

인공지능 기반의 교량 보수공법 선정 기술 개발을 위한 선행 분석

Preliminary Analysis on Artificial Intelligence-based Methodology for Selecting Repair and Rehabilitation Methods of Bridges

김종협¹, 정인수^{2*}, 윤원건³, 김정렬⁴, 박인석⁵

Jonghyeob Kim¹, In-Su Jung^{2*}, Won-Gun Yun³, Jung-Yeol Kim⁴, In-Seok Park⁵

〈Abstract〉

An efficient cost management is important for the domestic social overhead capital(SOC) based on a long lifecycle after 30 years since completion. Maintenance in South Korea have had the restrictions of consistency and suitability of decision-making by the establishment of a budget plan based on the company estimate and repair and reinforcement methods determined by the inspection and diagnosis engineers' subjective determination for each facility. To resolve this issue, the Korea Institute of Civil Engineering and Building Technology is currently in development of a methodology to propose an optimum maintenance method according to the damage of components by artificial intelligence. This study has deduced the primary factors by analyzing information generated during bridge maintenance and management as a prior step for the development of technologies, and conducted a preliminary analysis to select the optimum artificial intelligence technology.

Keywords : *Repair and Rehabilitation Method, Bridge, Maintenance, Artificial Intelligence*

-
- | | |
|---|---|
| <p>1 정회원, 주저자, 한국건설기술연구원, 건설정책연구소, 수석연구원/공학박사</p> <p>2* 정회원, 교신저자, 한국건설기술연구원, 건설정책연구소, 연구위원/공학박사
E-mail: jis@kict.re.kr</p> <p>3 정회원, 공동저자, 한국건설기술연구원, 건설정책연구소, 수석연구원/공학박사</p> <p>4 정회원, 공동저자, 인하대학교 건축학부(건축공학), 교수/공학박사</p> <p>5 정회원, 공동저자, 경기연구원 경기도공공투자관리센터, 투자분석원</p> | <p>1 Department of Construction Policy Research, Korea Institute of Civil Engineering and Building Technology (KICT), Senior Researcher</p> <p>2* Department of Construction Policy Research, Korea Institute of Civil Engineering and Building Technology (KICT), Research Fellow</p> <p>3 Department of Construction Policy Research, Korea Institute of Civil Engineering and Building Technology (KICT), Senior Researcher</p> <p>4 Dept. of Architecture, Inha University, Professor</p> <p>5 Gyeonggi Research Institute Gyeonggi Public Investment Management Center, Researcher</p> |
|---|---|

1. 서론

국내 인프라는 '16년을 기준으로 노후화 비율이 10.3%였으나, '26년에 21.4%, '36년에는 44.4%까지 증가될 것으로 예측되고 있다[1,2]. 더불어 3중 시설까지 포함하면 그 숫자와 노후화 가속도는 더욱 빨라질 수 있다. 이에 따라 중장기적 관점에서 교량관리의 중요성이 꾸준히 강조되고 있지만, 과거부터 수집한 시간이력 데이터를 사용하여 노후화 교량 구조물을 분석·평가·예측·의사결정 지원 기술은 여전히 초보적인 수준에 머물고 있는 실정이다.

최근 선진국 자산관리 시스템에서는 수명주기 계획(Life Cycle Planning)이 강조되고 있으며, 자산의 전체 수명주기에 대한 리스크, 운영, 투자, 재무 등이 고려된 일관성 있는 계획 절차를 운영[3] 중이며, 이중 시설 성능을 기반으로 한 최적 유지관리 비용산정이 중요한 부분을 차지하고 있다. 반면에 국내 '시설물의 안전 및 유지관리에 관한 특별법' 기반 업무에서는 대상 시설별 점검·진단 엔지니어의 주관적 판단에 의한 보수·보강 방법 결정과 업체의 견적에 따른 관리 예산계획 수립으로 의사결정의 일관성 및 적정성에 한계를 가지고 있다[4].

기존 유지관리 시스템은 1, 2중 교량을 대상으로 자산의 이력(조사, 점검, 상태 진단 등) 정보를 단순하게 데이터베이스화하여 보관하는 수준으로만 운영되고, 유지보수 비용 산정이 대부분 유지관리 업체의 견적에 의존해 이루어져 합리적이고 일관된 예산 계획 검토가 어려운 것이 현실이다.

한편, '지속가능한 기반시설 안전강화 종합대책(19. 6)'의 '선제적 관리강화 체계 마련' 및 '안전하고 스마트한 관리 체계 구축', '한국판 뉴딜 종합계획(20. 7)'에서는 디지털화된 SOC 정보 축적·활용을 위해 기반시설 빅데이터를 활용한 과학적 관리와 시스템 고도화를 강조함에 따라, 기존 교량시설 유지관리 시스템의 스마트화 및 고도화가 필요하며 이

를 통해 관리자의 의사결정 효율성과 신뢰도를 향상시킬 수 있다. 이에, 교량 유지관리 업무(유지관리 이력, 투입예산 등)를 수행하면서 발생하는 방대한 양의 정보를 기반으로 부재 손상에 따른 최적 유지관리 공법을 선정하고 현장 상황에 따른 비용산정을 인공지능(AI)을 기반으로 자동화할 수 있는 방안을 도출하기 위한 연구가 필요한 실정이다.

따라서 본 연구에서는 위 연구의 기술 개발을 위한 선행 단계로서, 교량 유지관리 업무 중 발생한 정보를 분석하여 보수보강 공법 선정을 위한 주요 영향요인을 도출하고 최적의 인공지능 기술을 선정하기 위한 선행 분석을 수행하고자 한다.

2. 이론적 고찰

2.1 교량 유지관리 의사결정

교량 유지관리 업무는 시설운용 중 관련 법·령 및 기준에 따른 주기적인(Cyclical) 점검과 진단 수행 및 보수·보강 공사의 실행으로 구분된다. 이와 관련해 '도로시설 성능개선기준(국도교통부 고시 제20201-213호)'에서는 유지관리를 '완공된 도로 시설의 기능을 보전하고, 도로시설 이용자의 편의와 안전을 높이기 위하여 도로시설을 일상적으로 점검·정비하고 손상된 부분을 원상복구하며 경과시간에 따라 요구되는 도로시설의 보수·보강 등에 필요한 활동'으로 정의하고 있다. 국내의 경우 국토교통부 '시설물의 안전 및 유지관리 실시 등에 관한 지침'에 따라 재료시험 및 외관조사에 의해 시설물의 각 부재로부터 발견된 결함, 손상, 열화 등 상태변화를 근거로 시설물 부재별로 상태평가를 수행하고, 발생된 결함의 종류 및 정도, 시설물의 중요도, 사용 환경조건 및 경제성을 고려해 보수·보강 방법을 결정하여 유지관리를 실행하고 있다.

여기서, 구조물 손상(damage)은 구조물에 외적 또는 내적으로 작용하는 물리적인 힘에 의하여 불완전하게 파손, 균열, 변형, 침식 등이 발생하는 상태를 칭하며[5], 이러한 손상은 부재종류 및 재료별로 다르고 이러한 상태 및 교량 특성정보에 따라 보수·보강 등 적절한 유지관리 공법을 결정하게 된다. 국토교통부에서 운용중인 교량통합관리시스템(Bridge Management System; BMS)에서는 교량 부재별 손상종류 및 보수공법 목록[6]을 정의하고 관련 수행 결과를 집계하고 있다. 하지만, 기존 교량통합관리시스템(BMS) DB에서는 시설 및 부재별 보수·보강 비용 산정 기준 및 서비스 미흡으로 관리주체별 합리적인 유지관리 예산 수립이 어려운 한계가 있다. 또한, 최근 지속가능한 기반시설 관리 기본법 및 기반시설 관리계획 작성 요령(「제1차 기반시설관리 기본계획(2020~2025)」(20.05.25. 국토교통부고시))에 따른 향후 5년간 보수·보강 및 성능 개선 실시계획 작성을 요구하고 있는 등 관리주체 담당자가 교량 상태정보를 기반으로 적정 보수공법을 선정하고 소요되는 예산을 산정하는데 요구되는 의사결정지원 기술이 필요하다.

2.2 유지관리 분야 인공지능 개념 및 동향

시설물 유지관리 업무는 다양한 종류의 정보와 정보량에 기반해 수행된다. 즉, 기존 점검 및 진단 결과보고서만 해도 수백에서 수천페이지 분량의 수치적 정보와 이미지 정보 등을 담고 있어, 최근 이러한 정보를 자동으로 취득하거나 신속하게 분류하여 의사결정에 활용하려는 목적의 인공지능 적용 연구가 수행되어오고 있다. 특히, 딥러닝(Deep Learning) 기술을 적용해 교량 상태평가를 위한 이미지 학습 기반의 손상 탐지 연구[7-9] 등이 활발하게 진행되고 있다. 여기서, 딥러닝 기술은 다양한 학습데이터로부터 인간이 찾지 못한 대상 사물의

특징을 컴퓨터가 직접 찾아내어 사물을 분별하도록 인공지능망을 학습하는 기술이다[10]. 또한, 딥러닝 모델을 통해 미래 교량의 거동을 예측하여 구조물의 잔존수명을 추정하는 연구[11], 인공지능을 활용하여 교량 손상의 영향 인자를 규명하고 특정 시점에 점검 대상 교량에서 발생하는 손상의 유형, 위치, 등급, 심각도 등 점검자에게 유용한 정보를 추정하는 기법[12]에 대한 연구들이 진행되었다. 하지만, 이러한 연구들은 주로 시설물의 점검·진단의 효율적 수행 및 결과 분석의 자동화에 한정되어 수행되었으며, 이후 단계인 최적 보수공법의 결정이나 비용의 예측에 대한 연구는 미흡하였다.

3. 데이터 수집 및 모델링

국토교통부는 국내 교량시설의 노후화와 유지관리 예산 부족 문제에 대응하기 위하여 교량통합관리시스템(BMS)을 재정비하여 2008년부터 체계적으로 정보를 축적 및 관리하고 있다[13]. BMS는 교량 관련 정보관리 및 분석시스템으로서 모든 정보의 처리는 개별 교량을 구성하고 있는 부재수준을 기본으로 이루어 지며 6개 대분류 메뉴를 통해 29개 이상의 항목에 대한 관리를 수행 중이다[14].

본 연구에서는 교량 유지관리 업무 중 발생한 정보를 분석하여 보수보강 공법선정의 주요 영향요인을 도출하고 최적의 인공지능 기술을 선정하기 위한 선행 분석을 위하여, BMS에 축적된 보수보강 관련 데이터 222,604건(2009-2021년) 중 RC슬라브(상부구조)-슬라브(부재)-균열(손상)에 해당하는 데이터 994개를 이용하였다. 데이터의 변수는 총 56개이며, 연속형 변수 19개, 명목형 변수 37개로 구성되어 있다. 연속형 변수는 입력값을 그대로 사용하였으며, 명목형 변수는 분석을 위하여 수치로 전환하여 적용하였다.

4. 교량 보수공법 선정 영향요인 분석

앞서 설명된 데이터를 활용하여 교량 보수보강 공법 선정에 위한 영향요인을 도출하기 위하여 통계 분석을 수행하였다. 영향요인 도출을 위한 분석내용은 총 네 가지이며, 교량 보수공법 등 56개 변수의 기초 통계량 분석, 연속형 변수와 명목형 변수간 연관분석, 연속형 변수간 상관분석, 공선성 진단을 통한 교량 보수공법 및 보수단가 주요 영향요인 도출을 실시하였으며 분석에는 PASW Statistics(SPSS) ver. 18이 이용되었다.

보수공법 영향요인은 명목형 변수이므로 도출을 위한 분석 절차는 다음과 같이 수행되었다. 첫째, 피어슨 상관분석(Pearson correlation analysis)을 통한 보수공법과 연속형 변수간 상관변수를 도출하고, 둘째, 카이제곱 검정을 통한 보수공법과 범주형 변수간 연관변수 도출, 셋째, 도출된 변수간 다중공선성 진단을 통해 영향요인 도출을 실시하였다. 이를 정리하면 Fig. 1과 같다.

본 분석에서 다룬 교량 보수관련 변수는 총 56개이며, 연속형 변수 19개, 명목형 변수 37개로 구성된다. 변수 별 기초 통계량은 Table 1과 같다.

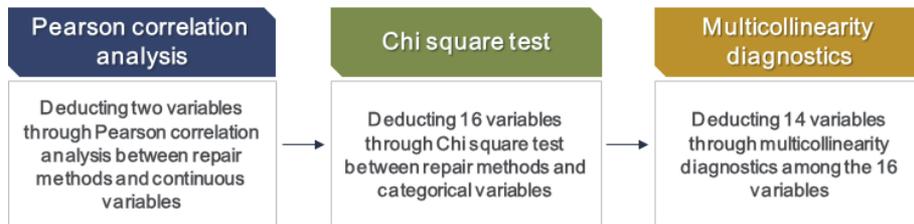


Fig. 1 The process for deducing factors selecting repair and rehabilitation methods of bridges

Table 1. Basic statistics for data collected

Variable	Type	No. of data	Minimum	Maximum	Average	Standard deviation
Road Type	nominal	994	4	5	4.00	.03
Mgmt Agency 1	nominal	994	1	2	1.00	.03
Ownership	nominal	994	3	9	5.08	1.74
Mgmt Agency 2	nominal	994	1	14	5.10	2.43
Mgmt. Type	nominal	994	1	3	2.71	.71
Y of Completion	nominal	994	1971	2010	1995.11	5.38
Length(m)	continuous	994	11.90	190.00	66.36	38.72
Width(m)	continuous	994	6.00	49.00	16.49	6.59
Effective Width(m)	continuous	994	5.00	45.00	15.01	6.30
height(m)	continuous	994	1.50	15.00	5.44	2.12
Up Lane	continuous	993	0	4	1.61	.71
Down Lane	continuous	992	0	4	1.63	.72
No of Span	continuous	994	1	17	4.68	2.68
Max Span Length	continuous	994	7.20	40.00	14.98	2.62
Type of Super Structure	nominal	994	7	7	7.00	.00
Type of Substructure	nominal	994	1	19	8.35	4.78

Table 1. Continue

Variable	Type	No. of data	Minimum	Maximum	Average	Standard deviation
Design Load	nominal	994	2	4	3.02	.35
Class of Facility	nominal	994	2	4	2.79	.47
Allowable Traffic Load	continuous	994	0	43	41.52	7.21
Clearance(m)	continuous	994	.00	24.00	2.06	2.99
Traffic Volume	continuous	994	361	43083	7942.47	6747.00
Bridge Type	nominal	964	1	3	2.01	.17
Aseismic Design	nominal	983	1	7	3.01	1.43
Special Bridge	nominal	0	-	-	-	-
Offshore Bridge	nominal	993	5	5	5.00	.00
Boundry Bridge	nominal	33	2	2	2.00	.00
Plane View Type	nominal	941	1	4	2.99	1.06
Skew Angle Start	continuous	966	.00	75.00	18.64	19.58
Skew Angle End	continuous	966	.00	75.00	18.58	19.60
Approach Road	continuous	967	.00	28.00	13.64	7.05
Median Strip	nominal	678	1	6	5.04	1.49
Road Curb	nominal	561	1	4	3.16	1.17
Parapet Type	nominal	965	1	8	4.89	2.00
Lighting Type	nominal	603	1	6	5.60	1.04
Noise Barrier	nominal	935	1	2	1.98	.15
Signboard	nominal	727	1	2	2.00	.04
Status Indicator for Movable Support	nominal	727	2	2	2.00	.00
Catwalk	nominal	731	1	2	1.95	.21
Measuring Equipment	nominal	755	1	2	1.99	.11
Inspection and Diagnosis Type	nominal	994	2	9	4.92	.54
Y of I/D	nominal	994	2013	2021	2016.95	2.45
Age	continuous	994	6	43	21.84	5.96
No of Span	nominal	994	0	7	.22	.88
Member Code	nominal	994	0	0	.00	.00
Detailed Member Code	nominal	994	0	6	3.11	3.00
Facility Performance Grade	nominal	994	2	4	2.26	.46
Member Performance Grade	nominal	994	1	7	2.56	.81
Span Member Performance Grade	nominal	992	1	7	2.58	.83
Damage Code	nominal	0	-	-	-	-
Damage Quantity	continuous	987	.01	1590.20	49.78	123.65
Damage Quantity Unit	nominal	989	1	6	3.33	.52
Repair Method Code	nominal	994	100	2400	184.21	145.78
Repair Quantity	continuous	929	.01	1590.20	44.77	119.59
Repair Quantity Unit	nominal	986	1	6	3.47	.53
Repair Cost(1KRW)	continuous	844	.60	370000.00	3748.36	16109.00
Repair Unit Cost(1KRW)	continuous	844	2.00	50473.00	852.90	5912.05

4.1 보수공법과 연속형 변수 간 분석

보수단가와 상관관계가 존재하는 변수를 도출하기 위해 피어슨 상관분석을 수행하였다. 피어슨 상관분석은 일반적으로 연속형 변수 간 상관관계를 분석하기 위해 수행되며, 두 변수가 동시에 변화하는 정도를 나타내는 공분산(Covariance)부터 시작한다[15]. 이는 연속형 확률변수에서 변동의 방향을 정의하는 대표적인 방법은 평균으로부터 자료가 왼쪽에 있는지 혹은 오른쪽에 있는지를 살펴보는 것이다. 두 연속형 변수의 연관성은 2개의 방향성을 지닌다. 우선, 하나의 변수가 평균보다 커지는 방향으로 변할 때 다른 변수도 평균보다 커지는 방향으로 변하는 경우, 또는 하나의 변수가 평균보다 커지는 방향으로 변할 때 다른 변수는 작아지는 방향으로 변하는 경우이다. 이러한 개념을 수식

화한 것이 공분산이며 두 확률변수의 편차 곱의 기댓값으로 정의한다. 다만, 공분산의 경우 각 변수의 측정단위가 달라지면 그 크기가 달라지기 때문에 비교가능성이 제한된다. 피어슨 상관계수는 두 변수의 공분산을 개별 변수의 표준편차로 나눈 값이며, -1과 1사이의 값을 갖는다. 상관정도는 상관계수에 따라 Zero부터 Perfect까지 등급으로 나눌 수 있으며, 0.1 이상의 경우 Weak 정도의 상관관계가 존재하는 것으로 볼 수 있다.

따라서 상관계수가 ± 0.1 이상인 경우 두 변수간 약한 상관관계가 존재하므로 본 분석에서는 피어슨 상관계수가 ± 0.1 이상, 유의수준 0.05 이상의 변수를 보수단가 상관변수로 정의하였다. 위 기준에 따라 “Skew Angle Start(교량사각시점)”, “Skew Angle End(교량사각종점)”의 2개 연속형 변수가 도출되었다. 이를 정리하면 Table 2와 같다.

Table 2. The result of Pearson correlation analysis

Variable	Coefficient of correlation	Level of significance	Observation
Repair Method Code	1	.	994
Length(m)	-.061	.054	994
Width(m)	-.045	.158	994
Effective Width(m)	-.042	.182	994
height(m)	.047	.137	994
Up Lane	-.078*	.014	993
Down Lane	-.039	.225	992
No of Span	-.056	.078	994
Max Span Length	-.026	.412	994
Allowable Traffic Load	-.024	.450	994
Clearance(m)	.006	.858	994
Traffic Volume	-.056	.080	994
Skew Angle Start	.128**	.000	966
Skew Angle End	.130**	.000	966
Approach Road	-.008	.800	967
Age	.040	.203	994
Damage Quantity	.016	.624	987
Repair Quantity	.006	.846	929
Repair Cost(1KRW)	-.004	.897	844
Repair Unit Cost(1KRW)	-.020	.566	844

4.2 보수공법과 범주형 변수 간 연관변수

보수공법과 상관관계가 존재하는 명목형 변수를 도출하기 위해 카이제곱 검정(Chi square Test)을 수행하였다. 일반적으로 수량적 특성을 반영하는 질적/양적 변수와 다르게 자료의 특성에 의해 구분되는 변수 중 이산형 변수를 범주형 변수라 한다. 범주형 변수 중 범주 간 순위의 의미가 없는 변수를 명목형 변수라 하며, 즉 범주에 주어진 숫자는 숫자적 의미를 갖지 않게 된다. 따라서 일반적인 통계분석과 다른 통계적 접근이 필요하다. 카이제곱 검정의 기본 아이디어는 두 범주형 변수가 확률적으로 독립이 아

니면 서로 연관이 있다고 판단을 내리는 것이다. 즉, 범주형 변수의 연관성 분석에서 귀무가설은 두 범주형 변수가 독립이며, 귀무가설이 기각되면 두 범주형 변수간에 연관성이 있다고 판단할 수 있다. 이를 판단하기 위해, 카이제곱 검정에서는 실제 관측빈도와 두 범주형 변수가 독립이라는 가정하에 구한 기대빈도와의 차이를 분석한다. 관측빈도와 기대빈도의 차이가 커질수록 두 범주형 변수가 독립이라는 귀무가설이 기각되며, 이 때 두 범주형 변수간 연관성이 존재한다고 판단할 수 있다. 본 연구에서 카이제곱 검정 결과, 유의수준 0.05에서 보수공법과 연관성이 존재하는 명목형 변수 14개가 도출되었다(Table 3).

Table 3. The result of chi square test and Cramer's v

Variable	Statistical methodology	Value	Degree of freedom	Level of significance
Ownership	Pearson Chi-Square	32.153 ^a	20	.042
	Likelihood Ratio	31.417	20	.050
	Linear-by-Linear Association	5.252	1	.022
	N of Valid Cases	994		
	Cramer's V	.090		.042
Year of completion	Pearson Chi-Square	256.164 ^a	124	.000
	Likelihood Ratio	116.638	124	.668
	Linear-by-Linear Association	.980	1	.322
	N of Valid Cases	994		
	Cramer's V	.254		.000
Type of Substructure	Pearson Chi-Square	98.493 ^a	60	.001
	Likelihood Ratio	58.845	60	.518
	Linear-by-Linear Association	1.726	1	.189
	N of Valid Cases	994		
	Cramer's V	.157		.001
Design Load	Pearson Chi-Square	22.133 ^a	8	.005
	Likelihood Ratio	10.802	8	.213
	Linear-by-Linear Association	2.835	1	.092
	N of Valid Cases	994		
	Cramer's V	.106		.005
Median Strip	Pearson Chi-Square	22.388 ^a	15	.098
	Likelihood Ratio	21.832	15	.112
	Linear-by-Linear Association	2.118	1	.146
	N of Valid Cases	678		
	Cramer's V	.105		.098

Table 3. Continue

Variable	Statistical methodology	Value	Degree of freedom	Level of significance
Lighting Type	Pearson Chi-Square	40.956 ^a	9	.000
	Likelihood Ratio	37.186	9	.000
	Linear-by-Linear Association	3.345	1	.067
	N of Valid Cases	603	.	.
	Cramer's V	.150	.	.000
Measuring Equipment	Pearson Chi-Square	75.064 ^a	4	.000
	Likelihood Ratio	9.513	4	.049
	Linear-by-Linear Association	14.102	1	.000
	N of Valid Cases	755	.	.
	Cramer's V	.315	.	.000
Inspection and Diagnosis Type	Pearson Chi-Square	116.307 ^a	20	.000
	Likelihood Ratio	38.415	20	.008
	Linear-by-Linear Association	.263	1	.608
	N of Valid Cases	994	.	.
	Cramer's V	.171	.	.000
No of Span	Pearson Chi-Square	270.795 ^a	28	.000
	Likelihood Ratio	36.401	28	.133
	Linear-by-Linear Association	3.159	1	.076
	N of Valid Cases	994	.	.
	Cramer's V	.261	.	.000
Facility Performance Grade	Pearson Chi-Square	55.223 ^a	8	.000
	Likelihood Ratio	17.169	8	.028
	Linear-by-Linear Association	13.995	1	.000
	N of Valid Cases	994	.	.
	Cramer's V	.167	.	.000
Member Performance Grade	Pearson Chi-Square	113.288 ^a	24	.000
	Likelihood Ratio	37.321	24	.041
	Linear-by-Linear Association	2.450	1	.118
	N of Valid Cases	994	.	.
	Cramer's V	.169	.	.000
Span Member Performance Grade	Pearson Chi-Square	118.110 ^a	24	.000
	Likelihood Ratio	41939	24	.013
	Linear-by-Linear Association	1.563	1	.211
	N of Valid Cases	992	.	.
	Cramer's V	.173	.	.000
Damage Quantity Unit	Pearson Chi-Square	180.493 ^a	9	.000
	Likelihood Ratio	221.630	9	.000
	Linear-by-Linear Association	9.229	1	.002
	N of Valid Cases	989	.	.
	Cramer's V	.247	.	.000
Repair Quantity Unit	Pearson Chi-Square	244.414 ^a	9	.000
	Likelihood Ratio	286.991	9	.000
	Linear-by-Linear Association	13.532	1	.000
	N of Valid Cases	986	.	.
	Cramer's V	.287	.	.000

추가적으로 해당 변수들의 연관정도를 파악하기 위해 크래머의 V(Cramer's V)를 수행하였다. 앞서 서술한 카이제곱 검정은 두 범주형 변수간 연관성을 판단할 수 있으나, 이 연관성의 강도가 얼마나 큰지는 판단하기 어렵다. 일반적으로 범주형 변수가 서열 정보를 포함한 경우 스피어만 순위상관계수(Spearman's rank order correlation)를 사용하지만 서열 정보를 포함하지 않는 범주형 변수인 명목형 변수일 경우 연관성의 정도를 파악하기 위해 파이 계수(phi coefficient), 크래머의 V등을 사용한다. 파이 계수의 경우 그 값이 표준화되어 나타나지 않으나, 크래머의 V의 경우 그 값이 0에서 1사이의 값을 가지며 1에 가까울수록 연관성이 높다고 판단할 수 있다. 본 연구의 크래머의 V 분석 결과, "Measuring Equipment"(계측시설)의 값이 0.315로 가장 높게 나타났다.

4.3 보수공법 영향요인 도출

상기 상관분석 및 카이제곱 검정으로 도출된 16개의 보수공법 상관변수간 다중공선성(Multicollinearity)을 검증하였다. 선형 회귀분석은 다음과 같은 네 가지 기본가정(①선형성, ②독립성, ③등분산성, ④ 정규성)이 존재하며, 위 기본가정을 만족하지 않을시 제대로 된 선형 회귀모델이 생성될 수 없다. 본 연구

의 목적이 교량 보수공법을 종속변수로 하는 회귀 분석에 고려될 적정한 독립변수를 도출하는 것이므로, 해당 기본가정들을 선별적으로 고려할 필요가 있다. 특히, 독립변수간의 독립성 문제인 다중공선성은 독립변수의 상관계수에 따라 유의한 독립변수가 유의하지 않은 독립변수로서 결과가 도출하는 문제를 야기할 수 있다.

이러한 다중공선성을 판단하기 위해 일반적으로 VIF(Variation Inflation Factor)를 사용한다. 만약 n개의 독립변수가 존재할 때, 변수 k의 VIF 값은 변수 k를 종속변수, 나머지 n-1개의 변수를 독립변수로 하는 선형회귀분석의 결정계수 R square 값을 기반으로 산정된다.

$$VIF_k = 1/(1 - R^2) \tag{1}$$

VIF 값이 1에 가까울수록 해당 변수의 다중공선성의 정도가 작음을 의미하며, 일반적으로 VIF 값이 10 이상인 경우 해당 변수가 다중공선성이 있다고 판단한다.

본 연구에서도 VIF가 10 이상일 경우 다중공선성이 존재한다고 판단하였으며, 그 결과 "Skew Angle Start(교량사각시점)", "Skew Angle End(교량사각종점)"의 VIF가 각각 27.24, 27.01로서 다중공선성이 존재하는 것으로 분석되었다(Table 4). "Skew Angle Start(교량

Table 4. The result of multicollinearity diagnostics

Variable	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
(Constant)	2633.731	2846.638	.	.925	.355	.	.
Skew Angle Start	.467	1.825	.060	.256	.798	.035	28.788
Skew Angle End	.618	1.822	.079	.339	.735	.035	28.727
Ownership	9.239	4.463	.094	2.070	.039	.911	1.098
Y of Completion	-1.371	1.414	-.046	-.970	.332	.857	1.167
Type of Substructure	-1.002	1.397	-.035	-.717	.474	.815	1.227
Design Load	-2.458	20.010	-.006	-.123	.902	.915	1.093

Table 4. Continue

Variable	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
Median Strip	-15.500	5.773	-.126	-2.685	.008	.862	1.160
Lighting Type	6.320	7.006	.041	.902	.367	.904	1.106
Inspection and Diagnosis Type	21.421	13.694	.077	1.564	.118	.772	1.295
No of Span	3.467	6.863	.024	.505	.614	.838	1.193
Facility Performance Grade	33.109	16.709	.100	1.982	.048	.737	1.356
Member Performance Grade	14.501	16.706	.079	.868	.386	.226	4.426
Span Member Performance Grade	-8.578	15.646	-.049	-.548	.584	.241	4.155
Damage Quantity Unit	-5.692	22.120	-.020	-.257	.797	.314	3.188
Repair Quantity Unit	29.375	20.911	.109	1.405	.161	.315	3.174

- Total Number of Instances: 994
- Correctly Classified Instances: 705 (70.9 %)
- Incorrectly Classified Instances: 289 (29.1 %)
- Confusion Matrix:

구분		True Class				
		주입	표면	단면	충전	교체
Predicted Class	주입	60	60	0	0	0
	표면	203	645	20	3	1
	단면	0	20	0	0	0
	충전	0	3	0	0	0
	교체	0	1	0	0	0

(a) JRip

- Total Number of Instances: 994
- Correctly Classified Instances: 702 (70.6 %)
- Incorrectly Classified Instances: 292 (29.4 %)
- Confusion Matrix:

구분		True Class				
		주입	표면	단면	충전	교체
Predicted Class	주입	49	43	1	0	0
	표면	203	653	18	3	0
	단면	6	1	0	0	1
	충전	5	10	1	0	0
	교체	0	0	0	0	0

(b) Naïve Bayes

Fig. 2. The results of applying AI algorithms

사각시점”와 “Skew Angle End(교량사각중점)의 상관분석 결과 상관계수가 0.985로서 매우 강한 상관관계가 존재하므로, 위 변수들 중 하나의 변수를 선택하거나, 병합하는 방식을 고려할 필요가 있다고 판단하여 “Skew Angle End(교량사각중점)을 변수에서 제외하였다.

5. 인공지능 기반 공법 선정을 위한 선행 분석

영향요인 도출 결과의 검증과 더불어 보수보강

공법 선정을 위한 알고리즘 선정을 위하여 머신러닝(Machine Learning) 알고리즘 2종에 대하여 선정된 변수들을 적용하여 공법 분류의 가능성을 시험하였다. 사용한 분석에 사용된 알고리즘은 규칙 기반의 JRip과 확률 기반의 Naïve Bayes이며, 논문 분량의 제한으로 인하여 알고리즘에 대한 상세한 고찰은 본 연구 범위에서 제외하고자 한다(Weka 사용).

모델의 구축은 BMS 데이터 994개 사용하여 수행되었으며, 10-fold Cross-validation 방법을 이용하여 훈련 및 테스트를 수행하였다. 공법 분류 시험 결과 Fig. 2와 같이 JRip 70.92%, Naïve

Bayes 70.62%로 나타났다. 두 가지 알고리즘에서 모두 70% 이상으로, 비교적 높은 정확도가 나타났다. 다만, Jrip의 경우 의사결정을 위한 명시적 룰이 제시되므로 알고리즘에 대한 설명이 가능하다는 장점이 있어 이를 함께 고려할 필요가 있다.

따라서 알고리즘 적용 결과를 바탕으로 본 연구에서 도출된 공법선정 영향요인은 비교적 적합한 것으로 판단할 수 있다. 그러나 최적 유지관리 공법을 선정하기 위한 알고리즘을 개발 및 적용하기 위해서는 영향요인의 정확도를 현재보다 더 높일 필요성이 있으며, 이를 위해서는 전문가 면담을 통한 변수 검토, 아웃라이어 제거를 통한 데이터 신뢰도 향상 등의 추가 연구가 필요할 것으로 판단한다.

6. 결론

국내 기반시설은 건설이후 30년 이상 경과되어 가면서부터 장기수명에 따른 비용 효율적 관리가 중요한 시점에 이르렀다. 국내 유지관리 업무에서는 대상 시설별 점검·진단 엔지니어의 주관적 판단에 의한 보수·보강 방법 결정과 업체의 견적에 따른 관리 예산계획 수립으로 의사결정의 일관성 및 적정성에 한계를 가지고 있다. 따라서 본 연구에서는 교량 유지관리 업무 중 발생한 정보를 분석하여 주요 영향요인을 도출하고 최적의 인공지능 기술을 선정하기 위한 분석을 수행하였다.

연구에는 총 56개 변수로 이루어진 994개 데이터가 사용되었으며, 피어슨 상관분석, 카이제곱분석, 다중공선성 분석을 통해 영향요인 13개가 도출되었다. 결과의 검증과 더불어 보수보강 공법 선정을 위한 최적 알고리즘 선정을 위한 선행 분석으로써, 인공지능(AI) 알고리즘 2종에 대하여 분석결과를 적용하였다. 분석 결과, 두가지 알고리즘

에서 모두 70% 이상으로, 비교적 높은 정확도가 나타났으며, 도출된 공법선정 영향요인은 비교적 적합한 것으로 판단할 수 있다. 따라서 본 연구의 결과는 교량의 부재 손상에 따른 최적 유지관리 공법을 선정하고 현장 상황에 따른 비용산정을 머신러닝 기반으로 자동화할 수 있는 방안에 대한 연구에 이론적 기여를 할 수 있을 것으로 기대한다.

그러나 최적 유지관리 공법을 선정하기 위한 알고리즘을 개발 및 적용하기 위해서는 영향요인의 정확도를 현재보다 더 높일 필요성이 있으며, 또한 BMS에서 관리되고 있는 56개 변수가 아닌 외부 변수가 공법선정에 영향을 줄 수 있는 가능성에 대한 검토가 이루어져야 한다. 이를 위해서는 전문가 면담을 통한 변수 검토, 아웃라이어 제거를 통한 데이터 신뢰도 향상 등의 추가 연구가 필요할 것으로 판단한다. 아울러 보다 다양한 머신러닝 알고리즘의 적용 및 분석을 통해 최적의 알고리즘을 선정할 필요가 있다.

감사의 글

이 연구는 한국건설기술연구원 주요사업“DNA 기반 노후 교량 구조물 스마트 유지관리 플랫폼 및 활용기술개발” 과제 (20210289-001)를 통해 수행되었으며, 이에 감사드립니다.

참고문헌

- [1] J. Kim, Strategy and Utilization of Local Development Fund for promoting investment of Aging Infrastructure, Construction Issue Focus, Construction Economy Research Institute of Korea, (2020).
- [2] Ministry of Land, Infrastructure and Transport,

- Schematic Planning for Safety and Maintenance of Facilities, (2018)
- [3] IPWEA (Institute of Public Works Engineering Australia), International Infrastructure Management Manual, (2015).
- [4] J. Kim, W. Yun, I. Jung, Y. Cha, and T. Park, "Development of an Optimal Maintenance Cost Estimation Framework for Bridge Damage", Proc. of KSCE 2021 CONVENTION, (2021)
- [5] Korea Expressway Corporation Research Institute, Prediction model for long-term maintenance costs of highway bridges, Korea Expressway Corporation, (2015).
- [6] Ministry of Land, Infrastructure and Transport, Guideline on information management of Bridge Management System, (2018).
- [7] S. Cho, B. Kim, and Y. Lee, "Image-Based Concrete Crack and Spalling Detection using Deep Learning." Journal of the Korean Society of Civil Engineers, vol. 66, no. 8, pp. 92-97, (2018).
- [8] V. Hoskere, Y. Narazaki, T.A. Hoang, B.F. Spencer Jr., "Vision-based Structural Inspection using Multiscale Deep Convolutional Neural Networks.", Proc. of 3rd Huixian International Forum on Earthquake Engineering for Young Researchers, arXiv preprint arXiv:1805.01055, (2017).
- [9] Y. Cha, W. Choi, and O. Büyüköztürk, "Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks", Computer-Aided Civil and Infrastructure Engineering, vol. 32, no. 5, pp. 361-378, (2017).
- [10] Y. Bengio, A. Courville, and P. Vincent, Representation Learning: A Review and New Perspectives, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, no. 8, pp. 1798-1828, (2014).
- [11] K. Lee, C. Jeon, M. Zan, E. Lee, and D. Shin, "Conceptual Approach of Preventive Maintenance for Bridge Using Deep Learning-based Damage Sensitive Feature". Proc. of KSCE(KOREAN SOCIETY OF CIVIL ENGINEERS) Convention 2020, pp. 1799-1800, (2020).
- [12] S. Lim, Bridge Damage Identification and Its Severity Estimation Using Artificial Intelligence, Ph.D Thesis, The Graduate School of Seoul National University, (2019).
- [13] Korea Institute of Civil Engineering and Building Technology, Study on establishing Bridge Management System considering life cycle cost, Ministry of Land, Infrastructure and Transport, (2008)
- [14] J. Sun, K. Park, and J. Song, Introduction on Bridge Management System based on Maintenance Information Analysis of Bridges, Journal of the Computational Structural Engineering Institute of Korea, vol. 29, no. 1, pp.16-23, (2016).
- [15] H. Akoglu, "User's guide to correlation coefficients." Turkish journal of emergency medicine, vol. 18, no. 3, pp. 91-93, (2018).