

## 橋梁定期点検データの分析および機械学習の利活用

長崎大学 学生会員 ○ 細井 優大  
長崎大学 正会員 山口 浩平  
成田国際空港株式会社 白井 聡

## 1. 背景および目的

我が国の橋梁の定期点検は橋梁定期点検要領<sup>1), 2), 3)</sup>などにに基づき実施されるが、点検項目が多く大変な労力や時間、費用を要するので、空港内橋梁においても、効率的な維持管理手法の構築が必要である。定期点検は、「点検」と「診断」から構成される。同要領では、点検における「損傷の種類」は26種類、「損傷の程度」はa~eの5段階で評価される。診断における「対策判定区分」は9段階、「健全性の診断」は4段階である。同要領には、「対策判定区分」と「健全性の診断」の対応はあるが、点検結果である「損傷の程度」から診断結果である「対策判定区分」は対応がなく、橋梁診断員の知識や経験に依存している。そこで本研究では、点検と診断の関係性に着目した研究が少ない現状に鑑み、「損傷の種類」や「損傷の程度」から「対策判定区分」を評価できる「判断基準」を分析し、機械学習<sup>4)</sup>により自動診断支援システムを構築することを目的とする。

## 2. 空港内橋梁の定期点検データの分析

点検結果である損傷の種類と損傷の程度から、診断結果となる対策区分の判定を評価できる判断基準を分析した。対象は空港内の橋梁全49橋（総損傷数10066個）であり、過去7年分の点検データを分析した。図1は機械学習に用いた7年分の10066個のデータの対策区分の判定の割合を示すが、対策区分BおよびC1が99%を占める不均一なデータである。本研究では部材、損傷の種類、損傷の程度が等しいデータのうち、判定区分が異なるデータの分析を行い、判定区分が異なる原因を分析することで、34個の判断基準が明らかになった。その内の損傷数の多い上位5つの判断基準を表1に示す。例えば、主桁に発生した腐食で損傷の程度がdの場合、塗装の耐用年数超過が懸念される場合はC1、懸念されない場合はBとなる。

## 3. 自動診断支援システムの構築

## 3.1 機械学習の手順

機械学習の手順を図2に示す。点検結果である損傷の種類と損傷の程度からの情報から診断結果を出力す




図1 対策区分の判定の割合

図2 機械学習の手順

表1 BまたはC1と診断された判断基準（上位5つ）

Step1 損傷の種類 損傷の程度	Step2 部材	Step3 判断基準	損傷数 (872損傷)	損傷数の割合
腐食	d	主桁 ①塗装の耐用年数超過	186損傷	21.3%
ひび割れ	c,d	梁部	184損傷	21.1%
		柱部・壁部		
	c	懸壁 地覆 防護柵		
剥離・鉄筋露出	d	梁部 地覆		
補修・補強材の損傷	c	柱部・壁部		
床版ひび割れ	d	床版		
舗装の異常	e	舗装 ③影響拡大または第三者被害	48損傷	5.5%
腐食	d	主桁 ④雨水の浸入、断面欠損、排水工不良、潮水	41損傷	4.7%
防食機能の劣化	e	主桁 ⑤潮水、排水工不良、雨水の影響		

表2 ネットワーク精度および正答率の結果

(a) AUC

対策区分の判定		2年分		5年分		7年分	
		AUC (%)	正答率 (%)	AUC (%)	正答率 (%)	AUC (%)	正答率 (%)
B	Step1	84	91	92	97	89	95
	Step2	88	94	90	96	92	91
	Step3	89	95	88	98	89	97
	Step4	92	96	92	97	90	96
C1	Step1	84	44	91	47	89	48
	Step2	87	60	90	52	91	51
	Step3	88	57	88	53	89	56
	Step4	92	69	93	62	90	61

(b) MCC

対策区分の判定		2年分		5年分		7年分	
		MCC (%)	正答率 (%)	MCC (%)	正答率 (%)	MCC (%)	正答率 (%)
B	Step1	50	91	53	97	51	95
	Step2	59	94	55	96	67	91
	Step3	58	95	61	98	60	97
	Step4	70	96	66	97	63	96
C1	Step1	49	44	53	47	51	48
	Step2	58	60	52	52	52	51
	Step3	58	57	59	53	58	56
	Step4	69	69	66	62	62	61

キーワード 機械学習、橋梁維持管理、自動診断、橋梁定期点検要領

連絡先 〒852-8135 長崎市文教町1-14 長崎大学大学院工学研究科構造工学コース TEL 095-819-2591

るものを Step1 とする。次に、Step1 に部材情報を付加したものを Step2 とする。一方、Step1 に表 1 に示す判断基準情報を付加したものを Step3 とする。最後に、Step1 に部材情報と判断基準情報の両方を付加したものが Step4 である。

### 3.2 ネットワーク精度と出力結果の評価方法

ネットワーク精度の評価には AUC と MCC を用いた。一方、出力結果の評価の指標には正答率を用いた。正答率は、全損傷数に占める、出力結果が真値と等しいものの割合である。なお本研究における真値は成田国際空港の点検データとする。

## 4. ネットワーク精度と出力結果および考察

### 4.1 出力結果

出力結果であるネットワーク精度および正答率を表 2 に示す。同表の正答率より、「対策不要 B」は全ての Step で 90%以上の高い精度が得られ、「予防保全 C1」は全 Step で 44~69%となった。

### 4.2 ネットワーク精度と正答率の比較

正答率とネットワーク精度の関係を図 3 に示す。同図(a)より AUC は、データ数が多い B の正答率に近い値である。一方、同図(b)より MCC は、データ数が少ない C1 の正答率に近い値となった。

### 4.3 考察

全ての Step で B の正答率が高いのは、データ数が多いためであると考えられる。一方、C1 における Step1 と Step2, Step1 と Step3 の正答率を比較すると、後者の方が、正答率が大きく向上することから、部材情報よりも判断基準情報を付加した方が高い正答率が得られることがわかった。

## 5. 正答率に影響を与える判断基準の分析

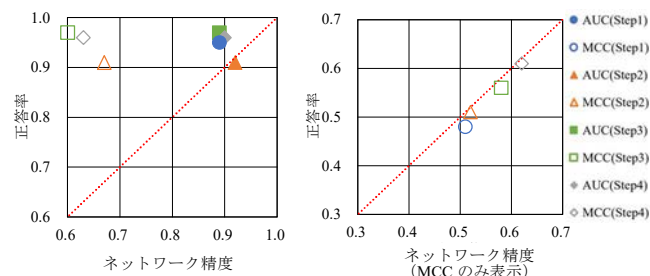
4.3 の考察より、C1 の正答率を向上させる判断基準を分析した。Step1 に、表 1 の①塗装の耐用年数超過、②鉄筋腐食、③影響拡大または第三者被害の判断基準をそれぞれ付加して機械学習を行った結果を図 4 に結果を示す。同図より、②を付加した正答率が①、③のケースよりも高い結果となった。ここで Step1 における C1 の正答と誤答の割合を図 5 に示すが、誤答は 52%であった。次に、図 6 に、図 5 の誤答 52%の内訳を示す。②鉄筋腐食が約 9 割を占めることから、鉄筋腐食に関する判断基準情報を入力データとすることにより正答率が向上するものと考えられる。

## 6. まとめ

- (1) 点検結果から診断結果を評価できる判断基準を分析し、34 個の判断基準を見出した。
- (2) 機械学習のネットワーク精度について、AUC は対策区分の判定 B、MCC は対策区分の判定 C1 の正答率を適切に評価できると考える。
- (3) 部材情報よりも判断基準情報を付加することで高い正答率が得られる。
- (4) 鉄筋腐食に関する判断基準情報が、正答率の向上の要因である。

## 参考文献

- 1) 国土交通省、道路局：橋梁定期点検要領、2019.3
- 2) 国土交通省、道路局：道路橋定期点検要領、2019.2
- 3) 長崎県橋梁点検マニュアル(案)、2020.3
- 4) Deep Learning Toolbox 入門ガイド、2020.6



(a) 対策区分の判定 B (b) 対策区分の判定 C1

図 3 正答率とネットワーク精度の関係

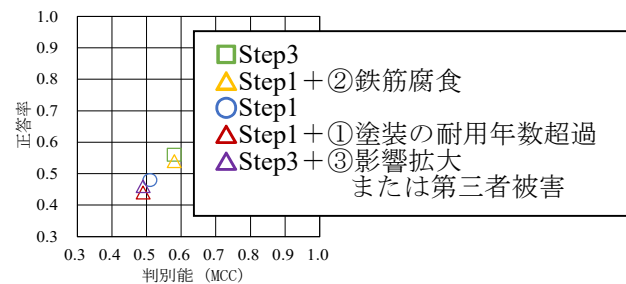


図 4 C1 の正答率に影響を与える判断基準




図 5 Step1 における C1 の正答率




図 6 図 5 の誤答 52%の内訳