1:事前に用意した重機画像約7,000枚を基に作成したAIエンジン（他のトンネルのデータ）

CASE2:取得した8,824枚の重機画像を使用して作成したAIエンジン（試行現場のデータ）

なお、AIエンジンの作成に当たっては各種のデータ数なるべく均等になるように重みを変えている。

(2) 重機判別結果と分析

表-3および表-4に2回の試行実験における重機判別結果を示す。ここで、正判別率は、正しく判別した重機数／総数、誤判別率は、誤って判別した重機数／総数を示している。表-3および表-4より明らかになった重機判別傾向は以下のとおりである。1点目は、CASE1では学



図-3 ドリルジャンボが吹付け機と誤判別された例



図-4 右カメラ前への待機重機の影響による誤判別例

学習対象外の誤判別率が138.3%と非常に高いが、CASE2では、誤判別率が1.1%と非常に低くなっている点である。事前に想定していた結果であるが、当現場では使用していない重機データを含むAIエンジンによる評価であったため、CASE1では誤判別の割合が非常に大きくなった。一方で、当現場の重機画像を用いたAIエンジンで評価したCASE2では、格段に誤判別の割合が減少している。この数字がゼロにならないのは学習重機を学習対象外重機として判別してしまうことが要因であると考えられる。2点目は、CASE1に比べCASE2の方が、10tトラック、吹付け機、アジテータ車、モルタル台車の正判別率が高くなっている点である。上記2点の傾向により重機判別の精度向上のためには、他現場の重機画像データを用いたAIエンジンより現場専用のAIエンジンが必要であることを示している。3点目は、CASE1、2ともにドリルジャンボの正判別率、誤判別率が非常に低く、吹付け機の正判別率、誤判別率が高くなっている点である。ドリルジャンボを吹付け機と判別していることが要因であり、システム内の重機判別のアルゴリズムが一因と考えられる。図-3に示すのは「ドリルジャンボと吹付け機の判別比較例」であるが、上段のドリルジャンボの例では、左カメラはドリルジャンボと判別され、右カメラが吹付け機に判別されている。最終的な統合結果は2つの判別結果の判別信頼度によって評価される（信頼度が高い方が優先されて結果が出力される）。ここでは右カメラの吹付け機の信頼度が、左カメラのドリルジャンボの信頼度より高いため、統合結果として吹付け機と判別されている。ドリルジャンボ自体の判別精度を向上させることで解決できる事象と考えている。

表-5 検出・判別された重機と工程の関係一覧

工程	作業重機			
掘削・ずり出し工	サイドダンプ	10tトラック	バックホウ	ブレーカー
吹付け・支保工	吹付け機	アジテータ車	バックホウ（待機）	ブレーカー（待機）
ロックボルト工	ドリルジャンボ	モルタル台車	—	—
その他	学習対象外の重機	判別信頼度の低い重機	—	—
作業無し	重機が存在しない	—	—	—

表-6 第2回実験個別工程判別結果

実験日	実工程	出力工程				
		掘削・ずり出し工	吹付け・支保工	ロックボルト工	その他	作業無し
2月8日	掘削・ずり出し工	61.8%	29.4%	3.2%	1.8%	3.7%
	吹付け・支保工	1.8%	91.1%	0.1%	3.8%	3.2%
	ロックボルト工	3.5%	91.5%	2.9%	0.4%	1.8%
2月9日	掘削・ずり出し工	43.0%	42.7%	2.2%	5.6%	6.6%
	吹付け・支保工	5.9%	85.2%	3.7%	0.7%	4.6%
	ロックボルト工	22.0%	68.8%	0.6%	4.8%	3.9%
2月10日	掘削・ずり出し工	45.3%	40.4%	5.9%	5.2%	3.1%
	吹付け・支保工	13.6%	71.5%	7.9%	4.0%	3.0%
	ロックボルト工	1.8%	70.4%	0.6%	6.4%	20.8%
2月11日	掘削・ずり出し工	59.5%	31.2%	3.2%	1.0%	5.0%
	吹付け・支保工	11.0%	83.5%	0.0%	0.2%	5.3%
	ロックボルト工	2.7%	80.8%	9.8%	0.6%	6.1%
2月12日	掘削・ずり出し工	55.9%	31.1%	5.0%	0.6%	7.5%
	吹付け・支保工	1.6%	91.9%	0.1%	0.2%	6.3%
	ロックボルト工	1.4%	62.3%	24.2%	4.7%	7.4%

(3) 工程判別結果と分析

実験の評価はカメラ映像を目視判別した重機に基づく掘削サイクル工程と、本システムが出力した掘削サイクル工程を比較して評価を行った。評価工程は、「掘削・ずり出し工」、「吹付け・支保工」、「ロックボルト工」の3工程とし、表-5に示すように切羽近傍で作業する重機種別を参考に工程判別を行っている。

表-6に、個別工程判別結果（第2回実験）を示す。紙面の都合上表示していないが、全体としては第1回実験（CASE1）に比べて工程判別精度の向上が見られた。ただし、「ロックボルト工」の工程判別率が低いのが特徴的である。

本現場の重機画像データで学習したことにより学習対象外の誤判別が大幅に減少し、「その他」工程の誤判別が減少している。実際の現場で使用されている重機の学習データを利用することが、重機判別、工程判別精度向上に直結することを示している。

ここで、本試行では、切羽の進行に伴い2月10日の昼勤と夜勤の間にセンサの盛替えを実施している。2月8日から2月10日にかけてセンサと切羽（重機作業位置）が離れていくにしたがって工程判別精度（「掘削・ずり出し工」、「吹付け・支保工」）が低下する傾向が見られ、センサの盛替えにより、精度は向上している。これはCASE2では遠距離の学習データが少ないため、遠距離の重機判別精度が低くなるのが要因と想定される。

ドリルジャンボが吹付け機に誤判別されているため、「ロックボルト工」は「吹付け・支保工」に誤判別されている。これは、学習データ（特に第1回撮影分）と実際の工事での重機の撮影条件（見え方、照明環境等）が異なること、遠方の学習データが少なく重機後方の画像（形状）が類似していることが主な要因と考えられる。

表-7 各工程の時間（分）（第2回試行実験時）

勤務体制	作業日	上半1基目			上半2基目			下半・インバート		全体時間 (分)
		掘削・ずり出し工	吹付け・支保工	ロックボルト工	掘削・ずり出し工	吹付け・支保工	ロックボルト工	掘削・ずり出し工	吹付け工	
昼勤	2月8日	62	54	26	72	102	36	48	27	427
	2月9日	57	62	29	62	118	27	44	34	433
	2月10日	60	58	21	69	99	29	54	34	424
	2月11日	—	—	—	—	—	—	—	—	—
	2月12日	67	53	27	82	94	35	55	36	449
	平均	61.50	56.75	25.75	71.25	103.25	31.75	50.25	32.75	433.25
	標準偏差	3.64	3.56	2.95	7.19	8.98	3.83	4.49	3.42	38.07
夜勤	2月8日	88	66	16	60	98	40	61	37	466
	2月9日	85	71	20	49	110	39	59	35	468
	2月10日	101	62	19	70	85	45	51	35	468
	2月11日	96	59	20	88	90	47	53	33	486
	2月12日	—	—	—	—	—	—	—	—	—
	平均	92.50	64.50	18.75	66.75	95.75	42.75	56.00	35.00	472.00
	標準偏差	6.34	4.50	1.64	14.34	9.44	3.34	4.12	1.41	45.15

さらに、図-4 に示すように「ロックボルト工」の時間帯に、右カメラ前への別重機の待機が多かったため、左カメラの画像を主とした重機判別も精度低下の要因であると考えられる。

4. 作業遅延要因の抽出

表-7 に第2回目の試行実験での各工程の作業時間を示す。ただし、各工程の時間は映像データより目視確認した時間を用いている。

昼勤と比較して夜勤の各工程の作業時間が長い傾向にあり、全体時間では、約 40 分長くなっている。作業班について現場ヒアリングしたところ、夜勤に比べて昼勤の年齢層が若く、比較的機敏な動きをしているとのことであった。第1回目も同様の傾向が見られることから、班の特性が作業時間の短縮に繋がっていると見られる。今回は短期間の結果ではあるが、長期的な集計を行うことで、各工程での課題が浮き上がってくる可能性がある。

上半1基目の「掘削・ずり出し工」の昼夜勤の差は、昼勤で上半1基目分のずり出し作業を実施していないためであり、工程遅延の要因ではない。

また、「吹付け・支保工」については、上半1基目と上半2基目に30分程度の差が生じているが、上半2基目の作業時間に下半支保建込み作業も含まれるための違いである。

今回は、試行的な実験によって作業工程の把握が出来たとの前提で、作業時間の分析を実施した。しかし、作業時間を自動的に集計・分析できるようになれば、標準作業時間からの乖離を把握し、地山条件変化による掘削、吹付け時間作業の変化、掘削進行に伴うずり出し時間の変化、建設重機のトラブル発生の可能性を事前に検知可能となり、現場作業の中断などによる生産性の低下を回避できるようになると考えられる。

5. 結論

本実験において以下の知見が得られた。今回の実証実験では学習データの収集期間の短さと、学習データ撮影時と実際の工事の撮影条件（見え方、照明条件等）が異なっていたため、一部の工程で精度の低下が見られた。撮影条件を多様化した学習データを用いて AI エンジンを構築すれば、80%程度の工程判別精度（第2回実験の「吹付け・支保工」の判別精度程度）が期待できる。また、「吹付け・支保工」の関連重機（吹付け機、アジテータ車）の判別精度が高いため、「吹付け・支保工」の判別率が高いが、次工程・前工程の待機重機を工程判別に採用することによる誤判別（映像内の重機判別は正しいが、実際の工程を誤判別）も含まれるため、この点を改善すれば更に判別精度は向上するものと考えられる。さらに、公開重機データベースのような大規模なデータベースを官民一体で作成して利用できるようになると、高精度な AI エンジンの構築が低コストで効率的に行えることも期待できる。

今回の試行実験によって得られた知見を基に、工程精度低下の要因となっている AI エンジンや工程判断方法の改善を進め、現場実装に向けて更に検証を進めたいと考えている。

6. 謝辞

この論文は、官民研究開発投資拡大プログラム（通称 PRISM）予算を活用して国土交通省が実施する『建設現場の生産性を飛躍的に向上するための革新的技術の導入・活用に関するプロジェクト』において現場試行実証を行った成果である。ここに記して謝意を表する。

参考文献

- 1) C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna: Rethinking the Inception Architecture for Computer Vision. In CVPR, pp.2818-2826, 2016.